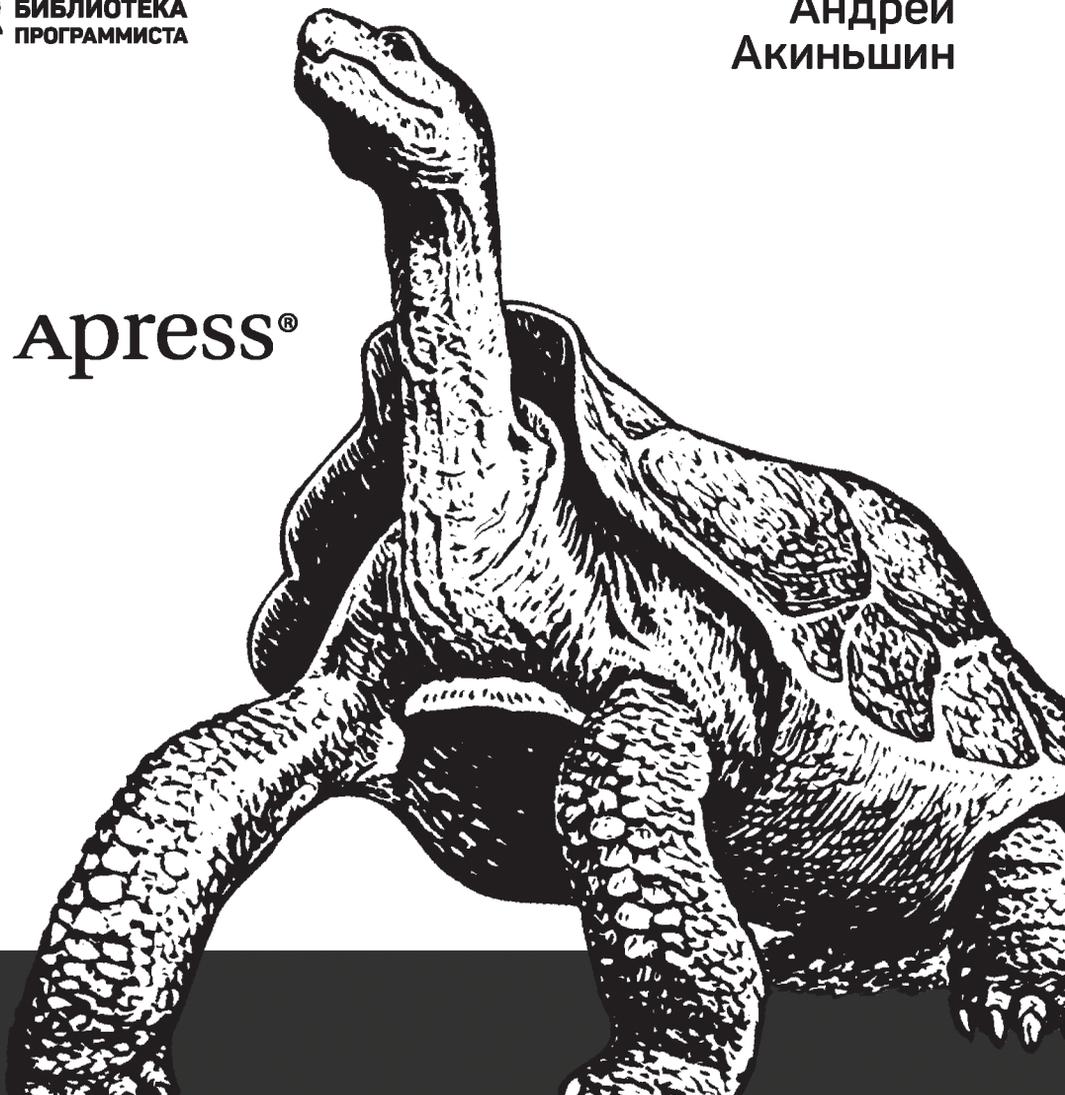




БИБЛИОТЕКА  
ПРОГРАММИСТА

Андрей  
Акиньшин

Apress®



**ПРОФЕССИОНАЛЬНЫЙ  
БЕНЧМАРК**



ИСКУССТВО ИЗМЕРЕНИЯ ПРОИЗВОДИТЕЛЬНОСТИ

# **Pro .NET Benchmarking**

## The Art of Performance Measurement

**Andrey Akinshin**

**Apress®**



Андрей Акиншин

# ПРОФЕССИОНАЛЬНЫЙ БЕНЧМАРК

ИСКУССТВО ИЗМЕРЕНИЯ ПРОИЗВОДИТЕЛЬНОСТИ



Санкт-Петербург • Москва • Минск

2022

ББК 32.973.2-018-07  
УДК 004.413.5  
А39

### **Акиншин Андрей**

А39 Профессиональный бенчмарк: искусство измерения производительности. — СПб.: Питер, 2022. — 576 с.: ил. — (Серия «Библиотека программиста»).

ISBN 978-5-4461-1551-8

Это исчерпывающее руководство поможет вам правильно разрабатывать бенчмарки, измерять ключевые метрики производительности приложений .NET и анализировать результаты. В книге представлены десятки кейсов, проясняющих сложные аспекты бенчмаркинга. Ее изучение позволит вам избежать распространенных ошибок, проконтролировать точность измерений и повысить производительность своих программ.

**16+** (В соответствии с Федеральным законом от 29 декабря 2010 г. № 436-ФЗ.)

ББК 32.973.2-018-07  
УДК 004.413.5

Права на издание получены по соглашению с APress Media, LLC, part of Springer Nature. Все права защищены. Никакая часть данной книги не может быть воспроизведена в какой бы то ни было форме без письменного разрешения владельцев авторских прав.

Информация, содержащаяся в данной книге, получена из источников, рассматриваемых издательством как надежные. Тем не менее, имея в виду возможные человеческие или технические ошибки, издательство не может гарантировать абсолютную точность и полноту приводимых сведений и не несет ответственности за возможные ошибки, связанные с использованием книги. Издательство не несет ответственности за доступность материалов, ссылки на которые вы можете найти в этой книге. На момент подготовки книги к изданию все ссылки на интернет-ресурсы были действующими.

ISBN 978-1484249406 англ.

First published in English under the title Pro .NET Benchmarking; The Art of Performance Measurement by Andrey Akinshin, edition: 1 © Andrey Akinshin, 2019 \*

This edition has been translated and published under licence from APress Media, LLC, part of Springer Nature. APress Media, LLC, part of Springer Nature takes no responsibility and shall not be made liable for the accuracy of the translation.

ISBN 978-5-4461-1551-8

© Перевод на русский язык ООО Издательство «Питер», 2022

© Издание на русском языке, оформление ООО Издательство «Питер», 2022

© Серия «Библиотека программиста», 2022

# Краткое содержание

Об авторе.....	15
О научных редакторах.....	16
Благодарности.....	17
От издательства.....	19
Введение.....	20
<b>Глава 1.</b> Введение в бенчмаркинг.....	25
<b>Глава 2.</b> Подводные камни бенчмаркинга .....	52
<b>Глава 3.</b> Как окружение влияет на производительность.....	103
<b>Глава 4.</b> Статистика для специалистов по производительности .....	178
<b>Глава 5.</b> Анализ и тестирование производительности .....	247
<b>Глава 6.</b> Инструменты для диагностики .....	336
<b>Глава 7.</b> Бенчмарки, ограниченные возможностями процессора .....	367
<b>Глава 8.</b> Бенчмарки, ограниченные возможностями памяти.....	469
<b>Глава 9.</b> Аппаратные и программные таймеры .....	512

# Оглавление

Об авторе.....	15
О научных редакторах.....	16
Благодарности.....	17
От издательства.....	19
Введение.....	20
Структура книги.....	21
Примеры.....	23
Ожидания.....	23
<b>Глава 1. Введение в бенчмаркинг.....</b>	<b>25</b>
Планирование измерения производительности.....	26
Определение проблемы и целей.....	27
Подбор правильных метрик.....	28
Выбор подхода и инструментов.....	30
Проведение эксперимента и получение результатов.....	32
Анализ и формулирование выводов.....	32
Цели бенчмаркинга.....	33
Анализ производительности.....	33
Бенчмаркинг как инструмент маркетинга.....	35
Научный интерес.....	36
Бенчмаркинг ради развлечения.....	36
Требования к бенчмаркам.....	37
Повторяемость.....	37
Проверяемость и переносимость.....	38

Принцип невмешательства.....	38
Приемлемый уровень точности .....	39
Честность .....	40
Пространства производительности .....	40
Основы.....	40
Модель производительности.....	42
Исходный код.....	42
Окружение .....	43
Входные данные .....	44
Распределение.....	45
Пространство.....	47
Анализ .....	47
Плохой, непонятный и хороший .....	47
Поиск узкого места.....	49
Статистика .....	50
Выводы.....	51
<b>Глава 2. Подводные камни бенчмаркинга .....</b>	<b>52</b>
Общие подводные камни .....	53
Неточные замеры времени .....	53
Неправильный запуск бенчмарка .....	56
Естественный шум.....	61
Сложные распределения .....	65
Измерение холодной загрузки вместо прогретого стабильного состояния.....	67
Недостаточное количество вызовов .....	69
Накладные расходы на инфраструктуру .....	72
Неравноценные итерации .....	73
Подводные камни, специфичные для .NET .....	77
Развертывание циклов .....	77
Удаление неисполняемого кода.....	81
Свертка констант .....	85
Удаление проверки границ.....	89
Инлайнинг .....	91
Условное JIT-компилирование .....	94
Диспетчеризация методов интерфейса .....	97
Выводы.....	100

<b>Глава 3. Как окружение влияет на производительность</b> .....	103
Среда исполнения .....	106
.NET Framework .....	107
.NET Core.....	110
Моно .....	115
Практический пример 1: StringBuilder и версии CLR.....	119
Практический пример 2: Dictionary и рандомизированное хеширование строк .....	122
Практический пример 3: IList.Count и неожиданное снижение производительности .....	124
Практический пример 4: время сборки и разрешение GetLastWriteTime .....	127
Подводя итог .....	129
Компиляция .....	129
Генерация промежуточного языка.....	130
JIT-компиляция .....	135
Компиляция Ahead-of-Time (AOT).....	138
Практический пример 1: Switch и версии компилятора C#.....	142
Практический пример 2: params и распределение памяти .....	145
Практический пример 3: замена и неочевидный промежуточный язык .....	146
Практический пример 4: большие методы и JIT-компиляция .....	149
Подводя итог .....	151
Внешнее окружение.....	152
Операционная система.....	152
Аппаратные средства.....	159
Физический мир.....	162
Практический пример 1: обновления Windows и изменения в .NET Framework .....	166
Практический пример 2: Meltdown, Spectre и важные патчи .....	167
Практический пример 3: MSBuild и Защитник Windows.....	169
Практический пример 4: длительность паузы и Intel Skylake .....	170
Подводя итог .....	172
Выводы.....	172
Источники.....	174
<b>Глава 4. Статистика для специалистов по производительности</b> .....	178
Описательная статистика .....	180
Базовые графики выборки.....	180
Размер выборки .....	183
Минимум, максимум и размах .....	184

Среднее арифметическое .....	185
Медиана.....	185
Квантили, квартили и процентиля.....	186
Выбросы .....	188
Диаграммы размаха.....	190
Частотные трассы .....	191
Моды .....	193
Дисперсия случайной величины и стандартное отклонение .....	196
Нормальное распределение.....	198
Коэффициент асимметрии .....	199
Коэффициент эксцесса распределения.....	200
Стандартная ошибка и доверительные интервалы.....	202
Центральная предельная теорема .....	205
Подводя итог .....	206
Анализ производительности .....	208
Сравнение распределений .....	209
Регрессионные модели.....	218
Произвольная остановка.....	224
Пробные эксперименты.....	229
Подводя итог .....	231
Как лгать с помощью бенчмаркинга .....	232
Ложь с помощью маленьких выборок .....	233
Ложь с помощью процентов.....	235
Ложь с помощью пропорций .....	236
Ложь с помощью графиков.....	238
Ложь с помощью слепого прочесывания данных .....	240
Подводя итог .....	242
Выводы.....	243
Источники.....	244
<b>Глава 5. Анализ и тестирование производительности .....</b>	<b>247</b>
Цели тестирования производительности .....	250
Цель 1: предотвращение ухудшения производительности .....	250
Цель 2: обнаружение непредотвращенных случаев ухудшения.....	252
Цель 3: обнаружение других типов аномалий производительности .....	252
Цель 4: снижение уровня ошибок 1-го рода .....	253
Цель 5: снижение уровня ошибок 2-го рода .....	253
Цель 6: автоматизация всего перечисленного .....	254
Подводя итог .....	256

Виды бенчмарков и тестов производительности .....	256
Тесты холодной загрузки .....	257
Разогретые тесты.....	260
Асимптотические тесты.....	264
Тесты длительности и выработки .....	266
Модульные и интеграционные тесты .....	268
Мониторинг и телеметрия.....	273
Тесты с внешними взаимозависимостями.....	274
Другие виды тестов производительности .....	276
Подводя итог .....	278
Аномалии производительности.....	278
Ухудшение.....	279
Ускорение .....	281
Временная кластеризация .....	282
Пространственная кластеризация .....	286
Высокая длительность .....	287
Высокая дисперсия .....	289
Высокие выбросы.....	290
Мультимодальные распределения .....	291
Ложные аномалии.....	293
Скрытые проблемы и рекомендации .....	297
Подводя итог .....	300
Стратегии защиты .....	301
Тесты перед подтверждением.....	302
Ежедневные тесты .....	303
Ретроспективный анализ .....	304
Тестирование контрольных точек.....	304
Тестирование до релиза.....	305
Тестирование вручную .....	306
Телеметрия и мониторинг после релиза.....	307
Подводя итог .....	308
Подпространства производительности .....	308
Подпространство метрик .....	309
Подпространство запусков.....	310
Подпространство тестов.....	311
Подпространство окружения.....	312
Подпространство параметров.....	313

Подпространство истории .....	314
Подводя итог .....	315
Уведомления и сигналы тревоги в сфере производительности .....	315
Абсолютный порог .....	317
Относительный порог .....	319
Адаптивный порог .....	320
Вручную настроенный порог .....	320
Подводя итог .....	322
Разработка с ориентацией на производительность .....	322
Определите задачу и цели в области производительности.....	323
Напишите тест производительности .....	324
Измените код.....	326
Проверьте новое пространство производительности .....	326
Подводя итог .....	327
Культура производительности .....	327
Общие цели в области производительности .....	328
Надежная инфраструктура для тестирования производительности .....	329
Чистота в области производительности .....	330
Личная ответственность.....	331
Подводя итог .....	331
Выводы.....	332
Источники.....	334
<b>Глава 6. Инструменты для диагностики .....</b>	<b>336</b>
BenchmarkDotNet.....	338
Инструменты Visual Studio.....	343
Встроенные профайлеры.....	343
Обзор дизассемблирования.....	344
Инструменты JetBrains.....	345
dotPeek.....	345
dotTrace и dotMemory .....	346
ReSharper .....	349
Rider.....	350
Windows Sysinternals.....	351
RAMMap.....	352
VMMap.....	353
Process Monitor .....	353

Другие полезные инструменты .....	354
ildasm и ilasm.....	355
Monodis.....	356
ILSpy.....	357
dnSpy .....	357
WinDbg.....	358
Asm-Dude.....	360
Консольные инструменты для Mono .....	360
PerfView.....	361
perfcollect.....	362
Process Hacker .....	362
Intel VTune Amplifier .....	363
Выводы.....	364
Источники.....	365
<b>Глава 7. Бенчмарки, ограниченные возможностями процессора.....</b>	<b>367</b>
Регистры и стек .....	369
Практический пример 1: продвижение структуры .....	369
Практический пример 2: локальные переменные .....	372
Практический пример 3: попытка-перехват.....	376
Практический пример 4: количество вызовов.....	379
Подводя итог .....	381
Инлайнинг .....	382
Практический пример 1: ограничения вызова.....	383
Практический пример 2: размещение регистров .....	387
Практический пример 3: кооперативные оптимизации.....	391
Практический пример 4: команда на промежуточном языке starg .....	394
Подводя итог .....	397
Параллелизм на уровне команд.....	399
Практический пример 1: параллельное выполнение .....	400
Практический пример 2: взаимозависимости данных.....	404
Практический пример 3: диаграмма взаимозависимостей .....	406
Практический пример 4: очень короткие циклы .....	409
Подводя итог .....	413
Прогнозирование ветвления .....	414
Практический пример 1: отсортированные и неотсортированные данные .....	414
Практический пример 2: количество условий.....	419
Практический пример 3: минимум.....	423

Практический пример 4: схемы .....	428
Подводя итог .....	431
Арифметика.....	431
Практический пример 1: денормализованные числа .....	435
Практический пример 2: Math.Abs.....	440
Практический пример 3: double.ToString.....	443
Практический пример 4: деление целых чисел .....	445
Подводя итог .....	450
Интринзики.....	451
Практический пример 1: Math.Round .....	451
Практический пример 2: ротация битов .....	454
Практический пример 3: векторизация .....	456
Практический пример 4: System.Runtime.Intrinsics .....	460
Подводя итог .....	463
Выводы.....	464
Источники.....	466
<b>Глава 8. Бенчмарки, ограниченные возможностями памяти.....</b>	<b>469</b>
Кэш процессора.....	470
Практический пример 1: схемы доступа к памяти .....	471
Практический пример 2: уровни кэша .....	473
Практический пример 3: ассоциативность кэша .....	476
Практический пример 4: ошибочное разделение .....	479
Подводя итог .....	482
Схема размещения памяти.....	483
Практический пример 1: размещение структур .....	483
Практический пример 2: конфликты кэш-банка .....	485
Практический пример 3: расщепление кэш-строки.....	488
Практический пример 4: альтернативное именование 4К .....	490
Подводя итог .....	495
Сборщик мусора .....	496
Практический пример 1: режимы сборки мусора.....	496
Практический пример 2: объем «инкубатора» в Mono.....	500
Практический пример 3: области динамической памяти для крупных объектов .....	503
Практический пример 4: финализация .....	505
Подводя итог .....	507
Выводы.....	508
Источники.....	509

<b>Глава 9. Аппаратные и программные таймеры</b> .....	512
Терминология .....	513
Единицы времени .....	513
Единицы частоты .....	515
Основные компоненты аппаратного таймера .....	517
Типы и погрешности дискретизации .....	519
Основные характеристики таймеров .....	521
Подводя итог .....	525
Аппаратные таймеры .....	526
TSC .....	527
HPET и ACPI PM .....	533
История магических чисел .....	535
Подводя итог .....	538
API для проставления отметок времени в ОС .....	539
API для проставления отметок времени в Windows: системный таймер .....	540
API для проставления отметок времени в Windows: QPC .....	547
API для проставления отметок времени в Unix .....	550
Подводя итог .....	554
API для проставления отметок времени на платформе .NET .....	555
DateTime.UtcNow .....	555
Подводя итог .....	563
Подводные камни при проставлении отметок времени .....	564
Низкое разрешение .....	564
Переполнение счетчика .....	564
Компоненты времени и общие свойства .....	565
Изменения в текущем времени .....	566
Последовательные чтения .....	567
Подводя итог .....	570
Выводы .....	571
Источники .....	573

## Об авторе



**Андрей Акинъшин** — старший разработчик в компании JetBrains. Там он трудится над Rider (кросс-платформенной средой разработки для .NET, основанной на платформе IntelliJ и ReSharper). Является мейнтейнером BenchmarkDotNet (самой популярной библиотеки для написания .NET-бенчмарков).

Андрей — программный директор конференции DotNext. На его счету более ста выступлений на различных мероприятиях для разработчиков, множество статей и постов. Кроме того, Андрей — обладатель звания

Microsoft .NET MVP и серебряной медали Международной студенческой олимпиады по программированию ACM ICPC.

Автор имеет степень кандидата физико-математических наук и занимается научными проектами в сфере математической биологии и теории бифуркаций в Институте математики имени С. Л. Соболева Сибирского отделения Российской академии наук. Раньше он работал постдокком (postdoctoral research) в Институте имени Вейцмана.

## О научных редакторах



**Джон Гарленд** — вице-президент по образовательным сервисам в компании Wintellect. Он профессионально разрабатывает программное обеспечение с 1990-х годов. Клиенты, которых он консультирует, — это и небольшие фирмы, и компании из списка Fortune 500. Его работа обсуждалась в основных тезисах и секциях конференций Microsoft. Он выступал на конференциях в Северной и Южной Америке и Европе. Джон живет в городе Камминге (штат Джорджия) с женой и дочерью. Он окончил Университет Флориды, получив степень бакалавра по

вычислительной технике, написал книгу *Windows Store Apps Succinctly* («Краткий обзор приложений для Windows Store») и был соавтором книги *Programming the Windows Runtime by Example* («Программирование Windows Runtime в примерах»). На данный момент Джон работает над архитектурой облачного сервиса Microsoft Azure, является участником группы Microsoft Azure Insiders, ценным специалистом по Microsoft Azure, сертифицированным преподавателем Microsoft и сертифицированным членом общества разработчиков Microsoft Azure.



**Саша Голдштейн** — разработчик программного обеспечения в Google Research. Он работает над применением машинного обучения в различных продуктах Google, связанных с диалогами, классификацией текста, системами рекомендаций и т. д. До работы в Google Саша более десяти лет занимался отладкой программного обеспечения и оптимизацией производительности, вел курсы по всему миру и выступал на множестве международных конференций. Написал книгу *Pro .NET Performance* («Оптимизация приложений на платформе .NET») (Apress, 2012).

# Благодарности

Я начал собирать материал для этой книги пять лет назад. На написание потратил около двух с половиной лет. Но, даже проработав над книгой тысячи часов, я все равно не смог бы закончить все главы в одиночку. Эта книга создана с помощью многих талантливых разработчиков.

Прежде всего я хотел бы поблагодарить Ивана Пашенко. Это человек, который вдохновил меня поделиться тем, что я знаю, и комментировал не только эту книгу, но и десятки моих ранних постов в блоге. Он поддерживал меня много лет и помог мне понять множество нюансов, необходимых для написания хорошей технической литературы. Спасибо, Иван!

Во-вторых, хочу поблагодарить всех моих неофициальных рецензентов: Ирину Ананьеву, Михаила Филиппова, Игоря Луканина, Адама Ситника, Карлена Симоняна, Стивена Тауба, Алину Смирнову, Федерико Андреса Луиса, Конрада Кокосу и Вэнса Моррисона. Они потратили немало времени на чтение черновиков и нашли кучу ошибок и опечаток на ранних стадиях написания. И дали много хороших советов, которые помогли мне значительно улучшить книгу.

В-третьих, я хочу поблагодарить команду издательства Apress: Джона Гарленда и Сашу Голдштейна (официальных технических рецензентов), Джоан Мюррей (рецензента издательства), Лору Берендсон (редактора-консультанта по аудитории), Нэнси Чен (редактора-координатора), Гвенан Спиринг (начального рецензента издательства) и остальных членов команды, которые помогли мне издать эту книгу. Прошу прощения за сорванные сроки и говорю вам спасибо за терпение. Благодаря этим людям из моих черновиков и заметок появилась реальная книга. Они помогли структурировать содержимое, представить мои идеи в понятной форме и исправить грамматические ошибки.

Далее я хочу поблагодарить всех разработчиков и пользователей BenchmarkDotNet. Я очень рад, что этот проект не только помогает программистам измерять

производительность и анализировать результаты, но и популяризирует правильные подходы к бенчмаркингу, способствует дискуссиям о тонкостях бенчмаркинга и производительности. Я особенно благодарен Адаму Ситнику за огромный вклад в проект: без него эта библиотека не была бы такой замечательной.

Хочу также поблагодарить всех, с кем я обсуждал бенчмаркинг и производительность, кто пишет статьи на эти темы и выступает на конференциях. Я узнал много нового из личных бесед, постов в блогах, дискуссий на GitHub, обсуждений в Twitter и вопросов на StackOverflow (многие ссылки указаны в примечаниях и списке источников в конце книги). В особенности я хотел бы поблагодарить Мэтта Уоррена, Брендана Грегга, Дэниела Лейкенса, Джона Скита, Энди Эйерса, Агнера Фога, Реймонда Чена, Брюса Доусона, Дениса Бахвалова, Алексея Шипилева, Александра Мьютела, Бена Адамса и сотни других разработчиков, которые делятся своими знаниями и помогают создавать проекты с открытым исходным кодом. В книге можно найти много прекрасных практических примеров, существующих благодаря тем участникам сообщества, кому небезразлична производительность.

И наконец, я хочу поблагодарить свою семью и всех друзей и коллег, которые верили в меня, поддерживали и все время спрашивали: «Когда же наконец издадут твою книгу?»

# От издательства

Ваши замечания, предложения, вопросы отправляйте по адресу [comp@piter.com](mailto:comp@piter.com) (издательство «Питер», компьютерная редакция).

Мы будем рады узнать ваше мнение!

На веб-сайте издательства [www.piter.com](http://www.piter.com) вы найдете подробную информацию о наших книгах.

# Введение

Нужно принять то, что вы не правы. Ваша цель — уменьшить степень неправоты.

*Илон Маск*

Я написал свой первый бенчмарк в 2004 году. Это было давно, поэтому точно не помню, что именно я измерял, но, думаю, исходный код выглядел примерно так:

```
var start = DateTime.Now;  
// Что-то сделать  
var finish = DateTime.Now;  
Console.WriteLine(finish - start);
```

Я помню, что я думал в тот момент: мне казалось, что я теперь знаю *все* об измерении времени.

Спустя много лет разработки в области производительности я узнал немало нового. Оказалось, что измерение времени — это не так просто. В этой книге я хочу провести вас по захватывающему пути в чудесный мир бенчмаркинга, на котором можно узнать о том, как провести точные измерения производительности и избежать сотен возможных ошибок.

В современном мире очень важно писать программы, которые работают очень быстро. Возможно, именно из-за высокой скорости пользователи предпочтут ваш продукт продукту конкурентов, а из-за низкой — перестанут им пользоваться. Но что означает «быстро»? В каком случае можно сказать, что одна программа работает быстрее другой? Что делать, чтобы убедиться в том, что наш код будет везде работать достаточно быстро?

Если мы хотим создать быстрое приложение, прежде всего мы должны научиться его измерять его скорость. И один из лучших способов для этого — бенчмаркинг.

В Новом Оксфордском американском словаре бенчмарк определяется как «задача, созданная для оценки производительности компьютерной системы». Здесь хочется задать пару вопросов. Что означает производительность? Как ее можно оценить? Кто-то скажет, что это очень простые вопросы. Но на самом деле они настолько сложны, что я решил написать о них целую книгу.

## Структура книги

В книге девять глав.

- **Глава 1 «Введение в бенчмаркинг».**

Здесь вы найдете базовую информацию о бенчмаркинге и других способах измерения производительности, а также о целях и требованиях бенчмаркинга. Мы обсудим пространства производительности и важность анализа результатов бенчмарка.

- **Глава 2 «Подводные камни бенчмаркинга».**

В этой главе вы найдете 15 примеров распространенных ошибок, обычно совершаемых разработчиками при бенчмаркинге. Все примеры маленькие и простые для понимания, но все они демонстрируют важные проблемы и объясняют, как их решать.

- **Глава 3 «Как окружение влияет на производительность».**

В ней объясняется, почему важно думать об окружении, и вводится много терминов, которые будут использоваться в последующих главах. Вы изучите 12 практических примеров, показывающих, как небольшие изменения в окружении могут значительно повлиять на производительность приложений.

- **Глава 4 «Статистика для специалистов по производительности».**

Здесь вы найдете важную информацию о статистике, необходимую при анализе производительности. Для каждого термина приведены практические рекомендации, которые помогут использовать статистические метрики при исследовании производительности. Также глава содержит несколько очень полезных для бенчмаркинга статистических подходов. В конце главы вы найдете описание того, как обмануть себя и окружающих с помощью бенчмаркинга. Эта информация поможет вам избежать неправильной интерпретации результатов.

- **Глава 5 «Анализ и тестирование производительности».**

В ней освещены темы, в которых нужно разбираться, если вы хотите контролировать уровень производительности крупного продукта автоматически. Вы узнаете о различных тестах производительности, об аномалиях производительности, которые можно наблюдать, и о том, как от них защититься. В конце этой главы

найдете описание подхода «разработка через производительность» (performance-drive development) и общее обсуждение культуры производительности.

- **Глава 6 «Инструменты для диагностики».**

Содержит краткий обзор различных инструментов, которые могут пригодиться при анализе производительности.

- **Глава 7 «Бенчмарки, ограниченные возможностями процессора».**

В ней описаны 24 практических примера, показывающие различные подводные камни бенчмарков, ограниченных возможностями процессора. Мы обсудим некоторые характеристики, зависящие от среды выполнения кода, например переименование регистров, инлайнинг и интринзики (intrinsic), а также характеристики, зависящие от технического оборудования, — параллелизм на уровне команд, прогнозирование ветвлений и арифметические операции, в том числе IEEE 754.

- **Глава 8 «Бенчмарки, ограниченные возможностями памяти».**

Глава содержит 12 практических примеров, показывающих различные подводные камни бенчмарков, ограниченных возможностями памяти. Мы обсудим некоторые характеристики, зависящие от среды выполнения кода, связанные со сборкой мусора и ее настройками, а также характеристики, зависящие от технического оборудования, такие как кэш процессора и структура физической памяти.

- **Глава 9 «Аппаратные и программные таймеры».**

В этой главе вы найдете все, что нужно знать о таймерах. Мы обсудим основную терминологию, различные виды аппаратных таймеров, соответствующие API для замеров времени в различных операционных системах и самые распространенные подводные камни при их применении. В этой главе также содержится много дополнительных материалов, которые при бенчмаркинге не особо нужны, но могут заинтересовать тех, кто хочет больше узнать о таймерах.

Порядок глав имеет значение (например, в главе 3 вводится много терминов, используемых в последующих главах), но я старался сделать их максимально независимыми друг от друга. Если вас интересуют конкретные темы, можете прочитать только соответствующие главы: основная часть материала должна быть понятна, даже если пропустить первые главы.

Эта книга позволяет разобраться в основных понятиях и научит вас применять их для измерения производительности. Технологии меняются — каждый год выходят новые версии устройств, операционных систем и среды выполнения кода .NET, но основные понятия остаются неизменными. Изучив их, вы с легкостью сможете адаптировать их к новым технологическим веяниям.

## Примеры

Непросто научиться бенчмаркингу без примеров. В книге их множество! Некоторые из них — это небольшие программы, иллюстрирующие теоретические понятия. Однако вы найдете и много примеров из реальной жизни.

Большинство из них основаны на моем личном опыте тестирования производительности в JetBrains (<https://www.jetbrains.com/>). Вы прочтаете про реальные задачи и их решения, которые возникали при разработке продуктов от JetBrains, таких как IntelliJ IDEA (<https://www.jetbrains.com/idea/>) (IDE на Java), ReSharper (<https://www.jetbrains.com/resharper/>) (плагин для Visual Studio) и Rider (<https://www.jetbrains.com/rider/>) (кросс-платформенная среда разработки для .NET, основанная на IntelliJ IDEA и ReSharper). Все эти продукты очень большие (исходный код Rider содержит более 20 млн строк кода) и включают в себя множество компонентов, важных для производительности. Сотни разработчиков каждый день вносят в них сотни изменений, поэтому сохранение производительности на приличном уровне — непростая задача. Надеюсь, что вы сочтете эти примеры и техники полезными и поймете, как применить их к собственным продуктам.

Другой источник опыта для меня — это BenchmarkDotNet. Я начал разрабатывать эту библиотеку в 2013 году как небольшой личный проект. Сегодня она стала самой популярной библиотекой для бенчмаркинга, которая используется практически во всех .NET-проектах, включая среду исполнения .NET. Работая с этим проектом, я участвовал в сотнях очень интересных обсуждений производительности. Некоторые из примеров в книге могут казаться искусственными, но почти все они взяты из реальной жизни.

## Ожидания

Мы будем много обсуждать производительность, но не сможем обсудить все возможные темы. Вы **не** узнаете о том:

- как писать быстрый код;
- как оптимизировать медленный код;
- как профилировать приложения;
- как находить сложные места в приложениях.

И не найдете ответов на многие другие вопросы, связанные с производительностью.

Существует множество прекрасных книг и научных работ на эти темы. Вы можете найти некоторые из них в списке источников в конце книги. Повторю, что **эта книга сосредоточена только на бенчмаркинге**. Вы узнаете:

- как написать хороший бенчмарк;
- как выбрать релевантные метрики;
- как избежать подводных камней бенчмаркинга;
- как анализировать результаты бенчмарков.

И получите ответы на многие другие вопросы, связанные с бенчмаркингом.

Также следует помнить о том, что бенчмаркинг подходит не ко всем ситуациям. Вы не станете хорошим специалистом по производительности, если бенчмаркинг — ваш единственный навык. Однако это один из важнейших навыков. Приобретя его, вы станете лучше как разработчик программного обеспечения и сможете выполнять очень сложные исследования производительности.

# 1

## Введение в бенчмаркинг

Проще оптимизировать правильный код, чем  
править оптимизированный код.

*Билл Харлен, 1997 год*

В этой главе мы обсудим концепцию бенчмаркинга, разницу между ним и другими видами исследований производительности, узнаем, какие задачи можно решить с помощью бенчмаркинга, как должен выглядеть хороший бенчмарк, как его написать и проанализировать его результаты. В частности, будут освещены следующие темы.

- **Исследования производительности.**

Как выглядит качественное исследование производительности? Почему так важно определить свои цели и задачи? Какие измерения, инструменты и подходы следует выбрать? Что нужно делать с показателями производительности, которые мы получаем?

- **Цели бенчмаркинга.**

Когда полезен бенчмаркинг? Как его можно использовать в анализе производительности или маркетинге? Как применять его для улучшения своих технических знаний или просто для развлечения?

- **Требования к бенчмаркингу.**

Каковы основные требования к бенчмаркингу? Почему так важно писать воспроизводимые, неразрушающие, верифицируемые, переносимые и честные бенчмарки с приемлемым уровнем точности?

- **Пространства производительности.**

Почему надо работать с многомерными пространствами производительности (и что это такое)? Почему важно построить качественную модель производительности? Как на нее влияют входные данные и окружение?

- **Анализ.**

Почему так важно анализировать результаты бенчмарка? Как их интерпретировать? Что такое узкие места и почему их нужно искать? Зачем нам знать статистику для бенчмаркинга?

В этой главе будут освещены основные теоретические концепции с помощью практических примеров. Если вы уже знаете, как измерять производительность, можете пропустить ее и перейти к главе 2.

Первый шаг к тому, чтобы узнать, как заниматься бенчмаркингом или другими видами измерения производительности, — создание хорошего плана.

## Планирование измерения производительности

Хотите, чтобы ваш код работал быстро? Конечно, кто же этого не хочет! Однако поддерживать высокий уровень производительности не всегда просто. Жизненный цикл приложения включает в себя сложные бизнес-процессы, которые не обязательно сосредоточены на производительности. Когда вы внезапно замечаете, что функция работает слишком медленно, не всегда есть время вникнуть в проблему и ускорить приложение. Не всегда очевидно, как прямо сейчас написать такой код, который будет быстро работать в будущем.

Если вы хотите улучшить производительность, но понятия не имеете, что делать, — это нормально. Все, что вам нужно, лежит в пределах одного качественного исследования производительности.

Любое тщательное исследование требует хорошего плана с несколькими важными пунктами.

1. Определение проблемы и целей.
2. Подбор правильных метрик.
3. Выбор подхода и инструментов.
4. Проведение эксперимента и получение результатов.
5. Анализ и формулирование выводов.

Конечно, это лишь пример плана. В собственном плане вы можете выделить 20 пунктов или, наоборот, пропустить какие-то из них, потому что они для вас очевидны. Однако полное исследование производительности так или иначе включает в себя (явно или неявно) как минимум все эти пункты. Обсудим каждый из них подробнее.

## Определение проблемы и целей

Этот пункт кажется очевидным, но многие его пропускают и сразу начинают что-то измерять или оптимизировать. Крайне важно задать себе несколько важных вопросов. Чем меня не устраивает нынешний уровень производительности? Чего я хочу достичь? Насколько быстро должен работать мой код?

Если вы просто начнете оптимизировать свою программу случайным образом, это будет пустой тратой времени. Лучше вначале определить проблемы и цели. Я даже рекомендую записать их на листике, держать этот листик на рабочем столе и поглядывать на него во время работы.

Посмотрим несколько примеров проблем и целей, которые встречаются в реальной жизни.

- **Проблема:** нам нужна библиотека, поддерживающая сериализацию JSON, но мы не знаем, какая именно библиотека будет достаточно быстрой для нас.

**Цель:** сравнение двух библиотек (анализ производительности).

Мы нашли две подходящие библиотеки для JSON, у обеих есть все нужные характеристики. Важно выбрать более быструю, но их сложно сравнивать на примере общих случаев. Поэтому мы хотим проверить, какая из них быстрее в типичных для нас сценариях.

- **Проблема:** наши клиенты пользуются программным обеспечением наших конкурентов, потому что, по их мнению, оно работает быстрее.

**Цель:** наши клиенты должны узнать, что мы быстрее конкурентов (маркетинг).

На самом деле существующий уровень производительности достаточно высок, но необходимо донести до клиентов, что мы быстрее.

- **Проблема:** мы не знаем, какой архитектурный подход наиболее эффективен с точки зрения производительности.

**Цель:** улучшить уровень технической компетентности наших разработчиков (научный интерес).

Разработчики не всегда знают, как писать код эффективно. Иногда имеет смысл потратить время на исследования и найти полезные методики и архитектурные подходы, которые будут оптимальны для тех случаев, когда производительность играет важную роль.

- **Проблема:** разработчики устали от реализации скучной бизнес-логики.

**Цель:** сменить рабочую обстановку и решить несколько интересных задач (развлечение).

Организуем соревнование по производительности между разработчиками, чтобы улучшить производительность вашего приложения. Выигрывает команда, добившаяся лучшей производительности.

Такие соревнования не обязательно помогают в решении проблем вашего бизнеса, но они могут улучшить атмосферу внутри организации и повысить продуктивность разработчиков в дальнейшем.

Как видите, определение проблемы может быть абстрактным предложением, описывающим цель высокого уровня. Следующий шаг — уточнить его, добавив детали. Их можно выразить с помощью *метрик*.

## Подбор правильных метрик

Допустим, вы недовольны производительностью одного из фрагментов своего кода и хотите ускорить его в два раза<sup>1</sup>. Но для вас ускорение может означать одно, а для другого разработчика в команде — совсем другое. Работать с абстрактными понятиями невозможно. Если вам нужна четкая постановка проблем и определенные цели, необходимо подобрать правильно определенные метрики, отвечающие этим целям. Решение, какую метрику включить в список, не всегда очевидно, поэтому давайте обсудим несколько вопросов, которые помогут вам его принять.

### ● Что я хочу улучшить?

Возможно, вы хотите уменьшить *период ожидания (latency)* отдельного запроса (временной интервал между началом и окончанием) или увеличить *пропускную способность (throughput)* метода (сколько запросов мы можем выполнить за секунду). Часто люди думают, что эти величины взаимосвязаны и неважно, какую метрику они выберут, потому что все они одинаково коррелируют с производительностью приложения. Однако это не всегда так. Например, изменения в исходном коде могут уменьшить период ожидания, но сократить пропускную способность. Примерами других метрик могут служить количество случаев непопадания в кэш, утилизация процессорных ресурсов, объем кучи больших объектов в динамической памяти, время холодного запуска и многие другие. Не переживайте, если эти термины вам незнакомы, — мы объясним их в следующих главах.

### ● Уверен ли я, что точно знаю, что именно хочу улучшить?

Чаще всего ответ — нет. Необходимо быть гибкими и готовиться менять цели после получения результатов. Исследование производительности — процесс итеративный. На каждой стадии можно выбрать новые метрики. Например, вы начинаете работу с замеров периода ожидания операции. После первой стадии

---

<sup>1</sup> Конечно, это плохое определение проблемы. Если вы собираетесь провести оптимизацию, нужны более веские причины, чем недовольство. В данный момент мы говорим о метриках, поэтому допустим, что у нас есть определенные требования к производительности, а наше программное обеспечение не отвечает целям бизнеса (здесь неважно, какие они).

обнаруживаете, что программа тратит слишком много времени на сборку мусора. Тогда вы вводите другую метрику — объем выделяемой памяти в секунду. После второй стадии оказывается, что вы создаете много экземпляров `int[]` с коротким жизненным циклом. Следующей метрикой может быть количество созданных массивов `int`. После некоторой оптимизации (например, вы реализуете пул массивов и повторно используете копии массивов между операциями), возможно, захотите измерить эту же метрику снова. Конечно, можно использовать только первую метрику — период ожидания операции. Однако в этом случае вы будете работать не с изначальной проблемой, а с наведенными эффектами. Общая производительность — предмет сложный, который зависит от многих факторов. Не так-то просто отследить то, как изменения в конкретном месте влияют на длительность операции. Намного проще отслеживать конкретные характеристики целой системы.

- **Каковы условия, в которых будет исполняться программа?**

Допустим, вы выбрали метрику «пропускная способность» и хотите добиться 10 000 операций в секунду. Какая именно пропускная способность для вас важна? Вы хотите улучшить ее при *средней* или *максимальной загрузке*? Приложение однопоточное или многопоточное? Какой уровень параллельной обработки подходит в вашей ситуации? Сколько оперативной памяти на вашем сервере? Важно ли улучшить производительность во всех целевых окружениях, или у вас есть только одно окружение, которое известно заранее?

Не всегда очевидно, как выбрать правильные целевые условия и как они влияют на производительность. Тщательно продумывайте ограничения, подходящие для ваших метрик. Мы обсудим различные ограничения далее в этой книге.

- **Как интерпретировать результаты?**

Квалифицированный специалист по производительности всегда собирает информацию по одной и той же метрике много раз. С одной стороны, это хорошо, потому что так *можно проверить* статистические характеристики измеряемой метрики. С другой — плохо, потому что теперь мы *должны проверять* эти характеристики. Как их суммировать? Необходимо ли всегда выбирать среднее арифметическое? Или медиану? Допустим, мы хотим убедиться, что 95 % запросов могут выполняться быстрее, чем за  $N$  миллисекунд. В таком случае нам подходит 95-й перцентиль. Мы подробно обсудим статистику и необходимость понимания того, что она важна не только для анализа результатов, но и для определения требуемых метрик. Всегда вдумчиво выбирайте те статистические характеристики, которые будут подходить для изначальной проблемы.

Таким образом, мы можем работать с различными метриками (от периода ожидания и пропускной способности до количества случаев непопадания в кэш и утилизации процессора) и различными условиями (например, средняя или максимальная загрузка) и агрегировать их разными способами (например, использовать среднее

арифметическое, медиану или 95-й перцентиль). Если вы не знаете, что применить, просто взгляните на бумажку, где записана проблема. Выбранные метрики всегда должны соответствовать вашей цели и определять детали на низком уровне проблемы. Нужно сделать так, чтобы улучшение выбранных метрик означало решение проблемы. В этом случае все будут довольны: и вы, и ваш начальник, и ваши пользователи.

После выбора правильных метрик наступает следующий этап — выбор способа сбора данных.

## Выбор подхода и инструментов

В современном мире существует множество инструментов, подходов и методов измерения производительности. Выбирайте инструменты, подходящие для вашей ситуации. Проверяйте, обладает ли выбранный инструмент нужными характеристиками: точностью измерения, переносимостью, простотой использования и т. д.

Для принятия правильного решения нужно рассмотреть доступные варианты и выбрать те, которые лучше всего соответствуют заданной проблеме и метрикам. Давайте обсудим несколько самых популярных методов и соответствующие им инструменты.

### ● Изучение кода.

Опытный разработчик с большим опытом может многое сказать о производительности и без измерений. Он может оценить асимптотическую сложность алгоритма, прикинуть накладные расходы на вызов определенных методов или заметить очевидно неэффективный фрагмент кода. Конечно, ничего нельзя сказать точно без измерений, но зачастую простые задачи, связанные с производительностью, можно решить, просто посмотрев на код и вдумчиво проанализировав его. Однако будьте осторожны, имейте в виду, что *личные ощущения и интуиция легко могут вас подвести* и даже самые опытные разработчики могут ошибиться. Не забывайте также о том, что технологии меняются и предыдущие предположения могут оказаться совершенно неправильными. Например, вы никогда не используете некоторый метод из-за того, что он очень медленный. В какой-то момент реализацию этого метода оптимизируют, и он становится супербыстрым. Но если вы не узнаете об этих улучшениях, то так и будете его избегать.

### ● Профилирование.

Что делать, если вы хотите оптимизировать приложение? С чего начать? Некоторые программисты начинают с первого же места, которое выглядит недостаточно оптимальным: «Я знаю, как оптимизировать этот фрагмент кода,

сейчас этим и займусь!» Обычно подобный подход не очень полезен. Случайные оптимизации могут не оказать никакого влияния на производительность всего приложения. Если этот метод занимает 0,01 % от общего времени, вы, скорее всего, вообще не заметите никакого эффекта. Или, что хуже, можете принести больше вреда, чем пользы. Попытка писать слишком умный или быстрый код может увеличить его сложность и создать новые проблемы. В лучшем случае вы просто впустую потратите свое время.

Чтобы получить действительно ощутимую разницу, найдите место, где приложение тратит значительную часть времени. Лучший способ сделать это — профилирование. Некоторые добавляют измерение метрик прямо в приложение и получают какие-то цифры, но это не настоящее профилирование. Профилирование подразумевает, что вы берете профайлер, присоединяете его к приложению, делаете снимок состояния и смотрите на профиль. Существует множество инструментов для профилирования, мы обсудим их в главе 6. Единственное требование к ним довольно простое: они должны показывать горячие методы (те, которые часто вызывают) и узкие места в приложении. Хороший профайлер должен помочь вам быстро найти то место, которое нужно оптимизировать в первую очередь.

- **Мониторинг.**

Иногда невозможно профилировать приложение на локальном компьютере (многие проблемы могут воспроизводиться только на сервере). В этом случае мониторинг может помочь найти операцию, у которой явные проблемы с производительностью. Существуют разные подходы, но чаще всего разработчики применяют логирование или используют внешние инструменты (например, основанные на ETW). Когда появляются проблемы с производительностью, можно посмотреть на собранные данные и попытаться найти источник проблем.

- **Тесты производительности.**

Представьте, что вы только что написали очень эффективный алгоритм. Приложение стало супербыстрым, и вы хотите, чтобы оно таким и оставалось. Но затем кто-то (скорее всего, вы сами) случайно вносит изменения, которые портят это прекрасное состояние. Часто люди пишут модульные тесты, чтобы оценить корректность бизнес-логики. Однако в нашем случае недостаточно проверить только логику приложения. Если зафиксировать текущий уровень производительности действительно важно, то разумно написать специальные тесты — так называемые тесты производительности, проверяющие, что до и после изменений программа работает одинаково быстро. Эти тесты могут выполняться на сервере сборки приложений как часть процесса непрерывной интеграции (CI).

Писать такие тесты нелегко, поскольку обычно требуется одинаковое серверное окружение (аппаратные средства + программное обеспечение) для всех конфигураций, в которых будут выполняться тесты. Если производительность

очень значима для вас, имеет смысл потратить время на создание инфраструктуры и разработку тестов производительности. Мы обсудим, как это правильно сделать, в главе 5.

- **Бенчмаркинг.**

Если вы спросите пять человек о том, что такое бенчмарк, то получите пять разных ответов. Мы называем так программу, которая измеряет характеристики производительности другой программы или фрагмента кода. Считайте бенчмарк научным экспериментом: он должен давать результаты, которые позволяют вам узнать что-то новое о вашей программе, о среде исполнения .NET, об операционной системе, о современных аппаратных средствах и мире вокруг нас. В идеале результаты подобного эксперимента возможно повторить, ими можно поделиться с коллегами, и они должны позволять нам принять правильное бизнес-решение, основанное на полученной информации.

## Проведение эксперимента и получение результатов

Теперь пришло время эксперимента. В конце эксперимента или серии экспериментов вы получите результаты в форме чисел, формул, таблиц, графиков, снимков состояния и т. д. В простом эксперименте может использоваться один подход, а более сложные способны потребовать большего количества. Приведу пример. Вы начинаете ваш эксперимент с мониторинга, который помогает найти очень медленный пользовательский сценарий. Далее с помощью профилирования вы находите горячие методы и пишете для них бенчмарки. После этого вы оптимизируете приложение и убеждаетесь с помощью бенчмарков, что выбранные метрики действительно улучшились. Далее вы превращаете бенчмарки в тесты на производительность, чтобы не допустить деградаций в будущем. Как видите, одного волшебного решения не существует: у каждого подхода есть своя цель и свое применение. Важно всегда помнить о проблемах и метриках при проведении каждого исследования.

## Анализ и формулирование выводов

Анализ — самая важная часть любого исследования производительности. Получив значения метрик, вы должны объяснить их и быть уверенными в том, что это объяснение правильное. Часто допускают такую ошибку — говорят что-то наподобие: «Профайлер показывает, что метод А быстрее метода Б. Давайте везде использовать А вместо Б!» Лучше сделать такой вывод: «Профайлер показывает, что метод А быстрее метода Б. У нас есть объяснение этому факту: метод А оптимизирован под те входные данные, которые мы использовали в этом эксперименте. Таким образом, мы понимаем, почему получили такие результаты профилирования. Однако следует продолжить исследования и проверить другие наборы входных данных, прежде

чем решить, какой метод использовать в коде приложения. Возможно, в некоторых крайних случаях метод А будет значительно медленнее метода Б».

Многие необычные значения в замерах производительности связаны с ошибками в методологии измерений. Всегда старайтесь выдвинуть разумную теорию, объясняющую каждое число в полученных результатах. Если такой теории нет, вы можете принять неверное решение и ухудшить производительность. Выводы стоит делать только после тщательного анализа.

## Цели бенчмаркинга

Теперь, обсудив основной план исследования производительности, сместим фокус на бенчмаркинг и шаг за шагом рассмотрим его важные аспекты. Начнем с самого начала — с целей бенчмаркинга и связанных с ними проблем.

Вы помните, что нужно сделать в начале любого исследования производительности? Определить проблему. Понять, какая у вас цель и почему важно решить эту проблему.

Бенчмаркинг не является универсальным подходом, полезным при любом исследовании производительности. Бенчмарки не могут сами оптимизировать код за вас или решить все проблемы с производительностью за вас. Они просто выдают набор цифр.

Поэтому, прежде чем начать, убедитесь, что эти цифры вам нужны и вы понимаете зачем. Множество людей просто начинают «бенчмарковать», не зная, как делать выводы из полученных данных. Бенчмаркинг — очень полезный подход, но только в том случае, если вы понимаете, когда и зачем его применять.

Пойдем дальше — узнаем о нескольких распространенных целях бенчмаркинга.

## Анализ производительности

Одна из самых популярных целей бенчмаркинга — анализ производительности. Он имеет большое значение, если вам важна скорость вашего приложения, и может помочь со следующими проблемами и сценариями.

- **Сравнение библиотек/платформ/алгоритмов.**

Часто люди хотят использовать уже существующие решения проблемы и выбирают самое быстрое из доступных (если оно отвечает базовым требованиям). Иногда имеет смысл тщательно проверить, какое из решений работает быстрее всех, и сказать что-то в духе: «Я сделал несколько пробных прогонов, и мне

кажется, что вторая библиотека быстрее всех». Однако нескольких измерений всегда недостаточно. Если необходимо выбрать самое быстрое решение, требуется выполнить рутинную работу по написанию бенчмарков, которые сравнивают варианты в различных состояниях и условиях и дают полную картину производительности. Кроме того, качественные измерения всегда служат мощным аргументом для убеждения ваших коллег!

- **Настройка параметров.**

В большинстве программ много магических констант. Некоторые из них, такие как объем кэша или степень параллелизма, могут повлиять на производительность. Трудно понять заранее, какие значения лучше всего подходят для вашего приложения, но бенчмаркинг поможет выбрать оптимальные значения для достижения достойного уровня производительности.

- **Проверка возможностей.**

Представьте, что вы ищете подходящий сервер для своего веб-приложения. Вам нужен максимально дешевый вариант, но при этом он должен делать  $N$  запросов в секунду (RPS). Было бы полезно иметь программу, которая может измерить максимальный RPS вашего приложения на различных устройствах.

- **Проверка эффекта от изменений.**

Вы реализовали прекрасную функцию, которая должна порадовать пользователей, но она работает довольно долго. Вы переживаете о том, как она повлияет на производительность приложения в целом. Чтобы оценить реальный эффект, вам понадобится измерить метрики производительности до и после того, как в продукт была добавлена эта функция.

- **Проверка концепций.**

У вас есть гениальная идея, которую вы хотите реализовать, но она влечет за собой множество изменений, и вы не уверены в том, как она повлияет на уровень производительности. В этом случае можете попытаться на скорую руку реализовать основную часть этой идеи и измерить ее влияние на производительность приложения.

- **Анализ регрессии.**

Вы хотите отследить, как производительность функции меняется с каждой модификацией, чтобы, если поступит жалоба вроде «В предыдущем релизе все работало гораздо быстрее», проверить, так ли это. Анализировать регрессию можно с помощью тестов производительности, но бенчмаркинг может быть применен и в этом случае.

Таким образом, анализ производительности является полезным подходом, позволяющим решить множество разных проблем. Однако это не единственная возможная цель бенчмаркинга.

## Бенчмаркинг как инструмент маркетинга

Сотрудники отделов маркетинга и продаж любят публиковать статьи и записи в блогах, рекламирующие скорость нового продукта. Качественный отчет об исследовании производительности может им помочь. Мы, как программисты, обычно максимально фокусируемся только на исходном коде и технических аспектах разработки, но следует согласиться с тем, что маркетинг — это тоже важно. Отчеты о производительности, основанные на результатах бенчмаркинга, могут быть полезны при продвижении нового продукта. В отличие от ваших обычных целей бенчмаркинга, при написании отчета о производительности для других людей вы обобщаете все свои эксперименты, относящиеся к производительности. Вы рисуете графики, составляете таблицы и проверяете каждый аспект своего бенчмарка. Обдумываете вопросы, которые могут задать о вашем исследовании, пытаетесь заранее заготовить ответы, продумываете важные факты, которые надо сообщить. При рассказе о производительности отделу маркетинга слишком много измерений не бывает. Хороший отчет о производительности украсит работу отдела маркетинга, чему все будут рады. Необходимо также сказать пару слов о черном маркетинге — ситуации, когда человек представляет результаты бенчмарка, которые заведомо являются ложью, и докладчику это известно. Это неэтично, но о таких вещах следует знать. Есть несколько видов бенчмаркинга для черного маркетинга.

- **Заголовки желтой прессы.**

Проведение каких-либо измерений и неподтвержденные заявления, например: «Наша библиотека — самый быстрый инструмент». Многие люди все еще верят, что, если что-то написано в Интернете, это правда, даже если утверждение не подкреплено достоверными измерениями.

- **Невоспроизводимое исследование.**

Добавление технических деталей, которые невозможно воспроизвести. Никто не сможет собрать исходный код, запустить ваши бенчмарки или найти указанные аппаратные средства.

- **Выборочные измерения.**

Выбор отдельных измерений. Например, вы провели 1000 измерений производительности для своего приложения и столько же для приложения конкурентов. После этого выбираете лучшие результаты для себя и худшие — для конкурентов. Технически вы предоставляете верные результаты, которые можно воспроизвести, но на самом деле это всего лишь небольшой фрагмент истинной картины производительности.

- **Выборочное окружение.**

Выбор параметров, которые выгодны для вас. Например, если вы знаете, что приложение конкурентов работает быстро только на компьютерах с большим

объемом оперативной памяти и SSD-диском, то выбираете устройство с малым объемом памяти и HDD-диском. Если знаете, что ваше приложение демонстрирует хорошие результаты только на Linux (а на Windows — плохие), то выбираете Linux. Возможно также найти конкретные входные данные, которые будут выгодны только для вас. Эти результаты будут верными и на 100 % воспроизводимыми, но необъективными.

- **Выборочные сценарии.**

Представление только выборочных сценариев бенчмаркинга. Вы можете честно выполнить бенчмаркинг при сравнении своего решения с решением конкурентов по пяти разным сценариям. Допустим, ваше решение оказывается лучше только при одном из них. В этом случае вы можете представить только этот сценарий, но сказать, что ваше решение быстрее во всех случаях.

Я надеюсь, все согласятся с тем, что методы черного маркетинга неэтичны и, что еще хуже, популяризируют плохие практики бенчмаркинга. В то же время белый маркетинг может стать хорошим инструментом для демонстрации результатов в области производительности. Если вы хотите легко выявлять удачные и неудачные исследования производительности, необходимо понимать их различия. Мы обсудим важные техники в этой области в главах 4 и 5.

## Научный интерес

Бенчмарки могут помочь вам развить навыки разработки и разобраться во внутренних деталях вашего приложения. Они помогут вам понять все уровни своей программы, включая принципы работы среды выполнения кода, баз данных, хранилищ данных, процессора и т. д. Когда читаешь абстрактную теорию о том, как устроено оборудование, сложно понять, как эта информация соотносится с реальной жизнью. В этой книге мы будем в основном обсуждать академические бенчмарки с небольшими фрагментами кода. Сами по себе они чаще всего не очень полезны, но если вы хотите оценивать большие и сложные системы, для начала нужно научиться работать на самом простом уровне.

## Бенчмаркинг ради развлечения

Многим моим друзьям нравятся игры, в которых нужно отгадывать загадки. Мои любимые загадки — это бенчмарки. Если много заниматься бенчмаркингом, часто встречаешь результаты измерений, которые не получается объяснить с первой попытки. Чтобы разобраться в ситуации, нужно обнаружить узкое место (bottleneck) и выполнить измерение снова. Однажды я провел несколько месяцев, пытаюсь объяснить один запутанный код, который выдавал странные значения метрик

производительности. После долгих недель мучений, найдя объяснение, я полчаса прыгал по офису от радости — это был момент истинного счастья и блаженства.

Возможно, вы когда-нибудь слышали о гольфе по производительности<sup>1</sup>. Вам дают простую задачу, которая решается легко, но необходимо найти самое быстрое и самое эффективное из решений. Если ваше решение быстрее решения вашего друга на несколько наносекунд, то, чтобы продемонстрировать различия, используется бенчмаркинг. При этом очень важно понимать, как грамотно работать с входными данными и окружением (ваше решение может быть самым быстрым только в определенных условиях). Бенчмаркинг для развлечения служит прекрасным способом развеяться после недели рутинной работы.

Теперь, когда вы знакомы с самыми распространенными целями бенчмаркинга, взглянем на требования к бенчмаркам, которые помогут нам достичь этих целей.

## Требования к бенчмаркам

В целом любая программа, измеряющая длительность операции, может быть бенчмарком. Однако *качественный* бенчмарк должен отвечать определенным требованиям. Официального списка требований к бенчмаркам не существует, так что мы обсудим наиболее полезные *рекомендации*.

### Повторяемость

Повторяемость — это самое важное требование. Если запустить бенчмарк дважды, он должен выдать один и тот же результат. Если запустить его трижды, он тоже должен выдать один и тот же результат. Если запустить его 1000 раз, он все равно должен выдать один и тот же результат. Конечно, *невозможно получать абсолютно одинаковые результаты каждый раз*, между измерениями всегда будут различия. Но они не должны быть значительными. Все результаты должны быть довольно близкими.

Нужно отметить, что выполнение одного и того же кода может очень сильно разниться по времени, особенно если он включает в себя дисковые или сетевые операции. Качественный бенчмарк — это не просто один эксперимент или одно число. Это распределение чисел. В качестве результата бенчмарка вы можете получить сложное распределение измерений с несколькими локальными максимумами.

Даже если измеряемый код зафиксирован и его нельзя изменить, вы все еще контролируете то, как запустить его итерации, какое будет исходное состояние системы

<sup>1</sup> Примеры можно найти по адресу <https://mattwarren.org/2016/05/16/adventures-in-benchmarking-performance-golf/>.

на момент старта или какие будут входные данные. Вы можете написать бенчмарк множеством способов, но он должен выводить в качестве результата повторяемые данные.

Иногда достичь повторяемости невозможно, но необходимо к этому стремиться. В данной книге мы изучим методы и подходы, которые помогут стабилизировать результаты. Даже если ваш бенчмарк стабильно повторяем, это не значит, что больше ни о чем волноваться не нужно. Надо удовлетворить и другие требования.

## Проверяемость и переносимость

Качественное исследование производительности проводится не в вакууме. Если вы хотите поделиться результатами с другими, убедитесь, что они смогут запустить программу на собственном устройстве. Попросите друзей, коллег или членов сообщества помочь вам улучшить результаты, но не забудьте подготовить соответствующий исходный код и убедиться, что бенчмарк доступен для проверки в других условиях.

## Принцип невмешательства

Во время бенчмаркинга часто возникает эффект наблюдателя, то есть сам процесс наблюдения может повлиять на результат. Приведу два доступных примера из физики, откуда и взят этот термин.

- **Электрическая цепь.**

Чтобы измерить напряжение в электрической цепи, к ней подключают вольтметр, но тем самым в цепь вносятся изменения, которые могут повлиять на изначальное напряжение. Обычно дельта напряжения меньше погрешности измерения, так что это не составляет проблемы.

- **Ртутный термометр.**

Классический ртутный термометр при использовании поглощает какое-то количество тепловой энергии. В идеале это поглощение, влияющее на температуру тела, также необходимо измерить.

Похожие примеры существуют и в мире измерения продуктивности.

- **Поиск горячих методов.**

Вы хотите узнать, почему программа работает медленно или где находится проблемное место, но у вас нет доступа к профайлеру или другим инструментам для измерения. Поэтому вы решаете добавить логирование и выводить в файл текущее время перед каждым вызовом подозрительного метода и после него. К сожалению, цена дисковых операций высока и строчки с логированием легко

могут стать новым узким местом. Станет невозможно найти изначальное проблемное место, поскольку вы потратили 90 % времени на запись данных на диск.

- **Использование профайлера.**

Применение профайлера может повлиять на измерение. Когда вы присоединяетесь к другому процессу, вы его замедляете. В некоторых режимах профайлера, например в режиме выборки (sampling), эффект будет незначительным, но в других может оказаться огромным. Например, отслеживание (tracing) легко может удвоить изначальное время. Мы обсудим различные режимы профайлера в главе 6.

Запомните, что при измерении производительности приложений обычно возникает эффект наблюдателя, который может оказать заметное влияние на результаты замеров.

## Приемлемый уровень точности

Однажды я исследовал необычное снижение производительности. После внесения изменений в Rider время одного из тестов увеличилось с 10 до 20 с. Я не внёс значительных изменений, так что это было похоже на мелкую ошибку. Ее было очень легко найти во время первой сессии профайлинга. Виновником оказался фрагмент бездумно скопированного кода. Я быстро все починил, но не торопился на этом останавливаться: нужно ведь убедиться, что все снова работает быстро. Как вы думаете, какой инструмент для измерения я использовал? Секундомер! И я не имею в виду `System.Diagnostics.Stopwatch` (который переводится как «секундомер»), я буквально использовал обычный секундомер, встроенный в мои старомодные наручные часы Casio 3298/F-105. У этого инструмента довольно низкая точность. Когда я получаю замер в 10 с, то на самом деле могло пройти 9 или 11 с. Однако точности моего секундомера хватило, чтобы обнаружить разницу между 10 и 20 с.

В любой ситуации есть инструменты, которые выполняют задачу, но ни один инструмент не годится для абсолютно всех ситуаций. Мои часы выполнили задачу, потому что измеряемая операция длилась около 10 с и мне была непринципиальна секундная погрешность. Когда операция длится 100 мс, ее определенно будет тяжело измерить с помощью физического секундомера. Понадобится специальная функция, которая умеет измерять время. Когда операция длится 100 мкс, то эта функция должна обладать высоким разрешением. Когда операция длится 100 нс, то простого использования такой функции может не хватить, чтобы корректно измерить длительность операции. Могут потребоваться дополнительные меры увеличения точности с многократным повторением операции.

Помните, что длительность операции — это не фиксированное число. Если измерить операцию десять раз, получится десять разных чисел. На современных

компьютерах источники шума могут легко испортить измерения, увеличить разброс значений и в итоге повлиять на конечную точность.

К сожалению, идеальной точности добиться не получится, погрешности измерения будут всегда. Здесь важно знать свой уровень точности и иметь возможность удостовериться, что достигнутого уровня достаточно для решения изначальной задачи.

## Честность

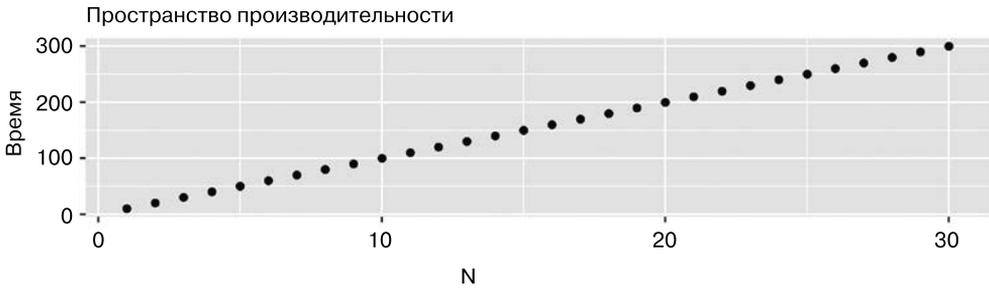
В идеальном мире каждый бенчмарк должен быть честным. Я всегда одобряю предоставление разработчиками полных и актуальных данных. В мире бенчмаркинга очень легко случайно обмануться. Если вы получили какие-то непонятные цифры, не прячьте их. Поделитесь ими с другими и признайтесь, что не знаете, откуда они взялись. Мы не сможем помочь друг другу улучшить бенчмарки, если во всех наших отчетах будут лишь идеальные результаты.

## Пространства производительности

Говоря о производительности, мы имеем в виду не одно число. Обычно одного измеренного временного интервала недостаточно для того, чтобы сделать значимый вывод. В любом исследовании производительности мы работаем с многомерным пространством производительности. Важно помнить, что объектом изучения является пространство с большим количеством измерений, зависящее от многих переменных.

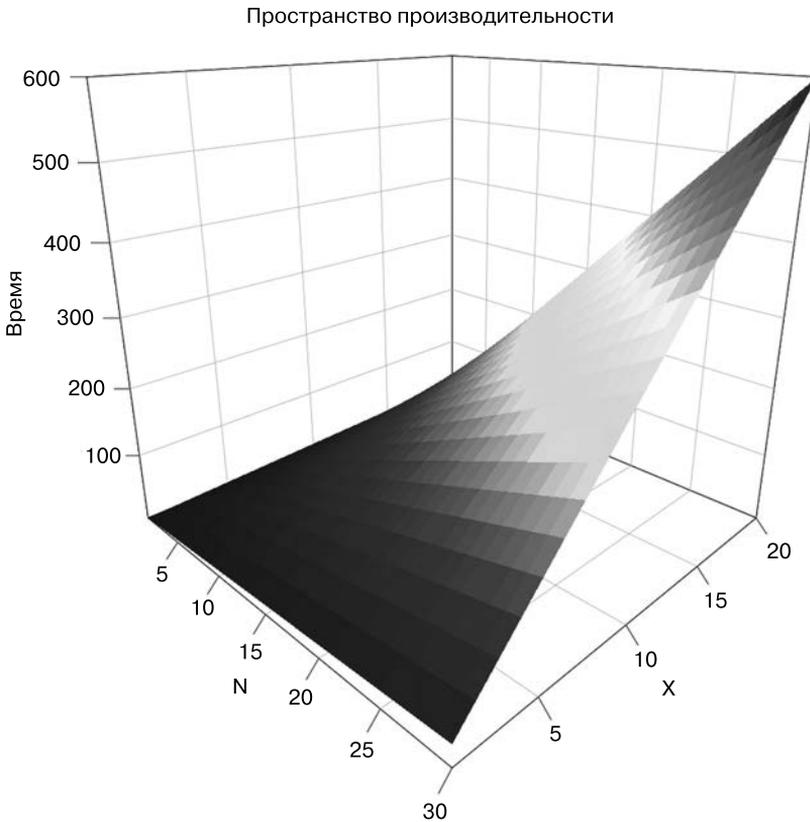
## ОСНОВЫ

Что мы имеем в виду под термином «многомерное пространство производительности»? Разберемся на примере. Допустим, мы собираемся написать сайт книжного магазина. В частности, хотим создать страницу, показывающую все книги в категории, например все книги жанра фэнтези. Для простоты допустим, что обработка одной книги занимает 10 мс, а скорость всего остального (например, сетевой конфигурации, работы с базой данных, рендеринга HTML и т. д.) так высока, что временем, затрачиваемым на эти операции, можно пренебречь. Сколько времени займет загрузка этой страницы? Очевидно, это зависит от количества книг в категории. Положим, что нам понадобится 150 мс на загрузку 15 книг и 420 мс — на 42 книги. В общем, нужно  $10N$  мс на  $N$  книг. Это очень простое *одномерное пространство*, выражаемое линейной моделью. Единственным измерением здесь является количество книг  $N$ . В каждой точке этого одномерного пространства есть число, описывающее производительность, — время, необходимое для загрузки страницы. Это пространство можно представить в виде двумерного графика (рис. 1.1).



**Рис. 1.1.** Пример 1 простого пространства производительности

Теперь допустим, что на обработку одной книги нужно  $X$  мс (вместо константы 10 мс). Таким образом, наше пространство становится двумерным. Измерениями являются количество книг  $N$  и время обработки одной книги  $X$ . Общее время вычисляется по простой формуле  $T = NX$  (рис. 1.2).



**Рис. 1.2.** Пример 2 простого пространства производительности

Конечно, в реальности общее время не может быть константой, даже если все параметры известны. Например, мы можем применить к нашей странице стратегию кэширования: иногда содержимое страниц находится в кэше и загрузка всегда занимает конкретное время, например 5 мс, а иногда не в кэше и загрузка длится  $NX$  мс. Таким образом, в каждой точке двухмерного пространства у нас не одно, а несколько временных значений.

Это был простой пример. Однако я надеюсь, что вы поняли концепцию многомерного пространства производительности. На самом деле измерений сотни или даже тысячи. Работать с такими пространствами производительности очень нелегко, поэтому нужна *модель производительности*, описывающая, какие факторы нужно рассмотреть.

## Модель производительности

Говорить о производительности и скорости программ всегда нелегко, потому что разные люди понимают эти термины по-разному. Иногда я вижу записи в блогах с заголовками вроде «Почему C++ быстрее, чем C#» или «Почему C# быстрее, чем C++». Как вы думаете, какой заголовок вернее? Ответ — оба неверны, потому что у языков программирования нет таких свойств, как скорость, быстрота, производительность и т. п.

Однако *в повседневной речи* вы можете сказать коллеге что-то в духе: «Думаю, в этом проекте нужно использовать язык X вместо языка Y, потому что он будет быстрее». Это нормально, если вы оба одинаково понимаете глубинный смысл этой фразы и обсуждаете конкретный стек технологий (специальные версии исходного кода/компиляторов и т. д.), конкретную среду (например, операционную систему и аппаратные средства) и конкретное окружение (разработать определенный проект с известными вам требованиями). Однако фраза в целом будет неверна, поскольку язык программирования — это абстракция, у него нет производительности.

Таким образом, нам нужна *модель производительности*. Это модель, включающая в себя все важные для производительности факторы: исходный код, окружение, данные ввода и распределение производительности.

## Исходный код

Исходный код — это первое, что вам следует рассмотреть, исходная точка исследования производительности. Также в этот момент можно начать говорить о производительности. Например, можно сделать асимптотический анализ и описать сложность вашего алгоритма с помощью индекса большого  $O$ <sup>1</sup>.

---

<sup>1</sup> Мы обсудим асимптотический анализ и индекс большого  $O$  в главе 4.

Допустим, у вас два алгоритма с коэффициентами сложности  $O(N)$  и  $O(N^2)$ . В некоторых случаях достаточно просто выбрать первый алгоритм без дополнительных измерений производительности. Однако следует помнить, что алгоритм  $O(N)$  не всегда быстрее, чем  $O(N^2)$ : во многих случаях ситуация противоположная для небольших значений  $N$ . Нужно понимать, что этот индекс описывает только предельный режим и обычно хорошо работает лишь с большими числами.

Если вы работаете не с академическим алгоритмом из институтской программы, вам может быть трудно подсчитать вычислительную сложность алгоритма. Даже если вы используете амортизационный анализ (который обсудим позже), ситуация не станет проще. Например, если в алгоритме, написанном на C#, создаете много объектов, появится неявное снижение производительности из-за сборщика мусора (GC).

Классический асимптотический анализ — это теоретическая деятельность. Она не учитывает характеристики современных устройств. Например, у вас может быть один алгоритм, работающий с кэшем процессора, и другой, не работающий с ним. При одинаковой сложности у них будут совершенно разные характеристики производительности.

Все сказанное не означает, что вам не следует пытаться анализировать производительность, основываясь только на исходном коде. Опытный разработчик часто может сделать множество верных предположений о производительности, бросив взгляд на код. Однако стоит помнить, что исходный код все еще является абстракцией. Строго говоря, мы не можем обсуждать скорость сырого исходного кода, не зная, как будем его запускать. Следующее, что нам нужно, — это окружение.

## Окружение

*Окружение* — это набор внешних условий, влияющих на исполнение программы.

Допустим, мы написали код на C#. Что дальше? Дальше компилируем его с помощью компилятора C# и запускаем в среде выполнения .NET, использующей компилятор JIT, чтобы перевести код на промежуточном языке (Intermediate Language, IL) в команды архитектуры процессора<sup>1</sup>. Он будет выполняться на устройстве с определенным объемом оперативной памяти и определенной пропускной способностью сетевой конфигурации.

Заметили, сколько здесь неизвестных факторов? В реальности ваша программа всегда запускается в конкретном окружении. Вы можете использовать платформы x86, x64 или ARM. Можете использовать LegacyJIT или новый современный RyuJIT. Можете использовать различные реализации платформы .NET или версии

<sup>1</sup> Мы обсудим эти термины в главе 3.

общезыковой среды выполнения (CLR). Вы можете запустить бенчмарк на платформе .NET Framework, .NET Core или Mono.

Не стоит экстраполировать результаты бенчмарка в одном окружении на все случаи. Например, если вы смените LegacyJIT на RyuJIT, это может значительно повлиять на результаты. LegacyJIT и RyuJIT используют разную логику для выполнения большинства оптимизаций (трудно сказать, что один из них лучше другого, — они просто разные). Если вы разработали приложение на .NET для Windows и .NET Framework и вдруг решили сделать его кросс-платформенным и запустить на Linux с помощью Mono или .NET Core, вас ждет много сюрпризов!

Конечно, проверить все возможные варианты окружения невозможно. Обычно вы работаете с одним окружением, установленным по умолчанию на вашем компьютере. Когда пользователи находят ошибку, можно услышать: «А на моем устройстве работает». Когда пользователи жалуются, что ПО работает медленно, можно услышать: «А на моем устройстве работает быстро». Иногда вы проверяете, как оно работает в нескольких других окружениях, например на x86 и x64 или в разных операционных системах. Однако существует множество конфигураций, которые никто не проверит. Только глубокое понимание внутренних элементов современного ПО и устройств может помочь вам догадаться, как все будет работать в другом производственном окружении. Мы обсудим окружения подробнее в главе 3.

Если вы можете проверить, как программа работает во всех нужных вам окружениях, — прекрасно. Однако есть еще один фактор, влияющий на производительность, — входные данные.

## Входные данные

*Входные данные* — это набор переменных, обрабатываемый программой. Он может быть введен пользователем, содержаться в текстовом файле, быть аргументом метода и т. д.

Допустим, мы написали код на C# и выбрали нужное окружение. Теперь уже можно говорить о производительности или сравнивать два разных алгоритма, чтобы проверить, какой из них быстрее? Ответ — нет, потому что для разных входных данных мы можем наблюдать разную скорость алгоритма.

Например, нам нужно сравнить две программы с реализацией движка регулярных выражений. Как можно это сделать? Мы можем выполнить поиск по тексту с помощью регулярного выражения. Но какой текст и какое выражение использовать? И сколько пар «текст — выражение» взять? Если проверить только одну пару и окажется, что программа А быстрее программы Б, это вовсе не означает, что так происходит всегда. Если у вас есть две реализации, то часто можно наблюдать, что

одна из них работает быстрее с одним типом входных данных, а другая — с другим. Полезно иметь набор эталонных входных данных, позволяющий сравнивать алгоритмы. Но создать его непросто: нужно включить в него разные наборы типовых входных данных и не забыть про крайние случаи.

Если вы хотите создать качественный набор эталонных данных, то должны понимать, что происходит во внутренней структуре вашего кода. Если работаете со структурой данных, проверьте разные паттерны доступа к памяти: последовательное считывание/запись, случайное считывание/запись и какие-нибудь регулярные паттерны. Если внутри ваших алгоритмов есть отдельная ветвь (обычный оператор `if`), проверьте разные шаблоны для следующих значений условий ветви: условие всегда верно, условие случайно, значения условия варьируются и т. д. (алгоритмы предсказания ветвления на современных устройствах творят просто волшебство, которое может значительно повлиять на производительность).

## Распределение

*Распределение производительности* — это набор всех измеренных в ходе бенчмаркинга параметров.

Допустим, мы написали код на C#, выбрали нужное окружение и определили эталонный набор входных данных. Теперь-то мы можем сравнить два алгоритма и сказать: «Первый алгоритм в пять раз быстрее второго»? Ответ — все еще нет. Если запустить один и тот же код в одном и том же окружении с одними и теми же данными дважды, мы не получим одни и те же значения замеров. Между измерениями всегда есть разница. Иногда она незначительная, и мы ею пренебрегаем. Однако в реальности нельзя описать производительность с помощью одного числа — это всегда какое-то распределение. В простом случае оно выглядит нормальным и мы можем для сравнения алгоритмов использовать только средние значения.

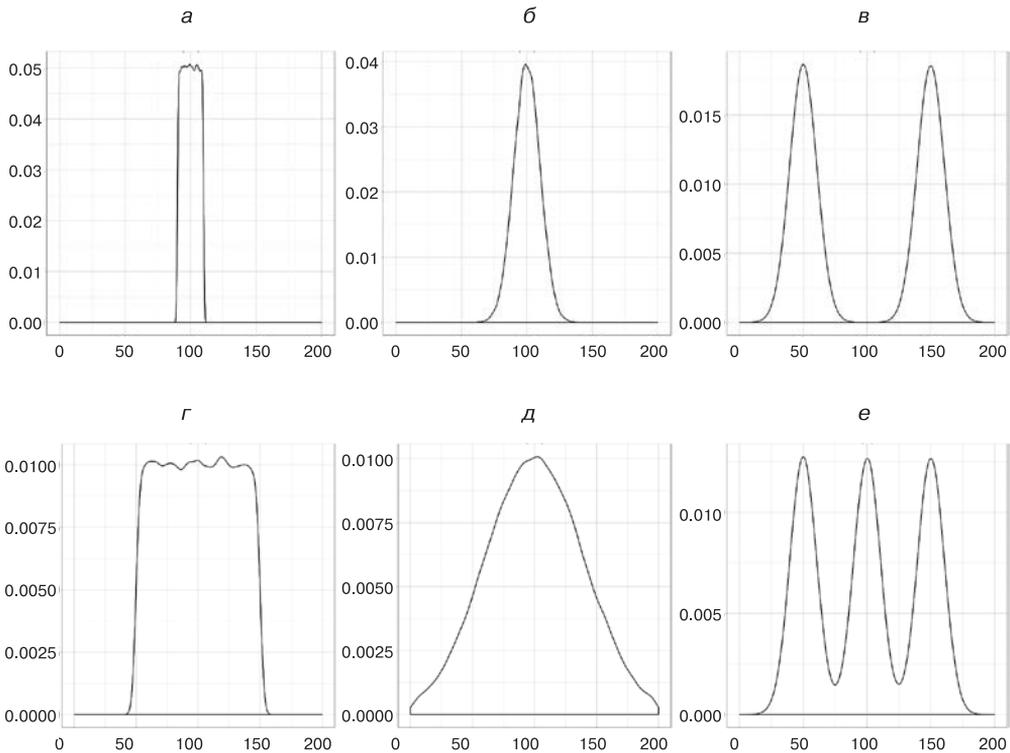
Но может появиться и множество характеристик, усложняющих анализ. Например, огромный разброс значений или несколько локальных максимумов в распределении (типичная ситуация для больших компьютерных систем). В таких случаях очень сложно сравнивать алгоритмы и делать полезные выводы.

Например, взгляните на шесть распределений на рис. 1.3. У них у всех одно среднее значение — 100.

Можно отметить следующее:

- на графиках *a* и *г* изображены равномерные распределения;
- на *б* и *д* — нормальные распределения;

- разброс на графиках *г* и *д* гораздо больше, чем на *а* и *б*;
- у распределения *в* два локальных максимума, 50 и 150, и оно не содержит значений 100;
- у распределения *е* три локальных максимума, 50, 100 и 150, и оно содержит много значений 100.



**Рис. 1.3.** Шесть различных распределений с одним средним значением

Очень важно различать разные виды распределений, потому что, если смотреть только на среднее значение, можно не заметить разницы между ними.

В ходе работы с более сложной логикой обычно появляются несколько локальных максимумов и большое стандартное отклонение. К счастью, *в простых случаях* обычно можно игнорировать распределения, поскольку для базового анализа производительности достаточно среднего значения всех измерений. Однако иногда проверять статистические характеристики распределений полезно.

Теперь, когда мы обсудили важные составляющие модели производительности, пора собрать их вместе.

## Пространство

Наконец мы можем говорить о *пространстве производительности*, которое помогает совместить исходный код, окружение и входные данные и проанализировать, как они влияют на распределение производительности. С математической точки зрения у нас есть функция от декартова произведения <ИсходныйКод>, <Окружение> и <ВходныеДанные> до <Распределение>:

(ИсходныйКод) × (Окружение) × (ВходныеДанные) --> (Распределение)

Это означает, что во всех ситуациях, в которых мы исполняем исходный код в определенном окружении с входными данными, мы получаем распределение измерений и функцию (в математическом смысле) с тремя аргументами: <ИсходныйКод>, <Окружение>, <ВходныеДанные>, которая выдает одно значение <Распределение>. Такая функция определяет пространство производительности. Когда мы исследуем производительность, то пытаемся понять внутреннюю структуру пространства, основанную на ограниченном наборе бенчмарков. В этой книге мы обсудим, какие факторы влияют на производительность, как проявляется это влияние и что нужно помнить при бенчмаркинге.

Итак, вы собрали эти функции и они выдают большое количество замеров, однако результаты еще нужно проанализировать. Поэтому обсудим анализ производительности.

## Анализ

Анализ — это важнейший этап любого исследования производительности, поскольку результаты эксперимента без анализа представляют собой просто набор бессмысленных цифр. Давайте обсудим, что нужно делать, чтобы получить максимум пользы от сырых данных о производительности.

## Плохой, непонятный и хороший

Иногда я называю бенчмарки плохими, но на самом деле они не могут быть ни *хорошими*, ни *плохими* (иногда бывают *непонятными*). Однако, раз уж мы используем эти слова в повседневной жизни и понимаем их значения, обсудим их в этом смысле.

**Плохой.** *Плохой бенчмарк* дает ненадежные, неясные результаты. Когда вы пишете программу, выдающую какие-то значения производительности, они всегда что-то означают, но, возможно, не то, чего вы ожидали. Вот несколько примеров.

- Вы хотите измерить производительность жесткого диска, а бенчмарк измеряет производительность файловой системы.

- Вы хотите узнать, сколько времени занимает рендеринг веб-страницы, а бенчмарк измеряет производительность базы данных.
- Вы хотите понять, насколько быстро процессор может обработать арифметические выражения, а бенчмарк измеряет, насколько эффективно компилятор оптимизирует эти выражения.

Плохо, когда бенчмарки не выдают надежной информации о пространстве производительности. Если вы написали ужасный бенчмарк, то все равно можете проанализировать его правильно и объяснить, откуда взялись такие цифры. А написав «лучший бенчмарк в мире», можете ошибиться в анализе. Использование сверхнадежной библиотеки для бенчмаркинга не гарантирует того, что вы непременно придете к правильным выводам. Если вы написали плохой бенчмарк в десять строк, основанный на простом цикле с применением `DateTime.Now`, это не значит, что результаты неверны: если вы прекрасно понимаете, что происходит внутри вашей программы, то сможете извлечь много полезной информации из полученных результатов.

**Непонятный.** *Непонятный бенчмарк* выдает результаты, которые трудно проверить. Это не означает их правильность или неправильность, просто им нельзя доверять. Если вы игнорируете хорошие практики бенчмаркинга и пишете запутанный код, то не можете быть уверены в том, что получили правильные результаты.

Представьте плохо написанный фрагмент кода. Никто не понимает, как он работает, но он работает и выполняет определенную задачу. Вы можете целый день распинаться об ужасном форматировании, непонятных названиях переменных и неконсистентном стиле, но программа продолжит работать корректно. То же самое происходит и в мире бенчмарков: непонятно написанный бенчмарк может выдавать правильные результаты, если вы правильно его анализируете. Поэтому вы не можете сказать, что их результаты непонятного бенчмарка *неверны* из-за того, что код написан слишком сложно, стадия прогрева пропущена, выполнено недостаточное количество итераций. Но можете назвать эти результаты *ненадежными* и потребовать дополнительного анализа.

**Хороший.** *Хороший бенчмарк* — это тот, который соответствует следующим критериям.

- *Исходный код выглядит надежным.* Он придерживается хороших практик бенчмаркинга и не содержит распространенных ошибок, которые могут запросто испортить результаты.
- *Результаты правильные.* Он измеряет то, что должен измерять, с высоким уровнем точности.
- *Представлены выводы.* Он объясняет контекст результатов и дает новую информацию о пространстве производительности на основе сырых значений измеренных метрик.

- *Результаты объясняются и подтверждаются.* Предоставляется дополнительная информация о результатах и о том, почему им можно доверять.

Хорошее исследование производительности всегда включает в себя анализ. Сырых цифр после измерений недостаточно. Главным результатом является вывод, основанный на анализе этих цифр.

В Интернете можно найти фрагменты кода, основанного на `Stopwatch`, которые содержат примеры результата без комментариев («Посмотрите, какой прекрасный бенчмарк» не считается). Если у вас есть значения производительности, их надо интерпретировать и объяснить, почему вы получили именно эти значения. Нужно объяснить, почему мы можем экстраполировать выводы и использовать их в других программах (вспомните, насколько сложными могут быть пространства производительности).

Конечно, этого недостаточно. Бенчмарк всегда должен включать в себя стадию проверки, если вы пытаетесь доказать, что его результаты верны.

## Поиск узкого места

При анализе результатов бенчмарка всегда задавайтесь вопросом, почему он не работает быстрее. Обычно у него есть ограничивающий фактор, или узкое место, которое важно найти по следующим причинам.

- Если вы не знаете об узком месте, сложно объяснить результат бенчмарка.
- Только информация об ограничивающем факторе позволяет проверить набор параметров. Вы уверены, что использованные параметры соответствуют вашей проблеме? Это довольно типичная ситуация, когда разработчик пытается измерить полное время исполнения бенчмарка, а лучше измерять конкретные метрики, такие как количество неудачных обращений в кэш или объем потраченной памяти.
- Понимание того, где находится узкое место, позволит вам разработать более качественный бенчмарк и исследовать пространство производительности в правильном направлении.
- Многие разработчики, пытаясь что-то оптимизировать, используют бенчмаркинг в качестве первой стадии, но, не зная ограничивающего фактора, они не поймут, что конкретно нужно делать с его результатами и как их правильно использовать.

Принцип Парето, известный также как правило «80/20», описывает неравное распределение, например: 20 % затраченных усилий дают 80 % результатов, 20 % опасностей приводят к 80 % травм, 20 % ошибок вызывают 80 % поломок и т. д. Можно применить принцип Парето к узким местам (назовем это правилом бутылочного

горлышка<sup>1</sup>) и сказать, что 20 % кода потребляют 80 % ресурсов. Если пойти дальше и попытаться найти проблему, используя эти 20 %, можно снова применить принцип Парето и получить принцип Парето второго порядка (Парето-2). В этом случае получится 4 % кода ( $4\% = 20\% \cdot 20\%$ ) и 64 % ресурсов ( $64\% = 80\% \cdot 80\%$ ). В больших приложениях со сложной многоуровневой архитектурой можно пойти еще дальше и сформулировать принцип Парето третьего порядка (Парето-3). В этом случае мы получим 0,8 % кода ( $0,8\% = 20\% \cdot 20\% \cdot 20\%$ ) и 51,2 % ресурса ( $51,2\% = 80\% \cdot 80\% \cdot 80\%$ ). Таким образом, имеются следующие **правила бутылочного горлышка**:

- **Парето-1:** 20 % кода потребляет 80 % ресурсов;
- **Парето-2:** 4 % кода потребляет 64 % ресурсов;
- **Парето-3:** 0,8 % кода потребляет 51,2 % ресурсов.

Здесь мы используем термин «ресурс» как абстрактный, но важно помнить, какие ресурсы ограничивают производительность и как они соотносятся с различными видами узких мест. В этой книге мы узнаем, что у каждого вида есть свои подводные камни и ограничивающие факторы, о которых важно помнить (см. главы 7 и 8). Понимание этого позволит сфокусироваться на более важных аспектах конкретной ситуации.

## Статистика

Хотелось бы, чтобы каждый бенчмарк выдавал одно и то же значение каждый раз, но в реальности у измерений производительности странные и пугающие распределения. Конечно, это зависит от выбора параметров, но стоит быть готовыми к распределению необычной формы, особенно если вы измеряете время по настенным часам. Если вы хотите проанализировать результаты бенчмарка как следует, то должны знать основные принципы статистики, например разницу между средним арифметическим и медианой, а также значение слов «выброс», «стандартная ошибка» и «процентиль». Полезно также знать о центральной предельной теореме и мультимодальных распределениях. Совсем хорошо, если знаете, как проводить тесты на статистическую значимость, не пугаетесь словосочетания «нулевая гипотеза» и можете рисовать красивые и непонятные статистические графики. Не переживайте, если вы что-то из этого не знаете, мы все обсудим в главе 4.

Надеюсь, теперь вы понимаете, почему так важно потратить время на анализ. А сейчас давайте подытожим все, что узнали в этой главе.

<sup>1</sup> Правило бутылочного горлышка придумал Федерико Луис. Вы можете посмотреть его прекрасную лекцию на эту тему и другие темы, связанные с производительностью, на YouTube: [www.youtube.com/watch?v=7GTpwgsmHgU](http://www.youtube.com/watch?v=7GTpwgsmHgU).

## Выводы

Вы кратко ознакомились с основными темами, важными для разработчика, желающего писать бенчмарки.

- Качественное исследование производительности и его этапы.
- Типичные цели бенчмаркинга и то, как они могут помочь создавать более быстрые программы и совершенствовать ваши навыки.
- Распространенные требования к бенчмаркам и разница между хорошими и плохими бенчмарками.
- Пространства производительности, а также почему важно учитывать исходный код, окружение и входные данные.
- Почему анализ так важен и как делать правильные выводы.

В последующих главах рассмотрим эти темы подробнее.

# 2

## Подводные камни бенчмаркинга

Если вы изучали результат бенчмарка меньше недели, скорее всего, он неверный.

*Брендан Грегг, автор книги Systems Performance: Enterprise and the Cloud (Prentice Hall, 2013)*

В этой главе мы обсудим самые распространенные ошибки, совершаемые при попытках измерить производительность. Если вы хотите писать бенчмарки, вам необходимо смириться с фактом, что в большинстве случаев вы будете ошибаться. К сожалению, универсального надежного способа удостовериться в том, что вы получите те измерения производительности, которые хотели, не существует. Подводные камни появляются на разных уровнях: компилятор C#, среда исполнения .NET, процессор и т. д. Вы также узнаете о подходах и техниках, которые помогут писать надежные и корректные бенчмарки.

Большая часть подводных камней особенно неприятна в случае микробенчмарков с очень коротким временем работы (такие методы могут длиться миллисекунды, микросекунды и даже наносекунды). То, что мы обсудим, относится не только к микробенчмаркам, но и ко всем прочим видам бенчмарков. Однако сосредоточимся в основном на микробенчмарках по следующим причинам.

- Простейшие микробенчмарки состоят всего из нескольких строчек кода. Чтобы понять, что происходит в каждом примере, обычно требуется не больше одной минуты. Однако простота обманчива. Вы увидите, как сложно проводить измерения даже на очень простых фрагментах кода.
- Микробенчмарки обычно становятся первым шагом в мир бенчмаркинга, который совершают разработчики. Если хотите писать качественные бенчмарки в реальной жизни, нужно научиться писать микробенчмарки. Стандартные действия одинаковы в обоих случаях, а учиться гораздо проще на небольших примерах.

В этой главе мы рассмотрим некоторые из самых распространенных ошибок при микробенчмаркинге. В каждом примере вы увидите подраздел «Плохой бенчмарк». В нем описывается бенчмарк, который может показаться нормальным некоторым разработчикам, особенно если у них нет опыта в данной области, но он выдает плохие результаты. После этого будет представлен «бенчмарк получше». Обычно он все еще не идеален, у него есть определенные недостатки, но он демонстрирует, в каком направлении двигаться, чтобы улучшить ваши бенчмарки. Можно сказать, что если в плохом бенчмарке  $N$  ошибок, то в бенчмарке получше — максимум  $N - 1$  ошибка. Надеюсь, такие примеры помогут понять, как избегать подобных ошибок.

И еще одно: если вы хотите получить не просто знания, но и навыки бенчмаркинга, не стоит бездумно пролистывать примеры. Запускайте каждый из них на своем компьютере. Поиграйте с исходным кодом: проверьте его в разных окружениях или поменяйте что-нибудь в коде. Посмотрите на результат и попытайтесь объяснить его для себя прежде, чем прочтете объяснение в книге. Навыки бенчмаркинга можно получить только опытным путем.

## Общие подводные камни

Мы начнем с общих подводных камней. Все примеры будут представлены на C#, но соответствующие проблемы относятся не только к .NET, но и ко всем языкам и любой среде исполнения.

### Неточные замеры времени

Прежде чем начать изучать подводные камни, поговорим об основах бенчмаркинга. Прежде всего нужно научиться замерять время.

Как измеряется время операции? Ответ на этот вопрос может показаться очевидным. Необходимо получить текущее время перед операцией (спросить у компьютера: «Который час?»), произвести операцию и получить текущее время еще раз. Затем вычесть первое значение из второго и получить затраченное время! Псевдокод может выглядеть примерно так (мы используем `var`, потому что тип отметки зависит от используемого API):

```
var startTimestamp = GetTimestamp();  
// Что-то сделать  
var endTimestamp = GetTimestamp();  
var totalTime = endTimestamp - startTimestamp;
```

Но как именно следует ставить эти отметки времени? Платформа .NET предлагает несколько API для этих целей. Многие разработчики, начинающие писать бенчмарки, используют `DateTime.Now`:

```
DateTime start = DateTime.Now;  
// Что-то сделать  
DateTime end = DateTime.Now;  
TimeSpan elapsed = end - start;
```

Для *некоторых* сценариев это работает нормально. Однако у `DateTime.Now` довольно много недостатков.

- Существует огромное количество не особо очевидных вещей, связанных с тем, как компьютер работает со временем. Например, правильное в настоящий момент время может вдруг измениться из-за перехода на зимнее время. Чтобы побороться с этой проблемой, можно использовать `DateTime.UtcNow` вместо `DateTime.Now`. Также `DateTime.UtcNow` работает быстрее, потому что ему не нужно высчитывать часовые пояса.
- Текущее время может быть синхронизировано с Интернетом в случайный момент. Синхронизация происходит довольно часто и запросто может привести к погрешности в несколько секунд.
- Точность `DateTime.Now` и `DateTime.UtcNow` невысока. Если ваш бенчмарк выполняется в течение нескольких минут или часов, это может быть не страшно, но если метод занимает меньше 1 мс, это совершенно неприемлемо.

Есть и много других проблем, связанных со временем. Мы их обсудим в главе 9. К счастью, существует другой системный класс `System.Diagnostics.Stopwatch`. Он разработан для измерения затраченного времени с наилучшим разрешением из возможных. Это лучшее из решений на платформе .NET для замеров времени. Вот пример его использования:

```
Stopwatch stopwatch = Stopwatch.StartNew();  
// Что-то сделать  
stopwatch.Stop();  
TimeSpan elapsedTime = stopwatch.Elapsed;
```

Использование методов `StartNew()` и `Stop()` — самый удобный способ применения `Stopwatch`. Внутри они просто вызывают `Stopwatch.GetTimestamp()` дважды и считают разницу. `GetTimestamp()` выдает текущее количество тиков времени (абстрактная единица времени, используемая `Stopwatch` и другими подобными API), которое можно перевести в реальное время с помощью поля `Stopwatch.Frequency`<sup>1</sup>. Обычно

---

<sup>1</sup> Чтобы получить количество часов, нужно разделить дельту тиков на частоту. Оба значения представляют собой целые числа, но результат должен быть дробным числом. Поэтому нужно перевести дельту в удвоенную величину, прежде чем производить операцию деления. Мой любимый способ — умножить числитель на 1,0.

в этом нет необходимости, но значение количества тиков может пригодиться при микробенчмаркинге (подробнее об этом — в главе 9). Вот пример применения:

```
long startTicks = Stopwatch.GetTimestamp();
// Что-то сделать
long endTicks = Stopwatch.GetTimestamp();
double elapsedSeconds = (endTicks - startTicks)
    * 1.0 / Stopwatch.Frequency;
```

Со `Stopwatch` также могут быть проблемы, особенно на старых компьютерах, но это все же лучший API для замеров времени. Когда вы пишете микробенчмарк, полезно знать, как работает логика замеров времени внутри. У вас должны быть ответы на следующие вопросы:

- Каковы точность/разрешение выбранного API?
- Какова возможная разница между двумя последовательными замерами времени? Может ли она быть равна нулю? А намного больше разрешения? А меньше нуля?
- Сколько времени занимает получение одного замера?

Все эти темы и многие детали реализации освещены в главе 9. Не страшно, если вы не помните детали внутреннего устройства `Stopwatch`, но у вас должны быть ответы на данные вопросы для выбранного вами окружения.

А теперь настало время примеров!

## Плохой бенчмарк

Допустим, мы хотим измерить, сколько времени требуется на сортировку списка из 10 000 элементов. Так выглядит *плохой* бенчмарк, основанный на `DateTime`:

```
var list = Enumerable.Range(0, 10000).ToList();
DateTime start = DateTime.Now;
list.Sort();
DateTime end = DateTime.Now;
TimeSpan elapsedTime = end - start;
Console.WriteLine(elapsedTime.TotalMilliseconds);
```

Этот бенчмарк ужасен: в нем куча проблем, и ему попросту нельзя доверять. Позже мы узнаем, почему он так плох и как исправить все проблемы. Сейчас же смотрим только на разрешение замеров времени.

Займемся вычислениями. На Windows 10 частота обновлений `DateTime` по умолчанию 64 Гц. Это означает, что мы получаем новое значение один раз в 15,625 мс. Некоторые приложения, например браузер или плеер, могут увеличить эту частоту до 2000 Гц (0,5 мс). Сортировка 10 000 элементов — это довольно быстрая операция на современных компьютерах. Обычно она выполняется быстрее чем за 0,5 мс.

Поэтому, если вы используете Windows и закрыли все несистемные приложения, бенчмарк выдаст 0 или ~ 15,625 мс (зависит от вашего везения). Очевидно, что такой бенчмарк бесполезен — эти значения нельзя использовать для оценки производительности метода `List.Sort()`.

## Бенчмарк получше

Можно переписать наш пример с помощью `Stopwatch`:

```
var list = Enumerable.Range(0, 10000).ToList();
var stopwatch = Stopwatch.StartNew();
list.Sort();
stopwatch.Stop();
TimeSpan elapsedTime = stopwatch.Elapsed;
Console.WriteLine(elapsedTime.TotalMilliseconds);
```

Такой бенчмарк все еще плох и нестабилен (если запустить его несколько раз, будет большая разница между измерениями), но теперь у нас есть хорошее разрешение замеров времени. Типичное разрешение `Stopwatch` в Windows — 300–500 нс. Этот код выдает результат 0,05–0,5 мс в зависимости от устройства и среды исполнения, что гораздо ближе к реальному времени сортировки.

### СОВЕТ

Выбирайте `Stopwatch` вместо `DateTime`.

В 99 % случаев основным инструментом для проставления отметок времени должен быть `Stopwatch`. Конечно, могут возникнуть крайние случаи, требующие других инструментов (мы обсудим их позже), но в простых случаях вам больше ничего не понадобится. Этот совет прост и не требует дополнительных строчек кода. `DateTime` может пригодиться, только если вам *действительно* нужно знать *текущее время* (и в этом случае, скорее всего, следует заняться мониторингом, а не бенчмаркингом). Если реальное текущее время не требуется, используйте правильный API: `Stopwatch`.

Теперь вы знаете, как написать простой бенчмарк с помощью `Stopwatch`. Пора узнать, как его запустить.

## Неправильный запуск бенчмарка

Вам также нужно знать, как выполнять бенчмарк. Это может казаться совершенно очевидным, но многие разработчики страдают из-за неверных результатов бенчмарка, испорченных из-за того, что программа была неправильно запущена.

## Плохой бенчмарк

Откройте свою любимую интерактивную среду разработки, создайте новый проект и напишите следующую простую программу:

```
var stopwatch = Stopwatch.StartNew();
for (int i = 0; i < 100000000; i++)
{
}
stopwatch.Stop();
Console.WriteLine(stopwatch.ElapsedMilliseconds);
```

Она ничего полезного не измеряет. Это просто пустой цикл. Результаты такого замера не имеют практической ценности, мы будем использовать его лишь для демонстрации некоторых проблем.

Давайте запустим эту программу. На моем ноутбуке она выдает значения около 400 мс (Windows, .NET Framework 4.6)<sup>1</sup>. Так в чем же тут главная проблема? По умолчанию каждый новый проект использует конфигурацию отладки (debug mode). Она предназначена для отладки, а не для бенчмаркинга. Многие забывают ее сменить, измеряют производительность сборок для отлаживания и получают неверный результат.

## Бенчмарк получше

Переключим в режим релиза (release mode) и запустим этот код еще раз. На моем ноутбуке в этом режиме бенчмарк показывает ~ 40 мс. Разница примерно в десять раз!

Теперь ваша очередь. Запустите пустой цикл в обеих конфигурациях на своем устройстве и сравните результаты.

### СОВЕТ

Используйте режим релиза без присоединенной программы отладки в реальном окружении.

У меня есть для вас несколько небольших подсказок. Давайте обсудим все хорошие практики, которых стоит придерживаться, если вам нужны надежные результаты.

- **Используйте режим релиза, а не отладки.**

При создании нового проекта у вас обычно есть две конфигурации: отладка (debug) и релиз (release). Режим релиза означает, что в файле `.csproj` значится `<Optimize>true</Optimize>` или вы применяете `/optimize` в `cs`.

---

<sup>1</sup> .NET Framework 4.6 честно выполняет этот цикл, но будьте осторожны: в дальнейшем может быть осуществлена дополнительная оптимизация JIT, и этот цикл придется отбросить, потому что он станет бесполезен (то есть бенчмарк будет выдавать 0).

Иногда (особенно в случае микробенчмарков) в режиме отладки выбранный вами метод может запускаться в 100 раз медленнее! Никогда не используйте отладочную сборку для бенчмаркинга.

Порой я нахожу в Интернете отчеты о производительности приложений с отдельными результатами для конфигураций: `debug` и `release`. Не делайте так! Результаты в режиме отладки не показывают ничего полезного. Компилятор Roslyn добавляет в скомпилированную сборку много дополнительных IL-команд с одной целью — упростить отладку. Оптимизации Just-In-Time (JIT) в режиме отладки тоже недоступны. Производительность отладочной сборки может быть интересна, только если вы разрабатываете инструменты для отладки. В остальных случаях всегда используйте режим релиза.

- **Не используйте присоединенную программу для отладки или профайлер.**

Советую никогда не применять при бенчмарке присоединенную программу для отладки, например встроенную в среду разработки или внешнюю, такую как WinDbg или gdb. Присоединенный отладчик обычно замедляет ваше приложение. Не в десять раз, как просто в режиме отладки, но все равно результаты могут заметно испортиться. Кстати, если вы используете программу для отладки Visual Studio (нажатием F5), она по умолчанию выключает оптимизацию JIT даже в режиме релиза (эту функцию можно отключить, но по умолчанию она включена). Лучше всего создать бенчмарк в режиме релиза и запустить его в командной строке (например, `cmd` в Windows).

Другие присоединенные приложения, например профайлеры производительности или памяти, также могут легко испортить общую картину производительности. В случае применения присоединенного профайлера эффект зависит от вида профилирования (например, `tracing` влияет на скорость сильнее, чем `sampling`), но он всегда значительнее.

Иногда можно использовать внутренние инструменты для диагностики среды исполнения программы. Например, если запустить `mono` с аргументами `--profile=log:sample`, будет создан файл `.mlpd` с информацией о профиле производительности приложения. Он может пригодиться для анализа относительной производительности (при поиске горячих методов), но абсолютная производительность будет сильно искажена из-за влияния профайлера.

Использовать отладочную сборку со встроенным отладчиком или профайлером нормально, только если вы отлаживаете или профилируете код. Не используйте ее для финального сбора измерений производительности, которые нужно будет анализировать.

- **Выключите другие приложения.**

Выключите все приложения, кроме процесса бенчмарка и стандартных процессов ОС. Если вы запускаете бенчмарк и в то же время используете среду

разработки, это может отрицательно повлиять на результаты бенчмарка. Кто-то может сказать, что в реальной жизни наше приложение будет работать параллельно с другими, поэтому следует измерять производительность в реалистичных условиях. Но у этих условий есть один недостаток: их влияние невозможно предсказать. Если вы хотите работать в реалистичных условиях, нужно как следует проверить, как каждое из сторонних приложений может повлиять на производительность, что не так-то просто (мы обсудим множество полезных инструментов для этого в главе 6). Гораздо лучше проверять производительность в идеальных условиях, когда вас не беспокоят другие приложения.

Когда вы разрабатываете бенчмарк, нормально проводить пробные прогоны напрямую из любимой среды разработки. Но когда собираете конечные результаты, лучше среду разработки отключить и запустить бенчмарк из терминала.

Некоторые бенчмарки выполняются несколько часов. Дождаться окончания скучно, поэтому многие разработчики любят делать что-то еще во время бенчмаркинга: играть, рисовать смешные картинки в Photoshop или писать новый код. Однако это не лучшая идея. Это может быть нормально, если вы четко понимаете, какие результаты хотите получить и как это может на них повлиять. Например, если вы проверяете гипотезу о том, что один метод работает в 1000 раз медленнее другого, выводы будет трудно испортить сторонними приложениями. Но если вы занимаетесь микробенчмаркингом, чтобы проверить предположение о разнице 5 %, запуск сложных фоновых процессов нежелателен: эксперимент перестанет быть стерильным и его результатам нельзя будет доверять. Конечно, вам может повезти и вы получите правильные результаты. Но вы не можете быть в этом уверены.

Будьте внимательны. Даже если вы отключите все приложения, которые можно завершить, в операционной системе все равно могут работать какие-то сервисы, потребляющие ресурсы процессора. Типичным примером является Защитник Windows (Windows Defender), который может решить произвести какую-нибудь сложную операцию в любой момент. На рис. 2.1 виден типичный шум от процессора в Windows<sup>1</sup>. Обычно системные процессы не настолько агрессивны, чтобы совсем испортить бенчмарк, но будьте готовы к тому, что некоторые из измерений окажутся намного больше других из-за шума на уровне процессора.

<sup>1</sup> Это снимок экрана программы Process Hacker (хорошая замена предустановленному диспетчеру задач). Ось *X* отображает время, а ось *Y* — использование процессора. Process Hacker применяет разные цвета для параметров использования ядра процессора (красный) и общей нагрузки (зеленый). Читателям бумажной версии: вы можете увидеть этот рисунок в цвете в пакете загрузок для книги.



Рис. 2.1. Типичный шум ЦП в Windows

Чтобы избежать подобных ситуаций, следует запускать бенчмарк много раз и собирать все результаты. Процессорный шум может появиться в случайно выбранный момент, поэтому он обычно портит не все измерения, а лишь некоторые. Вы можете удостовериться в том, что окружение стерильно, с помощью дополнительных инструментов, которые отслеживают использование ресурсов. В некоторых случаях подобные инструменты тоже могут повлиять на результаты, поэтому вам все равно нужно выполнять стерильные запуски бенчмарка, а мониторинг применять при дополнительных проверках.

- **Используйте режим энергопотребления «высокая производительность».**

Если вы занимаетесь бенчмаркингом на ноутбуке, не отключайте его от сети и работайте в режиме максимальной производительности. Давайте снова поиграем с бенчмарком в виде пустого цикла. Отключите питание ноутбука, выберите режим Сохранение энергии и подождите, пока не останется 10 % от заряда батареи. Запустите бенчмарк. Затем подключите питание, выберите режим Высокая производительность и запустите его снова. Сравните результаты. На моем ноутбуке производительность выросла с ~ 140 до ~ 40 мс. Похожая ситуация складывается не только с микробенчмарками, но и с любыми другими приложениями. Попробуйте проверить это на своих любимых программах: сколько времени занимает выполнение различных операций. Надеюсь, что после этого эксперимента вы не станете запускать бенчмарки на ноутбуке с отключенным питанием.

К сожалению, даже если вы запустили бенчмарк правильно, это все равно не означает, что вы получите хорошие результаты. Давайте продолжим рассматривать различные подводные камни микробенчмарков.

## Естественный шум

Даже если вы создадите суперстерильное окружение и запустите бенчмарк по всем правилам, от естественного шума все равно никуда не деться. Если запустить бенчмарк дважды, вы почти никогда не получите двух одинаковых результатов. Почему? Существует много источников шума.

- **Всегда существуют другие процессы, соревнующиеся за ресурсы компьютера.**

Даже если вы остановите все пользовательские процессы, останется много процессов операционной системы (каждый со своим приоритетом), которые нельзя отключить. Вы всегда будете делить с ними ресурсы. И поскольку вы не можете предсказать, что происходит в других процессах, невозможно прогнозировать и их воздействие на ваш бенчмарк.

- **Распределение ресурсов недетерминировано.**

Операционная система всегда контролирует выполнение вашей программы. Поскольку мы всегда работаем в многопроцессном и многопоточном окружении, невозможно предсказать, как ОС распределит ресурсы. К этим ресурсам относятся процессор, видеокарточка, сеть, диски и т. д. Количество переключений контекста процессов также непредсказуемо, а каждое из них будет ощутимо отражаться на измерениях.

- **Структура памяти и случайный порядок распределения адресного пространства.**

В момент запуска программы ей выделяется новый фрагмент глобального адресного пространства. Среда исполнения .NET может выделять память в разных местах с различными промежутками между одними и теми же объектами. Это может повлиять на производительность на разных уровнях. Например, выровненный и невыровненный доступ к данным работает за разное время; разные паттерны расположения данных создают различные ситуации в кэше процессора; процессор может использовать смещения объектов в памяти в качестве факторов в эвристических алгоритмах низкого уровня и т. д.

Еще одна интересная функция для обеспечения безопасности в современных операционных системах — это случайный порядок распределения адресного пространства (address space layout randomization, ASLR). Он защищает от вредоносных программ, которые могут эксплуатировать переполнение буфера. Это хорошо с точки зрения безопасности, но вот стабильность замеров времени от этого страдает<sup>1</sup>.

---

<sup>1</sup> Примеры можно найти в следующей статье: *Oliveira de, Born A., Petkovich J.-C., Fischmeister S.* How much does memory layout impact performance? A wide study // Intl. Workshop Reproducible Research Methodologies, 2014.

- **Увеличение и ускорение частоты ЦП.**

Современный процессор может динамически менять внутреннюю частоту в зависимости от состояния системы. К сожалению, этот процесс также недетерминирован — невозможно предугадать, когда и как изменится частота.

- **Внешнее окружение тоже важно.**

Я говорю не о версии .NET Framework или вашей операционной системе, а именно о факторах внешней среды, таких как температура. Однажды у моего ноутбука были проблемы с кулером. Он почти сломался, и температура процессора постоянно была повышена. Во время работы ноутбук издал громкий звук и через 10 мин выключился, потому что процессор перегрелся. К счастью, на дворе была зима, а жил я тогда в Сибири. Поэтому я открыл окно, сел на подоконник и работал в куртке, шапке и перчатках. Стоит ли здесь говорить о производительности? Из-за постоянного перегрева все работало очень медленно. И самое главное, скорость была непредсказуемой. Было невозможно запускать бенчмарки, потому что дисперсия значений оказывалась очень высокой.

Конечно же, это была исключительная ситуация, обычно таких ужасных условий не возникает. Вот еще один пример, с которым можно столкнуться в реальной жизни: запуск бенчмарков на облачном сервере. Это вполне нормальные условия для бенчмаркинга, если вас интересует именно производительность в реальных условиях. Важны условия в центре обработки данных провайдера вашего облачного сервиса. Внешних факторов очень много: окружающая температура, механические вибрации и т. д. Мы подробнее обсудим их в главе 3.

Таким образом, разница между похожими измерениями — это нормально, но необходимо всегда помнить о том, насколько значительными могут быть ошибки. В этом разделе мы рассмотрим пример, где естественный шум имеет значение.

## Плохой бенчмарк

Допустим, мы хотим проверить, является ли число простым. Попробуем несколько способов и сравним производительность. На данный момент у нас есть только реализация `IsPrime`, и нам прямо сейчас нужна инфраструктура для бенчмаркинга. Поэтому мы сравниваем производительность двух одинаковых вызовов, чтобы убедиться, что бенчмаркинг работает правильно:

```
// Это не самый быстрый метод,  
// но мы оптимизируем его позже  
static bool IsPrime(int n)  
{  
    for (int i = 2; i <= n - 1; i++)  
        if (n % i == 0)  
            return false;  
    return true;  
}
```

```

static void Main()
{
    var stopwatch1 = Stopwatch.StartNew();
    IsPrime(2147483647);
    stopwatch1.Stop();

    var stopwatch2 = Stopwatch.StartNew();
    IsPrime(2147483647);
    stopwatch2.Stop();

    Console.WriteLine(stopwatch1.ElapsedMilliseconds + " vs. " +
                      stopwatch2.ElapsedMilliseconds);
    if (stopwatch1.ElapsedMilliseconds < stopwatch2.ElapsedMilliseconds)
        Console.WriteLine("Первый метод быстрее");
    else
        Console.WriteLine("Второй метод быстрее");
}

```

Проверьте этот фрагмент у себя на компьютере, запустите его несколько раз.

Я уже проверил, как он работает на моем ноутбуке:

```

5609 против 5667
Первый метод быстрее.

```

И запустил его еще раз:

```

5573 vs. 5490
Второй метод быстрее

```

Таким образом, получены два показателя производительности для одной и той же программы с разными выводами. Наша основная проблема: мы забыли об ошибках! Если между двумя измерениями есть разница, это не значит, что один метод работает быстрее другого. Стоит проверить, превышает ли разница естественный шум. К сожалению, оценить размеры подобных ошибок непросто. Также непросто их минимизировать (в этой книге вы найдете множество полезных примеров). Обычно они составляют 5–20 % для примитивного бенчмарка, но иногда могут достигать 200–500%! Поэтому будьте внимательны при сравнении производительности двух методов!

Теперь пора улучшить бенчмарк `IsPrime`.

## Бенчмарк получше

Итак, у нас есть следующие требования.

1. Результаты должны быть стабильными, а выводы каждый раз одинаковыми.
2. Если методы занимают примерно одно и то же время, мы должны получать соответствующее сообщение.

Как это можно реализовать? Мы можем ввести максимально приемлемую ошибку (например, 20 %<sup>1</sup> от среднего значения двух измерений) и использовать ее при сравнении:

```
var error = ((stopwatch1.ElapsedMilliseconds +
    stopwatch2.ElapsedMilliseconds) / 2) * 0.20;
if (Math.Abs(stopwatch1.ElapsedMilliseconds -
    stopwatch2.ElapsedMilliseconds) < error)
    Console.WriteLine("Значительной разницы между методами нет");
else if (stopwatch1.ElapsedMilliseconds < stopwatch2.ElapsedMilliseconds)
    Console.WriteLine("Первый метод быстрее");
else
    Console.WriteLine("Второй метод быстрее");
```

Поправьте это в своем фрагменте и попробуйте запустить. Вот мой результат:

```
542 против 523
Значительной разницы между методами нет
```

Ура, мы получили правильный результат!

Однако повторяю еще раз: это неидеальное решение. С помощью такого кода нельзя определить отклонение в производительности на 5–10 %: если один метод на самом деле работает на 7 % дольше другого, вы этого не заметите. Но он подходит, если разница в производительности двух- или трехкратная и очевидно, какой метод быстрее. Будьте внимательны: он годится не всегда, естественный шум иногда бывает очень сильным.

## СОВЕТ

Всегда анализируйте случайные ошибки.

Мы не можем предотвратить естественный шум и случайные ошибки, поэтому лучшее, что можем сделать, — правильный анализ. Проведите много итераций бенчмарка, посмотрите на разброс и запомните порядок этих случайных ошибок. Если у вас два разных значения производительности для двух разных методов (в нашем жестоком мире всегда получаются разные цифры), сравните разницу с оценкой естественного шума для каждого метода, прежде чем делать выводы о том, какой

---

<sup>1</sup> Двадцать процентов — это пример. Это число зависит от целей бенчмаркинга и требований вашего бизнеса. Также полезно измерять все многократно и определять разницу между минимальным и максимальным затраченным временем: так вы получаете первую приближительную оценку естественного шума. Таким образом, у вас есть некая изначальная приближительная цифра, которую можно использовать в качестве максимально допустимой ошибки. В следующих главах мы обсудим стандартное отклонение при распределении производительности и узнаем, как с помощью этого значения сравнивать методы.

метод быстрее (есть ли между ними значительная разница). Мы обсудим статистические методы сравнения распределений в главе 4.

В следующем разделе поговорим о других сюрпризах, наблюдающихся в распределениях измерений.

## Сложные распределения

В предыдущих разделах мы обсудили, как достичь стабильных результатов бенчмарка. К сожалению, производительность кода не всегда можно описать с помощью одного числа.

### Плохой бенчмарк

Рассмотрим следующий бенчмарк ввода/вывода:

```
byte[] data = new byte[64 * 1024 * 1024];
var stopwatch = Stopwatch.StartNew();
var fileName = Path.GetTempFileName();
File.WriteAllBytes(fileName, data);
File.Delete(fileName);
stopwatch.Stop();
Console.WriteLine(stopwatch.ElapsedMilliseconds);
```

Здесь мы делаем простую вещь: создаем новый временный файл, записываем 64 Мбайт данных и удаляем файл. Есть ли проблема с этим бенчмарком? Да, есть: мы выполняем только одну итерацию! Уверены ли мы в том, что все операции ввода/вывода занимают одинаковое время?

### Бенчмарк получше

Теперь проведем несколько итераций и составим базовую статистику:

```
int N = 1000;
byte[] data = new byte[64 * 1024 * 1024];
var measurements = new long[N];
for (int i = 0; i < N; i++)
{
    var stopwatch = Stopwatch.StartNew();
    var fileName = Path.GetTempFileName();
    File.WriteAllBytes(fileName, data);
    File.Delete(fileName);
    stopwatch.Stop();
    measurements[i] = stopwatch.ElapsedMilliseconds;
    Console.WriteLine(measurements[i]);
}
```

```
Console.WriteLine("Минимум = " + measurements.Min());  
Console.WriteLine("Максимум = " + measurements.Max());  
Console.WriteLine("Средняя величина = " + measurements.Average());
```

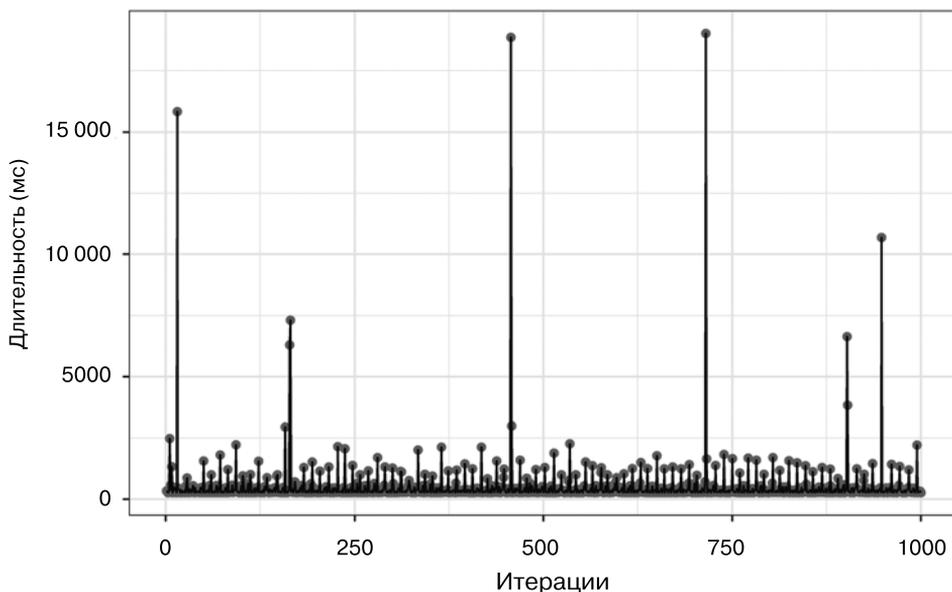
На своем SSD (SanDisk SD8SNAT128G1002) + Windows (10.0.17134.285) я получил следующие значения:

334, 304, 266, 333, **2488**, 575, 371, **1336**, 269, 488, 377, 472, 374,  
266, **15827**,...

А это данные, выведенные программой:

Минимум = 265  
Максимум = 19029  
Средняя величина = 531,176

Большинство значений укладываются в интервал 250–500, но есть и довольно большие значения от 600 до 19 000. Если увеличить количество итераций, мы увидим, что это не случайность: очень высокие значения появляются систематически (рис. 2.2).



**Рис. 2.2.** Измерения методов с ограничениями по вводу-выводу

Бенчмаркинг операций ввода-вывода — это очень тяжело. Ситуация, в которой невозможно описать производительность одним средним значением, — нормальная.

**СОВЕТ**

Всегда смотрите на свое распределение.

К счастью, во многих простых случаях мы можем просто взять среднее значение и работать с ним. Но как узнать это наверняка? Если мы хотим точно знать, что все в порядке, то всегда можем сначала проверить распределение. В главе 4 подробно обсудим, как правильно анализировать распределения.

В следующем разделе мы поговорим о разнице между первым и последующими измерениями и о том, почему наблюдается этот эффект.

## Измерение холодной загрузки вместо прогретого стабильного состояния

Выполнение кода впервые после запуска приложения называется холодным запуском. Он включает в себя большой объем сторонних действий (в основном на уровне среды исполнения и процессора): JIT-компиляцию запускаемых методов, загрузку сборок, прогрев кэша процессора и т. д. Могут также появиться пользовательские процессы: инициализация объектов, запуск конструкторов статических классов, заполнение пользовательского кэша и т. д. Все это может увеличить время работы и испортить результаты бенчмарка.

Измерение холодной загрузки — не очень частая задача: разработчики обычно занимаются этим, только когда оптимизируют время запуска. Во всех остальных случаях вы допустите ошибку, если будете неявно учитывать в своих замерах накладные расходы на инициализацию приложения. Чтобы этого избежать, необходимо произвести **прогрев** — запустить бенчмарк для метода несколько раз вхолостую (без измерений). Прогрев означает, что мы ждем, когда все переходные процессы инициализации закончатся и состояние стабилизируется (steady state). В таком состоянии при всех последующих итерациях бенчмарк будет выполнять один и тот же объем работы без побочных эффектов. Другими словами, мы должны стремиться к ситуации, когда перед каждой итерацией и после нее состояние программы остается неизменным.

Вы сами должны решить, какое состояние хотите измерять, холодное или прогретое. Например, когда вы оптимизируете запуск приложения, вас интересует только первая итерация бенчмарка (последующие будут прогретыми). Поэтому, если вы хотите сделать несколько измерений холодной загрузки, нужно будет каждый раз перезапускать все приложение.

Большинство бенчмарков работают с прогретой программой. Обычно следует прогреть программу и только после этого делать основные замеры.

Как мы можем проверить, что вошли в стабильное состояние? Короткий ответ — никак. Для реальных больших приложений со сложными стратегиями кэширования и многопоточностью могут потребоваться десятки и даже сотни итераций для прогрева. К счастью, для простых бенчмарков обычно достаточно 4–5 итераций (для уверенности прогоните их десять раз). Если каждый раз программа работает быстрее, чем предыдущий, вероятно, код все еще не прогрет (обычно в стабильном состоянии наблюдаются отклонения вокруг одного значения).

Теперь убедимся в том, что различать холодное и разогретое состояния действительно важно.

## Плохой бенчмарк

Рассмотрим следующий бенчмарк:

```
int[] x = new int[100000000];
var stopwatch = Stopwatch.StartNew();
for (int i = 0; i < x.Length; i++)
    x[i]++;
stopwatch.Stop();
Console.WriteLine(stopwatch.ElapsedMilliseconds);
```

Здесь мы видим массив `int` с 100 000 000 элементов и увеличиваем каждый элемент на единицу. Что не так с этим бенчмарком? Мы совершаем много действий по чтению и записи памяти в одном цикле. У современных процессоров сложная иерархическая структура с многоуровневым кэшем. Когда мы запускаем этот код впервые, кэш не прогрет. Доступ к основной памяти довольно дорогой, поэтому код выполняется долго. Результат будет описывать холодное состояние. Скорее всего, это не то, что нам действительно нужно.

## Бенчмарк получше

Проведем пять итераций и измерим время для каждого из них:

```
int[] x = new int[100000000];
for (int iter = 0; iter < 5; iter++)
{
    var stopwatch = Stopwatch.StartNew();
    for (int i = 0; i < x.Length; i++)
        x[i]++;
    stopwatch.Stop();
    Console.WriteLine(stopwatch.ElapsedMilliseconds);
}
```

Типичный результат на моем ноутбуке (проверьте, как это работает на вашем компьютере):

180  
80  
67  
71  
68

Как видите, первая итерация заняла около 180 мс. Это время холодной загрузки. После нескольких итераций мы можем наблюдать, что измерения варьируются около 70 мс. Здесь уже достигнуто стабильное прогретое состояние. Бенчмаркинг холодной загрузки слишком непредсказуем, поэтому с подобными измерениями требуется особое обращение. Говоря о бенчмаркинге в целом, обычно мы предполагаем прогретое состояние.

Предлагаю вам сделать следующее упражнение: возьмите фрагмент кода из вашего рабочего или личного проекта и запустите его несколько раз в начале метода `Main`, выполняя измерения с помощью обычного `Stopwatch`. Сравните первое измерение с последующими. Сделайте выводы о том, сколько раз нужно запустить код до перехода в стабильное состояние.

## СОВЕТ

Используйте разные подходы для холодного и разогретого состояний.

Перед началом бенчмаркинга всегда нужно решить, хотите вы измерять холодную загрузку или прогретое стабильное состояние? Если вас интересует холодная загрузка, обычно нужно перезапускать программу (иногда даже перезагружать компьютер) перед каждым измерением. В другом случае требуется провести несколько итераций для прогрева и перехода в стабильное состояние, прежде чем делать замеры производительности.

В следующем разделе обсудим, сколько раз нужно выполнять измерения.

## Недостаточное количество вызовов

Когда вы делаете микрооптимизации, может оказаться полезно замерять время очень маленьких методов, занимающих наносекунды. Если вы работаете с горячим методом и вызываете его миллион раз в секунду, даже рост производительности на 10–20 % может иметь значение. Однако измерять такие методы непросто.

Допустим, у нас есть метод, работающий около 100 нс, и мы пытаемся измерить его с помощью `Stopwatch`:

```
var stopwatch = Stopwatch.StartNew();  
Foo(); // 100ns  
stopwatch.Stop();  
// Вывести ElapsedTime
```

Как мы уже знаем, обычное разрешение `Stopwatch` для Windows — 300–500 нс. Этого недостаточно для измерения такого короткого метода: скорее всего, в результате получится ноль или значение разрешения `Stopwatch`. Даже если время исполнения метода измеряется микросекундами, мы все равно сталкиваемся с естественным шумом, который портит повторяемость бенчмарка. Эту проблему можно решить, если вызывать метод много раз между замерами и разделить общее время работы на количество вызовов. Посмотрим, как это работает.

## Плохой бенчмарк

Мы хотим узнать, сколько делителей у числа 100 000 (спойлер: их 36). Давайте решим эту простую задачу, сделаем замеры и повторим бенчмарк десять раз (как обычно, попробуйте запустить этот код на своем компьютере):

```
const int N = 100000;
for (int iter = 0; iter < 10; iter++)
{
    var stopwatch = Stopwatch.StartNew();
    int counter = 0;
    for (int i = 1; i <= N; i++)
        if (N % i == 0)
            counter++;
    stopwatch.Stop();
    var elapsedMs = stopwatch.Elapsed.TotalMilliseconds;
    Console.WriteLine(elapsedMs + " ms");
}
```

Вот типичный результат:

```
0.410468973641887 ms
0.475654133074913 ms
0.531752876344543 ms
0.308148026410656 ms
0.364641831252615 ms
0.460246731754378 ms
0.346864060498149 ms
0.308148026410656 ms
0.371752939554394 ms
0.274567792763341 ms
```

Как видите, дисперсия высока: разброс значений от 0,27 до 0,53 мс. Бенчмарк непродолжительный, поэтому случайный шум значительно влияет на измерения и каждый раз мы получаем новую случайную ошибку. Работать с такими измерениями сложно. Если выполнить какую-то оптимизацию и запустить бенчмарк еще раз, можно не увидеть разницу, потому что значения изначальных замеров могут различаться.

## Бенчмарк получше

Повторим измеренный код 3000 раз! Чтобы получить реальное время, нужно разделить полученное время на 3000.

```
const int N = 100000;
const int Invocations = 3000;
for (int iter = 0; iter < 10; iter++)
{
    var stopwatch = Stopwatch.StartNew();
    for (int rep = 0; rep < Invocations; rep++)
    {
        int counter = 0;
        for (int i = 1; i <= N; i++)
            if (N % i == 0)
                counter++;
    }
    stopwatch.Stop();
    var elapsedMs = stopwatch.Elapsed.TotalMilliseconds
        / Invocations;
    Console.WriteLine(elapsedMs + " ms");
}
```

Результат:

```
0.356982772550016 ms
0.358534890455352 ms
0.358426564572221 ms
0.356142476585688 ms
0.358213231323168 ms
0.356969735518129 ms
0.356878397282608 ms
0.357596382184145 ms
0.358787255787751 ms
0.359197546588624 ms
```

Теперь все выглядит куда более стабильно! Наш результат — 0,356–0,359 мс!

### СОВЕТ

Делайте много вызовов метода.

Иногда трудно решить, сколько вызовов нужно сделать. Их должно быть как минимум достаточно для предотвращения известных вам проблем. Общая рекомендация: при микробенчмаркинге повторяйте измеряемый код как минимум 1 с. Если вы торопитесь, во многих случаях приемлемое время — 100 мс. Работая с циклом 10 мс, вы легко можете ошибиться, потому что точность бенчмарка низкая, а разброс замеров высок.

Теперь мы знаем, что дополнительный цикл помогает стабилизировать результаты. Однако подобные изменения в исходном коде могут добавить нам проблем. В следующем разделе мы обсудим эти проблемы и способы их решения.

## Накладные расходы на инфраструктуру

Как видите, бенчмарк — это не просто код, который вы хотите измерить. У него есть инфраструктура — дополнительный код, помогающий правильно измерять время и получать надежные результаты. Однако у этой инфраструктуры есть накладные расходы: любые изменения в программе могут повлиять на измерения. Рассмотрим еще один пример, иллюстрирующий проблему.

### Плохой бенчмарк

Мы хотим измерить преобразование числа `0.0` из `double` в `int` с помощью `Convert.ToInt32`. Нам известно, что такой микробенчмарк должен быть обернут в цикл, потому что время конвертации между типами меньше разрешения `Stopwatch`. Приступим:

```
var stopwatch = Stopwatch.StartNew();
for (int i = 0; i < 100000001; i++)
    Convert.ToInt32(0.0);
stopwatch.Stop();
Console.WriteLine(stopwatch.ElapsedMilliseconds);
```

Здесь появляется эффект наблюдателя (мы обсудили его в главе 1): для подобных микроопераций необходим цикл, но он увеличивает общее время работы. Мы измеряем не только нужную операцию — мы измеряем весь цикл. Существует много сложных случаев, когда наличие цикла может повлиять на производительность самым неожиданным образом (см. подробнее в главе 7). В простых случаях всегда следует помнить, что инфраструктура бенчмарка (это весь код, который вы пишете для выполнения измерений) всегда добавляет какие-то ограничения и, возможно, еще как-то влияет на производительность.

### Бенчмарк получше

Один из способов улучшить результат — просто измерить инфраструктуру бенчмаркинга (в нашем случае цикл) для «пустого» кода (так называемая холостая итерация) и вычесть «пустые» измерения из целевых. Можно написать что-то подобное:

```
var stopwatchOverhead = Stopwatch.StartNew();
for (int i = 0; i < 100000001; i++)
{
}
```

```

stopwatchOverhead.Stop();
var stopwatchTarget = Stopwatch.StartNew();
for (int i = 0; i < 100000001; i++)
    Convert.ToInt32(0.0);
stopwatchTarget.Stop();
var resultOverhead =
    stopwatchTarget.ElapsedMilliseconds -
    stopwatchOverhead.ElapsedMilliseconds
Console.WriteLine(resultOverhead);

```

Пример результатов для RyuJIT-x64 на .NET Framework 4.6 приведен в табл. 2.1.

**Таблица 2.1.** Пустой цикл против цикла с ToInt32() Call

Замер	Время
Накладные расходы	≈ 34 мс
Целевой метод	≈ 295 мс
Результат	≈ 261 мс

Как видите, накладные расходы занимают более 10 % от целевых измерений. Конечно, это примитивная реализация, правильная оценка накладных расходов в более сложных бенчмарках может потребовать больших усилий.

## СОВЕТ

Всегда оценивайте накладные расходы на инфраструктуру.

Помните о том, что эффект наблюдателя есть всегда. Любая логика измерения времени может влиять на производительность кода. В некоторых случаях этими ограничениями можно пренебречь, но иногда они имеют значение. В любом случае довольно полезно оценивать ту часть общего времени измерения, которую вы тратите на накладные расходы.

Теперь мы знаем, как получить честные повторяемые результаты, не включающие в себя накладные расходы. В следующем разделе обсудим другую важную проблему, из-за которой распределения может быть сложно анализировать.

## Неравноценные итерации

Жизнь перформанс-инженеров была бы проще, если бы у каждого метода были фиксированные метрики производительности. К сожалению, производительность метода может зависеть не только от окружения, но и от состояния программы

в данный момент. Когда вы повторяете метод много раз, убедитесь в том, что каждый вызов метода потребляет одинаковое количество ресурсов и не имеет побочных эффектов. Иначе невозможно будет корректно агрегировать замеры.

## Плохой бенчмарк

Допустим, мы хотим измерить производительность `List.Add`. Напишем следующий бенчмарк:

```
void Measure(int n)
{
    var list = new List<int>();
    var stopwatch = Stopwatch.StartNew();
    for (int i = 0; i < n; i++)
        list.Add(0);
    stopwatch.Stop();
    Console.WriteLine("Capacity: " + list.Capacity + ", Time = ");
    Console.WriteLine("{0:0.00} ns",
        stopwatch.ElapsedMilliseconds * 1000000.0 / n);
}
```

Он добавляет элемент в `list` `n` раз и выдает общее время работы и итоговую емкость `list` (`capacity`). Обычно, когда мы выполняем много итераций, нам неважно, сколько конкретно, — это просто должно быть довольно большое количество. Поэтому запустим этот метод для `n = 16 777 216` и `n = 16 777 217`:

```
Measure(16777216);
Measure(16777217);
```

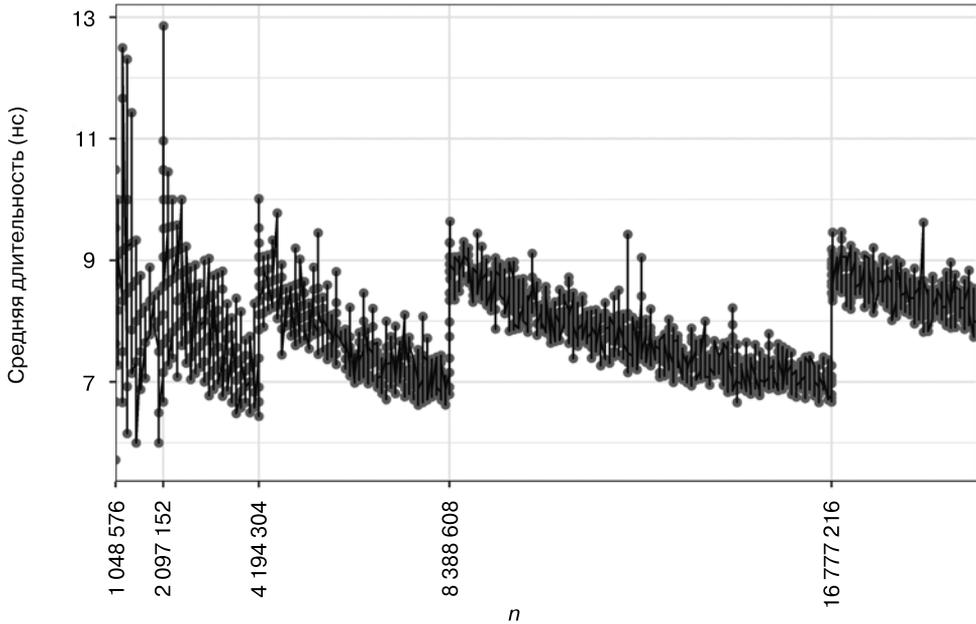
Пример возможных результатов приведен в табл. 2.2.

**Таблица 2.2.** Производительность `List.Add`

n	Емкость	Среднее время
16 777 216	16 777 216	~ 6,62 нс
16 777 217	33 554 432	~ 8,87 нс

Как такое возможно? Почему мы наблюдаем значительную разницу между результатами? Ответ прост: у метода `Add` есть два варианта внутренней логики. В первом, `list.Capacity > list.Count`, добавление нового элемента не очень затратно, потому что для него уже зарезервирована память. Во втором варианте `list.Capacity == list.Count`, поэтому приходится менять размер внутреннего массива, что занимает много времени.

Значение 16 777 216 — не случайное число, это  $2^{24}$ . Подобный эффект наблюдается у всех степеней двойки. На рис. 2.3 вы видите график с несколькими результатами Measure для разных значений  $n$ .



**Рис. 2.3.** Средняя длительность List.Add в зависимости от количества итераций

Вот некоторые подробности реализации List<T> с комментариями:

```
public void Add(T item)
{
    if (size == items.Length)
        EnsureCapacity(size + 1); // Здесь можно изменить размер списка
    items[size++] = item;
    version++;
}

private void EnsureCapacity(int min)
{
    if (items.Length < min)
    {
        int newCapacity = items.Length == 0
            ? defaultCapacity : items.Length * 2;
        if ((uint)newCapacity > Array.MaxLength)
```

```

        newCapacity = Array.MaxLength;
        if (newCapacity < min)
            newCapacity = min;
        Capacity = newCapacity; // Вызов метода, задающего значение емкости
    }
}

public int Capacity
{
    get { return items.Length; }
    set
    {
        if (value != items.Length)
        {
            if (value > 0)
            {
                // У установки нового значения емкости
                // есть побочный эффект: она может создать
                // новый внутренний массив
                T[] newItems = new T[value];
                if (size > 0)
                    // Копирование объектов в новый массив
                    Array.Copy(items, 0, newItems, 0, size);
                items = newItems;
            }
            else
            {
                items = emptyArray;
            }
        }
    }
}
}

```

Таким образом, производительность метода `Add` зависит от характеристик `Count` и `Capacity` текущего списка. Было бы неправильно высчитывать среднее время разных вызовов к `Add` — основная их часть будет выполняться очень быстро, а некоторые вызовы будут работать очень медленно.

## Бенчмарк лучше

Существует несколько возможных стратегий для решения этой проблемы, например:

- измерить пару `Add/Remove` вместе. В этом случае каждая итерация не будет изменять состояние `list` и не даст побочного эффекта. Это имеет смысл, когда вы начинаете и заканчиваете пустым списком, — такой бенчмарк позволяет оценить временные затраты на каждый элемент, который необходимо добавить или убрать;

- заранее выделить список с большой емкостью (`new List<int>(MaxCapacity)`). При этом нужно убедиться, что общее количество добавляемых элементов не превысит этой емкости. В этом случае все вызовы `Add` будут одинаково быстрыми.

## СОВЕТ

Измеряйте методы, которые характеризуются стабильным состоянием.

В общем случае важнейшим вопросом является не «*Как это измерить?*», а «*Почему мы хотим это измерить?*». Лучшая стратегия всегда зависит от того, чего мы хотим достигнуть.

Рекомендую проверять, зависит ли усредненный результат бенчмарка по всем итерациям от количества этих итераций. Если вы запускаете бенчмарк  $N$  раз, попробуйте также сделать  $2*N$ ,  $5*N$  или  $12.3456*N$  итераций. Убедитесь, что между полученными распределениями замеров нет значительной разницы.

Мы закончили знакомиться с наиболее распространенными ошибками бенчмаркинга, которые разработчики допускают вне зависимости от используемого языка и среды исполнения. Теперь пришло время узнать о некоторых проблемах, специфичных именно для платформы .NET.

## Подводные камни, специфичные для .NET

.NET — прекрасная платформа. У любой среды исполнения .NET есть множество прекрасных оптимизаций, ускоряющих ваши приложения. Если вы хотите написать очень быструю программу, эти оптимизации — ваши лучшие друзья. Если же вы хотите написать надежный бенчмарк, то они — ваши заклятые враги. Среда исполнения .NET не понимает, что вы хотите измерить производительность, — она пытается выполнять программу как можно быстрее.

В следующих разделах мы узнаем о различных оптимизациях среды исполнения, которые могут испортить измерения. Начнем с проблемы, которая влияет на циклы в бенчмарках.

### Развертывание циклов

Мы уже знаем, что очень быстрые методы следует заворачивать в циклы, чтобы корректно измерить время их работы. Известно ли вам, что происходит с подобными циклами во время компиляции?

Рассмотрим следующий простой цикл:

```
for (int i = 0; i < 10000; i++)
    Foo();
```

Если мы скомпилируем и запустим его в режиме релиза и посмотрим на полученный ассемблерный код для LegacyJIT-x86<sup>1</sup>, получится примерно так:

```
LOOP:
call dword ptr ds:[5B0884h] ; Foo();
inc esi                    ; i++
cmp esi,2710h              ; if (i < 10000)
jl LOOP                    ; Go to LOOP
```

Этот код выглядит довольно очевидным. Теперь посмотрим на код сборки для LegacyJIT-x64:

```
LOOP:
call 00007FFC39DB0FA8      ; Foo();
call 00007FFC39DB0FA8      ; Foo();
call 00007FFC39DB0FA8      ; Foo();
call 00007FFC39DB0FA8      ; Foo();
add ebx,4                  ; i += 4
cmp ebx,2710h              ; if (i < 10000)
jl 00007FFC39DB4787        ; Go to LOOP
```

Что здесь произошло? Наш цикл развернули! LegacyJIT-x64 выполнил развертывание цикла, и теперь код выглядит следующим образом:

```
for (int i = 0; i < 10000; i += 4)
{
    Foo();
    Foo();
    Foo();
    Foo();
}
```

О разных сложных оптимизациях JIT подробнее рассказывается в главе 7. Сейчас же вам нужно знать, что контролировать то, какие циклы будут развернуты, невозможно. В .NET Framework 4.6, LegacyJIT-x86 и RyuJIT-x64 не умеют применять такую оптимизацию. Таким навыком обладает только LegacyJIT-x64. Но он может развернуть цикл, только если количество итераций известно заранее и делится

<sup>1</sup> Не переживайте, если ничего не знаете о LegacyJIT-x86 и LegacyJIT-x64, в следующей главе мы обсудим разные компиляторы JIT. А сейчас вам следует знать, что мы говорим о .NET Framework для Windows и сравниваем версии x86 и x64 одной и той же программы. В современных версиях .NET Framework вы обычно работаете с RyuJIT для x64, но использование LegacyJIT тоже распространено для x86-приложений.

на 2, 3 или 4 (LegacyJIT-x64 старается выбрать максимальный делитель). Однако использовать специальные знания об оптимизации компилятора JIT — не самая удачная идея: все может измениться в любой момент. Оптимальное решение — хранить количество итераций в дополнительном поле, чтобы компилятор JIT не мог применить оптимизацию.

Действительно ли об этом нужно беспокоиться? Давайте проверим!

## Плохой бенчмарк

Допустим, мы хотим узнать, сколько времени нужно, чтобы выполнить пустой цикл с 1 000 000 001 и 1 000 000 002 итерациями. Это очередной абсолютно бессмысленный эксперимент, но в то же время это минимальный вариант воспроизведения обсуждаемой нами проблемы (почему-то многие разработчики любят измерять пустые циклы):

```
var stopwatch1 = Stopwatch.StartNew();
for (int i = 0; i < 1000000001; i++)
{
}
stopwatch1.Stop();
```

```
var stopwatch2 = Stopwatch.StartNew();
for (int i = 0; i < 1000000002; i++)
{
}
stopwatch2.Stop();
```

```
Console.WriteLine(stopwatch1.ElapsedMilliseconds + " vs. " +
    stopwatch2.ElapsedMilliseconds);
```

Пример приблизительных результатов для LegacyJIT-x86 и LegacyJIT-x64 приведен в табл. 2.3.

**Таблица 2.3.** Результаты для пустых циклов с константами

Количество итераций	LegacyJIT-x86	LegacyJIT-x64
1 000 000 001	~ 360 мс	~ 360 мс
1 000 000 002	~ 360 мс	~ 120 мс

Как такое возможно? Интереснее всего именно то, почему на LegacyJIT-x64 1 000 000 002 итерации производятся в три раза быстрее, чем 1 000 000 001. Все дело в разворачивании: 1 000 000 001 не делится на 2, 3 и 4, поэтому в данном случае LegacyJIT-x64 не может произвести разворачивание. Но второй цикл с 1 000 000 002 итерациями развернуть возможно, потому что это число

делится на 3! Оно делится и на 2, но компилятор JIT выбирает максимальный делитель для развертывания цикла. Взглянем на исходный код на ассемблере для обоих циклов:

```
; 100000001 iterations
LOOP:
inc    eax        ; i++
cmp    eax,3B9ACA01h ; if (i < 100000001)
j1     LOOP      ; Go to LOOP

; 100000002 iterations
LOOP:
add    eax,3      ; i += 3
cmp    eax,3B9ACA02h ; if (i < 100000002)
j1     LOOP      ; Go to LOOP
```

Во втором случае мы видим инструкцию `add eax, 3`, увеличивающую счетчик на 3: это развертывания цикла в действии! Теперь становится очевидно, почему второй цикл работает в три раза быстрее.

## Бенчмарк получше

Мы можем перехитрить JIT и хранить количество итераций в отдельных полях. Будьте внимательны, это должны быть именно поля, а не константы!

```
private int N1 = 100000001, N2 = 100000002;

public void Measure()
{
    var stopwatch1 = Stopwatch.StartNew();
    for (int i = 0; i < N1; i++)
    {
    }
    stopwatch1.Stop();

    var stopwatch2 = Stopwatch.StartNew();
    for (int i = 0; i < N2; i++)
    {
    }
    stopwatch2.Stop();
}
```

В этом случае JIT-компилятор не сможет применить развертывание цикла, ведь ему неизвестно количество итераций. Кроме того, эти значения могут быть изменены кем-то в другом потоке, так что проводить подобную оптимизацию слишком рискованно. Теперь у нас одинаковые результаты для всех конфигураций (табл. 2.4).

**Таблица 2.4.** Результаты для пустых циклов с переменными

Количество итераций	LegacyJIT-x86	LegacyJIT-x64
1 000 000 001	~ 360 мс	~ 360 мс
1 000 000 002	~ 360 мс	~ 360 мс

Да, конфигурация LegacyJIT-x64/1000000002 не такая быстрая, как в первом случае. Но теперь это честное сравнение: здесь мы не стремимся к максимальной производительности, а пытаемся сравнить производительность двух фрагментов кода.

## СОВЕТ

Используйте в циклах переменные вместо констант.

Вы хотите сравнить две разные реализации алгоритма, но цикл — это просто способ получить осмысленный результат для очень быстрых операций, на самом деле он не является частью измеряемой логики. Конечно же, мы не хотим, чтобы количество итераций цикла влияло на усредненное время работы. Так что лучше сделать N1 и N2 переменными, а не константами. Если вы и дальше будете внимательно читать эту главу, то заметите, что мы продолжаем использовать в циклах константы. Делаем это только для упрощения и берем константы, которые не делятся на 2 или 3. (LegacyJIT-x64, ты не сможешь их развернуть!) Все эти примеры не являются настоящими бенчмарками — это только иллюстрации подводных камней бенчмаркинга. Поэтому для подобной демонстрации применять константы допустимо, однако лучше так не делать в настоящих бенчмарках.

Теперь мы знаем, как предотвратить развертывание циклов, но это не единственная оптимизация среды исполнения. В следующем разделе разберемся, как предотвратить удаление тела цикла.

## Удаление неисполняемого кода

Современные компиляторы очень умны. В большинстве случаев они даже умнее разработчиков, которые пытаются что-то измерить с помощью бенчмарка. В типичном бенчмарке частенько присутствуют вызовы методов, возвращаемое значение которых не используется, ведь в бенчмаркинге нам неважен результат их работы, важно только время этой работы. Если измеренный код не производит никаких наблюдаемых эффектов, компилятор может его выкинуть. Эта оптимизация называется удалением неисполняемого кода (dead code elimination, DCE). Рассмотрим пример, наглядно показывающий эту оптимизацию.

## Плохой бенчмарк

Найдем квадратные корни всех чисел от 0 до 100 000 000:

```
double x = 0;
for (int i = 0; i < 100000001; i++)
    Math.Sqrt(x);
```

Теперь измерим время этого кода. Мы знаем, что цикл может добавить накладных расходов, поэтому оценим их и вычтем накладные расходы из основных измерений:

```
double x = 0;

var stopwatch = Stopwatch.StartNew();
for (int i = 0; i < 100000001; i++)
    Math.Sqrt(x);
stopwatch.Stop();

var stopwatch2 = Stopwatch.StartNew();
for (int i = 0; i < 100000001; i++);
stopwatch2.Stop();

var target = stopwatch.ElapsedMilliseconds;
var overhead = stopwatch2.ElapsedMilliseconds;
var result = target - overhead;
Console.WriteLine("Target = " + target + "ms");
Console.WriteLine("Overhead = " + overhead + "ms");
Console.WriteLine("Result = " + result + "ms");
```

Пример результата (Windows, .NET Framework, RyuJIT-x64, режим релиза):

```
Target = 37ms
Overhead = 37ms
Result = 0ms
```

Ура, `Math.Sqrt` работает мгновенно! Мы можем исполнять `Math.Sqrt` сколько захотим без затрат производительности! Давайте запустим еще раз:

```
Target = 36ms
Overhead = 37ms
Result = -1ms
```

Ура, вызовы `Math.Sqrt` работают за отрицательное время! Если мы добавим побольше таких вызовов, то программа ускорится! Хотя... Не смущает ли вас такой результат? Взглянем на ассемблерный код нашего цикла:

```
; for (int i = 0; i < 100000001; i++)
; Math.Sqrt(x);
LOOP:
```

```
inc     eax     ; i++
cmp     eax,2710h ; if (i < 10000)
jl      LOOP   ; Go to LOOP
```

Ага! Компилятор JIT применил здесь волшебную оптимизацию! Вы могли заметить, что мы никак не используем результаты `Math.Sqrt`. Этот код может быть спокойно удален. Увы, данная оптимизация портит наш бенчмарк. В обоих случаях мы измеряем пустой цикл. Из-за естественного шума появляется вариативность в измерениях, поэтому получить отрицательный результат нормально — это просто означает, что одно измерение больше другого.

Но мы все еще хотим измерить затраты производительности на `Math.Sqrt`. Как же улучшить наш бенчмарк?

## Бенчмарк получше

Типичное обходное решение — каким-то образом использовать этот результат (давайте перепишем первую часть плохого бенчмарка):

```
double x = 0, y = 0;

var stopwatch = Stopwatch.StartNew();
for (int i = 0; i < 100000001; i++)
    y += Math.Sqrt(x);
stopwatch.Stop();
Console.WriteLine(y);
```

Теперь вызовы к `Math.Sqrt` нельзя удалить, потому что нам нужен их результат, чтобы вывести сумму квадратных корней. Конечно, мы добавляем и небольшие накладные расходы из-за операции `y +=`. Это часть затрат на инфраструктуру бенчмаркинга. Проверим, как это работает:

```
Target = 327ms
Overhead = 37ms
Result = 290ms
```

Теперь `Result` — положительное число (290 мс), и в этом больше смысла.

## СОВЕТ

Всегда используйте результаты своих вычислений.

Современные компиляторы умны, но мы должны быть умнее! В наших бенчмарках не должно быть кода, который можно выбросить. Единственный способ добиться этого — каким-то образом использовать возвращаемые значения измеряемых методов. Roslyn и JIT не должны знать, что на самом деле эти результаты нам не нужны. Самый простой способ — собрать все вычисленные значения и сохранить

их в какое-нибудь поле. Если вы применяете локальную переменную, то значение этой переменной также должно быть как-то использовано после измерений (`Console.WriteLine` подойдет, если вас не волнует, что в результатах программы появляются лишние строчки).

Осторожно: любой код, предотвращающий удаление неиспользуемого кода, — тоже часть инфраструктуры бенчмарка и увеличивает общее время. Вы должны быть уверены в том, что это ограничение незначительно и не сильно повлияет на измерения. Представьте, что в результате у вас получается строка. Как ее использовать? Мы можем, например, добавить ее к другой строке следующим образом:

```
string StringOperation() { /* ... */ }

// Бенчмарк
var stopwatch = Stopwatch.StartNew();
string acc = "";
for (int i = 0; i < N; i++)
    acc += StringOperation();
stopwatch.Stop();
```

Стоит ли так хранить результаты бенчмарка? Нет, потому что накладные расходы на конкатенацию строк очень велики. Более того, они зависят от количества итераций: каждая следующая итерация занимает больше времени, чем предыдущая, потому что растет длина строки `acc`. Поэтому с каждой итерацией возрастает количество выделяемой памяти и увеличивается количество символов для копирования. Как же улучшить этот бенчмарк? В качестве одного из вариантов мы можем суммировать не сами строки, а их длины:

```
string StringOperation() { /* ... */ }

// Бенчмарк
var stopwatch = Stopwatch.StartNew();
int acc = 0;
for (int i = 0; i < N; i++)
    acc += StringOperation().Length;
stopwatch.Stop();
```

Так гораздо лучше, потому что сложение целых чисел и получение длины строки обычно работает гораздо быстрее, чем любые операции со строками. В большинстве случаев значительных накладных расходов при этом не будет, а данный прием идеально решает задачу предотвращения удаления ненужного кода: компилятор не может выкинуть вызовы `StringOperation()`, потому что мы используем их результат!

Удаление ненужного кода — не единственная оптимизация, которая может удалить часть логики из программы. В следующем разделе обсудим еще одну замечательную оптимизацию, которая может упростить код программы.

## Свертка констант

Допустим, мы хотим измерить следующую операцию умножения:

```
int Mul() => 2 * 3;
```

Выглядит ли это как метод, который мы действительно можем использовать для бенчмаркинга умножения? Чтобы узнать, скомпилируем его в режиме релиза и посмотрим на IL-код:

```
ldc.i4.6
ret
```

`ldc.i4.6` означает «Положить 6 на стек как `int32`», `ret` — «Взять значение из стека и вернуть его из метода».

Здесь вы видите результат умножения (6), жестко закодированный внутри программы. Компилятор C# достаточно умен, чтобы заранее высчитать такие выражения во время компиляции. Название этой оптимизации — свертка констант (`constant folding`). Она работает для всех констант, включая строки (например, `"a" + "b"` будет скомпилировано в `"ab"`). Эта оптимизация хороша с точки зрения производительности, но не очень хороша с точки зрения бенчмаркинга. Если мы хотим измерить производительность арифметических операций, мы должны быть уверены в том, что компилятор не сможет заранее выполнить никаких вычислений. Для этого мы можем хранить аргументы в отдельных полях:

```
private int a = 2, b = 3;
public int Mul() => a * b;
```

После применения данного рефакторинга в IL-коде появится команда `mul`:

```
ldarg.0
ldfld    a
ldarg.0
ldfld    b
mul
ret
```

`ldarg.0` означает «Положить нулевой аргумент на стек». Нулевым аргументом является текущий объект (`this`). Следующая команда `ldfld <field>` означает «Взять объект из стека, получить заданное поле и положить значение поля обратно на стек». `mul` означает «Перемножить два верхних значения из стека». Таким образом, в этом коде мы кладем на стек `this.a`, затем `this.b`, а потом берем из стека два последних значения, перемножаем их, кладем результат обратно на стек и возвращаем его из функции.

Свертка констант может казаться простой и предсказуемой оптимизацией, но это не всегда так. Рассмотрим еще один интересный пример.

## Плохой бенчмарк

Еще одна загадка: какой метод быстрее на RyuJIT-x64 (.NET Framework 4.6 без обновлений)?

```
public double Sqrt13()
{
    return
        Math.Sqrt(1) + Math.Sqrt(2) + Math.Sqrt(3) +
        Math.Sqrt(4) + Math.Sqrt(5) + Math.Sqrt(6) +
        Math.Sqrt(7) + Math.Sqrt(8) + Math.Sqrt(9) +
        Math.Sqrt(10) + Math.Sqrt(11) + Math.Sqrt(12) +
        Math.Sqrt(13);
}
public double Sqrt14()
{
    return
        Math.Sqrt(1) + Math.Sqrt(2) + Math.Sqrt(3)
        + Math.Sqrt(4) + Math.Sqrt(5) + Math.Sqrt(6)
        + Math.Sqrt(7) + Math.Sqrt(8) + Math.Sqrt(9)
        + Math.Sqrt(10) + Math.Sqrt(11) + Math.Sqrt(12)
        + Math.Sqrt(13) + Math.Sqrt(14);
}
```

Если мы внимательно измерим каждый метод, результат получится похожим на то, что показано в табл. 2.5.

**Таблица 2.5.** Результаты Sqrt13 и Sqrt14 на RyuJIT-x64

Метод	Время
Sqrt13	~ 91 нс
Sqrt14	0 нс

Выглядит очень странно. Мы добавили дополнительную операцию с вычислением квадратного корня, и она улучшила производительность кода. И не просто улучшила, а сделала его выполнение мгновенным! Разве такое возможно? Пора посмотреть на IL-код каждого из методов:

```
; Sqrt13
vsqrtsd    xmm0,xmm0,mmword ptr [7FF94F9E4D28h]
vsqrtsd    xmm1,xmm0,mmword ptr [7FF94F9E4D30h]
vaddsd     xmm0,xmm0,xmm1
vsqrtsd    xmm1,xmm0,mmword ptr [7FF94F9E4D38h]
vaddsd     xmm0,xmm0,xmm1
vsqrtsd    xmm1,xmm0,mmword ptr [7FF94F9E4D40h]
vaddsd     xmm0,xmm0,xmm1
vsqrtsd    xmm1,xmm0,mmword ptr [7FF94F9E4D48h]
```

```

vaddsd    xmm0,xmm0,xmm1
vsqrtsd  xmm1,xmm0,mmword ptr [7FF94F9E4D50h]
vaddsd    xmm0,xmm0,xmm1
vsqrtsd  xmm1,xmm0,mmword ptr [7FF94F9E4D58h]
vaddsd    xmm0,xmm0,xmm1
vsqrtsd  xmm1,xmm0,mmword ptr [7FF94F9E4D60h]
vaddsd    xmm0,xmm0,xmm1
vsqrtsd  xmm1,xmm0,mmword ptr [7FF94F9E4D68h]
vaddsd    xmm0,xmm0,xmm1
vsqrtsd  xmm1,xmm0,mmword ptr [7FF94F9E4D70h]
vaddsd    xmm0,xmm0,xmm1
vsqrtsd  xmm1,xmm0,mmword ptr [7FF94F9E4D78h]
vaddsd    xmm0,xmm0,xmm1
vsqrtsd  xmm1,xmm0,mmword ptr [7FF94F9E4D80h]
vaddsd    xmm0,xmm0,xmm1
vsqrtsd  xmm1,xmm0,mmword ptr [7FF94F9E4D88h]
vaddsd    xmm0,xmm0,xmm1
ret

; Sqrt14
vmovsd    xmm0,qword ptr [7FF94F9C4C80h]
ret

```

`vsqrtsd` вычисляет квадратный корень значения с плавающей запятой, `vaddsd` складывает значения с плавающей запятой, а `vmovsd` перемещает значение с плавающей запятой. Таким образом, `Sqrt13` каждый раз высчитывает всю сумму, а `Sqrt14` просто выдает константу.

Aga! Кажется, RyuJIT-x64 применил к `Sqrt14` оптимизацию свертки констант. Но почему этого не происходит с `Sqrt13`?

Если бы вы сами были JIT-компилятором, то жилось бы вам очень непросто. Вы бы знали столько потрясающих оптимизаций, но у вас было бы так мало времени, чтобы все их применить (никто не хочет возникновения проблем с производительностью из-за JIT-компиляции). Поэтому нужен компромисс между временем JIT-компиляции и количеством оптимизаций. Как решить, когда и какую оптимизацию применять? У RyuJIT-x64 есть набор эвристических алгоритмов, помогающих принимать подобные решения. В частности, если мы работаем с небольшим методом, можно пропустить некоторые оптимизации, потому что, скорее всего, метод и так будет достаточно быстрым. Если метод довольно большой, мы можем провести больше времени на стадии JIT-компиляции, чтобы улучшить скорость исполнения метода. В нашем примере добавление `Math.Sqrt(14)` — момент достижения эвристического порога: в этой точке RyuJIT решает применить дополнительную оптимизацию.

О подобных вещах стоит знать, но использовать эти знания в коде готового приложения — не лучшая идея. Не стоит пытаться улучшить производительность

приложения, добавляя дополнительные вызовы `Math.Sqrt` в разных местах. Детали реализации JIT-компилятора можно изменить в любой момент. К примеру, вышеописанная проблема со сверткой констант была обсуждена (<https://github.com/dotnet/coreclr/issues/978>) и исправлена (<https://github.com/dotnet/coreclr/issues/987>), поэтому ее нельзя воспроизвести на .NET Framework 4.7+ (и `Sqrt13`, и `Sqrt14` будут работать за нулевое время из-за свертки констант).

Давайте улучшим наш бенчмарк так, чтобы он работал корректно вне зависимости от версии .NET Framework.

## Бенчмарк получше

Лучший способ избежать свертки констант довольно прост — не использовать константы. Можно переписать наш код, добавив дополнительные поля для хранения используемых значений:

```
public double x1 = 1, x2 = 2, x3 = 3, x4 = 4, x5 = 5, x6 = 6,
              x7 = 7, x8 = 8, x9 = 9, x10 = 10, x11 = 11,
              x12 = 12, x13 = 13, x14 = 14;
public double Sqrt14()
{
    return
        Math.Sqrt(x1) + Math.Sqrt(x2) + Math.Sqrt(x3) +
        Math.Sqrt(x4) + Math.Sqrt(x5) + Math.Sqrt(x6) +
        Math.Sqrt(x7) + Math.Sqrt(x8) + Math.Sqrt(x9) +
        Math.Sqrt(x10) + Math.Sqrt(x11) + Math.Sqrt(x12) +
        Math.Sqrt(x13) + Math.Sqrt(x14);
}
```

Теперь RyuJIT не сможет применить свертку констант, потому что в теле метода больше нет никаких констант.

### СОВЕТ

Не используйте константы в своих бенчмарках.

Все просто: если у вас нет констант, свертку констант применить нельзя. Если вы хотите передать нужным методам какие-то аргументы, лучше заведите для них отдельные поля. Данный подход еще и улучшит дизайн ваших бенчмарков. Обычно при разных входных данных получаются разные замеры времени. Если вы используете параметры вместо жестко закодированных значений, в будущем станет проще проверять другие значения ввода.

У .NET много способов удаления различных частей кода. В следующем разделе мы обсудим еще один из них.

## Удаление проверки границ

.NET — прекрасная платформа, которая позволяет писать безопасный код. Например, если вы попытаетесь получить элемент массива `A` с несуществующим индексом (например, `A[-1]`), среда исполнения выбросит `IndexOutOfRangeException`. С одной стороны, это хорошо: среда помогает нам не писать неверный код, поскольку невозможно взять значение с не принадлежащего массиву участка памяти. С другой стороны, такие проверки занимают некоторое время и ухудшают производительность кода.

К счастью, JIT-компилятор достаточно умен, чтобы иногда не применять проверку границ. Эта оптимизация называется удалением проверки границ (`bound check elimination`, BCE). Ключевое слово здесь — «иногда». Мы не можем контролировать, когда применяется BCE. Подобные оптимизации полезны для производительности, но мешают тем, кто пишет бенчмарки.

### Плохой бенчмарк

Допустим, у нас есть большой массив постоянной длины и мы хотим увеличить каждый из его элементов на единицу. Как правильно написать цикл для такого бенчмарка? Можно задать в качестве верхнего предела цикла константу или длину массива. В обоих случаях получится одно и то же количество итераций, между результатами также не будет разницы. Но будет ли разница в производительности?

```
const int N = 1000001;
int[] a = new int[N];

var stopwatch1 = Stopwatch.StartNew();
for (int iteration = 0; iteration < 101; iteration++)
    for (int i = 0; i < N; i++)
        a[i]++;
stopwatch1.Stop();

var stopwatch2 = Stopwatch.StartNew();
for (int iteration = 0; iteration < 101; iteration++)
    for (int i = 0; i < a.Length; i++)
        a[i]++;
stopwatch2.Stop();

Console.WriteLine(stopwatch1.ElapsedMilliseconds + " vs. " +
    stopwatch2.ElapsedMilliseconds);
```

Пример результатов (Windows, .NET Framework 4.6, RyuJIT-x64) приведен в табл. 2.6.

**Таблица 2.6.** Производительность цикла модификации массива с разными значениями верхнего предела

Эксперимент	Верхний предел массива	Время метода
1	N	~ 175 мс
2	a.Length	~ 65 мс

Причиной разницы в производительности является удаление проверки границ. JIT-компилятор может пропускать проверку границ, когда верхним пределом является `a.Length`, но не может делать этого, когда верхний предел — константа. Активно использовать подобные плюсы JIT-компилятора во время бенчмаркинга не рекомендуется: они зависят от среды исполнения и ее версии. Но нам следует об этом знать и разрабатывать бенчмарки таким образом, чтобы результаты не были испорчены различными решениями JIT-компилятора по поводу удаления проверки границ.

## Бенчмарк получше

Основное правило борьбы с удалением проверки границ: используйте единообразный стиль циклов для всех своих бенчмарков. Если применяете константу в одном цикле, делайте то же самое везде (результаты для одного и того же окружения приведены в табл. 2.7):

```
const int N = 1000001;
int[] a = new int[N];

var stopwatch1 = Stopwatch.StartNew();
for (int iteration = 0; iteration < 101; iteration++)
    for (int i = 0; i < N; i++)
        a[i]++;
stopwatch1.Stop();

var stopwatch2 = Stopwatch.StartNew();
for (int iteration = 0; iteration < 101; iteration++)
    for (int i = 0; i < N; i++)
        a[i]++;
stopwatch2.Stop();

Console.WriteLine(stopwatch1.ElapsedMilliseconds + " vs. " +
    stopwatch2.ElapsedMilliseconds);
```

**Таблица 2.7.** Производительность цикла модификации массива с одинаковыми стилями верхнего предела

Эксперимент	Верхний предел массива	Время метода
1	N	~ 175 мс
2	N	~ 175 мс

Теперь результаты выглядят намного лучше.

## СОВЕТ

Используйте единообразный стиль циклов.

Если вы хотите использовать результаты бенчмарка для оптимизации своего приложения, применяйте тот же стиль цикла, что и в коде программы. Конечно, приведенный здесь бенчмарк является академическим, настоящие бенчмарки гораздо сложнее и могут включать в себя множество обращений к индексатору массива. Всегда нужно помнить о том, что проверка границ влечет за собой дополнительные затраты производительности, но иногда компилятор JIT может от нее избавиться.

В следующем разделе мы узнаем, как .NET может удалять вызовы метода.

## Инлайнинг

Если вы стремитесь делать свой код удобным для чтения и поддержки, а также красивым, то наверняка не любите слишком большие методы. Книжки о хорошем коде учат нас, что методы должны быть небольшими и каждый из них должен решать собственную небольшую задачу. Если в методе 100 строк, обычно есть возможность ввести дополнительные небольшие методы, отвечающие за небольшие подзадачи. Кто-то может сказать: «Дополнительные методы добавляют ограничения производительности из-за дополнительных вызовов». На это я могу ответить, что чаще всего вас это не должно беспокоить. Это должно беспокоить JIT-компилятор. Просто пишите хороший читаемый код и оставьте грязную работу JIT-компилятору. К тому же отсутствие вызова не всегда полезно для производительности. Иногда, когда вы упрощаете огромный метод с помощью вынесения части логики во вспомогательные методы, JIT-компилятор может нормально оптимизировать упрощенный метод, что значительно улучшает производительность (накладные расходы на дополнительный вызов метода будут пренебрежимо малы по сравнению с полученными улучшениями).

Но это лишь общая рекомендация. JIT-компилятор не всегда так умен, как нам бы хотелось. Полезно знать, что вы можете запретить инлайнинг для метода, но при этом вы не можете заставить JIT-компилятор заинлайнить произвольный метод.

Рассмотрим следующий метод:

```
void Run1()
{
    for (int i = 0; i < N; i++)
    {
        // много сложной логики
    }
}
```

Если мы много раз выполняем много сложной логики, имеет смысл вынести ее в отдельный метод. А цикл и все связанное с бенчмаркингом оставим в основном методе:

```
void Logic() => /* много сложной логики */
void Run2()
{
    for (int i = 0; i < N; i++)
        Logic();
}
```

Этот код выглядит идеально: у каждого уровня абстракции есть собственный метод. Стив Макконнелл<sup>1</sup> нами гордился бы! Но подобное перепроектирование кода может повлиять на производительность. Это особенно важно в случае микро-бенчмаркинга.

## Плохой бенчмарк

В следующем примере у нас будет два метода, А и В. Оба имеют один аргумент `x` типа `double`. Метод А просто считает произведение `x * x`. Метод В также вычисляет `x * x`, но для отрицательных аргументов выбрасывает `ArgumentOutOfRangeException`:

```
double A(double x)
{
    return x * x;
}

double B(double x)
{
    if (x < 0)
        throw new ArgumentOutOfRangeException("x");
    return x * x;
}

public void Measurements()
{
    double sum = 0;

    var stopwatchA = Stopwatch.StartNew();
    for (int i = 0; i < 1000000001; i++)
        sum += A(i);
    stopwatchA.Stop();

    var stopwatchB = Stopwatch.StartNew();
    for (int i = 0; i < 1000000001; i++)
```

<sup>1</sup> Автор книги «Совершенный код» (Питер, 2019).

```

    sum += B(i);
    stopwatchB.Stop();

    Console.WriteLine(
        stopwatchA.ElapsedMilliseconds + " vs. " +
        stopwatchB.ElapsedMilliseconds);
}

```

Проверьте, как это работает у вас на компьютере. Мои результаты (Windows, .NET Framework 4.6, RyuJIT-х64) находятся в табл. 2.8.

**Таблица 2.8.** Производительность разных стратегий обработки неверных значений

Метод	Время
A	~ 1335 нс
B	~ 2466 нс

Почему метод В работает так медленно? В нем только одна дополнительная проверка, но разница между результатами А и В выглядит слишком большой. Причина проста: метод А был заинлайнен, потому что он небольшой и простой. JIT-компилятор решил не инлайнить В, потому что он не такой уж и простой<sup>1</sup>. Таким образом, мы измеряем заинлайненный метод А (без накладных расходов на вызов) и незаинлайненный метод В (с накладными расходами на вызов), что нечестно. Требуем справедливости!

## Бенчмарк получше

Возможное решение заключается в том, чтобы запретить инлайнинг с помощью атрибута [MethodImpl]:

```

[MethodImpl(MethodImplOptions.NoInlining)]
double A(double x)
{
    return x * x;
}

[MethodImpl(MethodImplOptions.NoInlining)]
double B(double x)
{
    if (x < 0)
        throw new ArgumentOutOfRangeException("x");
    return x * x;
}

```

<sup>1</sup> Помните, что мы говорим только о .NET Framework 4.6. При использовании будущих версий .NET Framework или .NET Core вы увидите другие результаты.

Новые результаты:

Метод	Время
A	~ 2312 мс
B	~ 2469 мс

Теперь в обоих случаях время работы каждого из методов включает накладные расходы на вызов этих методов. Разница между измерениями все еще наблюдается, потому что у B есть дополнительная логика, но она не так значительна.

### СОВЕТ

Контролируйте замещение в проверяемых методах.

Вы должны быть уверены в том, что ко всем проверяемым методам применяется одна стратегия инлайнинга. Поскольку невозможно заставить JIT-компилятор всегда инлайнить заданный метод (`MethodImplOptions.AggressiveInlining` — всего лишь рекомендация, JIT-компилятор может ее проигнорировать), лучше всегда отключать возможность инлайнинга. Одним из простейших способов сделать это является `[MethodImpl(MethodImplOptions.NoInlining)]` (JIT-компилятор не может его игнорировать).

Если вы не хотите все время писать `MethodImplOptions.NoInlining` и вам нужен более общий подход, пригодятся делегаты. Сейчас JIT-компиляторы не способны инлайнить делегаты<sup>1</sup>, поэтому вы можете обернуть все измеряемые методы в делегаты и использовать их в вашей инфраструктуре для совершения измерения.

У JIT-компилятора много умных оптимизаций, но применяет он их по-разному. Мы обсудим инлайнинг более подробно в главе 7.

В следующем разделе рассмотрим ситуацию, когда содержимое финальной сборки зависит от дополнительных условий.

## Условное JIT-компилирование

Обычно вы получаете идентичный ассемблерный код для одного и того же метода вне зависимости от того, как и когда его вызывают. Однако исполняемый код иногда влияет на то, как скомпилируются остальные методы. Из-за этого может быть опасно запускать несколько бенчмарков в одной программе. Проще всего объяснить это на примере.

<sup>1</sup> Утверждение верно для .NET Framework 4.7.1, .NET Core 2.0, Mono 5.6. Кто знает, насколько умным .NET станет в будущем.

## Плохой бенчмарк

Рассмотрим следующий код:

```
static string Measure1()
{
    double sum = 1, inc = 1;
    var stopwatch = Stopwatch.StartNew();
    for (int i = 0; i < 1000000001; i++)
        sum = sum + inc;
    return $"Result = {sum}, Time = {stopwatch.ElapsedMilliseconds}";
}
static string Measure2()
{
    double sum = 1, inc = 1;
    var stopwatch = Stopwatch.StartNew();
    for (int i = 0; i < 1000000001; i++)
        sum = sum + inc;
    return $"Result = {sum}, Time = {stopwatch.ElapsedMilliseconds}";
}
static void Main()
{
    Console.WriteLine(Measure1());
    Console.WriteLine(Measure2());
}
```

Здесь два идентичных метода, измеряющих суммирование переменных типа `double`. Каждый метод выдает финальное значение переменной `sum` и затраченное время. Исходный код выглядит кривовато, но хорошо воспроизводит один интересный эффект. Запустим эту программу в LegacyJIT-x86 (Windows, .NET Framework 4.6):

```
Result = 1000000002, Time = 3362
Result = 1000000002, Time = 1119
```

Вероятно, вы ожидали одного и того же результата для обоих методов, поскольку они идентичны. Однако между измерениями разница в три раза. Почему? Посмотрим на ассемблерный код тела цикла для каждого метода:

```
; Measure1
fld1
fadd     qword ptr [ebp-14h]
fstp    qword ptr [ebp-14h]

; Measure2
fld1
faddp   st(1),st
```

Оказывается, первый метод хранит значение `sum` на стеке, а второй — в FPU-регистрах. Для такого короткого цикла это очень важно, поэтому способ хранения локальных переменных оказывает огромное влияние на производительность. Но почему же у этих методов разные ассемблерные листинги?

У JIT-компилятора много различных эвристических правил, основанных на разных факторах. Один из таких факторов в LegacyJIT-x86 — количество точек вызова (call sites). На момент начала работы первого метода статический конструктор класса `Stopwatch` еще не был вызван. Поэтому JIT-компилятор был вынужден добавить несколько дополнительных ассемблерных инструкций, проверяющих, нужно ли вызывать этот статический конструктор. Этот вызов выполняется только один раз, но ассемблерные инструкции с проверкой будут внутри метода всегда. На момент запуска второго метода статический конструктор `Stopwatch` уже был выполнен. Поэтому дополнительная проверка не нужна, и описанные ассемблерные инструкции можно пропустить.

Эта проверка никак не влияет на производительность, но увеличивает количество точек вызова. Механизм для работы с FPU-регистрами в LegacyJIT-x86 использует количество точек вызова в качестве фактора выбора того, будет ли он размещать локальные переменные с плавающей точкой в реестрах или на стеке. Таким образом, получились разный исходный код на ассемблере и разная производительность.

Отсюда можно вынести два важных урока.

- Выполнение одного бенчмарка может повлиять на производительность других бенчмарков. Поэтому не рекомендуется запускать несколько измерений в одной программе, так как можно получить разные результаты в зависимости от порядка бенчмарков.
- Если вы уберете из методов класс `Stopwatch`, оба метода будут работать одинаково быстро. То есть мы замедлили первый метод, добавив код для измерений. Это еще один пример эффекта наблюдателя: добавив логику для измерений, мы начали измерять модифицированный код вместо изначального. Так что дополнительные вызовы методов класса `Stopwatch` могут легко испортить общую производительность в очень маленьких методах.

## Бенчмарк получше

Лучше запускать каждый бенчмарк в отдельной программе. Просто не смешивайте их — и вы сможете избежать довольно неприятных проблем.

Другой подход — убрать `Stopwatch` из тела метода:

```
[MethodImpl(MethodImplOptions.NoInlining)]
public static double Measure1()
{
    double sum = 1, inc = 1;
    for (int i = 0; i < 1000000001; i++)
        sum = sum + inc;
    return sum;
}
[MethodImpl(MethodImplOptions.NoInlining)]
public static double Measure2()
{
```

```
double sum = 1, inc = 1;
for (int i = 0; i < 1000000001; i++)
    sum = sum + inc;
return sum;
}
public static void Main()
{
    var stopwatch1 = Stopwatch.StartNew();
    Measure1();
    stopwatch1.Stop();
    var stopwatch2 = Stopwatch.StartNew();
    Measure2();
    stopwatch2.Stop();
    Console.WriteLine(stopwatch1.ElapsedMilliseconds + " vs. " +
        stopwatch2.ElapsedMilliseconds);
}
```

Результат:

1119 vs. 1117

Второй подход годится для этого конкретного случая, но в целом это не очень хорошее решение. Нельзя контролировать условное JIT-компилирование и угадать, когда оно испортит измерения.

## СОВЕТ

Используйте отдельный процесс для каждого проверяемого метода.

Если вы создадите отдельный процесс для каждого метода, то эти методы не смогут повлиять друг на друга. Да, сложно каждый раз выполнять это вручную, но это полезная практика, способная предотвратить множество проблем. Если вы не хотите думать о низкоуровневых особенностях JIT-компилятора, то лучше всегда запускать каждый бенчмарк отдельно. До сих пор не убедились в этом? Тогда прочтите следующий раздел, где рассматривается еще один пример, связанный с изоляцией бенчмарков.

## Диспетчеризация методов интерфейса

Условная компиляция — не единственная причина, по которой необходимо изолировать каждый бенчмарк в отдельном процессе. В большинстве случаев, если JIT-компилятор генерирует ассемблерный код для метода, впоследствии он не будет меняться. Однако существуют исключения<sup>1</sup>.

<sup>1</sup> Например, в .NET Core 2.x представлено многоуровневое компилирование. Если эта функция включена, JIT может быстро сгенерировать простой машинный код для первого вызова алгоритма. Если эта реализация оказывается медленной, а алгоритм — популярным (вы вызываете его много раз), JIT может обновить машинный код, сделав его лучше и быстрее.

Одно из таких исключений — диспетчеризация методов интерфейса. Когда вы вызываете метод интерфейса, среда исполнения должна выяснить тип объекта и найти соответствующую таблицу виртуальных методов. Для этого она генерирует метод-заглушку, вызываемый, когда вы пытаетесь обратиться к методу интерфейса. Заглушка зависит от текущего состояния программы и может быть регенерирована. Другими словами, временные затраты на вызов метода интерфейса могут быть неявно изменены в любой момент. Важно здесь то, что один бенчмарк может повлиять на результаты другого.

Рассмотрим пример.

## Плохой бенчмарк

Допустим, у нас есть простой интерфейс `IIncrementer`, который знает, как увеличить значение типа `int` на единицу. И у этого интерфейса есть две идентичные реализации. Также есть метод для измерений `Measure`, который берет экземпляр интерфейса и много раз запускает метод `Inc` в цикле:

```
interface IIncrementer
{
    int Inc(int x);
}
class Incrementer1 : IIncrementer
{
    public int Inc(int x) => x + 1;
}
class Incrementer2 : IIncrementer
{
    public int Inc(int x) => x + 1;
}
static void Measure(IIncrementer incrementer)
{
    for (int i = 0; i < 100000001; i++)
        incrementer.Inc(0);
}

static void Main()
{
    var stopwatch1 = Stopwatch.StartNew();
    Measure(new Incrementer1());
    stopwatch1.Stop();

    var stopwatch2 = Stopwatch.StartNew();
    Measure(new Incrementer2());
    stopwatch2.Stop();

    Console.WriteLine(stopwatch1.ElapsedMilliseconds + " vs. " +
        stopwatch2.ElapsedMilliseconds);
}
```

В методе `Main` мы измеряем производительность цикла для первой, а затем второй реализации интерфейса. Человек, не знающий о диспетчеризации методов интерфейса, может ожидать одинаковых результатов. Но если мы знаем особенности нашей среды исполнения, то можем не удивиться разным результатам. Вот типичные результаты для Windows, .NET Framework 4.6 и LegacyJIT-x64:

241 vs. 328

Как видите, второй вариант намного медленнее первого. В первом случае в памяти находится только одна реализация `IIncrementer`. Поэтому JIT-компилятор может сгенерировать быструю и простую заглушку, знающую, что вызову метода `Inc` соответствует только одна таблица виртуальных методов. Во втором случае у нас уже две реализации интерфейса `IIncrementer`, и поэтому JIT-компилятору нужно регенерировать заглушку. Теперь все работает не так быстро, потому что нам нужно каждый раз выбирать правильную таблицу виртуальных методов из двух вариантов. Конечно, это упрощение — полный механизм работы куда сложнее, но, надеюсь, вы поняли идею.

## Бенчмарк получше

Таким образом, лучший выбор для бенчмаркинга — запускать каждый измеряемый метод в отдельном процессе. Смешивание бенчмарков в одной программе может привести к неправильным результатам.

Вот наша первая программа:

```
// Program1.cs
static void Main()
{
    var stopwatch1 = Stopwatch.StartNew();
    Measure(new Incrementer1());
    stopwatch1.Stop();

    Console.WriteLine(stopwatch1.ElapsedMilliseconds);
}
```

А вот вторая программа:

```
// Program2.cs
static void Main()
{
    var stopwatch2 = Stopwatch.StartNew();
    Measure(new Incrementer2());
    stopwatch2.Stop();

    Console.WriteLine(stopwatch2.ElapsedMilliseconds);
}
```

Теперь мы получим равные результаты:

```
// Program1
243
// Program2
242
```

Выглядит гораздо лучше.

## СОВЕТ

Используйте отдельный процесс для каждого проверяемого метода.

Изолирование всегда полезно для бенчмарков. Кто-то может сказать, что нам нужно измерять реальную производительность в реальном окружении, поэтому изолировать их неправильно, ведь так мы упустим важные особенности среды исполнения. Это имеет смысл, но сейчас мы обсуждаем процесс дизайна хороших бенчмарков. Хорошие бенчмарки должны давать повторяемые, стабильные результаты независимо от их порядка. Если вы хотите учитывать такие эффекты, как диспетчеризация методов интерфейса, вам придется разработать соответствующий набор бенчмарков.

Стоит упомянуть, что такие проблемы возникают не очень часто. Вы вряд ли будете часто наткаться на условную JIT-компиляцию или диспетчеризацию методов интерфейса. Но вы не сможете предсказать такие ситуации заранее! Также могут появиться проблемы, связанные с порядком измеряемых методов, из-за механизмов высокого уровня, таких как кэширование (первый бенчмарк инициализирует кэш, а второй работает уже на прогревом кэше). Поэтому изолировать каждый бенчмарк в отдельном процессе — очень хорошая практика.

Это последний пример распространенной ошибки бенчмаркинга, который мы обсудили в этой главе (но далеко не последний в книге). Давайте подытожим то, что мы узнали.

## Выводы

В этой главе мы обсудили некоторые распространенные подводные камни, типичные для тех, кто только начал писать бенчмарки. Некоторые из них общие и могут относиться к разным языкам и средам исполнения.

- **Неточные замеры времени.**

У бенчмарков, основанных на `DateTime`, много проблем, таких как маленькое разрешение, поэтому лучше использовать для измерения времени `Stopwatch`. Мы обсудим все API для отметок времени в .NET и их характеристики в главе 9.

- **Неправильный запуск бенчмарка.**

Бенчмарки всегда должны выполняться с включенной оптимизацией (режим релиза), без присоединенной программы для отладки, в стерильном окружении.

- **Естественный шум.**

При каждой итерации бенчмарка появляются случайные ошибки из-за естественного шума.

- **Сложные распределения.**

Распределения производительности часто имеют сложную форму: может появиться большой разброс значений или чрезвычайно высокие значения. Такое распределение нужно тщательно анализировать. Мы обсудим, как это делать, в главе 4.

- **Измерение холодной загрузки вместо прогретого стабильного состояния.**

Первые итерации бенчмарка — холодные, они могут занять больше времени, чем последующие прогретые.

- **Недостаточное количество вызовов.**

В случае микробенчмарков измеряемый код должен повторяться много раз, иначе появятся огромные ошибки, поскольку замеры времени ограничены на уровне устройства и не могут корректно измерять слишком быстрые операции.

- **Накладные расходы на инфраструктуру.**

У каждого бенчмарка есть инфраструктура, помогающая получить надежные и повторяемые результаты. Она может влиять на результаты и портить измерения. Накладные расходы должны быть вычислены и удалены из конечных результатов.

- **Неравноценные итерации.**

Если вы повторяете код несколько раз, то должны быть уверены, что все повторения занимают одно и то же время.

Существуют и другие подводные камни, связанные с оптимизациями среды исполнения .NET.

- **Развертывание циклов.**

Если в качестве верхнего предела цикла используется константа, этот цикл может быть развернут из-за разных факторов в зависимости от делителей этой константы.

- **Удаление неиспользуемого кода.**

Если вы не используете результаты вызываемых методов, то эти вызовы могут быть полностью удалены.

- **Свертка констант.**

Если в выражениях используются константы, эти выражения могут быть вычислены заранее на стадии компиляции.

- **Удаление проверки границ.**

Если вы манипулируете элементами массива, среда исполнения может проверить границы массива или пропустить эти проверки.

- **Инлайнинг.**

Иногда среда исполнения инлайнит вызовы методов, что может оказаться довольно важным фактором для микробенчмарков. Мы обсудим инлайнинг и похожие на него оптимизации в главе 7.

- **Условное JIT-компилирование.**

Код финальной сборки метода может зависеть от предыдущих выполненных методов. Поэтому правильнее будет изолировать бенчмарки и запускать каждый из них в отдельном процессе.

- **Диспетчеризация методов интерфейса.**

Если вызывать методы интерфейса, производительность этих методов будет зависеть от загруженных в память реализаций данного интерфейса. Это еще одна причина, по которой изоляция бенчмарков полезна.

Надеюсь, теперь вы понимаете, почему бенчмаркинг может быть сложным занятием. Бенчмаркинг (и в особенности микробенчмаркинг) требует глубокого знания используемой вами среды исполнения .NET, современных операционных систем и современных устройств.

Конечно, не нужно создавать отдельную инфраструктуру для бенчмаркинга и решать все эти проблемы каждый раз, когда хотите что-то измерить. В главе 6 мы обсудим BenchmarkDotNet — библиотеку, которая может защитить вас от большинства подводных камней и помочь провести качественное исследование производительности.

Однако библиотека BenchmarkDotNet не способна решить все проблемы: вам все еще нужно знать, как правильно спроектировать бенчмарк и какие оптимизации среды исполнения могут испортить получаемые результаты. Это непросто, потому что вы не знаете заранее, какие оптимизации будут применяться к вашей программе. Все зависит от среды выполнения (например, .NET Framework, .NET Core или Mono), конкретной версии компилятора C#, конкретной версии JIT-компилятора (например, LegacyJIT-x86 или RyuJIT-x64) и т. д. В следующей главе мы обсудим различные окружения и их влияние на производительность приложения.

# 3

## Как окружение влияет на производительность

Окружение — это все, что не я.

*Альберт Эйнштейн*

В главе 1 мы обсудили пространства производительности. Основными компонентами пространства производительности являются исходный код, окружение и выходные данные. Исходный код — это математическая абстракция, у него нет характеристики «производительность». Если вы хотите говорить о скорости своей программы, то должны поместить ее в реальное окружение. В любом окружении исходный код пройдет долгий путь, прежде чем мы сможем обсуждать его производительность (рис. 3.1).

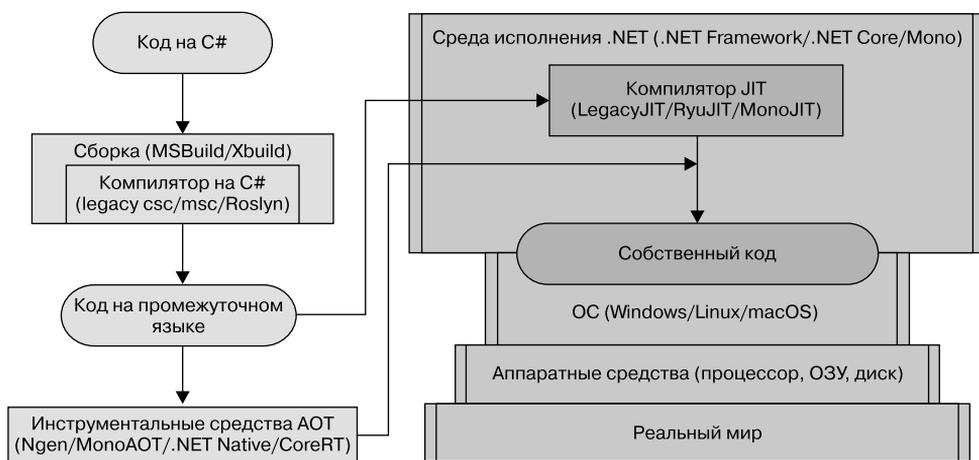


Рис. 3.1. Путь исходного кода

В этой главе обсудим разные факторы, влияющие на производительность на протяжении этого пути.

- **Среда исполнения.**

Среда исполнения — возможно, одна из самых важных частей вашего окружения. Сегодня .NET — это не только .NET Framework для Windows: есть

три популярные среды исполнения, и вам нужно понимать разницу между ними. Например, вы можете получить совершенно разную производительность, если запустите одну и ту же программу на .NET Core и Mono. Важна также версия среды исполнения. Даже небольшое обновление может изменить производительность. Мы обсудим краткую историю каждой среды исполнения, рассмотрим самые важные их версии и узнаем о некоторых интересных функциях. В масштабе этой книги мы обсудим три самые популярные среды исполнения: .NET Framework, .NET Core и Mono.

- **Компиляция.**

Путь от исходного кода до исполняемых бинарных файлов долгий. Обычно он включает в себя несколько стадий.

- **Генерация промежуточного языка.**

Первая типичная стадия компиляции — трансформация исходного кода (на C#, VB.NET или другом языке) в промежуточный язык IL. Мы обсудим основные компоненты этой трансформации: системы сборки (например, *MSBuild* или *XBuild*), компиляторы (например, *компилятор Microsoft C#, Mono Compiler* или *Roslyn*) и их версии.

- **JIT-компиляция.**

После генерации промежуточного языка мы получаем набор бинарных сборок, но это не конец нашего путешествия. Далее нам нужно превратить его в нативный машинный код. Говоря «нам», я имею в виду JIT-компилятор. Он создает нативный код из промежуточного языка динамически (во время исполнения). Как обычно, у нас есть разные компиляторы JIT (мы обсудим *LegacyJIT*, *RyuJIT* и *MonoJIT*). Важна и выбранная платформа, поэтому поговорим также о компиляторах под *x86* и *x64*.

- **Статическая компиляция (Ahead-of-Time, AOT).**

JIT-компиляция — не единственный способ получить нативный код: мы можем скомпилировать промежуточный язык Ahead-of-Time (перед выполнением). AOT-компиляция также является важным сценарием, меняющим пространство производительности. И конечно, существуют разные AOT-компиляторы (например, *NGen [Native Image Generator]*, *Mono AOT*, *.NET Native* и *CoreRT*). Хороший отчет с результатами бенчмаркинга обычно включает в себя тип используемой компиляции (JIT или AOT), тип компилятора, его версию, целевую платформу и ее параметры.

- **Внешнее окружение.**

Последний раздел посвящен окружению среды исполнения: существует много факторов за пределами экосистемы .NET, которые также влияют на производительность.

- **Операционные системы.**

Классический .NET Framework предназначен только для Windows, но мы живем во времена кросс-платформенных .NET-приложений. Это означает, что мы можем запускать C#-программы на Windows, Linux и macOS (а также под Sun Solaris, FreeBSD или tvOS, если захотите). У каждой операционной системы много уникальных характеристик производительности. Мы рассмотрим краткую историю ОС, обсудим каждую ОС и ее версии и сравним производительность одних и тех же программ в разных операционных системах.

- **Аппаратные средства.**

Конфигураций устройств слишком много. Мы обсудим процессор, оперативную память, диски, сеть и другие аппаратные средства. Самое главное, что нужно запомнить: сравнивать производительность на разных устройствах очень сложно. Существует много деталей на низком уровне, которые могут повлиять на программу. В этом разделе мы кратко рассмотрим разнообразие аппаратных средств и обсудим важнейшие параметры конфигурации.

- **Физический мир.**

Аппаратные средства всегда существуют в реальных физических условиях. На производительность могут повлиять многие физические факторы, такие как температура, вибрация, влажность и т. д.

У этой главы три цели.

1. **Познакомить вас с важными кодовыми названиями, заголовками, надписями и т. д.** В этой главе вы узнаете полезные термины (например, *Rotor*, *CoreFx*, *mcs*, *SGen*, *Roslyn*, *RyuJIT*, *Darwin* или *Sandy Bridge*), поэтому, если пропустите ее и перейдете к более интересной главе, то всегда можете вернуться сюда за описанием различных окружений, короткими объяснениями, что есть что, и пониманием, почему это важно.
2. **Предоставить способы получить информацию о текущем окружении.** Если вы пишете собственные инструменты для анализа производительности, довольно важно добавить логику для сбора информации о текущем окружении. Не всегда очевидно, как получить точную версию установленного .NET Framework или .NET Core или определить тип JIT-компилятора (например, LegacyJIT или RyuJIT). В этой главе вы узнаете, как собрать детальную информацию об окружении программы на .NET.
3. **Объяснить, почему окружение имеет большое значение.** Вы узнаете, как небольшие различия между окружениями могут значительно повлиять на результаты.

У всех разделов этой главы одна и та же структура. Мы начнем с обзора: история, версии, кодовые названия технологий и т. д. После этого вы прочтете четыре

истории о том, как технология может повлиять на бенчмарки. Эти истории подобраны не случайным образом — все они представлены здесь по определенной причине. У каждой истории есть раздел «Выводы» в конце, подытоживающий то, что вы должны из него узнать. Также есть раздел «Упражнения». Если хотите, можете пропустить упражнения, потому что для некоторых из них требуются специальные условия (например, конкретная модель процессора или конкретная операционная система) и много времени. Но если вы решите эти задачи, то получите навыки, которые могут пригодиться в реальных исследованиях производительности. Часть историй основана на моем личном опыте разработчика, некоторые — на исследованиях других людей, а некоторые просто представляют собой довольно интересные фрагменты кода.

Конечно, мы не будем обсуждать *все возможные окружения*. Мы не будем особо обсуждать Windows Servers, процессоры ARM, MONO LLVM, GPU и т. д. Но зато мы кратко поговорим о версиях каждого компонента окружения, хоть и не будем изучать каждую из них в отдельности. В этом просто нет необходимости. Выучить все версии всех технологий нереально — их слишком много, и новые появляются каждый день. Но важно получить общее представление о том, какие окружения у нас есть, и понять, какие компоненты могут влиять на производительность и как именно. В этом случае при бенчмаркинге вы сможете проверить все важные детали.

Начнем с самого важного — среды исполнения .NET. Конечно, можно работать только с одной фиксированной версией среды исполнения и изучить ее досконально, но пока вы не поймете, как работают другие, вы не сможете обсуждать производительность .NET в целом.

## Среда исполнения

Сейчас существуют три популярные среды исполнения .NET: .NET Framework, .NET Core и Mono. Технически все они не просто среды исполнения, поскольку включают в себя также библиотеки классов. Однако люди часто называют их средами исполнения, потому что термина лучше еще не придумали (корректнее было бы «платформа» (framework), но тогда будет легко перепутать с .NET Framework). То есть, когда вы видите термин «среда исполнения», обычно он означает «среда исполнения и соответствующие библиотеки классов».

Если честно, .NET Framework, .NET Core и Mono — не единственные доступные среды исполнения .NET. Было много попыток создать альтернативные среды исполнения .NET, например *Silverlight*, *Moonlight*, *.NET Micro Framework* и т. д. Существует также много способов запустить код на C# в браузере: *Blazor* (экспериментальная веб-платформа .NET, использующая C#/Razor и HTML, которая запускается в браузере с помощью WebAssembly), *Script#*, *Bridge.NET* и т. д. Все это — настоящие окружения для .NET-приложений, но они не так популярны,

как .NET Framework, .NET Core и Mono, поэтому мы не будем говорить о них в данной книге. Хороший обзор различных сред исполнения .NET можно найти в [Warren, 2018a].

Все три среды исполнения, о которых пойдет речь, существуют давно и широко распространены. В этом разделе кратко поговорим о каждой из них в трех контекстах: их история, доступные версии (и как их получить) и изменения производительности в этих версиях. В конце вы найдете несколько практических примеров, демонстрирующих, почему так важно знать точную версию вашей среды исполнения.

## .NET Framework

.NET Framework — первая реализация .NET, выпущенная Microsoft. Чтобы избежать путаницы между .NET Framework как средой исполнения и всей экосистемой .NET, давайте договоримся о том, что .NET Framework как среда исполнения состоит из двух главных частей: общезыковой среды исполнения (CLR или Desktop CLR) и библиотеки классов платформы (FCL). Чтобы четко различать .NET Framework и остальные реализации .NET, часто используют такие названия, как *Full .NET Framework* (или .NET Full Framework), *Microsoft .NET Framework* или *Desktop .NET Framework*. В данной книге, говоря .NET Framework, мы имеем в виду классический .NET Framework от Microsoft для Windows.

Начнем с начала и вспомним историю .NET Framework. Она была создана Microsoft. Первая версия вышла в 2002 году (разработка началась в конце 1990-х). В табл. 3.1 приведен список версий .NET Framework<sup>1</sup>.

**Таблица 3.1.** История релизов .NET Framework

Версия платформы	Версия CLR	Дата релиза	Дата окончания поддержки
1.0	1.0	13.02.2002	14.07.2009
1.1	1.1	24.04.2003	14.06.2015
2.0	2.0	07.11.2004	12.07.2011
3.0	2.0	06.11.2006	12.07.2011
3.5	2.0	19.11.2007	10.10.2028
4.0	4.0	12.04.2010	12.01.2016
4.5	4.0	15.08.2012	12.01.2016
4.5.1	4.0	17.10.2013	12.01.2016

Продолжение ⇨

<sup>1</sup> .NET Framework 4.8 была анонсирована в [Lander 2018b], но на момент написания книги еще не выпущена. Актуальный список версий находится здесь: <https://docs.microsoft.com/en-us/dotnet/framework/migration-guide/versions-and-dependencies>.

Таблица 3.1 (продолжение)

Версия платформы	Версия CLR	Дата релиза	Дата окончания поддержки
4.5.2	4.0	05.05.2014	Не объявлена
4.6	4.0	20.07.2015	Не объявлена
4.6.1	4.0	30.11.2015	Не объявлена
4.6.2	4.0	02.08.2016	Не объявлена
4.7	4.0	05.04.2017	Не объявлена
4.7.1	4.0	17.10.2017	Не объявлена
4.7.2	4.0	30.04.2018	Не объявлена
4.8	4.0	18.04.2019	Не объявлена

Несколько полезных и важных фактов:

- версии .NET Framework 1.0–3.0 устарели и больше не поддерживаются Microsoft;
- некоторые большие legacy-проекты все еще используют .NET Framework 3.5, потому что обновлять среду исполнения тяжело. Между CLR 2, применяемой в .NET Framework 3.5, и CLR 4, используемой в .NET Framework 4.0+, много значительных различий.

Все версии .NET Framework 4.x — это in-place обновления старых версий 4.x (включая CLR и FCL), они используют одну и ту же папку установки C:\Windows\.NET Framework\4.0.30319. То есть, если вы установите .NET Framework 4.5 и 4.7, все приложения будут использовать 4.7. Нельзя задействовать две разные версии .NET Framework 4.x на одном устройстве одновременно. Версия CLR для всех версий 4.x одинакова (CLR 4), но это не значит, что для исполнения берется одна и та же реализация CLR — она обновляется с каждым обновлением .NET Framework.

### Пример

Вы работаете на Windows с установленным .NET Framework 4.6.1 и разрабатываете приложение под .NET Framework 4.0. Но если вы запустите это приложение локально, то будет использован .NET Framework 4.6.1. Если решите исполнять его на компьютере друга, установившего себе .NET Framework 4.7, будет использована версия 4.7. В этом случае 4.0 в свойствах вашего проекта означает, что вы не можете применять API из .NET Framework 4.5+, но можете запустить это приложение на устройстве с установленным .NET Framework 4.0+.

Между версиями .NET Framework много существенных различий. Можно получить разные значения метрик производительности одного и того же кода на разных версиях .NET Framework. Таким образом, важно знать, как определить версию

установленного .NET Framework. Вы можете сделать это с помощью специальных ключей в реестре Windows. Например, для .NET Framework 4.5+ нужно смотреть на значение HKLM\SOFTWARE\Microsoft\NET Framework Setup\NDP\v4\Full\Release. Это внутренний номер, который может быть соотнесен с версиями .NET Framework. У одной и той же версии .NET Framework могут быть разные внутренние номера в зависимости от версии Windows и установленных ограничений. Вы найдете минимальные значения Release в табл. 3.2<sup>1</sup>.

**Таблица 3.2.** Значения Release в реестре .NET Framework

Версия .NET Framework	Минимальное значение
4.5	378 389
4.5.1	378 675
4.5.2	379 893
4.6	393 295
4.6.1	394 254
4.6.2	394 802
4.7	460 798
4.7.1	461 308
4.7.2	461 808

Важно сказать несколько слов об исходном коде .NET Framework. Он недоступен для старых версий .NET Framework. Однако у нас есть доступ к исходному коду некоторых из них. *Shared Source Common Language Infrastructure (SSCLI, кодовое название Rotor)* – открытый исходный код от Microsoft, который содержит основные части .NET Framework. Первая версия была выпущена в 2002 году, а вторая, и последняя, версия SSCLI – в 2006-м<sup>2</sup>. Она содержит важнейшие части .NET Framework 2.0. Хороший обзор исходного кода можно найти в [SSCLI Internals]. К сожалению, обновлений SSCLI для .NET Framework 3.0, 3.5, 4.0 или 4.5 нет. Позже Microsoft открыла исходный код .NET Framework 4.5.1+ в режиме «только для чтения». Его можно найти на сайте Microsoft Reference Source<sup>3</sup>.

<sup>1</sup> Полное актуальное руководство можно найти здесь: <https://docs.microsoft.com/en-us/dotnet/framework/migration-guide/how-to-determine-which-versions-are-installed>.

<sup>2</sup> К сожалению, официальные ссылки Microsoft на страницу загрузки SSCLI устарели и не работают. К счастью, Интернет помнит все: исходный код можно найти здесь: <https://github.com/AndreyAkinshin/shared-source-cli-2.0>.

<sup>3</sup> Исходный код последней версии .NET Framework можно посмотреть здесь: <https://referencesource.microsoft.com>. Старые версии доступны в виде ZIP-файлов в разделе «Загрузки». Исходный код также доступен на GitHub: <https://github.com/Microsoft/referencesource>.

Сейчас .NET Framework все еще является средой исполнения только для Windows, что становится серьезным ограничением для многих разработчиков. К счастью, Microsoft решила создать бесплатную открытую кросс-платформенную версию — .NET Core.

## .NET Core

.NET Core — альтернативная реализация .NET Framework. Изначально .NET Core был создан как ответвление версии .NET Framework, но затем он стал полнофункциональной независимой платформой.

.NET Core с самого начала был бесплатным проектом с открытым исходным кодом (он использует лицензию MIT). Среда исполнения .NET Core называется *CoreCLR* (<https://github.com/dotnet/coreclr>), в отличие от CLR в .NET Framework. Она содержит сборщик мусора, JIT-компилятор, System.Private.CoreLib (вместо mscorlib) и некоторые базовые классы, специфичные для этой среды исполнения. Набор базовых библиотек .NET Core называется *CoreFX* (<https://github.com/dotnet/corefx>), в отличие от FCL в .NET Framework. Он содержит все базовые классы, такие как коллекции, классы для ввода-вывода, глобализацию и т. д. Другим важным проектом в экосистеме .NET Core является *.NET Core SDK* (<https://github.com/dotnet/core-sdk>), включающая в себя .NET Core, шаблоны проектов, интерфейс командной строки .NET Core (CLI) (<https://github.com/dotnet/cli>), MSBuild, инструменты NuGet и другие компоненты, помогающие разрабатывать приложения в .NET Core.

.NET Core — кросс-платформенная среда исполнения, в то время как .NET Framework работает только под Windows. То есть многие компоненты .NET Framework нельзя использовать в .NET Core из-за сильной интеграции с Windows. Однако некоторые из них могут исполняться в .NET Core под Windows с помощью *Windows Compatibility Pack* (см. [Landwerth 2017b]). Начиная с версии .NET Core 3.0 возможно даже разрабатывать в ней WPF и WinForms приложения для Windows (см. [Lander 2018a]).

Основная часть кодовой базы одинакова для .NET Core и .NET Framework. Однако есть и много различий. У этих платформ разные циклы релиза: может быть довольно трудно опознать версии .NET Framework, содержащие определенные изменения из .NET Core. В .NET Core много кросс-платформенной логики, необходимой для Linux и macOS. В то же время в .NET Framework много «костылей» для совместимости с предыдущими версиями под Windows. Между этими платформами много общего, но мы будем говорить о них независимо друг от друга.

Вспомним краткую историю .NET Core. .NET Core 1.0 была выпущена 27 июня 2016 года. С тех пор вышло много версий. Некоторые из них приведены в табл. 3.3.

Таблица 3.3. История релизов .NET Core

Среда исполнения	Версия SDK	Дата выхода
1.0.0	1.0.0-preview2-003121	27.06.2016
1.0.1	1.0.0-preview2-003131	13.09.2016
1.0.2	1.0.0-preview2-003148	17.10.2016
1.1.0	1.0.0-preview2.1-003177	16.11.2016
1.0.3	1.0.0-preview2-003156	13.12.2016
1.1.1	1.0.1	07.03.2017
1.0.4	1.0.1	07.03.2017
1.1.2	1.0.4	09.05.2017
1.0.5	1.0.4	09.05.2017
2.0.0	2.0.0	14.08.2017
1.0.7	1.1.4	21.09.2017
1.1.4	1.1.4	21.09.2017
1.0.8	1.1.5	14.11.2017
1.1.5	1.1.5	14.11.2017
2.0.3	2.0.3	14.11.2017
2.0.3	2.1.2	04.12.2017
2.0.5	2.1.4	04.12.2017
1.0.10	1.1.8	13.03.2018
1.1.7	1.1.8	13.03.2018
2.0.6	2.1.101	13.03.2018
1.0.11	1.1.9	17.04.2018
1.1.8	1.1.9	17.04.2018
2.0.7	2.1.105	17.04.2018
2.0.7	2.1.200	08.05.2018
2.0.7	2.1.201	21.05.2018
2.1.0	2.1.300	30.05.2018
2.1.1	2.1.301	19.06.2018
1.0.12	1.1.10	10.07.2018
1.1.9	1.1.10	10.07.2018
2.0.9	2.1.202	10.07.2018
2.1.2	2.1.302	10.07.2018
2.1.2	2.1.400	14.08.2018

Продолжение ⇨

Таблица 3.3 (продолжение)

Среда исполнения	Версия SDK	Дата выхода
2.1.3	2.1.401	14.08.2018
2.1.4	2.1.402	11.09.2018
2.1.5	2.1.403	02.10.2018
1.0.13	1.1.11	09.10.2018
1.1.10	1.1.11	09.10.2018
2.1.6	2.1.500	13.11.2018
2.2.0	2.2.100	04.12.2018

Из этой таблицы мы можем сделать несколько важных выводов.

- Первая стабильная версия этой среды исполнения была выпущена с *предварительной версией SDK (preview)*. Если вы попытаете поработать с ранними версиями SDK, то вместо обычных `.csproj`-файлов нужно будет работать с `.xproj+project.json`. Многим разработчикам эти изменения не нравились, поэтому проекты на основе `project.json` были оставлены в прошлом и решено было вернуться к файлам `*.csproj`, чтобы сохранить совместимость с предыдущими версиями MSBuild. Но если вы хотите проверить что-то на старых версиях среды исполнения, вам не нужны старые версии SDK — новые сборки SDK поддерживают старые версии среды исполнения.
- Одна и та же версия среды исполнения может быть использована с разными версиями SDK.

C .NET Core SDK и MSBuild 15+ Microsoft ввела улучшенную версию формата `.csproj`. Выглядит он так:

```
<Project Sdk="Microsoft.NET.Sdk">
  <PropertyGroup>
    <TargetFrameworks>net46;netcoreapp2.1</TargetFrameworks>
  </PropertyGroup>
</Project>
```

Мы будем называть это *проектами в стиле SDK*. Если проект использует изначальный формат (с большим количеством строк в файле `.csproj`), будем называть его *классическим* проектом. Проекты в стиле SDK были введены вместе с .NET Core SDK, но это не означает, что его можно использовать только с .NET Core. В предыдущем примере проект предназначен для .NET Framework 4.6 (`net46`) и .NET Core 2.1 (`netcoreapp2.1`). Если вы разрабатываете библиотеку, которая должна быть совместима с большим количеством платформ<sup>1</sup>, можете перечислить их все в каждом проекте, но это не очень удобно. Данная проблема была решена с помощью *.NET Standard*. Вот официальное определение .NET Standard из документации Microsoft:

<sup>1</sup> Их очень много. Полный список можно найти на <https://docs.microsoft.com/en-us/dotnet/standard/frameworks>.

«*.NET Standard* представляет собой официальную спецификацию интерфейсов API *.NET*, которые должны быть доступны во всех реализациях *.NET*. *.NET Standard* создана для того, чтобы повысить согласованность экосистемы *.NET*. ECMA 335 продолжает обеспечивать единообразие для реализации *.NET*, но аналогичные спецификации для библиотек базовых классов (BCL) *.NET* отсутствуют» (<https://docs.microsoft.com/en-us/dotnet/standard/net-standard>).

В табл. 3.4 можно увидеть соответствия между *.NET Standard* и различными платформами *.NET*<sup>1</sup>.

**Таблица 3.4.** Матрица совместимости *.NET Standard*

<b>.NET Standard</b>	1.0	1.1	1.2	1.3	1.4	1.5	1.6	2.0
<b>.NET Core</b>	1.0	1.0	1.0	1.0	1.0	1.0	1.0	2.0
<b>.NET Framework</b>	4.5	4.5	4.5.1	4.6	4.6.1	4.6.1	4.6.1	4.6.1
<b>Mono</b>	4.6	4.6	4.6	4.6	4.6	4.6	4.6	5.4
<b>Xamarin.iOS</b>	10.0	10.0	10.0	10.0	10.0	10.0	10.0	10.14
<b>Xamarin.Mac</b>	3.0	3.0	3.0	3.0	3.0	3.0	3.0	3.8
<b>Xamarin.Android</b>	7.0	7.0	7.0	7.0	7.0	7.0	7.0	8.0

Допустим, у нас есть библиотека, соответствующая *.NET Standard 2.0*. Это значит, что ее можно использовать с *.NET Core 2.0*, *.NET Framework 4.6.1* или *Mono 5.4*. Вот главное, что нужно понимать в контексте бенчмаркинга: *.NET Standard* — это не среда исполнения, это набор API. Нельзя запустить приложение или модульное тестирование (<https://xunit.github.io/docs/why-no-netstandard>) на *.NET Standard*. То есть мы не можем обсуждать производительность *.NET Standard 2.0*, но можем — производительность *.NET Core 2.0*, *.NET Framework 4.6.1* и *Mono 5.4*. И не имеют никакого смысла фразы вроде «*.NET Standard 1.3* работает быстрее, чем *.NET Standard 1.2*».

Очень важно знать версию среды исполнения при обсуждении производительности. Давайте узнаем, как определить текущую версию *.NET Core*. К сожалению, не существует общедоступного API, позволяющего определить текущую версию *.NET Core* в среде исполнения. Однако, если очень хочется это сделать, можно воспользоваться следующим приемом. Обычное расположение библиотек среды исполнения в *.NET Core SDK* выглядит примерно так: `dotnet/shared/Microsoft.NETCore.App/2.1.0/`. Как видите, полный путь включает в себя версию среды исполнения. Таким образом, мы

<sup>1</sup> Это неполная таблица. Полную можно найти по адресу <https://docs.microsoft.com/en-us/dotnet/standard/net-standard>. Кроме того, реальная совместимость зависит от версии *.NET Core SDK*. Например, *.NET Standard 1.5* соответствует *.NET Framework 4.6.2*, если вы используете *.NET Core SDK 1.x*, и *.NET Framework 4.6.1*, если используете *.NET Core SDK 2.x*. Если вы не уверены, что правильно понимаете концепцию *.NET Standard*, рекомендуем вам посмотреть [Landwerth, 2017a].

можем взять расположение сборки, содержащей один из базовых типов, например `GCSettings`, и найти часть пути с точной версией:

```
public static string GetNetCoreVersion()
{
    var assembly = typeof(System.Runtime.GCSettings).GetTypeInfo().Assembly;
    var assemblyPath = assembly.CodeBase.Split(new[] { '/', '\\' },
        StringSplitOptions.RemoveEmptyEntries);
    int netCoreAppIndex = Array.IndexOf(assemblyPath, "Microsoft.NETCore.App");
    if (netCoreAppIndex > 0 && netCoreAppIndex < assemblyPath.Length - 2)
        return assemblyPath[netCoreAppIndex + 1];
    return null;
}
```

Это работает для обычной установки .NET Core, но не работает для особых окружений, таких как контейнеры Docker (<https://github.com/dotnet/BenchmarkDotNet/issues/788>). В случае Docker получить версию среды исполнения можно из переменных окружения, например `DOTNET_VERSION` и `ASPNETCORE_VERSION` (подробнее см. [Hanselman, 2018]).

Для диагностики может быть полезно знать также внутреннюю версию `CoreCLR` и `CoreFX`:

```
var coreclrAssemblyInfo = FileVersionInfo.GetVersionInfo(
    typeof(object).GetTypeInfo().Assembly.Location).FileVersion;
var corefxAssemblyInfo = FileVersionInfo.GetVersionInfo(
    typeof(Regex).GetTypeInfo().Assembly.Location).FileVersion;
```

Вот примеры возможных значений:

```
.NET Core 3.0.0-preview-27122-01
CoreCLR 4.6.27121.03
CoreFX 4.7.18.57103
```

Как видите, они не совпадают друг с другом. Внутренние версии `CoreCLR` и `CoreFX` особенно важны, когда вы работаете над изменениями в самом .NET Core.

В каждой версии .NET Core добавляется очень много оптимизаций (см. [Toub, 2017], [Toub, 2018]). Если вам важна скорость приложения, рекомендуется использовать последнюю из доступных версий. Однако набор старых версий .NET Core представляет собой прекрасный предмет для упражнений в бенчмаркинге.

Последнее, что вы должны знать, — это *NET Core Configuration Knobs*<sup>1</sup>. Это параметры конфигурации, помогающие настроить среду исполнения. Включить эти

<sup>1</sup> Полный список всех ручек управления для .NET Core 2.2.0 можно найти на GitHub: <https://github.com/dotnet/coreclr/blob/v2.2.0/Documentation/project-docs/clr-configuration-knobs.md>.

параметры можно с помощью переменных окружения `COMPlus_*`. Например, если вы хотите включить `JitAggressiveInlining` (мы обсудим JIT позже в этой главе), нужно установить `COMPlus_JitAggressiveInlining=1`.

.NET Core появилась в 2016 году, но это была не первая кросс-платформенная реализация .NET. Разработчики и до этого могли пользоваться .NET на Linux и macOS с помощью другой среды исполнения .NET — Mono.

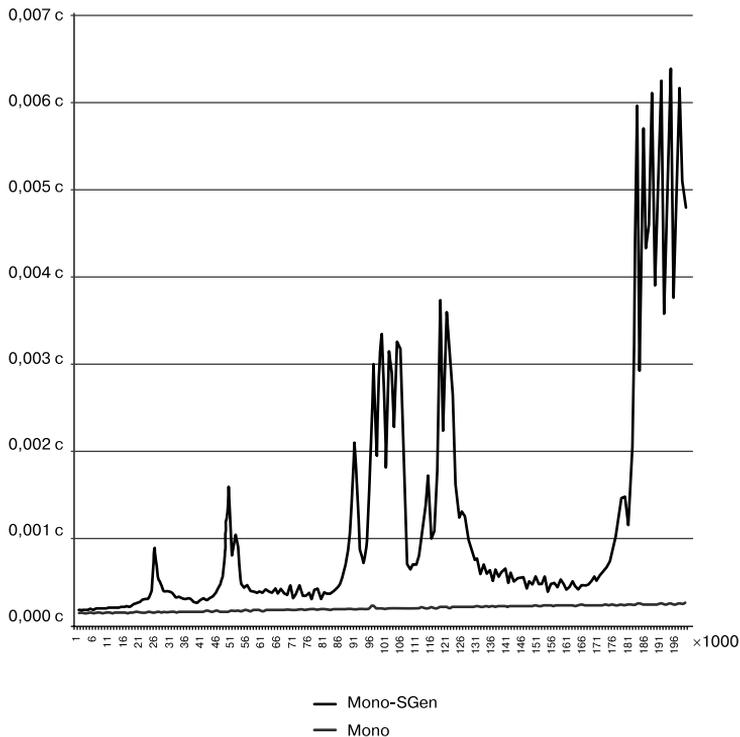
## Mono

Microsoft анонсировала .NET Framework в 2000 году. Среда исполнения казалась прекрасной, но была предназначена только для Windows. Мигель де Икаса из компании Ximian решил создать открытую версию .NET, работающую под Linux. Попытка оказалась весьма успешной. Разработка продолжалась три года, в результате появилась Mono 1.0. У первых версий было множество багов, ошибок и проблем с производительностью. Но среда исполнения быстро эволюционировала, и вскоре Mono стала хорошей альтернативой для .NET-разработчиков на Linux/macOS. В 2003 году Ximian была приобретена компанией Novell. В 2011-м Мигель де Икаса и Нат Фридман основали Xamarin — компанию, продолжившую разрабатывать Mono. В 2016 году Xamarin была куплена Microsoft. С тех пор Mono стала частью .NET Foundation (<https://dotnetfoundation.org/>). Хотя .NET Core и является хорошим вариантом для кросс-платформенных приложений с точки зрения надежности и производительности, Mono все еще широко используется — в основном для мобильных приложений (<https://visualstudio.microsoft.com/xamarin/>) и приложений Unity (<https://unity3d.com/>).

После выхода первого релиза Mono в 2004 году появились десятки мажорных и минорных версий. В каждой версии был гигантский список изменений. Все детали можно найти в официальной документации релизов ([www.mono-project.com/docs/about-mono/releases/](http://www.mono-project.com/docs/about-mono/releases/)). Хочу привести лишь некоторые конкретные изменения, связанные с производительностью.

- **Mono 1.0** (30.01.2004) — первый официальный релиз Mono.
- **Mono 1.2** (02.11.2006) — много общих оптимизаций (инлайнинг, удаление ненужного кода, свертка констант и т. д.), АОТ-компиляция, сборщик мусора Boehm.
- **Mono 2.0** (01.10.2008) — улучшены производительность операций с десятичными числами и блокировками, уменьшено использование памяти для обобщенных коллекций.
- **Mono 2.2** (09.01.2009) — новый механизм генерации кода с улучшенными оптимизациями, улучшенный АОТ, интерпретатор регулярных выражений.

- **Мono 2.4** (13.03.2009) — поддержка SIMD (Single Instruction Multiple Data), оптимизированы XPath и загрузка ресурсов.
- **Мono 2.6** (14.12.2009) — поддержка LLVM.
- **Мono 2.8** (05.10.2010) — поддержка нового сборщика мусора — SGen (разница между Boehm и SGen показана на рис. 3.2<sup>1</sup>. Нижняя прямая линия соответствует SGen, верхняя кривая линия — Boehm).



**Рис. 3.2.** Разница между Boehm и SGen в Mono 2.8

- **Мono 2.10** (15.02.2011) — значительные улучшения SGen, такие как concurrent marks и sweeping.
- **Мono 3.0** (19.10.2012) — новая система управления задачами в SGen, низкоуровневые интринзики для ThreadLocal<T>, List<T>.
- **Мono 3.2** (24.07.2013) — LLVM 3.2 с более качественными оптимизациями, SGen становится сборщиком мусора по умолчанию, важные оптимизации AOT и LINQ, более быстрое клонирование и преобразование крупных объектов, оптимизация Marshal.Read и Marshal.Write.

<sup>1</sup> Рисунок взят из официальной документации релиза: [www.mono-project.com/docs/about-mono/releases/2.8.0/](http://www.mono-project.com/docs/about-mono/releases/2.8.0/).

- **Mono 3.4** (31.03.2014) — различные мелкие улучшения производительности.
- **Mono 3.6** (12.08.2014) — новые режимы сборщика мусора, улучшена производительность блокировки, оптимизирован EqualityComparer.
- **Mono 3.8** (04.09.2014) — многочисленные улучшения JIT, такие как улучшение работы с остатками степеней двойки, ускорение кода для делегатов, которые вызываются только один раз.
- **Mono 3.10** (04.10.2014) — удалены ненужная блокировка ключевых функций обработки метаданных и перегрузка кэша массива локальных переменных при переборе элементов перечисления.
- **Mono 3.12** (13.01.2015) — важные улучшения SGen в производительности и потреблении памяти, генерация кода для x86 без использования push-команд.
- **Mono 4.0** (29.04.2015) — принятие открытого кода Microsoft (значительные изменения производительности во многих классах BCL, например System.Decimal), оптимизации выражений с плавающей запятой, тонкая параметризация SGen, много улучшений в разных местах, таких как Interlocked, Thread.MemoryBarrier, Enum.HasFlag и т. д.
- **Mono 4.2** (25.08.2015) — дальнейшее принятие открытого кода Microsoft (и много значительных изменений производительности в BCL), обновлена внутренняя реализация делегатов.
- **Mono 4.4** (08.06.2016) — unmanaged thin locks (в некоторых случаях улучшение производительности блокировки в десять раз), кооперативный режим сборщика мусора.
- **Mono 4.6** (13.09.2016) — улучшен сборщик мусора для Android, различные улучшения производительности.
- **Mono 4.8** (22.02.2017) — начальная поддержка concurrent SGen, дальнейшее принятие MS Reference Source.
- **Mono 5.0** (10.05.2017) — добавление компилятора Roslyn C# (сюприз в области производительности для всех, кто использовал старый mcs), ускорение SIMD-операций, включение concurrent SGen по умолчанию, принятие CoreFx + Reference Source, интерфейсы для отложенной инициализации массивов, снижение использования памяти средой исполнения, сканирование SIMD-регистров.
- **Mono 5.2** (14.08.2017) — экспериментальная поддержка реализации методов интерфейсов по умолчанию, оптимизация хранилищ массивов, улучшение инициализации классов, уменьшение времени пауз сборок мусора.
- **Mono 5.4** (05.10.2017) — параллельная компиляция методов, оптимизация хранения элементов массива, улучшение масштабирования загрузки, оптимизация write barrier для ValueType, Intrisificy Marshal.PtrToStruct для blitable-типов.
- **Mono 5.8** (01.02.2018) — новые режимы для сборщика мусора SGen (balanced, throughput, pause).

- **Мono 5.10** (26.02.2018) — барьеры памяти ARM, снижение объема AOT-кода благодаря дедупликации кода.
- **Мono 5.12** (08.05.2018) — поддержка jemalloc.
- **Мono 5.14** (07.08.2018) — улучшенное совместное использование обобщенных классов, оптимизация памяти для указателей, улучшенный инлайнинг в LLVM, работа автоматического управления памятью с очень крупными объектами.
- **Мono 5.16** (08.10.2018) — гибридная остановка сборщика мусора, улучшение 32-битных математических операций с плавающей запятой, интринзики для `Span<T>` и `ReadOnlySpan<T>`.

Как видно из журнала изменений, в каждый мажорный релиз были внесены важные улучшения производительности. При измерении вашего кода очень важно знать, какую версию Mono вы используете. Изменения влияют на основные компоненты Mono — JIT-компилятор, реализацию базовых классов и сборщик мусора. Доступны два основных сборщика мусора: *Boehm* и *SGen*. Boehm нужен для связи с предыдущими версиями, а SGen является механизмом по умолчанию, начиная с Mono 3.2, он работает намного быстрее по сравнению с Boehm. В SGen масса возможностей для настройки, которые мы обсудим в главе 8.

Mono — это кросс-платформенная среда исполнения. В этой книге мы обсуждаем главным образом Windows, Linux и macOS, но Mono 5.12+ можно использовать также на iOS, tvOS, watchOS, Sun Solaris, разных видах BSD, Sony PlayStation 4, XboxOne и т. д.<sup>1</sup>

С самого начала Mono была разработана в качестве альтернативой среды исполнения для существовавших программ под .NET Framework. У нее нет своей собственной целевой платформы. Если ваше приложение предназначено для net47 и netcoreapp2.0, то профиль net47 может исполняться и в .NET Framework, и в Mono, а netcoreapp2.0 — только в .NET Core. Если вы хотите узнать, является ли ваша текущая среда исполнения Mono, нужно проверить наличие типа `Mono.Runtime` ([www.mono-project.com/docs/faq/technical/#how-can-i-detect-if-am-running-in-mono](http://www.mono-project.com/docs/faq/technical/#how-can-i-detect-if-am-running-in-mono)):

```
bool isMono = Type.GetType("Mono.Runtime") != null;
```

Чтобы узнать, какая версия Mono установлена, нужно ввести в командную строку `mono --version`. Эта команда выдаст также дополнительную полезную информацию о вашей сборке Mono, например архитектуру или тип сборщика мусора по умолчанию. Вот пример результата:

```
$ mono --version
Mono JIT compiler version 5.16.0.220
(2018-06/bb3ae37d71a Fri Nov 16 17:12:11 EST 2018)
```

<sup>1</sup> Полный список поддерживаемых платформ и архитектур можно найти в официальной документации: [www.mono-project.com/docs/about-mono/supported-platforms/](http://www.mono-project.com/docs/about-mono/supported-platforms/).

Copyright (C) 2002-2014 Novell, Inc, Xamarin Inc and Contributors.  
www.mono-project.com

```
TLS: normal
SIGSEGV: altstack
Notification: kqueue
Architecture: amd64
Disabled: none
Misc: softdebug
Interpreter: yes
LLVM: yes(3.6.0svn-mono-release_60/0b3cb8ac12c)
GC: sgen (concurrent by default)
```

Существует две сборки Mono для Windows: x86 и x64 (мы обсудим различные архитектуры процессора позже в этой главе). Для Linux и macOS доступна только версия x64.

Теперь перейдем к захватывающим историям о производительности, посвященным разным версиям различных сред исполнения .NET.

## Практический пример 1: StringBuilder и версии CLR

В .NET строка — неизменяемый тип. Это значит, что каждая операция, такая как конкатенация или замена, создает новую копию строки. Если вы работаете с длинными строками, подобные операции занимают много памяти и времени. К счастью, у нас есть класс `StringBuilder` (<https://docs.microsoft.com/en-us/dotnet/api/system.text.stringbuilder>), появившийся в .NET Framework 1.1. Он представляет собой изменяемую строку и позволяет производить эффективные операции со строками без ненужных затрат памяти.

Выглядит `StringBuilder` очень просто, но его внутренняя реализация не такая уж простая. Кроме того, различные версии .NET Framework используют разные алгоритмы реализации.

Допустим, мы хотим реализовать метод логирования `Log(string s)`, который должен собрать все строки и соединить их в одну большую строку. Вот примитивная реализация, основанная на обычных строках:

```
private string buffer = "";

public void Log(string s)
{
    buffer += s;
}
```

Эта реализация неэффективна, поскольку каждый вызов `Log` будет *создавать новый экземпляр строки*, копировать содержимое `buffer` в эту копию, копировать туда же содержимое `s` и сохранять эту копию обратно в поле `buffer`. В итоге мы получаем

значительные затраты памяти и должны потратить много времени на копирование одних и тех же данных между строками. Перепишем ее с помощью `StringBuilder`:

```
private StringBuilder buffer = new StringBuilder();

public void Log(string s)
{
    buffer.Append(s);
}
```

Насколько эффективен этот код? Зависит от среды исполнения.

В **.NET Framework 1.1-3.5 (CLR2)** реализация была довольно проста<sup>1</sup>. У `StringBuilder` есть внутреннее поле `string`, хранящее текущее значение. В этом контексте будем считать его изменяемой строкой, потому что его можно модифицировать с помощью небезопасного кода. Изначальная емкость (длина этого внутреннего поля) `StringBuilder` по умолчанию 16. Когда мы вызываем метод `Append`, `StringBuilder` проверяет, достаточно ли велика емкость, чтобы хранить дополнительные символы. Если все в порядке, он просто добавляет новые символы. Если нет, создает новую строку с удвоенной емкостью (<https://github.com/AndreyAkinshin/shared-source-cli-2.0/blob/master/clr/src/bcl/system/text/stringbuilder.cs#L604>), копирует старое содержимое в новую копию и затем добавляет нужные символы.

В **.NET Framework 4.x (CLR4)** Microsoft внесла много значительных изменений<sup>2</sup>. Важнейшее из них связано с внутренним представлением данных — это больше не одна копия `string`. Теперь это связанный список областей памяти, содержащих массивы символов для частей хранящейся строки. Такой подход позволяет оптимизировать многие операции. Например, `Append` не выделяет новую длинную строку, когда недостаточно места, — вместо этого он может выделить новые области памяти и не модифицировать те, которые содержат начало строки! Новая реализация метода `Append` в CLR4 стала намного лучше. Однако это не означает, что производительность всех методов улучшилась. Например, `ToString()` работает медленнее, потому что конечную строку нужно собирать из областей памяти (в CLR2 была готовая строка во внутреннем поле). Индексатор тоже замедлился, поскольку надо искать нужную область памяти в связанном списке (в CLR2 мы могли сразу же получить нужный символ, потому что была всего одна копия строки). Но, возможно, это удачный компромисс, поскольку большое количество вызовов `Append` — самый популярный случай использования `StringBuilder`. Больше информации о различиях в реализации `StringBuilder` между CLR2 и CLR4 можно найти в [Guev, 2017].

<sup>1</sup> Весь исходный код для .NET Framework 2.0 можно найти здесь: <https://github.com/AndreyAkinshin/shared-source-cli-2.0/blob/master/clr/src/bcl/system/text/stringbuilder.cs>.

<sup>2</sup> Весь исходный код для новейшей версии .NET Framework можно найти здесь: <https://referencesource.microsoft.com/#mscorlib/system/text/stringbuilder.cs>.

Это не единственное изменение в `StringBuilder`, влияющее на его производительность, есть много других захватывающих историй. Вот несколько примеров (мы не будем обсуждать в этой книге все вопросы, связанные со `StringBuilder`, поэтому рекомендую самостоятельно прочитать эти обсуждения на GitHub):

- [corefx#4632](https://github.com/dotnet/corefx/issues/4632) (<https://github.com/dotnet/corefx/issues/4632>): *StringBuilder creates unnecessary strings with Append methods*;
- [corefx#29921](https://github.com/dotnet/corefx/issues/29921) (<https://github.com/dotnet/corefx/issues/29921>): *ValueStringBuilder is slower at appending short strings than StringBuilder*;
- [corefx#25804](https://github.com/dotnet/corefx/issues/25804) (<https://github.com/dotnet/corefx/issues/25804>): *Iterating over a string builder by index becomes ~exponentially slow for large builders*;
- [coreclr#17530](https://github.com/dotnet/coreclr/pull/17530) (<https://github.com/dotnet/coreclr/pull/17530>): *Adding GetChunks which allow efficient scanning of a StringBuilder*;
- [msbuild#1593](https://github.com/Microsoft/msbuild/issues/1593) (<https://github.com/Microsoft/msbuild/issues/1593>): *Performance issue in ReusableStringBuilder.cs with large string and many appends*.

## Выводы

- **Версия .NET Framework имеет значение.**

Большинство современных приложений для .NET Framework основаны на .NET Framework 4.x+ (CLR4). Однако в мире все еще существует много legacy-проектов, использующих .NET Framework 3.5 (CLR2). Между 3.5 и 4.0 множество различий. Если вы работаете с проектом, основанным на .NET Framework 3.5, то не можете использовать измерения в .NET Framework 4.0 для выводов о производительности вашего приложения.

- **Основные обновления среды исполнения могут содержать значительные изменения в основных алгоритмах.**

Обновления в области производительности связаны не только с улучшенными API или крайними случаями. Иногда значительные изменения могут появиться даже в базовых классах, таких как `StringBuilder`.

- **Некоторые обновления приводят к изменениям в компромиссах.**

Когда вы читаете об изменениях в области производительности в журнале обновлений, это не значит, что в новой версии среды исполнения производительность улучшится для всех возможных вариантов применения. Некоторые обновления могут просто приводить к новым компромиссам: они могут улучшить производительность часто используемых сценариев, но замедлить менее популярные сценарии. Если у вас написан сложный и нетривиальный код, после обновления среды исполнения вы можете заметить снижение производительности.

### Упражнение

Напишите две программы, использующие `StringBuilder.Insert` и `StringBuilder.Remove`. Одна из них должна быть гораздо быстрее в .NET Framework 3.5, чем в .NET Framework 4.0+, вторая — гораздо быстрее в .NET Framework 4.0+, чем в .NET Framework 3.5. Это один из моих любимых типов упражнений, потому что многие разработчики частенько с уверенностью заявляют что-то наподобие «.NET Framework 4.0+ всегда быстрее .NET Framework 3.5». Упражнение должно помочь вам понять, что глубокое знание внутреннего устройства среды исполнения часто позволяет написать бенчмарк, демонстрирующий, что одна среда быстрее другой (неважно, какая из них должна быть быстрее).

## Практический пример 2: Dictionary и рандомизированное хеширование строк

В старых версиях .NET Framework у класса `String` была известная функция хеширования, одинаковая в разных доменах приложений. Она позволяла производить атаку с помощью таблицы хеширования на такие классы, как `Dictionary` и `HashSet`. Суть атаки проста: нужно заранее найти большое количество строк с одинаковыми хеш-кодами и поместить их в словарь. В итоге алгоритмическая сложность поиска по словарю будет  $\theta(N)$  вместо  $\theta(1)$ .

В .NET Framework 4.5 было решено ввести рандомизированное хеширование строк, чтобы предотвратить подобные атаки. Из-за требований обратной совместимости (<https://github.com/dotnet/corefx/issues/1534#issuecomment-143086216>) новый алгоритм хеширования нельзя включить по умолчанию — он может навредить старому коду, использующему знания об алгоритмах хеширования предыдущих версий .NET Framework. Но если мы уже подверглись атаке, нам больше не так уж и важна совместимость с предыдущими версиями и мы можем переключить алгоритм хеширования со старого на рандомизированный. Вот фрагмент (<https://referencesource.microsoft.com/#mscorlib/system/collections/generic/dictionary.cs>) исходного кода `Dictionary` (метод `Insert`, .NET Framework 4.7.2):

```
#if FEATURE_RANDOMIZED_STRING_HASHING

#if FEATURE_CORECLR
// При достижении порогового количества коллизий необходимо
// переключиться на алгоритм сравнения, который использует
// рандомизированное хеширование строк.
// В данном случае это EqualityComparer<string>.Default.
// Рандомизированное хеширование строк включено по умолчанию
// в coreclr, поэтому EqualityComparer<string>.Default будет
// использовать рандомизированное хеширование строк
```

```

if (collisionCount > HashHelpers.HashCollisionThreshold &&
    comparer == NonRandomizedStringEqualityComparer.Default)
{
    comparer = (IEqualityComparer<TKey>) EqualityComparer<string>.Default;
    Resize(entries.Length, true);
}
#else
if (collisionCount > HashHelpers.HashCollisionThreshold &&
    HashHelpers.IsWellKnownEqualityComparer(comparer))
{
    comparer = (IEqualityComparer<TKey>)
        HashHelpers.GetRandomizedEqualityComparer(comparer);
    Resize(entries.Length, true);
}
#endif// FEATURE_CORECLR

#endif

```

Как видите, если `collisionCount` больше, чем `HashHelpers.HashCollisionThreshold` (в .NET Framework 4.7.2 он равен 100), и используется `IEqualityComparer` из предыдущих версий, мы меняем `comparer`.

Это поведение можно контролировать с помощью свойства `UseRandomizedStringHashAlgorithm` (<https://docs.microsoft.com/en-us/dotnet/framework/configure-apps/file-schema/runtime/userandomizedstringhashalgorithm-element>) в `app.config`. Пример:

```

<?xml version ="1.0"?>
<configuration>
  <runtime>
    <UseRandomizedStringHashAlgorithm enabled="1" />
  </runtime>
</configuration>

```

В .NET Core нет проблем с совместимостью с предыдущими версиями, поэтому рандомизированное хеширование строк включено по умолчанию. Более подробную информацию об этом можно найти в [Lock, 2018].

## Выводы

- **Производительность метода может быть изменена посреди программы.**

В главе 2 мы обсудили, что для бенчмаркинга важен прогрев: первый вызов метода может занять гораздо больше времени, чем последующие. Однако это не единственный случай, когда производительность метода способна измениться. В .NET Framework есть набор эвристических правил, которые в особых случаях могут повлиять на внутреннюю реализацию. Если мы хотим написать хороший бенчмарк, то должны знать о таких возможностях и отдельно измерять разные способы использования API.

- **Внутренние алгоритмы можно настроить с помощью настроек `app.config`.**

Мы уже знаем, что разные версии .NET Framework могут иметь различия в производительности из-за изменений в реализации. А еще мы можем вручную повлиять на используемые алгоритмы с помощью выставления специальных флагов в `app.config` или с помощью переменных окружения.

- **.NET Framework и .NET Core могут иметь разные алгоритмы для одного и того же API.**

В .NET Framework и .NET Core совпадает основная часть баз кода. Обычно мы наблюдаем один и тот же уровень производительности для одних и тех же базовых классов (сопоставить версии .NET Framework и .NET Core не всегда просто, но можно проверить исходный код каждой версии каждой среды исполнения). Однако поведение некоторых классов может различаться даже в одинаковых версиях: в .NET Framework содержится много приемов, обеспечивающих совместимость с предыдущими версиями, которые были убраны из .NET Core.

### Упражнение

Попробуйте реализовать атаку с помощью функции хеширования на `HashSet` или `Dictionary` с выключенным `FEATURE_RANDOMIZED_STRING_HASHING` (нужно найти больше 100 разных строк с одинаковыми хеш-кодами). Напишите бенчмарк, демонстрирующий разницу в производительности между старой и новой стратегиями хеширования. Это упражнение должно помочь вам узнать, как использовать внутренние детали реализации, находить вырожденные случаи и демонстрировать производительность для распространенных API.

## Практический пример 3: `IList.Count` и неожиданное снижение производительности

Эта история посвящена разработке JetBrains Rider. Когда был выпущен Rider 2017.1, он использовал Mono 4.9. Затем мы начали обновлять его до Mono 5.2. К сожалению, после обновления некоторые тесты производительности «покраснели». Сначала у нас были проблемы с анализом ошибок в коде всего решения (Solution-Wide Error Analysis, SWEA). На Mono 4.9 один из тестов занимал около 3 мин (мы пытаемся найти все ошибки и предупреждения в решениях, это занимает какое-то время). После обновления этот тест упал после истечения времени ожидания через 5 мин. Было сложно расследовать данный случай, потому что в Mono 4.9/5.2 все было очень плохо с профилированием (продвинутое профилирование появилось только в Mono 5.6). Если мы запускали этот тест с профилированием (`mono --profile`) с достаточной частотой замеров, он занимал около 30 мин, а снимок состояния весил около 50 Гбайт и его было почти невозможно открыть.

Через несколько недель безуспешных попыток профилирования мы решили найти другие тесты с той же проблемой и небольшим общим временем исполнения. Однако оказалось, что длительность почти всех наших тестов совпадала в обеих версиях Mono. Поэтому мы отсортировали все тесты по разнице в производительности между 4.9 и 5.2. Наверху оказались два вида тестов: SWEA и завершение кода (code completion)! Тест на завершение кода выглядит примерно так: мы открываем файл, передвигаем курсор в конкретное место, нажимаем Ctrl+Пробел, ждем списка возможных вариантов для завершения кода, нажимаем Enter, завершаем выражение. Один подобный тест занимал 4 с на Mono 4.9 и 18 с на Mono 5.2! Разница огромная, но довольно маленькая с точки зрения профилирования: создать снимок производительности гораздо проще для 18-секундного сеанса, чем для 5-минутного. Конечно, с первой попытки мы проблему не нашли. Измерение показало примерное место снижения производительности. Далее мы начали добавлять Stopwatch в разных местах (это же снижение производительности с 4 до 18 с, его ведь должно быть легко найти?). Еще через несколько дней исследований мы наконец нашли строчку, ответственную за снижение. Она содержала вызов Count для объекта IList<>. Сначала я не поверил, что это действительно то самое место, поэтому создал минимальный пример воспроизведения и написал микробенчмарк с помощью BenchmarkDotNet:

```
private readonly IList<object> array = new string[0];
```

```
[Benchmark]
```

```
public int CountProblem() => array.Count;
```

Вот результаты на Linux:

```
BenchmarkDotNet=v0.10.9, OS=ubuntu 16.04
Processor=Intel Core i7-7700K CPU 4.20GHz (Kaby Lake), ProcessorCount=8
Mono49 : Mono 4.9.0 (mono-49/f58eb9e642b Tue), 64bit
Mono52 : Mono 5.2.0 (mono-52/da80840ea55 Tue), 64bit
```

Runtime	Mean	Error	StdDev
Mono49	5.038 ns	0.2869 ns	0.8459 ns
Mono52	1,471.963 ns	19.8555 ns	58.5445 ns

А вот — на macOS:

```
BenchmarkDotNet=v0.10.9, OS=Mac OS X 10.12
Processor=Intel Core i7-4870HQ CPU 2.50GHz (Haswell), ProcessorCount=8
Mono49 : Mono 4.9.0 (mono-49/f58eb9e642b Tue), 64bit
Mono52 : Mono 5.2.0 (mono-52/da80840ea55 Tue), 64bit
```

Runtime	Mean	Error	StdDev
Mono49	5.548 ns	0.0631 ns	0.1859 ns
Mono52	2,443.500 ns	44.6687 ns	131.7068 ns

Как видите, вызов `Count` занимает около 5 нс на Linux/macOS+Mono 4.9, около 1500 нс на Linux+Mono 5.2 и около 2500 нс на macOS+Mono 5.2. Это сильно влияет на Rider в некоторых местах, например в тесте на завершение кода и в тесте на SWEA. Возможно, преобразовывать `string[]` в `IList` — не очень хорошая идея, но у нас был такой шаблон глубоко внутри разных подсистем Rider, а обнаружить и перепроектировать его непросто.

Теперь нужно понять, почему мы получили такую значительную деградацию в таком простом месте. Если вы внимательно читали об изменениях Mono в области производительности, то могли заметить упоминание об отложенной инициализации интерфейсов массивов в Mono 5.0. Вот фрагмент из официальной документации релиза ([www.mono-project.com/docs/about-mono/releases/5.0.0/#lazy-array-interfaces](http://www.mono-project.com/docs/about-mono/releases/5.0.0/#lazy-array-interfaces)): «Отложенная инициализация интерфейсов массивов. Одним из любопытных аспектов C# является то, что массивы реализуют инвариантные интерфейсы, словно ковариантные. Это происходит с `IList<T>`, `ICollection<T>` и `IEnumerable<T>`. Например, `string[]` реализует и `IList<string>`, и `IList<object>`».

Mono традиционно реализовывала это с помощью создания со стороны среды исполнения метаданных для всех этих интерфейсов, и это приводило к большим затратам памяти на создание множества интерфейсов, которые никогда не упоминались в коде на C#.

В Mono 5.0 мы теперь относимся к этим интерфейсам как к волшебным/особенным и используем другой путь выполнения кода приведения. Это позволяет использовать отложенную инициализацию для массивов, что сохраняет большое количество памяти при большом количестве LINQ-запросов. В процессе выполнения этой задачи мы перепроектировали код приведения в JIT-компиляторе, чтобы сделать его проще и удобнее для поддержки».

К сожалению, в диспетчеризацию методов интерфейсов закралась ошибка. Мы связались с разработчиками Mono, поэтому ее быстро исправили (<https://github.com/mono/mono/pull/5486>). Мы применили к Mono 5.2 патч с этим исправлением и выпустили Rider 2017.2 не только без какого-либо снижения производительности, но и с некоторыми улучшениями.

## Выводы

- **Обновления среды исполнения могут непредсказуемо повлиять на любые фрагменты вашего кода.**

Читать журналы изменений полезно, если вы обновляете среду исполнения или сторонние библиотеки. Это может помочь вам предугадать серьезные проблемы. Но невозможно знать заранее, как эти изменения повлияют на ваше приложение. Не доверяйте интуиции, внимательно измеряйте производительность перед обновлением.

- **Реализация простого API может в некоторых случаях серьезно повлиять на производительность.**

До этого случая я не верил, что можно столкнуться с серьезными проблемами с производительностью из-за реализации `IList<>.Count`. При виде таких вызовов обычно думаешь: об их производительности беспокоиться нечего, потому что они всегда работают очень быстро. Но даже самые простые вызовы API могут сильно повлиять на производительность, особенно если вы вызываете их слишком часто, сталкиваетесь с пограничными случаями или они содержат ошибки.

### Упражнение

Попробуйте воспроизвести эту проблему локально. Если вы хотите исследовать изменения производительности в среде исполнения, нужно узнать, как устанавливать (или собирать из исходного кода) разные версии среды (например, Mono) и запускать бенчмарк в каждой из них.

## Практический пример 4: время сборки и разрешение `GetLastWriteTime`

Следующая история также посвящена обновлению Rider. В Rider 2018.2 мы решили обновить Mono с 5.10 до 5.12. Как говорилось в предыдущем примере, внимательно читать журналы изменений — полезное занятие. Вот короткая цитата из документации релиза Mono 5.12 (<http://www.mono-project.com/docs/about-mono/releases/5.12.0/>): «Добавлена поддержка наносекундного разрешения в информации о файле на платформах, где эта информация доступна. Таким образом, итоговое значение некоторых API, например `FileInfo.GetLastWriteTime()`, стало более точным».

Рассмотрим это изменение (<https://github.com/mono/mono/pull/6307>) подробнее. Вот значения `File.GetLastWriteTime(filename).Ticks` для одного и того же файла в Mono 5.10 и Mono 5.12 (1 тик = 100 нс):

`InternalTicks`

Mono 5.10: 636616298110000000

Mono 5.12: 636616298114479590

Как видите, в старых версиях Mono была информация только о секундах (10 000 000 тиков равны 1 с). В новых версиях появилась информация о миллисекундах и микросекундах. Это определенно полезное улучшение, но оно ломает обратную совместимость. Кажется, что оно безобидно и не повлияет на производительность.

Но на самом деле может и повлиять. Как обычно, мы решили проверить, что в новой версии Mono нет снижения производительности. И обнаружили множество тестов с увеличившимся временем выполнения. Как такое возможно? Давайте разберемся!

У Rider есть интересная функция под названием «система сборки решений» (Solution Builder). Нетрудно догадаться, что она собирает решения. Очевидно, если решение уже собиралось ранее и пользователь просит собрать его заново, мы не должны пересобирать проекты без изменений. У системы сборки решений есть набор эвристических алгоритмов, позволяющих определять такие проекты. Один из них использует последнее изменение времени файла, чтобы найти файлы без изменений.

Система сборки решений состоит из двух частей. Первая размещается в основном процессе Rider, запускающемся на встроенной версии Mono (эта версия зафиксирована для каждого релиза Rider). В этом процессе мы сохраняем информацию о времени последней модификации файлов в кэше. Вторая часть размещается в MSBuild-процессе<sup>1</sup>, использующем установленную версию Mono (эта версия зависит от пользовательского окружения). Здесь мы проверяем актуальное время последней модификации файла. Далее сравниваем эти два значения, кэшированное и актуальное, и решаем, нужно ли собирать проект.

Представьте ситуацию, когда Rider использует Mono 5.12, а у пользователя установлена Mono 5.10. Это означает, что в кэшированных значениях времени есть данные о миллисекундах/микросекундах, а в актуальных значениях их нет. В предыдущем примере эти значения были равны 636616298114479590 и 636616298110000000. То есть вероятность того, что эти два значения будут равны, крайне мала. В итоге система сборки решений все время пересобирает все проекты, а это неправильное поведение. Конечно, мы проверяли систему сборки решений с помощью множества тестов, но они проводились только под Windows (по историческим причинам), где мы используем .NET Framework. Под Linux/macOS мы таких тестов для Rider 2018.1 автоматически не запускали, поэтому система сборки решений считалась исправной. Однако мы обнаружили серьезное снижение производительности по некоторым тестам, поскольку Rider выполнял лишние сборки решений. Ошибка была быстро найдена и исправлена.

Здесь не проводилось долгое исследование производительности, тем не менее эта история поучительна.

**Вывод: небольшие безобидные изменения могут значительно повлиять на производительность.**

<sup>1</sup> Мы обсудим это в разделе «Компиляция».

Этот пример снова напоминает нам, что предсказать, как изменения воздействуют на производительность большого приложения, очень сложно. Не забывайте все измерять и не доверяйте своей интуиции.

### Упражнение

Как обычно, попробуйте локально воспроизвести описанное изменение в Mono: загрузите Mono 5.10 и 5.12, затем вызовите `File.GetLastWriteTime(filename).Ticks` для произвольного файла. Попробуйте вызвать его также в .NET Framework и .NET Core.

## Подводя итог

В этом разделе мы обсудили три самые популярные среды исполнения .NET: .NET Framework, .NET Core и Mono. .NET Framework защищена правом собственности и работает только в Windows, а .NET Core и Mono предоставляются бесплатно и являются кросс-платформенными. Теперь мы знаем краткую историю этих сред исполнения и способы узнать точную версию каждой из них.

Какую бы среду исполнения вы ни использовали, не забывайте, что даже небольшие изменения в обновлениях среды могут непредсказуемо повлиять на производительность в самых неожиданных местах. Не забывайте всегда измерять все варианты применения приложения, в которых важна производительность.

Если у вас получились некоторые результаты бенчмаркинга в одной среде исполнения, не экстраполируйте их на всю экосистему .NET. Помните, что сред исполнения .NET много и у каждой своя реализация.

В следующем разделе поговорим о превращениях исходного кода в машинный.

## Компиляция

Если вы хотите запустить свою программу на C#<sup>1</sup>, сначала нужно ее скомпилировать. После компиляции мы получаем бинарный файл, основанный на промежуточном языке IL (Intermediate Language). Когда этот файл исполняется средой, наступает следующая стадия компиляции: среда исполнения трансформирует его

<sup>1</sup> С платформой .NET могут использоваться многие языки. Кроме C#, есть еще два довольно популярных языка — Visual Basic .NET и F#, а также много других, менее популярных, например Managed C++ или Q#. Здесь и далее будем обсуждать C#, но почти все сказанное подходит и для других языков для .NET.

в машинный код. Эта трансформация называется JIT-компиляцией. Есть много инструментов, которые могут производить эту трансформацию заранее — перед запуском приложения. Такой процесс называется АОТ-компиляцией (Ahead-of-Time). Чтобы избежать путаницы, первую стадию компиляции будем называть генерацией промежуточного языка.

В данном разделе обсудим следующие аспекты этих трех видов компиляции:

- виды компиляторов и различия между ними;
- как узнать точную версию компилятора;
- как повлиять на процесс компиляции.

Начнем с первой стадии компиляции — генерации промежуточного языка.

## Генерация промежуточного языка

В этом подразделе поговорим об инструментах, помогающих компилировать и собирать исходный код.

### Компилирование

Если мы хотим скомпилировать программу на С#, нам нужен *С#-компилятор*, переводящий код с С# на промежуточный язык<sup>1</sup>. Обсудим самые популярные компиляторы.

- **Старые компиляторы С#/VB.**

В эпоху С# 1 — С# 5 компиляторы С# и VB были частью .NET Framework. Они были написаны на С++.

- **Roslyn.**

Roslyn — современный компилятор с открытым исходным кодом (<https://github.com/dotnet/roslyn>) для С# и Visual Basic. Для Microsoft было довольно сложно поддерживать старые компиляторы С#/VB и вводить новые функции. Поэтому было решено переписать их на С#. Так и появился Roslyn. Первая СТР-версия была представлена в октябре 2011 года и распространялась в качестве части Visual Studio 2010 SP1 (см. [Osenkov, 2011]). Первая версия компилятора выпущена в июле 2015-го (см. [Lander, 2015]) вместе с .NET Framework 4.6 и Visual Studio 2015. В эту версию была включена поддержка С# 6 и VB 14. Все последующие релизы С# и VB также основаны на Roslyn. Последняя версия С#,

---

<sup>1</sup> Промежуточный язык (IL) известен также как CIL (общий промежуточный язык) или MSIL (промежуточный язык Microsoft).

поддерживаемая старым компилятором, — C# 5. Roslyn распространяется отдельно от .NET Framework. Конкретную версию Roslyn можно загрузить с помощью NuGet-пакета Microsoft.Net.Compilers ([www.nuget.org/packages/Microsoft.Net.Compilers/](http://www.nuget.org/packages/Microsoft.Net.Compilers/)). Полную историю Roslyn вы найдете в [Torgersen, 2018].

- **Компилятор Mono C#.**

Исторически у Mono был собственный компилятор — Mono C#<sup>1</sup>. Он был разработан в качестве кросс-платформенной замены с открытым исходным кодом компилятору Microsoft C#. Изначально существовало несколько разных версий этого компилятора — gmcs, smcs, dmcs (<https://stackoverflow.com/q/3882590>). Начиная с Mono 2.11, появилась универсальная версия — mcs. Начиная с Mono 5.0, компилятор по умолчанию сменили с mcs на Roslyn, который теперь встроен в Mono. Но mcs продолжает обновляться в новых версиях Mono.

Если вы установили .NET Framework 4.x, старый компилятор для C# можно найти в C:\Windows\Microsoft.NET\Framework\v4.0.30319\Csc.exe. Запустив его, вы увидите такое стандартное сообщение:

```
Microsoft (R) Visual C# Compiler version 4.7.3056.0 for C# 5
Copyright (C) Microsoft Corporation. All rights reserved.
```

```
This compiler is provided as part
of the Microsoft (R) .NET Framework,
but only supports language versions up to C# 5,
which is no longer the latest version.
For compilers that support newer versions
of the C# programming language,
see http://go.microsoft.com/fwlink/?LinkID=533240
```

Компилятор Roslyn не является частью .NET Framework, поэтому его нужно устанавливать отдельно. Один из типичных путей установки для Windows выглядит примерно так: C:\Program Files (x86)\Microsoft Visual Studio\2017\Community\MSBuild\15.0\Bin\Roslyn\csc.exe (этот путь действителен для Visual Studio Community 2019). Если его запустить, стандартное сообщение будет выглядеть так:

```
Microsoft (R) Visual C# Compiler version 2.9.0.63208 (958f2354)
Copyright (C) Microsoft Corporation. All rights reserved.
```

Отметьте, что название обоих компиляторов совпадает (Visual C# Compiler), но у Roslyn ниже номер версии (2.9 вместо 4.7). Это не означает, что это старая версия компилятора для C#. После создания Roslyn Microsoft начала нумерацию версий с 1.0. Старый компилятор можно легко узнать по указанию, что он для C# 5.

---

<sup>1</sup> В Mono 5.8 его переименовали в Mono Turbo C#: <https://github.com/mono/mono/commit/7d68dc8e71623ba76b16c5c5aa597a2fc7783f16>.

## Сборка

Если у вас большое проектное решение с множеством файлов, довольно тяжело вручную определить все аргументы, которые надо передать в компилятор. К счастью, мы можем использовать *систему сборки*, управляющую процессом компиляции: она контролирует не только то, как мы компилируем отдельные файлы с исходным кодом, но и то, как собрать целое решение со многими проектами и какие нужны дополнительные меры. Существует несколько инструментов, которые могут собрать проекты и решения на платформе .NET.

- **MSBuild.**

Это самый популярный инструмент для сборки в экосистеме .NET. Изначально это был проект с закрытым кодом, предназначенный только для Windows и распространяющийся как часть .NET Framework. Сегодня MSBuild — кросс-платформенный проект с открытым исходным кодом (<https://github.com/Microsoft/msbuild>). Его можно установить разными способами, например получить с Visual Studio, установить инструменты для сборки для Visual Studio (<https://visualstudio.microsoft.com/downloads/#build-tools-for-visual-studio-2017>) или собрать из исходного кода. Последние версии MSBuild включают в себя Roslyn для компилирования файлов на C# и VB.

- **.NET Core CLI.**

CLI (инструмент командной строки) позволяет производить все базовые операции по разработке: сборку, тестирование, развертывание и т. д.<sup>1</sup> У него есть собственная версия MSBuild.

- **XBuild.**

Это классический инструмент для сборки для Mono. В прежние времена это был единственный способ собирать проекты на Linux и macOS. Начиная с Mono 5.0, XBuild был помечен как устаревший (deprecated), потому что в Mono теперь входит MSBuild в качестве системы сборки по умолчанию.

- **Другие системы сборки.**

Многим разработчикам не нравится MSBuild в чистом виде, и они пробуют использовать разные системы для сборки в придачу к нему. В основном эти системы предлагают DSL (предметно-ориентированный язык), который упрощает конфигурацию процесса сборки. К популярным системам сборки относятся *Fake*, *Cake* и *Nuke*<sup>2</sup>.

Сейчас самый популярный набор инструментальных средств — MSBuild + Roslyn. Однако некоторые проекты могут все еще использовать старый компилятор C#

<sup>1</sup> Его можно загрузить здесь: [www.microsoft.com/net/download](http://www.microsoft.com/net/download).

<sup>2</sup> <https://fake.build/>, <https://cakebuild.net/>, <https://nuke.build/>.

или XBuild. Мы обсуждаем эти технологии, потому что они предоставляют много хороших примеров, демонстрирующих, как изменения в компиляторе могут повлиять на производительность приложений.

Когда MSBuild и компилятор для C# были частью .NET Framework, существовало всего несколько широко распространенных версий компилятора. С новым расписанием релизов, которое появилось с Visual Studio 2017 ([www.visualstudio.com/en-us/productinfo/vs2017-release-rhythm](http://www.visualstudio.com/en-us/productinfo/vs2017-release-rhythm)), обновления компилятора выходят постоянно.

## Конфигурации сборки

Создавая новый проект в Visual Studio, можно выбрать две конфигурации сборки по умолчанию: Отладка (Debug) и Релиз (Release). Если мы откроем файл `csproj` классического приложения, то найдем там такие строчки (некоторые были удалены для упрощения):

```
<PropertyGroup Condition="'$(Configuration)|$(Platform)'=='Debug|AnyCPU' ">
  <DebugSymbols>true</DebugSymbols>
  <DebugType>full</DebugType>
  <Optimize>>false</Optimize>
  <OutputPath>bin\Debug\</OutputPath>
</PropertyGroup>
<PropertyGroup Condition="'$(Configuration)|$(Platform)'=='Release|AnyCPU' ">
  <DebugType>pdbonly</DebugType>
  <Optimize>>true</Optimize>
  <OutputPath>bin\Release\</OutputPath>
</PropertyGroup>
```

Самый важный для нас элемент — `<Optimize>`. Это значение передается в компилятор и контролирует режим оптимизации. По умолчанию оптимизации отключены, но мы можем специально вызвать компилятор с включенными оптимизациями с помощью флага `/optimize`:

```
csc /optimize Program.cs
```

В файле `csproj` мы можем определять собственную конфигурацию сборки с конкретными правилами для `<Optimize>`. Можем даже включить оптимизации в режиме отладки и отключить их в режиме релиза. Но это нетипичная конфигурация. В этой книге мы будем использовать самую распространенную ситуацию: Релиз означает `<Optimize>true</Optimize>`, а Отладка — `<Optimize>>false</Optimize>`. Нужную конфигурацию MSBuild можно контролировать с помощью `/p:Configuration`:

```
msbuild /p:Configuration=Release Project.csproj
```

Если вы используете .NET Core SDK, вам нужна `--configuration` или просто `-c`:

```
dotnet build -c Release Project.csproj
```

Будьте внимательны: *Отладка* (конфигурация сборки с *отключенными* оптимизациями) всегда является опцией по умолчанию. Этот режим хорош для отлаживания, но не очень подходит для бенчмаркинга.

## Версия языка и версии компилятора

Иногда разработчики путают версию C# и версию компилятора C#. Версия C# — это версия спецификации языка. *Версия компилятора C#* — это версия программы, которая переводит исходный код C# на промежуточный язык. Выясним, в чем разница, с помощью старого компилятора C#. Рассмотрим следующую программу:

```
var numbers = new int[] { 1, 2, 3 };
var actions = new List<Action>();
foreach (var number in numbers)
    actions.Add(() => Console.WriteLine(number));
foreach (var action in actions)
    action();
```

У нее два возможных результата: 3 3 3 и 1 2 3. Старые версии компилятора C# создавали отдельное поле для `number`, которое использовалось потом во всех лямбда-выражениях. После окончания цикла значение поля `number` равно 3. Поскольку все лямбда-выражения ссылаются на одно и то же поле, все они выдадут 3 (более подробное объяснение есть в [Lippert, 2009]). Это часто путало разработчиков, поэтому команда создателей компилятора решила внести изменение, ломающее обратную совместимость. Теперь компилятор вводит отдельное поле для каждой итерации цикла. То есть мы получаем результат 1 2 3, потому что у каждого лямбда-выражения есть собственное поле.

Это изменение было внесено в компилятор, а не в версию языка. Рассмотрим некоторые возможные конфигурации компиляции в табл. 3.5.

**Таблица 3.5.** Замыкания в различных версиях старого компилятора C#

Версия компилятора	Командная строка	Результат
3.5.30729.7903 (C#3)	v3.5/csc.exe	3 3 3
4.0.30319.1 (C#4)	v4.0.30319/csc.exe	3 3 3
4.0.30319.33440 (C#5)	v4.0.30319/csc.exe	1 2 3
4.0.30319.33440 (C#5)	v4.0.30319/csc.exe /langversion:4	1 2 3

Обсудим это подробнее.

- **3.5.30729.7903** — это *версия компилятора*, поддерживающая C#3.
- **4.0.30319.1** — это *версия компилятора*, поддерживающая C#4.
- **4.0.30319.33440** — это *версия компилятора*, поддерживающая C#5.

- **4.0.30319.33440 с langversion:4** — это *версия компилятора*, поддерживающая C#5 и направленная на C#4. Мы можем определить нужную версию языка для компилятора C# с помощью аргумента `/langversion`. То есть можем запустить компилятор C# 4.0.30319.33440 для C#4, а не для C#5. В целом это означает, что мы не будем использовать функции языка C#5, такие как асинхронные методы. Но это *не означает*, что у нас получится такой же код на промежуточном языке, как в компиляторе C# 4 (4.0.30319.1). Как можно видеть, с `/langversion:4` мы все равно получаем результат 1 2 3. Изменение, ломающее обратную совместимость, сохранилось.

Компилятор C# производит код на промежуточном языке, а не машинный код. Далее мы обсудим следующую стадию компиляции — JIT-компиляцию. Иногда будем называть компилятор из этого подраздела генератором промежуточного языка, обычным компилятором или компилятором C#, чтобы избежать путаницы с JIT-компилятором. Для краткости я также буду называть его Roslyn, потому что это самый популярный компилятор для .NET, но большая часть выводов может быть применена и к старому компилятору C# или другим генераторам промежуточного языка (например, у F# есть собственный компилятор, этот язык не поддерживается Roslyn).

## JIT-компиляция

JIT-компиляция (Just-In-Time) — это прекрасная технология, преобразующая код на промежуточном языке в машинный код (я также буду называть его ассемблерным кодом или просто *ASM*-кодом). Вот некоторые из основных преимуществ компиляции JIT.

- Код на промежуточном языке не зависит от аппаратных средств, поэтому можно использовать один и тот же бинарный файл на разных платформах.
- Компилятор JIT компилирует только те методы, которые вам действительно нужны.
- Сгенерированный код может быть оптимизирован под текущий профиль использования.
- Некоторые методы могут быть сгенерированы заново для улучшения производительности.

В этом разделе мы обсудим разные JIT-компиляторы в экосистеме .NET.

В первых версиях .NET Framework было два компилятора JIT: *JIT32* и *JIT64* (для 32- и 64-битной версий платформы). Оба они имели независимые базы кода и разные наборы оптимизаций. После нескольких лет разработки их стало очень сложно поддерживать и улучшать, поэтому было принято решение написать компилятор

JIT следующего поколения под названием *RyuJIT*<sup>1</sup>. Изначально *JIT32* и *JIT64* не имели кодовых названий, потому что у .NET был только один компилятор JIT для каждой платформы. Чтобы избежать путаницы, в этой книге я буду использовать термины *LegacyJIT-x86* и *LegacyJIT-x64*.

Команда .NET начала проектировать RyuJIT в 2009 году, к разработке приступили в 2011-м, первая предварительная версия была анонсирована в сентябре 2013 года (см. [RyuJIT, 2013]), и окончательно он был выпущен в 2015-м (только x64): RyuJIT стал JIT-компилятором x64- по умолчанию в .NET Framework 4.6. То есть, если у вас 64-битное приложение на .NET 4.0, оно будет автоматически использовать RyuJIT после установки .NET Framework 4.6+.

У ранних версий RyuJIT было много проблем, особенно на стадии СТР. Некоторые из них были связаны с производительностью (в сравнении с LegacyJIT он выдавал медленный код). Другие были критическими ошибками и вызвали большие проблемы в некоторых реальных продуктах<sup>2</sup>. Но сейчас RyuJIT стал довольно стабильным, надежным и быстрым JIT-компилятором. Путь разработки был тернист, но в итоге мы получили крутой новый JIT-компилятор. Еще один интересный факт: оригинальный исходный код RyuJIT-x64 был основан на LegacyJIT-x86, поэтому у этих двух компиляторов много схожих оптимизаций.

Если вы хотите перейти обратно на LegacyJIT-x86 в .NET Framework, есть несколько способов это сделать. Можно установить `<useLegacyJit enabled="1" />` в разделе `configuration/runtime` вашего `app.config`, определить переменную окружения `COMPLUS_useLegacyJit=1` или добавить 32-битное значение `DWORD useLegacyJit=1` в подключках реестра `Windows HKEY_LOCAL_MACHINE\SOFTWARE\Microsoft\ .NETFramework` и `HKEY_CURRENT_USER\SOFTWARE\Microsoft\ .NETFramework`. Полные актуальные инструкции по отключению RyuJIT можно найти в [MSDOCS RyuJIT].

Начнем разбираться в том, какой JIT-компилятор (LegacyJIT или RyuJIT) используется в x64-программе. Хочу рассказать об одном из моих любимых приемов, который я применял много лет.

Рассмотрим следующий метод:

```
int bar;  
  
bool Foo(int step = 1)
```

<sup>1</sup> Краткий рассказ о происхождении этого названия здесь: <https://github.com/dotnet/coreclr/blob/master/Documentation/botr/ryujit-tutorial.md#why-ryujit>.

<sup>2</sup> Есть знаменитый пост Ника Кравера со StackOverflow: [Craver, 2015]. Это интригующая история о проблемах с предупреждением об ошибках на производственных серверах StackOverflow после обновления .NET до 4.6. Ее стоит прочитать и сходить по всем ссылкам в посте.

```

{
    var value = 0;
    for (int i = 0; i < step; i++)
    {
        bar = i + 10;
        for (int j = 0; j < 2 * step; j += step)
            value = j + 10;
    }
    return value == 20 + step;
}

```

Если вы вызовете этот метод в LegacyJIT-x64 с *включенной* оптимизацией, Foo вернет значение true: value будет равным 21 вместо 11. Вы найдете подробное описание этой ошибки с примерами исходного кода на ассемблере в [Akinshin, 2015]. В Microsoft Connect был отправлен отчет об ошибке<sup>1</sup>, но он был закрыт с пометкой «Закрыт как Won't Fix. В связи с несколькими факторами команда этого продукта решила сосредоточить свои усилия на других задачах». То есть, если запустить этот код в качестве x64-приложения в .NET Framework и Foo вернет значение true, используется LegacyJIT-x64. Если нет, значит, среда исполнения применяет RyuJIT-x64.

Другой способ основан на списке модулей jit, который загружен в текущий процесс. Его можно вывести таким образом:

```

var modules = Process.GetCurrentProcess().Modules
    .OfType<ProcessModule>()
    .Where(module => module.ModuleName.Contains("jit"));
foreach (var module in modules)
    Console.WriteLine(
        Path.GetFileNameWithoutExtension(module.FileName) + " " +
        module.FileVersionInfo.ProductVersion);

```

В CLR2 вы увидите mscorjit. Это всегда означает, что используется LegacyJIT, потому что это единственный компилятор JIT, применяемый в CLR2. В CLR4 у RyuJIT-x64 только один модуль — clrjit (в прошлом известен как protojit). У LegacyJIT-x64 два модуля: clrjit и compatjit. То есть, если вы видите в списке модулей compatjit, это значит, что применяется LegacyJIT. RyuJIT-x86 недоступен в .NET Framework — для программ с x86 единственным вариантом является LegacyJIT-x86.

Теперь поговорим о компиляторах JIT в .NET Core. .NET Core 1.x использует RyuJIT-x64 для x64 и LegacyJIT-x86 для x86 (версия x86 доступна только для Windows). В .NET Core 2.0 LegacyJIT-x86 был заменен на RyuJIT-x86 (<https://github.com/dotnet/announcements/issues/10>). В итоге весь код, связанный с LegacyJIT-x86, удален из

<sup>1</sup> Эта страница недоступна, потому что сервис устарел.

исходного кода .NET Core (<https://github.com/dotnet/coreclr/pull/18064>). .NET Framework и .NET Core пользуются одной и той же кодовой базой RyuJIT-x64<sup>1</sup>.

В Mono JIT-компилятор не имеет известного имени, поэтому будем называть его *MonoJIT*. Это часть среды исполнения Mono, поэтому в него вносятся улучшения при каждом обновлении Mono. В придачу к JIT-компилятору по умолчанию у нас есть опция *Mono LLVM* для JIT-компиляции, использующая LLVM<sup>2</sup> для генерации машинного кода (доступна с момента выхода Mono 2.6). Ее можно контролировать с помощью аргументов `--nollvm` или `--llvm`.

В табл. 3.6 приведена матрица совместимости между разными компиляторами JIT и средами исполнения .NET.

**Таблица 3.6.** Совместимость компиляторов JIT

JIT	.NET Framework	.NET Core	Mono
LegacyJIT-x86	1.0+	1.x	—
LegacyJIT-x64	2.0+	—	—
RyuJIT-x86	—	2.0+	—
RyuJIT-x64	4.6+	1.0+	—
MonoJIT	—	—	1.0+
MonoLLV	—	—	2.6+

В следующем подразделе обсудим еще один подход к генерации платформенно-ориентированного кода.

## Компиляция Ahead-of-Time (AOT)

JIT-компилятор генерирует машинный код для метода в тот момент, когда вы хотите вызвать этот метод. Данная стратегия используется по умолчанию для большинства приложений .NET, но она — не единственная существующая. Вы также можете компилировать свой код заранее с помощью AOT-компилятора (Ahead-of-Time) и создать бинарные файлы, которым не нужен JIT-компилятор. У AOT-компиляции есть плюсы и минусы в сравнении с JIT-компиляцией: в некоторых случаях она может значительно улучшить производительность, но способна и навредить.

<sup>1</sup> Вы можете найти интересные технические детали на GitHub: <https://github.com/dotnet/coreclr/issues/14250>.

<sup>2</sup> LLVM — популярное кросс-платформенное решение для генерации платформенно-ориентированного кода на разных платформах, основанное на промежуточном представлении. Больше информации можно найти на официальном сайте <https://llvm.org/>.

Преимущества АОТ (в сравнении с JIT) таковы.

- **Сокращение времени запуска.**

JIT-компилятор может потратить много времени на изначальную загрузку сборки (assembly) и замедлить время запуска. В случае АОТ-компилятора таких проблем нет.

- **Уменьшение объема используемой памяти.**

Если несколько приложений используют одну сборку, они могут пользоваться одним машинным образом сборки. То есть общее количество используемой памяти может быть сокращено.

- **Улучшение оптимизаций.**

JIT-компилятор должен работать быстро, и ему не хватает времени на все полезные оптимизации. АОТ-компилятор не ограничен временем компилирования, поэтому у него есть возможность подумать о том, как лучше всего оптимизировать код.

Недостатки АОТ (в сравнении с JIT) следующие.

- **Оптимизации не всегда лучше.**

Компиляция АОТ не гарантирует, что все оптимизации будут лучше. У компилятора JIT есть информация о текущем сеансе среды исполнения, поэтому он может создавать более производительный машинный код. Также он может более эффективно размещать сгенерированный код в оперативной памяти (например, если у вас есть цепочка вызовов методов, JIT-компилятор разместит их рядом друг с другом).

- **Ограничения API.**

Не всегда есть возможность использовать все .NET API в АОТ-компиляторе. Например, у вас могут появиться проблемы с динамической загрузкой сборок, динамическим исполнением кода, рефлексией, обобщенными классами и интерфейсами и другими API.

- **Ограничения по сопряжению JIT/АОТ.**

Если у вас есть взаимодействие между методами, скомпилированными АОТ и JIT, может появиться заметное снижение производительности из-за затрат на передачу данных между такими методами.

- **Усложнение процесса сборки.**

АОТ-компиляция обычно занимает гораздо больше времени, чем JIT-компиляция. Кроме того, вам нужно сгенерировать отдельные собственные бинарные файлы для всех нужных платформ.

- **Большой размер бинарных файлов.**

JIT-компилятор может создавать машинный код только для тех методов, которые вы на самом деле вызываете. Компилятор AOT должен сгенерировать машинный код для всех классов и методов, потому что вы заранее не знаете, какой метод будет вызван. JIT-компилятор может удалить какие-то ветви исходного кода, основываясь на информации от среды исполнения, такой как значения `readonly`-полей (например, `IsSupported`). AOT-компилятор должен генерировать код для всех ветвей в исходном коде, поскольку у него нет значений, которые будут вычисляться в среде исполнения.

Таким образом, AOT-компилятор может быть не лучшим вариантом для всех приложений, но в некоторых случаях он весьма полезен. Функции AOT для .NET предоставляют несколько механизмов.

- **NGen** (<https://docs.microsoft.com/en-us/dotnet/framework/tools/ngen-exe-native-image-generator>).

NGen — классический и самый известный инструмент для AOT в .NET Framework. Он может создавать собственные образы (`.ni.dll` или `.ni.exe`) управляемых сборок и устанавливать их в кэш собственных образов. Одна из интересных функций NGen — это MPGO (<https://docs.microsoft.com/en-us/dotnet/framework/tools/mpgo-exe-managed-profile-guided-optimization-tool>) (управляемая профильная оптимизация): она позволяет отслеживать ваш код во время исполнения, создание «профиля» приложения и использование этого профиля для генерации более качественного собственного кода. MPGO работает прекрасно, когда реальные сценарии применения похожи на эти профили.

- **CrossGen** (<https://github.com/dotnet/coreclr/blob/v2.2.0/Documentation/building/cross-gen.md>).

**CrossGen** является аналогом NGen (который используется только в .NET Framework) для .NET Core. Он также генерирует собственные образы для управляемых сборок, но он кросс-платформенный: его можно применять в Windows, Linux или macOS. В .NET Core также доступна функция MPGO (см. [Le Roy, 2017]).

- **Mono AOT.**

Mono также предоставляет инструмент для AOT-компиляции ([www.mono-project.com/docs/advanced/runtime/docs/aot/](http://www.mono-project.com/docs/advanced/runtime/docs/aot/)), который может быть использован аргументами среды исполнения `--aot`. Он генерирует машинные образы (с расширением `.so` в Linux, `.dylib` в macOS), которые будут автоматически использоваться при исполнении сборки. У Mono AOT много опций. Например, с помощью `--aot=full` можно включить полный режим AOT. Он разработан для платформ,

не поддерживающих динамическую генерацию кода: все нужные методы будут АОТ-скомпилированы. Также вы можете запустить приложение с `mono --full-aot` (это не эквивалент `mono --aot=full`, а другая команда!), что означает: механизм JIT-компиляции (и все динамические функции) будет отключен. Также АОТ можно использовать в Xamarin.Android и Xamarin.iOS<sup>1</sup>.

- **.NET Native.**

Если мы говорим о приложениях для UWP (универсальной платформы Windows), нужно упомянуть интересную технологию под названием .NET Native (<https://docs.microsoft.com/en-us/dotnet/framework/net-native/>). Многие приложения для UWP разработаны для мобильных устройств и предъявляют высокие требования к времени запуска, времени исполнения, использованию памяти и потреблению энергии. Внутри .NET Native оптимизирует код с помощью C++-компилятора. Он оптимизирован для статической предварительной компиляции и связывает нужные части .NET Framework напрямую в приложении. Когда пользователь загружает приложение, используется предварительно скомпилированный машинный образ. Благодаря этому значительно сокращается время загрузки и нам не нужно тратить энергию мобильного устройства на JIT-компиляцию.

- **CoreRT** (<https://github.com/dotnet/corert>).

**CoreRT** — это среда исполнения .NET Core, оптимизированная для АОТ-компиляции. Она кросс-платформенная, то есть позволяет создавать нативные приложения для Windows, Linux и macOS. Вы можете узнать подробнее о внутреннем устройстве CoreRT в [Warren, 2018b].

- **RuntimeHelpers.**

В отличие от предыдущих способов АОТ-компиляции **RuntimeHelpers** — это управляемый статический класс с удобными методами, который можно использовать для АОТ-компиляции во время исполнения программы. Представьте, что у вас есть метод, требующий сложной JIT-компиляции, но вы не хотите ждать во время первого вызова метода и не можете прогреть его, вызвав заранее, потому что каждый вызов создает побочные эффекты. В этом случае вы можете получить дескриптор метода с помощью рефлексии и поставить перед JIT-компилятором задачу сгенерировать машинный код заранее с помощью `RuntimeHelpers.PrepareMethod`.

Теперь обсудим несколько практических примеров разных видов компиляции.

---

<sup>1</sup> <https://xamarinhelp.com/xamarin-android-aot-works/>, <https://docs.microsoft.com/en-us/xamarin/ios/internals/architecture#aot>.

## Практический пример 1: Switch и версии компилятора C#

`switch` является одним из базовых ключевых слов в C#. Вы знаете, как оно работает с точки зрения внутреннего устройства? На самом деле это зависит от версии вашего компилятора C#. Рассмотрим следующий код с использованием `switch`:

```
string Capitalize(string x)
{
    switch (x)
    {
        case "a":
            return "A";
        case "b":
            return "B";
        case "c":
            return "C";
        case "d":
            return "D";
        case "e":
            return "E";
        case "f":
            return "F";
        case "g":
            return "G";
    }
    return "";
}
```

Старый компилятор C# 4.0.30319.33440 генерирует следующий код:

```
; Phase 0: Dictionary<string, string>
IL_000d: volatile.
IL_000f: ldsfld class Dictionary<string, int32>
IL_0014: brtrue.s IL_0077
IL_0016: ldc.i4.7
IL_0017: newobj instance void class Dictionary<string, int32>::.ctor
IL_001c: dup
IL_001d: ldstr "a"
IL_0022: ldc.i4.0
IL_0023: call instance void class Dictionary<string, int32>::Add
IL_0028: dup
IL_0029: ldstr "b"
IL_002e: ldc.i4.1
IL_0023: call instance void class Dictionary<string, int32>::Add
IL_0034: dup
IL_0035: ldstr "c"
; ..
```

```

; Phase 1:
IL_0088: ldloc.1
IL_0089: switch (
    IL_00ac, IL_00b2, IL_00b8,
    IL_00be, IL_00c4, IL_00ca, IL_00d0)
IL_00aa: br.s IL_00d6
; Phase 2: cases
IL_00ac: ldstr "A"
IL_00b1: ret
IL_00b2: ldstr "B"
IL_00b7: ret
IL_00b8: ldstr "C"
IL_00bd: ret
IL_00be: ldstr "D"
IL_00c3: ret
IL_00c4: ldstr "E"
IL_00c9: ret
IL_00ca: ldstr "F"
IL_00cf: ret
IL_00d0: ldstr "G"
IL_00d5: ret
IL_00d6: ldstr ""
IL_00db: ret

```

Он выделяет статичный `internal`-экземпляр `Dictionary<string, int>` и помещает все значения в этот словарь. Данный код выполняется только один раз после первого вызова метода.

Roslyn генерирует более оптимальную версию кода:

```

// Phase 1: ComputeStringHash
uint num = ComputeStringHash(x);
// Phase 2: Binary search
if (num <= 3792446982u) {
    if (num != 3758891744u) {
        if (num != 3775669363u) {
            if (num == 3792446982u) {
                if (x == "g") { return "G"; }
            }
        }
        else if (x == "d") { return "D"; }
    }
    else if (x == "e") { return "E"; }
}
else if (num <= 3826002220u) {
    if (num != 3809224601u) {
        if (num == 3826002220u) {
            if (x == "a") { return "A"; }
        }
    }
}

```

```

    else if (x == "f") { return "F"; }
}
else if (num != 3859557458u) {
    if (num == 3876335077u) {
        if (x == "b") { return "B"; }
    }
}
else if (x == "c") { return "C"; }
return "";

```

Как видите, дополнительного словаря больше нет. Мы высчитываем хеш-код данной строки и выполняем бинарный поиск. Нам нужно значение, не зависящее от среды исполнения, поэтому вместо `string.GetHashCode` используется дополнительный метод:

```

internal static uint ComputeStringHash(string s)
{
    uint num = default(uint);
    if (s != null)
    {
        num = 2166136261u;
        for (int i = 0; i < s.Length; i++)
            num = (s[i] ^ num) * 16777619;
    }
    return num;
}

```

Поскольку все ключи должны быть константами, известными на стадии компиляции, мы можем заранее высчитать хеш-коды для всех ключей. Далее можем отсортировать хеш-коды и применить бинарный поиск по известным значениям. С точки зрения производительности и памяти это довольно эффективно.

**Вывод: производительность может зависеть от версии компилятора C#.** Основная часть оптимизаций — ответственность JIT- и AOT-компиляторов. C#-компилятор из исходного кода создает код на промежуточном языке. В большинстве случаев он не применяет полезных оптимизаций. Однако некоторые продвинутые языковые конструкции, такие как `switch`, могут быть переведены на промежуточный язык по-разному. Когда мы обсуждаем новую версию компилятора, обычно упоминаем новые функции языка, но не стоит забывать и об изменениях в существующих функциях.

### Упражнение

Напишите программу с оператором `switch`, внутри которого будет много `case`-выражений. Попробуйте написать бенчмарк, показывающий разницу в производительности между старым C#-компилятором и Roslyn.

## Практический пример 2: params и распределение памяти

В C# много синтаксического сахара, позволяющего писать лаконичный и понятный код. Но разработчики не всегда думают о затратах производительности на этот сахар. Существует ключевое слово `params`, помогающее создавать методы с переменным количеством аргументов:

```
void Foo(params int[] x)
{
    // ..
}
```

В некоторых случаях это хороший подход. Однако он может скрыть неявное создание объектов от разработчиков. Например, что происходит, если вызвать такой метод без аргументов?

```
Foo();
```

Правильный ответ: все зависит от свойств проекта. Если он собран для .NET Framework 4.5, Roslyn формирует следующий код:

```
IL_0000: ldc.i4.0
IL_0001: newarr System.Int32
IL_0006: call Foo(int32[])
IL_000b: ret
```

Как видите, был создан новый пустой массив. Это означает, что среда исполнения создает новый объект на каждый вызов метода без аргументов.

В .NET Framework 4.6 Microsoft ввел новый API `Array.Empty<T>` (<https://docs.microsoft.com/en-gb/dotnet/api/system.array.empty>), он возвращает копию пустого массива. Реализация довольно проста:

```
public class Array
{
    private static class EmptyArray<T>
    {
        internal static readonly T[] Value = new T[0];
    }

    public static T[] Empty<T>()
    {
        return EmptyArray<T>.Value;
    }
}
```

Для каждого типа `T` мы получаем как максимум один экземпляр массива, который будет переиспользован. Roslyn знает об этом API. Если проект собран для .NET

Framework 4.6+, Roslyn сгенерирует оптимизированную версию кода на промежуточном языке:

```
IL_0000: call !!0[] System.Array::Empty<int32>()
IL_0005: call void ConsoleApp7.Program::Foo(int32[])
IL_000a: ret
```

В этом случае используется статический экземпляр `Array.Empty<T>`. Это означает, что вам не нужно будет волноваться о нежелательном выделении памяти.

**Вывод: сгенерированный код на промежуточном языке может зависеть от свойств проекта.** Версия компилятора не единственный фактор, способный повлиять на сгенерированный код. Одна и та же версия компилятора может создавать разный код на промежуточном языке для одной и той же языковой конструкции в зависимости от версии .NET Framework и доступного API.

### Упражнение

Взгляните на то, какой код на промежуточном языке генерирует старый компилятор C# для предыдущего примера в .NET Framework 4.5 и 4.6<sup>1</sup>.

## Практический пример 3: замена и неочевидный промежуточный язык

Рассмотрим простой метод, который берет две переменные типа `int`, меняет их местами и делит одну на другую (данный метод не особо полезный — это просто небольшой пример с довольно интересными свойствами). Эту логику можно реализовать по-разному. Вот одно из самых очевидных решений:

```
public int SwapAndDiv1(int a, int b)
{
    var temp = a;
    a = b;
    b = temp;
    return a / b;
}
```

Здесь мы меняем переменные с помощью дополнительной переменной `temp`. Метод работает правильно, но выглядит слишком многословным: нужны три строчки кода и дополнительная переменная. К счастью, в C# 7.0 появился синтаксис кортежей, позволяющий переписать метод следующим образом:

<sup>1</sup> Мы обсудим, как получить сгенерированный код на промежуточном языке, в главе 6.

```
public int SwapAndDiv2(int a, int b)
{
    (a, b) = (b, a);
    return a / b;
}
```

Теперь мы можем поменять значения с помощью одной строчки кода без дополнительных переменных. Этот код проще читать, и он выглядит выразительнее. А теперь загадка: какой из двух приведенных выше реализаций метода получит более оптимизированное представление на промежуточном языке? Можно выдвинуть следующую гипотезу: «Второй метод может менять переменные без дополнительных переменных, поэтому у него должно быть лучшее представление на промежуточном языке». Это звучит логично, но данная гипотеза основана на том, что у нас есть на уровне C#. Проверим ее, скомпилировав код с помощью Roslyn 2.6.0.62309 (d3f6b8e7), и посмотрим на код.

Вот первый метод:

```
.method public hidebysig
    instance int32 SwapAndDiv1 (
        int32 a,
        int32 b
    ) cil managed
{
    ; Header Size: 1 byte
    ; Code Size: 10 (0xA) bytes
    .maxstack 8

    ; Swap
    IL_0000: ldarg.1    ; Loads 'a' onto the stack
    IL_0001: ldarg.2    ; Loads 'b' onto the stack
    IL_0002: starg.s a ; Pops the stack top value ('b') in the 'a' argument slot
    IL_0004: starg.s b ; Pops the stack top value ('a') in the 'b' argument Slot

    ; Division
    IL_0006: ldarg.1
    IL_0007: ldarg.2
    IL_0008: div
    IL_0009: ret
}
```

Дополнительная переменная, которая у нас есть на уровне C#-программы, отсутствует на уровне промежуточного языка: Roslyn загружает обе переменные на стек и выгружает их в обратном порядке. А теперь посмотрим на листинг промежуточного языка для второго метода:

```
.method public hidebysig
    instance int32 SwapAndDiv2 (
        int32 a,
        int32 b
```

```

) cil managed
{
; Header Size: 12 bytes
; Code Size: 12 (0xC) bytes
; LocalVarSig Token: 0x11000002 RID: 2
.maxstack 2
.locals init (
[0] int32 ; an additional variable 'temp'
)

IL_0000: ldarg.2 ; Loads 'b' onto the stack
IL_0001: ldarg.1 ; Loads 'a' onto the stack
IL_0002: stloc.0 ; Pops the stack top value ('a') in the local variable 'temp'
IL_0003: starg.s a ; Pops the stack top value ('b') in the 'a' argument slot
IL_0005: ldloc.0 ; Loads the local variable 'temp' onto the stack
IL_0006: starg.s b ; Pops the stack top value ('temp') in the 'b' argument slot

; Division
IL_0008: ldarg.1
IL_0009: ldarg.2
IL_000A: div
IL_000B: ret
}

```

Здесь вы видите обратную ситуацию: на уровне C# дополнительной переменной нет, а на уровне промежуточного языка она появляется. Это не значит, что в первом случае производительность будет лучше, но JIT-компилятору будет проще генерировать оптимизированный машинный код.

**Вывод: не доверяйте интуитивным гипотезам о результате работы компилятора.** Многие разработчики пытаются угадать сгенерированный код на промежуточном языке, машинный код и мысленно сделать оценки производительности приложения, основываясь на том, что содержится в исходном коде на C#. Даже если у вас богатый опыт, интуиция может вас обмануть. Не стоит делать никаких выводов, основываясь на догадках. Всегда проверяйте сгенерированный код и внимательно измеряйте производительность.<sup>1</sup>

### Упражнение

Как вы думаете: будет ли разница в производительности между `SwapAndDiv1` и `SwapAndDiv2`? Попытайтесь написать маленький бенчмарк и измерить оба метода. Проверьте сгенерированный код сборки разными JIT-компиляторами и сравните его для обоих случаев<sup>1</sup>. Можете попробовать написать свои версии рассматриваемого метода и попытаться найти максимально производительный вариант.

<sup>1</sup> Мы обсудим, как получить сгенерированный собственный код, в главе 6.

## Практический пример 4: большие методы и JIT-компиляция

Один мой друг рассказал мне историю о своем проекте. У него были серьезные проблемы с производительностью (ее уровень не соответствовал требованиям бизнеса). Он безуспешно пробовал много разных способов оптимизации. В итоге решил попробовать применить генерацию кода. Идея была проста: промежуточный язык предоставляет много конструкций, недоступных на чистом С#. Поэтому мой друг попытался вручную переписать самый медленный метод на промежуточном языке. Он также решил сократить количество вызовов и уместить все в один большой метод. После написания первого бенчмарка оказалось, что сгенерированный метод потребляет значительно больше времени, чем изначальный метод на С#. После недолгого исследования проблема была обнаружена: среда исполнения тратила 95 % времени на JIT-компиляцию! Метод был таким большим, что на генерацию машинного кода уходило несколько секунд. Однако второй вызов этого метода был очень быстрым.

Мы не будем воспроизводить эту ситуацию во всех подробностях. Вместо этого мы напишем небольшой пример, демонстрирующий этот эффект. Допустим, мы хотим вычислить значение следующего выражения:

$$0 - 1 + 2 - 3 + 4 - 5 + \dots - 999\,999 + 1\,000\,000.$$

Конечно, мы можем это сделать с помощью простого цикла `for`:

```
var result = 0;
for (var i = 1; i <= 1000000; i++)
    result += (i % 2 == 0 ? 1 : -1) * i;
```

Но вместо этого попробуем сгенерировать выражение без циклов на промежуточном языке:

```
// Вспомогательная логика для генерации IL-кода на лету
var assemblyName = new AssemblyName {Name = "MyAssembly"};
var assembly = AppDomain.CurrentDomain
    .DefineDynamicAssembly(assemblyName, AssemblyBuilderAccess.RunAndSave);
var module = assembly.DefineDynamicModule("Module");
var typeBuilder = module.DefineType("Type", TypeAttributes.Public);
var methodBuilder = typeBuilder.DefineMethod(
    "Calc", MethodAttributes.Public | MethodAttributes.Static,
    typeof(int), new Type[0]);
```

```
// Создаем основную логику метода
var generator = methodBuilder.GetILGenerator();
generator.Emit(OpCodes.Ldc_I4, 0); // Размещаем 0 на стеке
for (var i = 1; i <= 1000000; i++)
{
    generator.Emit(OpCodes.Ldc_I4, i); // Размещаем i на стеке
```

```

    generator.Emit(i % 2 == 0 // Используем '+' или '-' для двух верхних
                    // значений стека
                ? OpCodes.Add : OpCodes.Sub);
}
generator.Emit(OpCodes.Ret); // Возвращаем верхнее значение стека

// Создаем нужный тип
var type = typeBuilder.CreateType();
// Определяем лямбда-выражение, вызывающее наш метод с помощью рефлексии
Func<int> calc = () => (int) type.InvokeMember("Calc",
    BindingFlags.InvokeMethod | BindingFlags.Public |
    BindingFlags.Static, null, null, null);

// Измеряем длительность 1-го и 2-го вызовов метода
var stopwatch1 = Stopwatch.StartNew();
calc(); // 1-й вызов (холодный старт)
stopwatch1.Stop();
var stopwatch2 = Stopwatch.StartNew();
var result = calc(); // 2-й вызов (прогретое состояние)
stopwatch2.Stop();

// Выводим результаты замеров
Console.WriteLine($"Result : {result}");
Console.WriteLine($"1st call : {stopwatch1.ElapsedMilliseconds} ms");
Console.WriteLine($"2nd call : {stopwatch2.ElapsedMilliseconds} ms");

```

Вот возможные результаты:

```

Result : 500000
1st call : 612 ms
2nd call : 0 ms

```

Если вы попытаетесь запустить данный код на своем компьютере, то можете получить другие абсолютные значения для первого вызова, но итог будет тем же: первый вызов занимает намного больше времени.

## Выводы

- **Компиляция одного метода может занять очень много времени.**

JIT-компилятор способен значительно замедлить не только запуск приложения, но и первый вызов отдельного метода. Такую проблему легко обнаружить с помощью профилирования.

- **Некоторые оптимизации могут поменять баланс между холодным и прогретым стартом.**

Когда у вас есть два возможных способа решения задачи, не всегда можно однозначно определить, какой из них быстрее. Как в сказке про зайца и черепаху, некоторые подходы могут быть медленными на старте, но в среднем более быстрыми на долгой дистанции.

### Упражнение

Замените `1000000` в фрагменте с генерацией кода на параметр `n`. Измерьте разные значения `n` и нарисуйте график, показывающий время выполнения первого вызова для каждого `n`. Попробуйте несколько JIT-компиляторов (LegacyJIT, RyuJIT, MonoJIT) и сравните графики. Найдите значение `n`, при котором каждая компиляция длится больше 100 мс. Попытайтесь написать собственную реализацию этого метода на промежуточном языке и повторите измерения. Это упражнение должно дать вам основное представление о том, насколько затратной может быть JIT-компиляция в зависимости от тела метода.

Это был последний практический пример в этом разделе. Суммируем все, что мы здесь узнали.

## Подводя итог

В этом разделе мы обсудили разные виды компиляции.

- **Генерация промежуточного языка.**

Когда мы создаем новую программу на любимом языке, совместимом с .NET (например, C#, VB.NET, F#, Managed C++ или Q#), компилятор переводит ее в промежуточный язык. Система сборки управляет процессом компиляции и помогает собирать проекты и проектные решения. Самый популярный набор инструментальных средств — MSBuild + Roslyn, но существуют и другие технологии, такие как XBuild и старый C#-компилятор, которые все еще используются в некоторых проектах. По умолчанию программы будут компилироваться в режиме отладки (с отключенными оптимизациями), который хорош для отлаживания, но не слишком пригоден для бенчмаркинга. Если мы хотим что-то измерить, нужно переключиться в режим релиза (с включенными оптимизациями).

- **JIT-компиляция.**

Код на промежуточном языке можно трансформировать в машинный код с помощью JIT-компилятора. Это происходит в среде исполнения по запросу: среда генерирует машинный код перед первым вызовом метода. В .NET Framework есть три доступных JIT-компилятора: LegacyJIT-x86 (единственный вариант для x86), RyuJIT-x64 (вариант по умолчанию, начиная с .NET Framework 4.6) и LegacyJIT-x64 (вариант по умолчанию, до .NET Framework 4.6, в последних версиях может быть включен вручную). .NET Core 2.0+ использует RyuJIT для архитектур x86 и x64. Mono использует свой собственный JIT-компилятор (MonoJIT), который можно переключить в режим LLVM (MonoLLVM).

- **АОТ-компиляция.**

Машинный код можно сгенерировать заранее с помощью дополнительных инструментов, таких как NGen, CrossGen, Mono AOT, .NET Native, CoreRT или RuntimeHelpers.PrepareMethod. Такой подход может уменьшить время запуска приложения с помощью более грамотных оптимизаций, но у него есть ограничения (например, динамическое исполнение кода, рефлексия, обобщенные коллекции и т. д.).

Теперь мы знаем о самых популярных инструментах для компилирования и сборки в экосистеме .NET. Пора обсудить внешнее окружение наших сред исполнения.

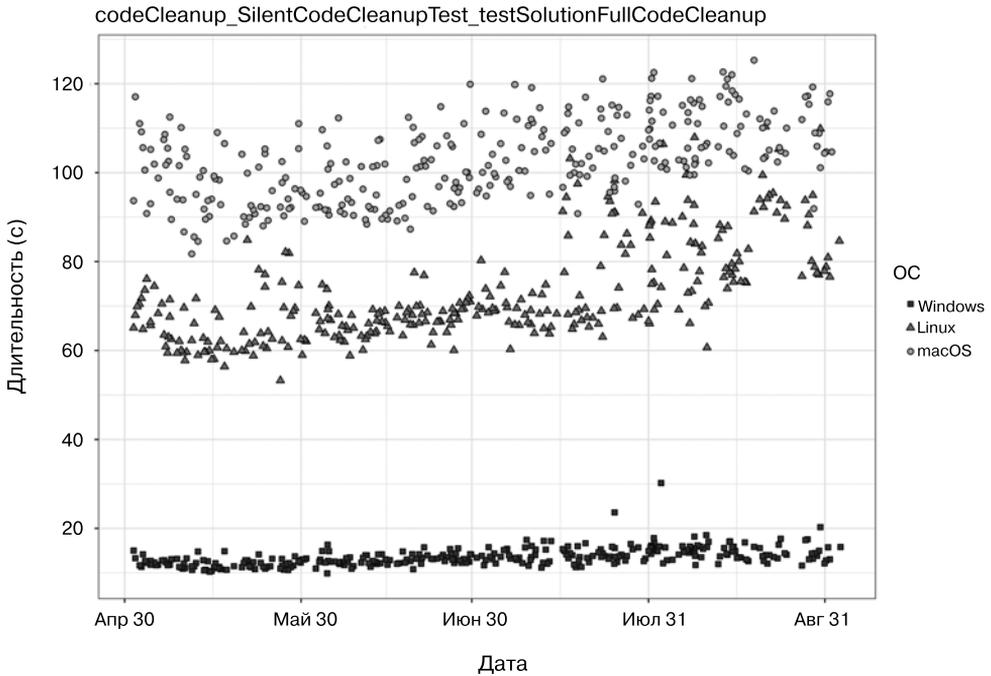
## Внешнее окружение

Окружением программы является среда исполнения. Но и у нее тоже есть окружение. Мы используем среду исполнения в конкретной операционной системе, которая запущена на конкретном устройстве, существующем *в реальном мире*. В этом разделе мы обсудим варианты внешнего окружения: почему они важны и как могут повлиять на производительность.

## Операционная система

В современном мире экосистема .NET является кросс-платформенной. С точки зрения разработчика это хорошо, потому что мы можем запускать .NET-приложения в разных операционных системах. С точки зрения специалиста по производительности это не очень хорошо, потому что в общем случае нужно анализировать производительность во всех операционных системах.

Продолжительность одного и того же вызова метода может различаться в зависимости от операционной системы. Рассмотрим пример. На рис. 3.3 приведен график, который демонстрирует длительность одного интеграционного теста в Rider 2018.2. Тест показывает совершенно разные результаты в разных операционных системах: в июне он проходил за 9–16 с в Windows, 58–77 с в Linux и 87–120 с в macOS. Это не значит, что Windows всегда работает быстро, а macOS всегда медленно: есть тесты, где macOS работает быстрее всех, а Windows показывает самый медленный результат, а в других тестах все три операционные системы показывают один и тот же результат. Если внимательно посмотреть на график и сравнить май и август, можно заметить значительное ухудшение производительности в Linux и macOS (в Windows продолжительность теста не изменилась). Кажется, произошли какие-то деструктивные изменения, случайным образом замедлившие время прохождения теста в Linux и macOS.



**Рис. 3.3.** Длительность теста очистки в Rider 2018.2 для разных ОС

В этом подразделе мы кратко вспомним историю Windows, Linux и macOS, посмотрим на основные версии операционных систем и узнаем, как определить версию с помощью командной строки и управляемого кода.

Windows — единственная операционная система, поддерживающая все три среды исполнения .NET, потому что .NET Framework работает только под Windows. В Unix-подобных операционных системах (Linux и macOS) мы можем использовать только .NET Core и Mono. Существуют и другие операционные системы, в которых можно запускать программы для .NET. Например, .NET Core можно собрать под FreeBSD. Mono поддерживает разные мобильные ОС (например, Android, iOS, tvOS и watchOS) и игровые консоли (например, PlayStation 3, Xbox 360 и Wii). Однако эти операционные системы выходят за рамки нашей книги, поэтому мы обсудим только Windows, Linux и macOS.

Давайте подробно поговорим о каждой из операционных систем.

## Windows

Windows — это родина .NET, поскольку .NET Framework была разработана именно для этой операционной системы. Многие подсистемы .NET Framework (например, WPF) тесно связаны с Windows API и могут использоваться только в Windows.

Кратко рассмотрим важнейшие версии Windows. В табл. 3.7 приведены некоторые основные версии для рабочих станций и серверов.

**Таблица 3.7.** Некоторые версии Windows

Вариант	Версия	Версия ядра	Дата выхода
Рабочая станция	95	4.00	24.08.1995
	98	4.10	25.06.1998
	ME	4.90	14.09.2000
	2000	NT 5.0	17.02.2000
	XP	NT 5.1	25.10.2001
	Vista	NT 6.0	30.01.2007
	7	NT 6.1	22.10.2009
	8	NT 6.2	26.10.2012
	8.1	NT 6.3	17.10.2013
	10	NT 10.0	29.07.2015
Сервер	2000	NT 5.0	17.02.2000
	2003	NT 5.2	24.04.2003
	2003 R2	NT 5.2	06.12.2005
	2008	NT 6.0	27.02.2008
	2008 R2	NT 6.1	22.10.2009
	2012	NT 6.2	04.12.2012
	2012 R2	NT 6.3	18.10.2013
	2016	NT 10.0	12.10.2016
	2019	NT 10.0	02.10.2018

В этой книге мы будем обсуждать в основном Windows 10 (для рабочей станции), потому что это самая свежая версия Windows (поддержка Windows 8.1 закончилась 9 января 2018 года). .NET Framework 3.5+ поддерживает Windows XP<sup>1</sup> (и Windows Server 2003+), поэтому иногда мы будем обсуждать также Windows XP, Vista, 7, 8 и 8.1. Другие версии Windows (например, 1.01 или NT 3.1) не рассматриваются.

Поскольку нас интересует в основном версия Windows 10, полезно знать ее основные обновления (табл. 3.8).

<sup>1</sup> .NET Framework 1.0, 1.1. и 2.0 могут использоваться в Windows 98/ME/2000.

Таблица 3.8. Основные сборки Windows 10

Версия	Сборка	Маркетинговое название	Кодовое название	Дата выхода
1507	10 240	RTM	Threshold 1	29.07.2015
1511	10 586	Ноябрьское обновление	Threshold 2	10.11.2015
1607	14 393	Юбилейное обновление	Redstone 1	02.08.2016
1703	15 063	Обновление для дизайнеров	Redstone 2	05.04.2017
1709	16 299	Осеннее обновление для дизайнеров	Redstone 3	17.10.2017
1803	17 134	Апрельское обновление 2018 года	Redstone 4	30.04.2018
1809	17 763	Октябрьское обновление 2018 года	Redstone 5	13.11.2018

Также полезно знать, как выяснить точную версию ОС. В частности, нас интересуют полные номера из четырех чисел, например 10.0.15063.674. В Windows существует несколько способов узнать текущую версию операционной системы. Например, на рис. 3.4 можно увидеть снимки экрана следующих программ:

- **ver** в командной строке, выдающей Microsoft Windows [Version 10.0.15063]. Теперь мы знаем основную часть версии (сборка 15 063 соответствует «Обновлению для дизайнеров» 1703), но не знаем ревизию; **ver** выдает значение ревизии, только начиная с 10.0.16299+;

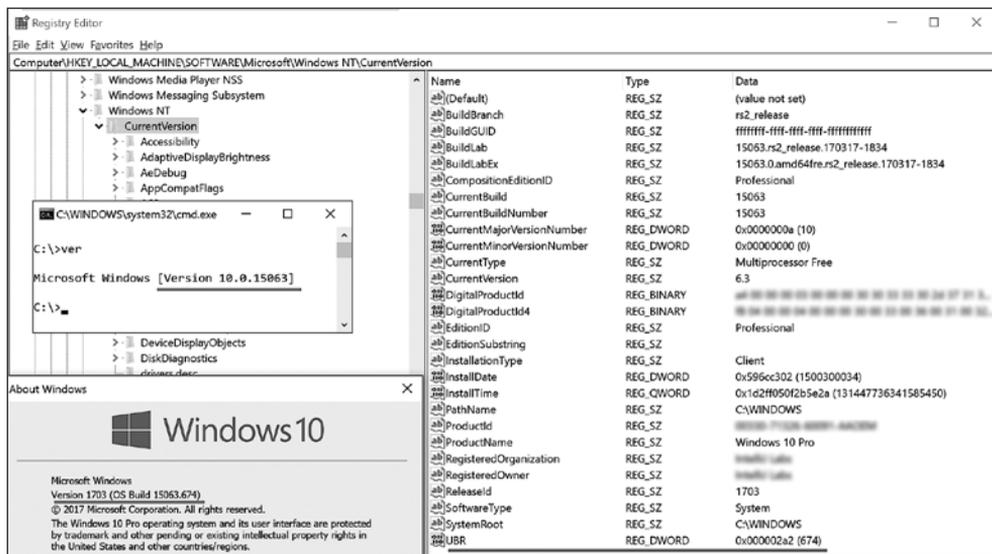


Рис. 3.4. Снимки экрана разных программ с версией Windows

- **regedit** (редактор реестра) с открытым HKEY\_LOCAL\_MACHINE\SOFTWARE\Microsoft\Windows NT\CurrentVersion\UBR. Как видите, значение UBR (номер ревизии) равно 674, это означает, что полная версия Windows — 10.0.15063.674;
- **winver**, предоставляющей более удобный для пользователей способ получить полную версию Windows.

## Linux

.NET Framework под Linux не работает, но для .NET-приложений можно использовать Mono и .NET Core. Дистрибутивов Linux великое множество<sup>1</sup>, и, конечно же, мы не можем их все обсудить в этой книге. Основным смыслом проверки разных версий Linux состоит в том, чтобы показать, как они могут повлиять на производительность. Нужно понимать: недостаточно сказать, что вы работаете под Linux, стоит также упомянуть название дистрибутива Linux и его полную версию.

Главные операционные системы, официально поддерживаемые в последних версиях Mono, — это Ubuntu, Debian, Raspbian и CentOS. Однако его можно использовать и в других дистрибутивах, таких как openSUSE, Fedora, Linux Mint и т. д.

.NET Core поддерживает некоторые дистрибутивы Linux<sup>2</sup>: Red Hat Enterprise Linux, CentOS, Oracle Linux, Fedora, Debian, Ubuntu, Linux Mint, openSUSE, SUSE Enterprise Linux (SLES) и Alpine Linux.

В этой книге мы обсудим только популярные дистрибутивы на базе Debian (например, Ubuntu), но основная часть сказанного применима и к другим дистрибутивам Linux.

Один из лучших способов проверить версию дистрибутива из командной строки — `lsb_release -a`.

Типичный результат для Ubuntu:

```
Distributor ID: Ubuntu
Description:   Ubuntu 16.04.3 LTS
Release:      16.04
Codename:     xenial
```

## macOS

macOS — еще одна операционная система, разработанная компанией Apple. В табл. 3.9 приведен список основных версий с кодовыми названиями и версиями ядра (ядро macOS известно как Darwin). Ранее macOS была известна под названиями Mac OS X (10.0–10.7) и OS X (10.8–10.11), но в версии 10.12 была пере-

<sup>1</sup> Список самых популярных дистрибутивов Linux есть по адресу [www.distrowatch.com](http://www.distrowatch.com).

<sup>2</sup> Разные версии .NET Core поддерживают разные дистрибутивы.

именована в macOS, чтобы быть похожей на другие операционные системы Apple, например iOS, watchOS и tvOS.

**Таблица 3.9.** Список основных версий Mac OS X/OS X/macOS

Название	Версия	Кодовое имя	Darwin	Дата выхода
Mac OS X	10.0	Cheetah	1.3.1	24.03.2001
	10.1	Puma	1.4.1	25.09.2001
	10.2	Jaguar	6	24.08.2002
	10.3	Panther	7	24.10.2003
	10.4	Tiger	8	29.04.2005
	10.5	Leopard	9	26.10.2007
	10.6	Snow Leopard	10	28.08.2009
	10.7	Lion	11	20.07.2011
OS X	10.8	Mountain Lion	12	25.07.2012
	10.9	Mavericks	13	22.10.2013
	10.10	Yosemite	14	16.10.2014
	10.11	El Capitan	15	30.09.2015
macOS	10.12	Sierra	16	20.09.2016
	10.13	High Sierra	17	25.09.2017
	10.14	Mojave	18	24.09.2018

Есть несколько способов проверить версию Mac из командной строки. Первая — запустить `sw_vers`, который выдаст вам примерно такой результат:

```
ProductName: Mac OS X
ProductVersion: 10.14.2
BuildVersion: 18C54
```

Если вам нужен только номер версии, можете запустить `sw_vers -productVersion` (он возвращает 10.14.2). Если нужна расширенная информация, включая версию ядра, запустите `system_profiler SPSoftwareDataType`. Вот несколько типичных строчек результата:

```
System Version: macOS 10.14.2 (18C54)
Kernel Version: Darwin 18.2.0
Environment.OSVersion = "Unix 18.2.0.0"
```

macOS основана на Unix, поэтому у нее много общего с Linux. К сожалению, отличить Linux от macOS с помощью `Environment.OSVersion` невозможно, потому что для современных версий обеих операционных систем она возвращает `Unix`.

Если хотите проверить, какая у вас ОС, без дополнительных зависимостей, можно применить следующий прием, основанный на `uname` из `libc`:

```
[DllImport("libc", SetLastError = true)]
private static extern int uname(IntPtr buf);

private static string GetSysnameFromUname()
{
    var buf = IntPtr.Zero;
    try
    {
        buf = Marshal.AllocHGlobal(8192);
        int rc = uname(buf);
        if (rc != 0)
        {
            throw new Exception("uname from libc returned " + rc);
        }

        string os = Marshal.PtrToStringAnsi(buf);
        return os;
    }
    finally
    {
        if (buf != IntPtr.Zero)
            Marshal.FreeHGlobal(buf);
    }
}
```

`GetSysnameFromUname()` возвращает `Linux` для `Linux` и `Darwin` для `macOS`.

Есть еще один способ получить полную информацию о текущей версии ОС — установить NuGet-пакеты `Microsoft.DotNet.PlatformAbstractions`, требующие `.NET Framework 4.5.1+` или `.NET Standard 1.3+`, и использовать класс `RuntimeEnvironment` из пространства имен `Microsoft.DotNet.PlatformAbstractions`. Вот пример свойств `RuntimeEnvironment` в `macOS`:

```
RuntimeEnvironment.OperatingSystem = "Mac OS X"
RuntimeEnvironment.OperatingSystemPlatform = "Darwin"
RuntimeEnvironment.OperatingSystemVersion = "10.14"
```

Если вы работаете в `.NET Core`, можно также использовать `System.Runtime.InteropServices.RuntimeInformation` (<https://docs.microsoft.com/en-us/dotnet/api/system.runtime.interopservices.runtimeinformation>). `RuntimeInformation.OSDescription` вернет примерно такую строку:

```
Darwin 18.2.0 Darwin Kernel Version 18.2.0: Mon Nov 12 20:24:46 PST 2018;
root:xnu-4903.231.4~2/RELEASE_X86_64
```

Этот API также доступен для `.NET Framework 4.7.1+`, но в Mono он возвращает `Unix 18.2.0.0`.

Mono 5.18+ поддерживает OS X 10.9 и более поздние версии<sup>1</sup>. .NET Core 1.0 поддерживает macOS 10.11, 10.12; .NET Core 2.0 поддерживает macOS 10.12+. В этой книге мы будем обсуждать macOS 10.12+.

В следующем подразделе поговорим об окружении операционной системы, состоящем из аппаратных средств.

## Аппаратные средства

В современном мире огромное количество различных устройств. Открыв техническую спецификацию на своем компьютере или мобильном телефоне, вы найдете множество характеристик, влияющих на производительность. Сравнить разные устройства довольно сложно: не всегда можно сказать, какое из них быстрее, потому что разные устройства можно оптимизировать под конкретные случаи использования и они будут лучшими только в конкретных ситуациях<sup>2</sup>.

В этом подразделе мы кратко обсудим основные компоненты устройств: процессор, оперативную память, диски, сетевое оборудование и др.

Процессор — это сердце любого компьютера. Это электронный блок, производящий все основные операции, включая арифметические, логические и операции ввода-вывода. Существует много различных компаний, производящих чипы процессора, самые известные среди них — это Intel, AMD и VIA Technologies. У каждого процессора есть архитектура, определяющая набор инструкций. Одна из самых популярных архитектур — x86 с 32-битным набором инструкций, разработанным Intel. Есть и 64-битная версия этой архитектуры под названием x64, известная также как x86\_64, AMD64 или Intel 64. Изначально компания Intel пыталась создать еще одну 64-битную архитектуру под названием Itanium, но она не стала популярной, потому что не поддерживала существующие программы на базе x86. В то же время AMD разработала собственный набор инструкций AMD64, совместимый с x86. Он очень широко распространен, поэтому Intel также решила его использовать. Хотя x86 и x64 часто встречаются на серверах и рабочих станциях, есть еще одна архитектура под названием ARM, широко применяемая на мобильных и встроенных устройствах, поскольку была разработана для низкого энергопотребления. У ARM есть 32- и 64-битные версии ARM32 и ARM64. Платформа .NET Core 2.1+ поддерживает ARM32 (<https://github.com/dotnet/announcements/issues/29>), поэтому ее можно запустить даже на Raspberry Pi (<https://github.com/dotnet/core/blob/v2.1.3/samples/RaspberryPiInstructions.md>). В то же время Mono поддерживает и другие архитектуры,

<sup>1</sup> Ранее Mono поддерживала Mac OS X 10.7+, но требования обновились из-за ограничений стека TLS. См. <https://github.com/mono/mono/issues/9581>.

<sup>2</sup> Если вы действительно хотите сравнивать конфигурации двух устройств, можете использовать [www.userbenchmark.com](http://www.userbenchmark.com) для получения базовых характеристик. Это означает, что вы не узнаете, какое устройство лучше в целом, но получите примерную картину.

такие как MIPS, PowerPC, SPARC (32 бита), s390x (64 бита) и др. ([www.mono-project.com/docs/about-mono/supported-platforms/](http://www.mono-project.com/docs/about-mono/supported-platforms/)). Существует огромное количество различных архитектур процессоров от разных производителей, но в книге мы сосредоточимся на x86 и x64.

Если вы создаете классическое приложение для .NET из шаблона, то можете найти в соответствующем `csproj`-файле следующую строчку:

```
<PlatformTarget>AnyCPU</PlatformTarget>
```

Это означает, что приложение может использоваться на любой платформе, специальных требований нет. Если хотите запустить приложение только на конкретной платформе, можете поменять значение (например, конкретизировать — x86 или x64).

Есть еще одна интересная опция, которую можно встретить в `csproj`-файлах:

```
<Prefer32bit>>false</Prefer32bit>
```

Значение `Prefer32bit` по умолчанию — `true`. Это означает: если вы создадите новый классический проект в .NET Framework в Windows-x64 (поддерживающей программы и на x86, и на x64), он будет исполняться с помощью набора инструкций x64. Если хотите запустить ее на x64, нужно установить `PlatformTarget=x64` или `Prefer32bit=false`. Режим AnyCPU with Prefer32bit имеет особую функцию: он будет корректно работать на Windows на основе ARM, а программа для x86 на ARM не запустится (подробнее — в [Goldshstein, 2012]). Если компилировать файлы на C# напрямую через компилятор, можно конкретизировать платформу с помощью аргумента `/platform:` (возможные значения: x86, x64, Itanium, arm, anycpu32bitpreferred, anycpu).

Мы не собираемся обсуждать все виды процессоров, тем не менее важно показать, как производительность зависит от внутреннего устройства процессора. В книге сосредоточимся на процессорах Intel Core iX. Это семейство включает в себя Core i3, Core i5, Core i7 и Core i9 (i5 мощнее, чем i3, i7 мощнее, чем i5, i9 мощнее, чем i7). У каждой модели есть несколько разных поколений микроархитектур (Micro-arch), некоторые из них приведены в табл. 3.10. Обычно микроархитектуру можно вычислить по номеру процессора. Полную спецификацию вы найдете на официальном сайте Intel ([www.intel.com/content/www/us/en/processors/processor-numbers.html](http://www.intel.com/content/www/us/en/processors/processor-numbers.html)).

У процессора может быть несколько *физических ядер*. Каждое ядро может обрабатывать инструкции независимо от других. Технология под названием «*гиперпоточность*» (hyperthreading) позволяет имитировать два *логических ядра* на одном физическом ядре. Одна из базовых характеристик процессора — его *частота* (или *уровень тактовой частоты*). Она определяет количество выполняемых тактов процессора в секунду. Каждая машинная инструкция соответствует одному или нескольким тактам. Если вы откроете техническую спецификацию вашего процессора, вы найдете значение, описывающее основную частоту процессора. Однако

это не константа — частота может меняться динамично или постоянно с помощью разнообразных техник, таких как *overclocking*, *undervolting*, CPU-тротлинг (*throttling*) и др. У процессора есть много других характеристик, важных для производительности: количество *уровней кэша* и их объем, поддерживаемые наборы инструкций (например, SSE или AVX), поддерживаемые технологии (например, *технология экономии энергии*) и т. д.

**Таблица 3.10.** Список последних процессоров Intel Core iX

Поколение	Процесс	Micro-arch	Кодовое название	Дата выхода
1	45nm	Nehalem	Nehalem	17.11.2008
1	32nm	Nehalem	Westmere	04.01.2010
2	32nm	Sandy Bridge	Sandy Bridge	09.01.2011
3	22nm	Sandy Bridge	Ivy Bridge	29.04.2012
4	22nm	Haswell	Haswell	02.06.2013
5	14nm	Haswell	Broadwell	05.09.2014
6	14nm	Skylake	Skylake	05.08.2015
7	14nm	Skylake	Kaby Lake	03.01.2017
8	14nm	Skylake	Coffee Lake	05.10.2017

Процессор — не единственное аппаратное средство, ответственное за производительность. Есть и много других.

- **Оперативная память.**

Любая программа постоянно взаимодействует с оперативной памятью. С точки зрения производительности важны тип оперативной памяти (например, *DDR2*, *DDR3*, *DDR3L*, *DDR4*), время отклика, частота и общий объем памяти (если у вас недостаточно памяти, могут возникнуть большие проблемы).

- **Диски.**

Программы требуют также разных постоянных запоминающих устройств. Есть много мест хранения данных: *HDD*, *SSD*, *SSHD*, *RAID*, *различные виртуальные хранилища* и т. д.

- **Сетевые устройства.**

Современные приложения активно взаимодействуют с Интернетом или локальной сетью. Пропускная способность сети может стать узким местом для производительности приложения. Если вы хотите отправить данные с одного компьютера на другой, в процессе их транспортировки может быть использовано огромное количество различных сетевых устройств с разными типами соединения.

- **Другие аппаратные средства.**

В зависимости от использования приложений большое значение могут иметь и другие аппаратные средства. Если приложение добывает криптовалюту, довольно важна *модель видеокарты*. Продвинутые механизмы для 3D-рендеринга также чувствительны к характеристикам видеокарты, но их производительность может зависеть и от *разрешения экрана*. Важны и такие компоненты, как *батарея и кулер*.

Во время исследований производительности в JetBrains у меня на столе работают шесть разных физических компьютеров: три эквивалентных Mac mini с установленными на них macOS, Windows и Linux, а также MacBook Pro, рабочая станция с Linux и ноутбук с Windows. Три эквивалентных Mac mini позволяют сравнивать производительность разных операционных систем и не беспокоиться о различиях между устройствами. Кроме того, используются три разных монитора: два с разрешением 4K и один без поддержки 4K. Такой набор — это не роскошь, а основной инструмент, который значительно упрощает исследования производительности. Конечно, у нас есть и множество удаленных устройств, но их нельзя применять для всех задач, потому что наши основные продукты, такие как Rider и IntelliJ IDEA, — это приложения для рабочих станций. Довольно важно проверять производительность в условиях, близких к условиям пользовательского окружения. Некоторые сложные проблемы специфичны для HiDPI, поэтому требуется физический монитор. Многие бенчмарки графического интерфейса нельзя корректно исполнять через удаленный сеанс.

Все зависит от используемого вами оборудования. Однако есть несколько основных компонентов, которые могут быть проблемными для многих приложений: *процессор, память, диски, сеть*. Мы подробнее поговорим о процессоре и памяти в главах 7 и 8. А теперь осталось обсудить последнюю часть окружения — реальный мир.

## Физический мир

Устройства всегда действуют в реальных физических условиях. Эти условия также могут влиять на производительность ваших приложений. В этом разделе мы кратко обсудим некоторые физические факторы, влияющие на производительность: температуру, вибрацию, физическое расположение и влажность.

### Температура

Температура — одна из важнейших физических характеристик с точки зрения производительности и надежности. Компании, у которых есть свои центры данных, тратят огромное количество времени и сил на поддержание оптимального температурного режима. Проблемы охлаждения решать непросто, но для этого существует

много технологий и подходов. Например, Microsoft решила создать дата-центры под водой (см. [Roach, 2018]).

Охлаждение важно не только для дата-центров, но и для компьютеров и ноутбуков. Есть несколько способов спасти процессор от перегрева. Один из самых очевидных подходов — использовать внешний кулер. Его не всегда хватает, поэтому есть еще один вариант снижения температуры. У многих современных процессоров есть хорошая функция — дросселирование тактов, или тротлинг (CPU throttling). Она позволяет динамически менять частоту процессора в зависимости от внешних факторов. То есть, если сложные вычисления вызывают опасное повышение температуры, с которым кулер не справляется, мы можем замедлить процессор и уменьшить количество выделяемого тепла.

Есть много интересных историй о проблемах производительности и тротлинге, я расскажу свою любимую. В июле 2018 года Apple начала продавать новое поколение MacBook Pro, включавшее в себя модель с шестиядерными процессорами Intel Core i9. Это должно было быть устройство с высокой производительностью, но в системе управления температурой была допущена ошибка: если выполнялось много вычислений на процессоре, температура росла и тротлинг заметно снижал процессорную частоту. В итоге компьютер работал медленнее, чем более дешевый MacBook того же поколения с менее продвинутым процессором Core i7. Некоторые пользователи жаловались (см. [Lee, 2018]), что MacBook Pro мог обогнать по производительности i7, только если поставить его в морозилку. Эта ошибка была исправлена в дополнительном обновлении macOS High Sierra 10.13.6.

Тротлинг — событие нередкое. Я наблюдаю его все время на разных ноутбуках. В целом это хорошая технология, так как защищает компьютер от повреждений. Однако это серьезная проблема для бенчмаркинга: внезапный тротлинг может испортить корректность измерений производительности.

## Вибрация

В то время как температура имеет значение для программ с высокой нагрузкой на CPU, вибрации могут повлиять на программы, активно использующие диск, если вы применяете HDD. У него есть механические части, поэтому любая вибрация может повлиять на его производительность или надежность.

Есть знаменитое видео Брендана Грегга под названием «Крик в центре данных» (см. [Gregg, 2008]). В этом ролике Брендан кричит на жесткие диски и показывает графики времени выполнения операций в реальном времени с пиками в моменты крика. Этот эксперимент показывает, что даже вибрации от крика могут значительно увеличить время выполнения операций ввода-вывода.

Наблюдаются и еще несколько интересных эффектов, основанных на чувствительности HDD к вибрации. Например, в проекте kscope (<https://github.com/ortegaalfredo/kscope/>)

Альфредо Ортега демонстрирует, как использовать HDD в качестве микрофона: он измеряет время исполнения операций диска и высчитывает частоту HDD. Он применяет эту технику и для программы под названием `hdd-killer`: если издавать звук с текущей частотой HDD, он резонирует с устройством и может его серьезно повредить (в придачу к изменению производительности).

В [Shahrad, 2017] ученые из Принстонского университета представляют другую атаку, основанную на акустическом резонансе. Они показывают, как атакующий может выключить систему видеонаблюдения, нанеся удар по устройству записи видео. Атака может быть направлена и на персональный компьютер, вызывая падение операционной системы.

Другая интересная характеристика HDD — активная защита жесткого диска. Когда внутренний акселерометр определяет избыточное ускорение или вибрацию, жесткий диск разгружает свои головки, чтобы предотвратить ущерб. То есть, случайно уронив ноутбук с HDD во время дискового бенчмаркинга, вы увидите спад производительности в этот момент.

Как видите, вибрация — серьезная проблема для производительности HDD. При бенчмаркинге могут появиться сбои производительности из-за вибрации, которые можно неправильно интерпретировать, если не знать о таком феномене. Если же вы используете SSD, вибрацию можно игнорировать, потому что у таких дисков нет движущихся частей. Однако жесткие диски все еще очень широко распространены, поэтому полезно знать о возможных проблемах с производительностью.

## Физическое расположение

В современном мире многие активно используют разные мобильные приложения на телефонах и планшетах. Сеть становится проблемой большинства таких приложений: производительность зависит от мощности сигнала. Наверное, вы и сами наблюдали снижение сигнала, когда были за городом или на пикнике в лесу: браузер и все приложения работают очень медленно. Типичные операции, обычно производимые мгновенно, могут занимать много секунд или даже минут. К сожалению, разработчики часто забывают об этом при разработке своих мобильных приложений и запускают бенчмарки только при хорошем сигнале. Вероятно, это не лучшая стратегия, если вы хотите, чтобы все пользователи были довольны.

Таким образом, разработчики, которым важна производительность в любых местах, пытаются разобраться с ситуациями, возникающими при плохом сигнале. Некоторые из подходов выглядят довольно любопытно. Например, в [Colwell, 2018] Брайан Колуэлл говорит об удаленной лаборатории узловых устройств. Она представляет собой коробку с устройствами на Android и iOS. Такие коробки были размещены в различных городах в разных местах: на опорных станциях, в безопасных

офисных зданиях, магазинах, дата-центрах, движущихся машинах/автобусах и т. д. С помощью этого подхода его команда смогла определить места с плохим сигналом, собрать релевантные измерения, сделать записи тестов с проблемами производительности, отладить эти тесты и исправить их.

Некоторые компании пытаются симитировать плохую связь в условиях офиса<sup>1</sup>. Например, в Facebook есть практика под названием «2G-вторники» (см. [McComick, 2015]): они имитируют очень медленное соединение с Интернетом в течение часа. Это помогает разработчикам получить тот же опыт, которым обладают люди с 2G-Интернетом. С помощью этого простого упражнения они находят функции мобильного приложения, не оптимизированные под медленную связь.

## Влажность

Физическое расположение не единственный фактор, воздействующий на мощность сигнала. В [Luomala, 2015] исследователи из Университета Ювяскюля изучили, как температура и влажность влияют на мощность радиосигнала в беспроводных уличных сетях. Они провели много экспериментов в разные сезоны года (зимой и летом) и время суток (днем и ночью) в разных погодных условиях и в итоге показали связь между погодой и мощностью радиосигнала. Мы уже говорили, что температура может влиять на производительность, но имели в виду температуру устройства и операции, связанные с процессором. Согласно данному исследованию температура и влажность на улице могут повлиять на сетевые операции. То есть можно получить разные измерения производительности в одном и том же месте в зависимости от погоды.

Физические условия очень важны для любого устройства. Внешние факторы, такие как температура, вибрация, физическое расположение, влажность и др., влияют на производительность приложений<sup>2</sup>. Устройства не существуют в вакууме — не забывайте о реальном физическом мире. Если вы знаете, какие внешние факторы важны для конкретного бенчмарка, то можете предсказать возможные проблемы, которые способны испортить измерения, а затем стабилизировать результат, контролируя внешние условия.

Теперь обсудим несколько интересных историй о внешних факторах, которые могут сильно повлиять на производительность.

---

<sup>1</sup> Существует много способов имитировать слабую связь с сетью. Вот довольно интересный: <https://stackoverflow.com/a/8630401>.

<sup>2</sup> Внешние условия могут довольно странно влиять на устройства. Вот интересный тред в Twitter, в котором Джон Хифен объясняет, почему он опоздал: <https://twitter.com/JohnHyphen/status/971405857446645761>. Его часы показывали неправильное время из-за несбалансированной частоты в электросети.

## Практический пример 1: обновления Windows и изменения в .NET Framework

Разработчикам обычно важна версия среды исполнения и неважна версия ОС. Однако и она может иметь большое значение. Например, небольшие обновления Windows могут изменить установленные версии .NET Framework.

В оптимизациях RyuJIT существовала ошибка, известная как `coreclr#11574` (<https://github.com/dotnet/coreclr/issues/11574>). Она влияла на .NET Framework 4.7. Рассмотрим следующий код:

```
using System;

class Program
{
    static byte[] s_arr2;
    static byte[] s_arr3;

    static void Init()
    {
        s_arr2 = new byte[] { 0x11, 0x12, 0x13 };
        s_arr3 = new byte[] { 0x21, 0x22, 0x33 };
    }

    static void Main(string[] args)
    {
        Init();

        byte[] arr1 = new byte[] { 2 };
        byte[] arr2 = s_arr2;
        byte[] arr3 = s_arr3;
        int len = arr1.Length + arr2.Length + arr3.Length;
        int cur = 0;
        Console.WriteLine("1: cur = {0}", cur);
        cur += arr1.Length;
        Console.WriteLine("2: cur += {0}, now {1}", arr1.Length, cur);
        cur += arr2.Length;
        Console.WriteLine("3: cur += {0}, now {1}", arr2.Length, cur);
        cur += arr3.Length;
        Console.WriteLine("4: cur += {0}, now {1}", arr3.Length, cur);
        Console.WriteLine("5: len is {0}", len);
    }
}
```

Из-за этой ошибки данный фрагмент кода выдавал следующий результат:

```
1: cur = 0
2: cur += 1, now 1
3: cur += 3, now 6
```

```
4: cur += 3, now 7  
5: len is 7
```

В строчке 3 — `cur += 3`, `now 6` — мы видим, что значение `cur` вычислено неверно: получено 6 вместо 4. Ошибка была исправлена в обновлении .NET Framework по безопасности и качеству от сентября 2017 года.

Допустим, у вас установлена Windows 10 1703 (10.0.15063). Исправление ошибки для этой версии появилось в KB4038788 (<https://support.microsoft.com/en-us/help/4038788/windows-10-update-kb4038788>, часть обновления .NET Framework по безопасности и качеству от сентября 2017-го (<https://blogs.msdn.microsoft.com/dotnet/2017/09/12/net-framework-september-2017-security-and-quality-rollup/>)), соответствующей Windows 10.0.15063.608 (от 12 сентября 2017 года). Если у вас более ранняя версия 1703 (10.0.15063.x, где x — 0, 13, 138, 250, 296, 297, 332, 413, 414, 447, 483, 502 или 540), ошибка остается. Если у вас обновленная версия (10.0.15063.x, где x — 608 или выше), ошибки нет. Версии .NET Framework остаются теми же самыми, что и основные части версии Windows (major.minor.build), но логика оптимизаций RyuJIT зависит от номера обновленной версии Windows.

Если вы публикуете результаты производительности для .NET Framework, рекомендуется также публиковать полную версию вашей Windows, включая номер обновленной версии.

**Вывод: номер обновленной версии Windows имеет значение.**

Полной версии установленного .NET Framework может быть недостаточно, чтобы полностью описать поведение ваших приложений. Обновления Windows могут содержать важные исправления ошибок для существующих версий среды исполнения.

### Упражнение

Проверьте другие обновления .NET Framework по безопасности и качеству (их можно найти в блоге Microsoft .NET (<https://blogs.msdn.microsoft.com/dotnet/>)) и попытайтесь найти другие изменения, влияющие на работу JIT-компилятора.

## Практический пример 2: Meltdown, Spectre и важные патчи

Meltdown и Spectre — вероятно, самые известные уязвимые места в безопасности процессора в XXI веке. Их обнаружили 3 января 2018 года, и это была очень важная новость. Кратце: эти уязвимые места позволяют читать данные из ядра

операционной системы или других процессов без разрешения. Это относится почти ко всем современным процессорам (Intel, AMD, ARM), созданным с 1995 года (с некоторыми ограничениями). Пропустим подробное описание этих уязвимых мест, поскольку это не относится к теме нашей книги, о них можно почитать в [Meltdown] и [Spectre]<sup>1</sup>.

Звучит впечатляюще, но эти уязвимые места являются проблемой в области безопасности. Почему мы здесь должны переживать по поводу производительности? Некоторые из самых важных дыр в безопасности были исправлены с помощью патчей операционной системы (без обновления аппаратных средств). Эти патчи для самых популярных операционных систем были опубликованы почти сразу же. Единственным минусом было падение производительности до 30 % в некоторых ситуациях. Многие сообщения о проблемах с производительностью из-за этих исправлений можно найти в Google. Одна из моих любимых записей в блоге — это [Gregg, 2018] от Брендана Грегга.

Важный факт: мы говорим о небольших обновлениях Windows! Но, несмотря на свой размер, они несут с собой важные изменения и влияют на производительность.

## Выводы

- **Версии операционной системы имеют значение.**

Не только основная часть, важны даже номера сборки и ревизии. И это относится не только к .NET Framework, а в целом к производительности операционных систем в отношении всех видов программного обеспечения.

- **Исправление ошибок в безопасности может замедлить ваши приложения.**

Если в журнале обновлений нет информации об изменениях в области производительности, это не означает, что вас не ждет спад. Довольно часто патчи безопасности чинят уязвимые места, жертвуя производительностью.

### Упражнение

Найдите компьютер, который подвержен Meltdown-атаке, и исследуйте производительность. Вам нужно написать несколько бенчмарков и показать проблемы с производительностью, появившиеся из-за исправлений ошибок в безопасности. Можете использовать старые и новые версии любимой операционной системы или найти способ отключить патчи для Meltdown. Выполнить это упражнение не так уж просто или быстро, но оно поможет вам приобрести важные навыки.

<sup>1</sup> Если вам нравятся истории об интересных уязвимых местах, рекомендую прочесть также [Foreshadow].

## Практический пример 3: MSBuild и Защитник Windows

Это очередная история о Rider. Однажды мы купили новые устройства для изучения производительности, установили на них образы Windows, Linux и macOS и начали запускать конкретную часть комплекса тестов по несколько раз в день. Мы проверили текущий уровень производительности — все было в порядке. А через несколько дней заметили серьезный спад производительности у некоторых тестов в Windows. Мы попытались свернуть последние подтверждения, но это не помогло: тесты все еще занимали значительный период времени. После расследования оказалось, что проблема была в Защитнике Windows (Windows Defender) ([www.microsoft.com/en-us/windows/windows-defender/](http://www.microsoft.com/en-us/windows/windows-defender/))! Большая часть теста со спадом производительности включала в себя систему сборки решений, производившую много операций ввода-вывода. Защитник Windows<sup>1</sup> может замедлять подобные операции, особенно если процесс создает много файлов EXE и DLL. К сожалению, отключить его не так-то просто: если его просто выключить в настройках, после перезагрузки он опять включится. Это и случилось в день спада. Есть способ отключить его навсегда, но по ошибке этот подход не применялся к обновленным образам Windows. На рис. 3.5 приведен график производительности одного из подобных тестов: результат — около 28 с со включенным Защитником Windows и 4 с после исправления этой проблемы.

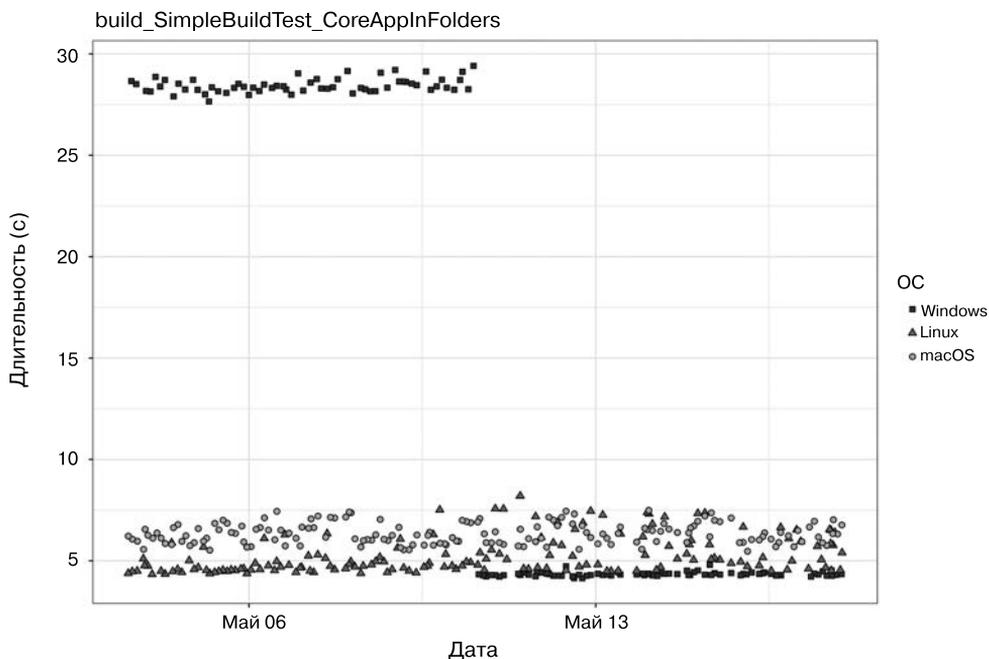


Рис. 3.5. График производительности Rider SimpleBuildTest

<sup>1</sup> Его можно найти в проводнике процессов, если искать процесс mspeng.exe.

Существует много процессов в ОС, способных замедлить ваши бенчмарки. Например, после очередного обновления устройств с macOS мы обнаружили снижение производительности на 300 %. После краткого расследования выяснилось, что единственная проблема заключалась в процессе экранной заставки, который случайно был включен во время обновления. Это распространенная проблема для виртуальных машин с macOS. Больше подробностей можно найти в [Albrechtslund, 2013].

**Вывод: некоторые функции ОС могут значительно замедлить вашу программу.**

Как видите, Защитник Windows серьезно влияет на некоторые процессы с большим количеством операций ввода-вывода. Если вы хотите добиться улучшения производительности локальных проектов, имеет смысл добавить вашу рабочую директорию в список исключений Защитника Windows. При бенчмаркинге вы можете проверять менеджер процессов на наличие процессов, совершающих операции с процессором, диском или сетью. Это поможет убедиться, что измерения производительности не нарушатся из-за других процессов.

#### Упражнение

Если вы работаете с Windows, проверьте, включен ли Защитник Windows и есть ли ваша рабочая директория в списке исключений. Попробуйте пересобрать свой проект со включенным и отключенным Защитником Windows. Если вам повезет и сборка проекта будет простой, разницы между этими конфигурациями вы не увидите. В противном случае можете заметить интересное влияние на производительность.

## Практический пример 4: длительность паузы и Intel Skylake

Обсудим разные модели процессоров. Обычно при обновлении до следующей версии микроархитектуры процессора люди не ожидают серьезных изменений в производительности. Если вы спросите коллег: «В чем разница между пятым и шестым поколениями Intel Core iX?» — скорее всего, вам ответят что-то вроде: «Шестое поколение лучше, оно должно быстрее работать», но большинство разработчиков не смогут объяснить, почему оно работает быстрее и что означает «лучше». На самом деле процессор следующего поколения не всегда быстрее, некоторые операции могут даже замедлиться. Рассмотрим пример.

В наборе инструкций x86 есть инструкция `pause`. Она используется `Thread.SpinWait` (<https://docs.microsoft.com/en-us/dotnet/standard/threading/spinwait>) для циклов «спин — ожидание». Этот метод способен помочь улучшить производительность многопо-

точных приложений, потому что потоки могут получать объекты в монопольное пользование без затратного переключения контекста. В [Intel OptManual], раздел 8.4.7, можно найти интересную информацию о длительности `pause`: «Длительность инструкции `PAUSE` в предыдущих поколениях микроархитектуры составляет около **10 циклов**, в то время как в микроархитектуре Skylake она была расширена до **140 циклов**.

<...> Поскольку длительность `PAUSE` значительно увеличилась, процессы, чувствительные к длительности `PAUSE`, претерпят потерю производительности».

Да, 140 циклов процессора могут показаться небольшим значением. Например, для процессора с частотой 2 ГГц мы получим около  $140 \cdot 1 \text{ с} / (2 \cdot 10^9)$ , или 70 нс. Стоит ли об этом беспокоиться? По изначальной задумке увеличенная длительность `pause` должна положительно влиять на производительность приложений с большим количеством потоков. Но все зависит от реализации. Оказалось, что это изменение повлияло на многие приложения .NET. Например, Алоис Краус сообщает о снижении производительности на 50 % в некоторых случаях в [Kraus, 2018].

Описанная ситуация довольно типична для приложений с большим количеством потоков. Представьте много потоков, которые пытаются получить один и тот же объект в монопольное пользование. Чтобы избежать сложных переключений контекста, каждый поток пытается выполнить цикл «спин — ожидание» первым. В .NET Core 2.0/.NET Framework 4.7.2 реализация захвата в монопольное пользование содержит много итераций вызовов `Thread.SpinWait(PlatformHelper.ProcessorCount * (4 << i))`, где `i` — индекс итерации. Такие вызовы становятся весьма затратными с длительностью `pause` 140 циклов при больших значениях `i`: каждый поток продолжает функционировать и тратить все больше и больше времени ЦП на каждую итерацию. Соответствующая проблема в .NET Core была изложена в `coreclr#13388` (<https://github.com/dotnet/coreclr/issues/13388>). Она активно обсуждалась на GitHub, там можно найти много интересных подробностей. Проблему исправили в `coreclr#13556` (<https://github.com/dotnet/coreclr/pull/13556>) с помощью замены затратных вызовов на `Thread.SpinWait(4 << i)`. Эта небольшая поправка решила изначальную проблему. Исправление доступно в .NET Core 2.1.0 и .NET Framework 4.8 Preview (<https://github.com/Microsoft/dotnet-framework-early-access/blob/master/releases/NET48/dotnet-48-changes.md>). Позже реализация была значительно улучшена — см. `coreclr#13670` (<https://github.com/dotnet/coreclr/pull/13670>) и `coreclr#29989` (<https://github.com/dotnet/corefx/pull/29989>).

## Выводы

- **Модель процессора имеет значение.**

Обычно людям неважно поколение модели процессора, особенно если частота не меняется. Но для некоторых процессов разные модели процессора могут показать значительную разницу в производительности.

- **У некоторых инструкций может наблюдаться снижение производительности на новых версиях процессоров.**

Большинство разработчиков ожидают, что обновление аппаратных средств принесет небольшое улучшение производительности, и не ожидают серьезных спадов. Но так происходит не всегда. Часто в области производительности приходят к компромиссу. Инженеры из компании Intel решили изменить длительность `pause`, чтобы оптимизировать некоторые процессы, пожертвовав производительностью других.

### Упражнение

Прочтите обсуждение этой проблемы на GitHub и [Kraus, 2018]. Напишите собственный многопоточный бенчмарк, показывающий разницу между .NET Core 2.0.0 и 2.1.0 (вам понадобится процессор подходящей модели).

## Подводя итог

Когда говорят об окружении программы, часто имеют в виду конкретную версию определенной среды исполнения. Но у каждой среды исполнения есть внешнее окружение: она запущена в операционной системе (например, Windows, Linux или macOS). У операционной системы также есть внешнее окружение, а именно аппаратные средства, включающие в себя процессор (с конкретной архитектурой вроде x86 или x64), оперативную память, диски, сетевое оборудование и другие компоненты. У аппаратных средств тоже есть внешнее окружение: реальный мир с меняющимися температурой, вибрацией и влажностью.

Бенчмаркинг требует разбираться в факторах окружения и понимать, как они влияют на производительность. В этом разделе мы кратко обсудили каждый из них и познакомились с некоторыми терминами и технологиями. Будем использовать их в последующих главах, чтобы проиллюстрировать некоторые теоретические концепции. Вы не сможете изучить все аспекты каждого компонента окружения (и мы не будем обсуждать даже часть из них). Достаточно просто понимать, какие факторы могут быть важны для конкретных измерений производительности. Эта информация поможет вам разработать эксперименты для бенчмарка и сделать правильные выводы.

## Выводы

Единственное, что вы должны понять из этой главы: окружение имеет значение. Нельзя обсуждать производительность абстрактного исходного кода в общем.

В этой главе мы осветили следующие темы, посвященные окружению.

- **Среда исполнения.**

- **.NET Framework.**

Изначальная версия платформы .NET от Microsoft. Первоначально — закрытый ресурс. Исходный код некоторых частей среды исполнения был открыт для чтения (*Rotor*). Сейчас исходный код библиотеки базовых классов для .NET Framework 4.5.1+ также доступен. Работает только с Windows.

- **.NET Core.**

Альтернативная реализация .NET Framework от Microsoft. Кросс-платформенный проект с открытым исходным кодом (находится на GitHub).

- **Моно.**

Еще одна альтернативная реализация платформы .NET. Первые версии поддерживались Xamarin, но теперь проект принадлежит .NET Foundation. Кросс-платформенный проект с открытым исходным кодом (находится на GitHub).

- **Компиляция.**

- **Генерация промежуточного языка.**

*Компилятор C#* переводит код с C# на промежуточный язык. Существовало два поколения компиляторов C# от Microsoft: *старый компилятор* (C# 1 — C# 5) и *Roslyn* (начиная с C# 6). У Mono была своя реализация компилятора C# (*msc*), но в Mono 5.0.0 она заменена Roslyn. Другой важный компонент инфраструктуры .NET — *система сборки*. Самой популярной системой сборки, входившей в .NET Framework с самого начала, является *MSBuild*. У Mono была своя система сборки (*XBuild*), но в Mono 5.0.0 она заменена MSBuild. В дополнение к MSBuild существуют наборы инструментальных средств для сборки, такие как *.NET Core SDK* (первоначальный способ собирать и запускать проекты в стиле SDK), *Cake*, *Fake*, *Nuke* и т. д.

- **JIT-компиляция.**

*Компилятор JIT* переводит код на промежуточном языке в машинный код во время запуска. Оригинальный JIT в .NET Framework — это *LegacyJIT*. Начиная с .NET Framework 4.6, он заменен *RyuJIT* для x64 (при желании переключиться на LegacyJIT все еще можно). .NET Core изначально использовала RyuJIT. У Mono есть своя реализация JIT (*MonoJIT*).

- **АОТ-компиляция.**

Кроме компиляции JIT, есть различные инструментальные средства АОТ. АОТ (статическая компиляция) означает, что мы создаем собственный код заранее — до начала исполнения программы. Есть несколько способов АОТ, такие как *NGen*, *Crossgen*, *Mono AOT*, *.NET Native* или *CoreRT*.

- **Внешнее окружение.**

- **Операционная система.**

- Существует много разных операционных систем. В этой книге мы обычно будем обсуждать Windows, Linux и macOS.

- **Аппаратные средства.**

- Самыми важными компонентами аппаратных средств являются *процессор*, *оперативная память*, *диски* и *сетевое оборудование*. В главах 7 и 8 мы продемонстрируем, как характеристики устройства влияют на производительность.

- **Реальный мир.**

- Многие физические характеристики и внешние условия, например температура, вибрация и влажность, важны и с точки зрения производительности.

Окружение — один из ключевых компонентов пространства производительности. Даже небольшие изменения в окружении могут значительно повлиять на бенчмарки. Если вы хотите опубликовать результаты исследования производительности, будет правильным опубликовать также как можно больше информации о вашем окружении.

Конечно же, вам не нужна вся эта информация во всех бенчмарках. Но думать о возможных проблемах и о том, какой компонент окружения важен в вашем случае, полезно. Например, в бенчмарке, активно использующем процессор, важнейший фактор окружения — модель процессора. Для бенчмарка, связанного с диском, полезно проверить модель диска. Если вы не знаете точно, какие характеристики окружения вам нужны, лучше записать больше деталей, чем меньше. Любая из них может очень помочь людям, которые работают с вашими бенчмарками. Всегда думайте о своем окружении и не забывайте делиться его подробностями, публикуя результаты измерения производительности.

## Источники

[Akinshin, 2015] *Akinshin A.* A Bug Story About JIT-X64. 2015. February 27. <https://aakinshin.net/blog/post/subexpression-elimination-bug-in-jit-x64/>.

[Albrechtslund, 2013] *Albrechtslund M. F.* Save CPU Time, Disable Screen Saver on Mac OS X VMs. 2013. <https://hazenet.dk/2013/06/01/save-cpu-time-disablescreensaver-on-mac-os-x-vm/>.

[Colwell, 2018] Mobile Performance Testing in Real User Conditions // Presented at the Performance @Scale 2018, March 13. <https://atscaleconference.com/videos/mobile-performance-testing-in-real-user-conditions/>.

[Craver, 2015] *Craver N.* Why You Should Wait on Upgrading to .Net 4.6. 2015. July 27. <https://nickcraver.com/blog/2015/07/27/why-you-should-wait-ondotnet-46/>.

[Foreshadow] *Weisse O., Bulck J. V., Minkin M., Genkin D., Kasikci B., Piessens F., Silberstein M., Strackx R., Wenisch T. F., Yarom Y.* Foreshadow-Ng: Breaking the Virtual Memory Abstraction with Transient Out-of-Order Execution // Technical report, 2018. <https://foreshadowattack.eu/foreshadow-NG.pdf>.

[Goldshtein, 2012] *Goldshtein S.* What AnyCPU Really Means as of .NET 4.5 and Visual Studio 11. 2012. April 4. <http://blogs.microsoft.co.il/sasha/2012/04/04/what-anycpu-really-means-as-of-net-45-and-visual-studio-11/>.

[Gregg, 2008] Shouting in the Datacenter. 2008. December 31. [www.youtube.com/watch?v=tDacjrSceq4](http://www.youtube.com/watch?v=tDacjrSceq4).

[Gregg, 2018] *Gregg B.* KPTI/KAISER Meltdown Initial Performance Regressions. 2018. February 9. [www.brendangregg.com/blog/2018-02-09/kpti-kaisermeltdown-performance.html](http://www.brendangregg.com/blog/2018-02-09/kpti-kaisermeltdown-performance.html).

[Guev, 2017] *Guev T.* StringBuilder: The Past and the Future. 2017. February 13. <http://codingsight.com/stringbuilder-the-past-and-the-future/>.

[Hanselman, 2018] *Hanselman S.* Detecting That a .NET Core App Is Running in a Docker Container and SkippableFacts in XUnit. 2018. June 29. [www.hanselman.com/blog/DetectingThatANETCoreAppIsRunningInADockerContainerAndSkippableFactsInXUnit.aspx](http://www.hanselman.com/blog/DetectingThatANETCoreAppIsRunningInADockerContainerAndSkippableFactsInXUnit.aspx).

[Intel OptManual] Intel® 64 and IA-32 Architectures Optimization Reference Manual (248966-033). 2016. [www.intel.com/content/dam/www/public/us/en/documents/manuals/64-ia-32-architectures-optimization-manual.pdf](http://www.intel.com/content/dam/www/public/us/en/documents/manuals/64-ia-32-architectures-optimization-manual.pdf).

[Kraus, 2018] *Kraus A.* Why Skylake CPUs Are Sometimes 50% Slower — How Intel Has Broken Existing Code. 2018. June 16. <https://aloiskraus.wordpress.com/2018/06/16/why-skylakex-cpus-are-sometimes-50-slower-how-intel-has-broken-existing-code/>.

[Lander, 2015] *Lander R.* Announcing .NET Framework 4.6 // Microsoft .NET Blog, 2015. July 20. <https://blogs.msdn.microsoft.com/dotnet/2015/07/20/announcingnet-framework-4-6/>.

[Lander, 2018a] *Lander R.* Announcing .NET Core 3 Preview 1 and Open Sourcing Windows Desktop Frameworks // Microsoft .NET Blog, 2018. December 4. <https://blogs.msdn.microsoft.com/dotnet/2018/12/04/announcing-net-core-3-preview-1-and-open-sourcing-windows-desktop-frameworks/>.

[Lander, 2018b] *Lander R.* .NET Core 3 and Support for Windows Desktop Applications // Microsoft .NET Blog, 2018. May 7. <https://blogs.msdn.microsoft.com/dotnet/2018/05/07/net-core-3-and-support-for-windows-desktop-applications/>.

[Landwerth, 2017a] *Landwerth I.* Explaining .NET Standard Versioning in Front of My Fire Place. 2017. October 6. [www.youtube.com/watch?v=vMRS1Q5modg](http://www.youtube.com/watch?v=vMRS1Q5modg).

[Landwerth, 2017b] *Landwerth I.* Announcing the Windows Compatibility Pack for .NET Core // Microsoft .NET Blog, 2017. November 16. <https://blogs.msdn.microsoft.com/dotnet/2017/11/16/announcing-the-windows-compatibility-packfor-net-core/>.

[Lee, 2018] *Lee D.* MacBook Pro 15 (2018) — Beware the Core I9. 2018. July 17. [www.youtube.com/watch?v=Dx8J125s4cg](http://www.youtube.com/watch?v=Dx8J125s4cg).

[Le Roy, 2017] *Le Roy B., Podder D.* Profile-Guided Optimization in .NET Core 2.0. 2017. July 20. <https://blogs.msdn.microsoft.com/dotnet/2017/07/20/profile-guided-optimization-in-net-core-2-0/>.

[Lippert, 2009] *Lippert E.* Closing over the Loop Variable Considered Harmful. 2009. November 12. <https://blogs.msdn.microsoft.com/ericlippert/2009/11/12/closing-over-the-loop-variable-considered-harmful/>.

[Lock, 2018] *Lock A.* Why Is string.GetHashCode() Different Each Time I Run My Program in .NET Core? 2018. <https://andrewlock.net/why-is-stringgethashcode-different-each-time-i-run-my-program-in-net-core/>.

[Luomala, 2015] *Luomala J., Hakala I.* Effects of Temperature and Humidity on Radio Signal Strength in Outdoor Wireless Sensor Networks // Computer Science and Information Systems (Fedcsis), 2015 Federated Conference. IEEE: 1247–1255. <https://doi.org/10.15439/2015F241>.

[McCormick, 2015] *McCormick R.* Facebook’s ‘2G Tuesdays’ Simulate Super Slow Internet in the Developing World // The Verge, 2015. October 28. [www.theverge.com/2015/10/28/9625062/facebook-2g-tuesdays-slow-internet-developing-world](http://www.theverge.com/2015/10/28/9625062/facebook-2g-tuesdays-slow-internet-developing-world).

[Meltdown] *Lipp M., Schwarz M., Gruss D., Prescher T., Haas W., Mangard S., Kocher P., Genkin D., Yarom Y., Hamburg M.* Meltdown. 2018. arXiv Preprint arXiv:1801.01207, January. <https://meltdownattack.com/meltdown.pdf>.

[MSDOCS RyuJIT] .NET Framework — Troubleshooting RyuJIT // Microsoft Docs. <https://github.com/Microsoft/dotnet/blob/master/Documentation/testing-withryujit.md>.

[Osenkov, 2011] *Osenkov K.* Introducing the Microsoft ‘Roslyn’ CTP // The Visual Studio Blog, 2011. October 19. <https://blogs.msdn.microsoft.com/visualstudio/2011/10/19/introducing-the-microsoft-roslyn-ctp/>.

[Roach, 2018] *Roach J.* Under the Sea, Microsoft Tests a Datacenter That’s Quick to Deploy, Could Provide Internet Connectivity for Years // Microsoft News, 2018. June 5. <https://news.microsoft.com/features/under-the-sea-microsoft-tests-adatacenter-thats-quick-to-deploy-could-provide-internet-connectivity-foryears/>.

[RyuJIT, 2013] RyuJIT: The Next-Generation JIT Compiler for .NET // Microsoft .NET Blog, 2013. September 30. <https://blogs.msdn.microsoft.com/dotnet/2013/09/30/ryujit-thenext-generation-jit-compiler-for-net/>.

[Shahrad, 2017] *Shahrad M., Mosenia A., Song L., Chiang M., Wentzlaff D., Mittal P.* Acoustic Denial of Service Attacks on Hdds. 2017. arXiv Preprint arXiv:1712.07816, December. <https://arxiv.org/abs/1712.07816v1>.

[SSCLI Internals] *Pobar J., Neward T., Stutz D., Shilling G.* Shared Source Cli 2.0 Internals. 2008.

[Spectre] *Kocher P., Genkin D., Gruss D., Haas W., Hamburg M., Lipp M., Mangard S., Prescher T., Schwarz M., Yarom Y.* Spectre Attacks: Exploiting Speculative Execution. 2018. arXiv Preprint arXiv:1801.01203, January. <https://spectreattack.com/spectre.pdf>.

[Torgersen, 2018] *Torgersen M.* How Microsoft Rewrote Its C# Compiler in C# and Made It Open Source. 2018. September 26. <https://medium.com/microsoft-opensource-stories/how-microsoft-rewrote-its-c-compiler-in-c-and-made-it-opensource-4ebed5646f98>.

[Toub, 2017] *Toub S.* Performance Improvements in .NET Core // Microsoft .NET Blog, 2017. June 7. <https://blogs.msdn.microsoft.com/dotnet/2017/06/07/performance-improvements-in-net-core/>.

[Toub, 2018] *Toub S.* Performance Improvements in .NET Core 2.1 // Microsoft .NET Blog, 2018. April 18. <https://blogs.msdn.microsoft.com/dotnet/2018/04/18/performance-improvements-in-net-core-2-1/>.

[Warren, 2018a] *Warren M.* A History of .NET Runtimes. 2018. October 2. <http://mattwarren.org/2018/10/02/A-History-of-.NET-Runtimes/>.

[Warren, 2018b] *Warren M.* CoreRT — A .NET Runtime for AOT. 2018. June 7. <https://mattwarren.org/2018/06/07/CoreRT-.NET-Runtime-for-AOT/>.

# 4

## Статистика для специалистов по производительности

Без данных вы всего лишь еще один человек со своим мнением.

*У. Э. Деминг, ученый-статистик*

В этой главе мы обсудим статистику и ее применение в бенчмаркинге. Вы узнаете о многих полезных подходах и техниках, которые помогут вам улучшить дизайн бенчмарков и проанализировать их результаты.

Статистике посвящено много превосходных работ. Я, как автор этой книги, мог бы назвать некоторые из них и сказать: «Прочтите их, если хотите анализировать результаты бенчмарка». Но у этой идеи есть несколько недостатков. Во-первых, большинство разработчиков не хотят читать книги по статистике. И их можно понять: обычно в таких книгах очень много информации, не имеющей отношения к стоящей перед ними задаче. Поэтому большинству разработчиков они просто кажутся недостаточно полезными и интересными. Даже если прочесть несколько хороших книг по статистике, мозг может включить свою неприятную особенность — быстро забыть неиспользуемую информацию. Если в прошлом вы изучали статистику, но теперь ею не занимаетесь, скорее всего, не сможете воспроизвести все важные формулы и приемы.

Даже если помнишь абсолютно все, часто бывает непонятно, как применять статистику в реальной жизни к *распределениям производительности*. Термин «распределение производительности» означает, что это распределение получено после настоящих измерений производительности. У таких распределений есть много характеристик, нетипичных для других источников данных. К сожалению, многие классические академические подходы просто невозможно применить к распределениям производительности. В этой главе вы найдете много практических рекомендаций о том, как использовать разные измерения в реальной жизни. Здесь не будет классических примеров о шариках в коробке или выборах президента. Мы сосредоточимся только на статистике в бенчмаркинге. Некоторые из этих рекомендаций нельзя применить к статистическим исследованиям в целом. Также они могут не подходить для некоторых конкретных исследований производительности. Однако в них есть эмпирические правила, работающие

в большинстве случаев, которые помогут вам сделать первичные предположения о своих данных.

В этой главе мы рассмотрим следующие темы.

- **Описательная статистика.**

Несколько измерений формируют распределение, которое можно описать с помощью специальных статистических параметров: минимума, максимума, медианы, среднего арифметического, процентилей, квартилей, дисперсии, среднеквадратичного отклонения и т. д. Мы обсудим, как находить все эти значения и правильно их интерпретировать. Иногда работать с сырыми цифрами трудно, поэтому вы узнаете о нескольких способах визуализировать данные.

- **Анализ производительности.**

Как сравнить два распределения? Как определить взаимосвязь между производительностью метода и его параметрами? Как найти параметры, сильнее всего влияющие на производительность? Вы узнаете ответы на все эти вопросы и познакомитесь с важными понятиями, такими как нулевая и альтернативная гипотезы, ошибки первого и второго рода и р-значения. Статистика может пригодиться не только после исследования производительности, но и в процессе. Вы можете адаптивно задавать оптимальное количество итераций и другие опции бенчмарка, вместо того чтобы заранее выбирать магические числа.

- **Как обманывать с помощью бенчмаркинга.**

Одурочить себя или других с помощью статистики довольно легко. В целях самозащиты вам нужно знать самые популярные способы обмануть с помощью бенчмаркинга. Вы узнаете о техниках обмана, основанных на небольших выборках, процентных соотношениях, пропорциях, графиках и драгировании данных (data dredging).

Я не буду освещать внутреннюю реализацию статистических алгоритмов. На практике почти всегда лучше взять существующую реализацию и рассматривать такие алгоритмы как черные ящики. Самые важные навыки связаны с правильной интерпретацией статистических измерений, а не с тем, как они высчитываются (будут представлены только самые простые формулы). Некоторые утверждения из области статистики не являются математически верными. Это сделано, чтобы упростить объяснения и пропустить множество примечаний о крайних случаях, о которых вам не стоит переживать. В бенчмаркинге не нужно глубокое знание статистики — достаточно основных понятий и способов их применения.

Мы предполагаем, что у нас уже есть качественно написанные бенчмарки, которые были исполнены в правильном окружении без ошибок. Результатом этих бенчмарков является не одно число, а набор чисел, формирующих распределение, даже если мы занимаемся бенчмаркингом в одном и том же окружении. Начнем с основ и узнаем, как описывать типичные распределения производительности.

## Описательная статистика

В этом разделе обсудим важнейшие статистические измерения и визуализации, которые помогают исследовать одно распределение.

Допустим, у нас есть бенчмарк, выдающий результат в виде одного параметра производительности, например длительность операции. Запустив его  $n$  раз, мы для каждой итерации получим новые числа. Обозначим их  $x_1, x_2, \dots, x_n$ . Этот набор измерений известен как *выборка  $x$* , а  $n$  является *размером выборки*. Было бы проще, если бы все эти числа совпадали. Но, к сожалению, это не так: измерения формируют распределение, которое необходимо проанализировать. Давайте узнаем о подходах, которые помогут собирать и анализировать такие выборки. Мы обсудим такие темы, как базовые графики выборки (временной график, rug-график, гистограмма, график плотности, каскадная диаграмма), размер выборки, минимум, максимум, размах, среднее арифметическое, медиана, квантили, квартили, процентиля, пятичисловая сводка, межквартильный диапазон, выбросы, диаграмма размаха, частотные трассы, моды, стандартное отклонение, дисперсия случайной величины, нормальное распределение, коэффициент асимметрии, коэффициент эксцесса, стандартная ошибка, доверительный интервал и центральная предельная теорема.

### Базовые графики выборки

Анализировать множество сырых чисел тяжело. Анализ можно упростить с помощью хорошей визуализации. Одна картинка стоит тысячи слов: по хорошему графику можно мгновенно понять характеристики распределения, что не всегда возможно, когда просто смотришь на числа. Есть несколько способов изобразить распределение. Вот несколько самых популярных.

- **Временной график (timeline plot).**

Пример временного графика приведен на рис. 4.1 (центральная часть с точками). Это самый прямой способ продемонстрировать измерения. Каждая итерация  $i$  (ось  $X$ ) обозначена точкой, соотносящейся с длительностью  $x$  (ось  $Y$ ) этого запуска.

- **Rug-график (rug plot).**

Пример rug-графика тоже дан на рис. 4.1 (правая часть с горизонтальными штрихами). Это одномерный график со всеми измерениями. Он содержит все значения  $x_i$  на одной оси. Его можно считать сжатой версией временного графика, в которой опущена информация по индексам итераций.

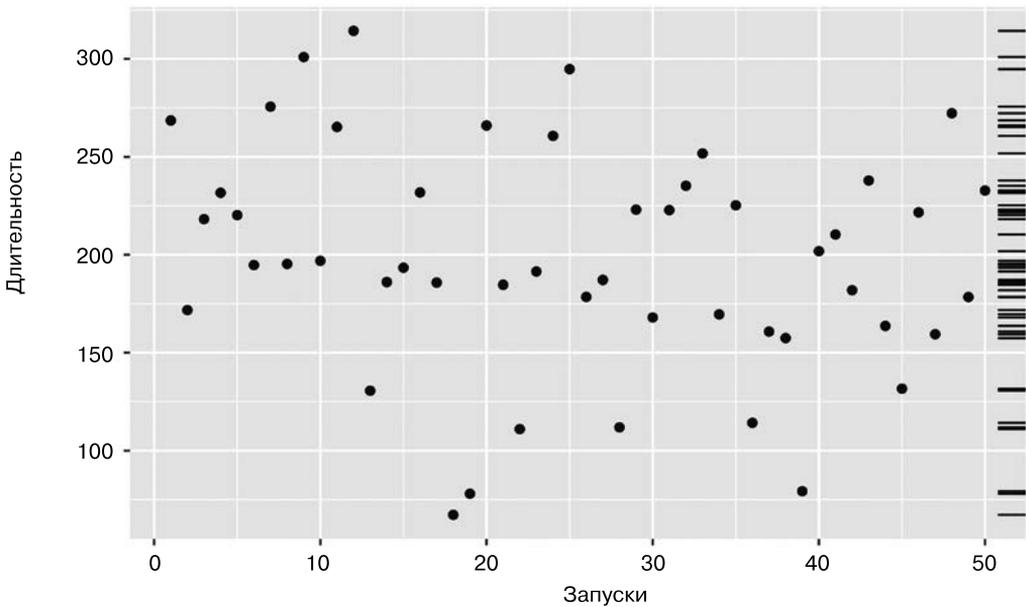


Рис. 4.1. Временной график и rug-график

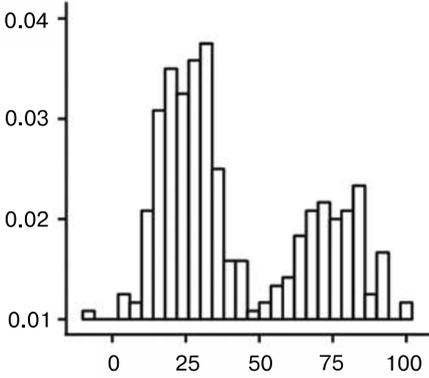
- **Гистограмма (histogram).**

Пример гистограммы приведен на рис. 4.2, А. Гистограмма показывает *форму* вашего распределения. Это столбчатая диаграмма, где каждый столбик показывает, сколько измерений содержится в соответствующем интервале. Если один столбик вдвое выше другого, значит, в нем вдвое больше значений из выборки. Обычно все столбики одной ширины, но вы можете выбрать собственные функции группирования, например логарифмические. Если хотите использовать фиксированную ширину, существует много разных подходов к ее выбору<sup>1</sup>.

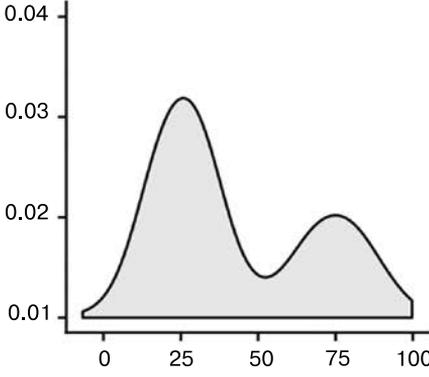
- **График плотности (density plot).**

Пример графика плотности вы видите на рис. 4.2, Б. График плотности — это «сглаженная» версия гистограммы. Он показывает форму распределения с помощью гладкой кривой вместо столбиков. Если вам неважна конкретная высота столбиков, а просто нужно знать, как выглядит распределение, предпочтительнее график плотности, поскольку на нем меньше визуальных помех. Гистограмму и график плотности можно соединить в одно изображение, как показано на рис. 4.2, В.

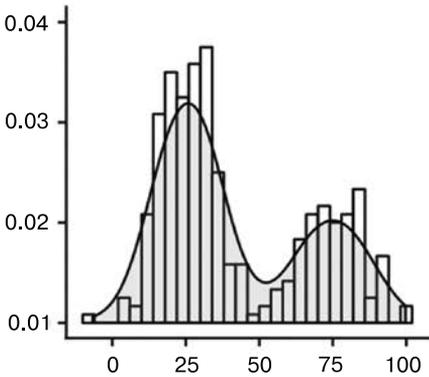
<sup>1</sup> Например, правило нормальной ссылки Скотта, правило Райса, выбор Фридмана — Диакониса, формула Доана, выбор квадратного корня, формула Стерджеса и др.



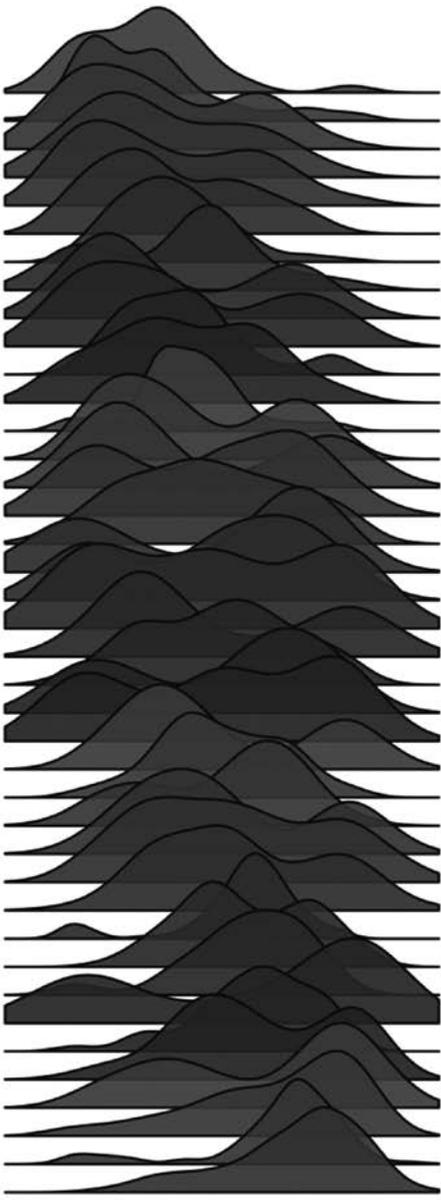
А. Гистограмма



Б. График плотности



В. Гистограмма + график плотности



Г. Каскадные графики плотности

Рис. 4.2. Разные визуализации распределения

- **Каскадные графики плотности (density waterfall plots).**

Если у вас много распределений для одного бенчмарка, их может быть сложно анализировать по одному. Каскадный график сочетает в себе много изображений и отображает их на одной картинке одно под другим. Наложение делает график компактным. Пример каскадного графика плотности приведен на рис. 4.2, Г.

Графики прекрасно подходят для демонстрации данных, но у них есть один серьезный недостаток: их трудно анализировать автоматически. Можно мгновенно понять форму распределения, если посмотреть на одно изображение, но если распределений сотни, увидеть их одновременно нельзя. Каскадный график может решить эту проблему для одного бенчмарка, но при работе с множеством разных методов и параметров эта проблема возникает вновь. Если у вас происходит непрерывный бенчмаркинг (вы ежедневно запускаете объемный набор бенчмарков на сервере), вам вряд ли захочется каждый день изучать все сгенерированные графики — нужны только проблемные. Поэтому важно найти способ определять подозрительные распределения, что нелегко, если у вас есть только изображения, — нужны числовые данные.

### Практические рекомендации

Посмотреть на гистограмму или график плотности никогда не помешает. Однако типичное исследование производительности включает в себя десятки экспериментов, а постоянное наблюдение за графиками может занять очень много времени. Рекомендуется рассматривать графики в особенные моменты исследования, например после первого запуска бенчмарка (чтобы получить представление о форме распределения), после последнего запуска бенчмарка (чтобы подтвердить, что ваша гипотеза верна, прежде чем делать выводы) и после запуска бенчмарка с подозрительными статистическими параметрами (чтобы проверить распределение на наличие аномалий).

## Размер выборки

**Размер выборки** — это число  $n$  измерений в выборке. Гистограммы и графики плотности показывают форму распределения, но в них нет информации о размере выборки. То есть, если у вас три графика плотности для выборок с  $n = 5$ ,  $n = 100$  и  $n = 10\,000$ , не всегда возможно сказать, какой из графиков относится к каждой выборке. А между тем размер выборки — это очень важная характеристика: она отвечает за точность. Если взять много разных выборок с  $n = 5$  для одного и того же бенчмарка, вы получите абсолютно разные графики плотности и значения базовых статистических параметров. Если взять много выборок с  $n = 10\,000$ , результаты будут похожи друг на друга. Большой размер выборки помогает улучшить повторяемость результатов. Однако очень большие размеры выборки неоптимальны с точки зрения общей длительности исследования: возможно, придется слишком

долго ждать результатов бенчмарка. Таким образом, имеет смысл выбирать минимально возможный размер выборки, предоставляющий требуемый уровень точности и повторяемости.

### Практические рекомендации

Для первого запуска бенчмарка рекомендуется размер выборки от 15 до 30: 15 — это значение, при котором важнейшие статистические характеристики (которые мы скоро обсудим) обычно начинают давать достоверные значения; 30 — это значение, при котором большинство статистических тестов начинают работать и показывать правдоподобные результаты. Конечно, 15 и 30 — лишь изначальные приблизительные величины: можно получить хорошее измерение за 10 итераций или абсолютно неверные результаты статистического теста за 40 итераций. Если внести изменения в исходный код и перезапустить бенчмарк, пытаясь определить значительные улучшения, такие как ускорение в пять раз, вы можете попытаться сделать несколько итераций (или даже всего одну). Одно измерение не дает никаких статистических характеристик, но помогает примерно оценить размах измерений. Иногда достаточно сказать, что бенчмарк длится несколько миллисекунд или несколько минут. Бенчмарки со сложными распределениями могут требовать сотен или даже тысяч запусков для получения правильных значений параметров. Рекомендуется запускать бенчмарк много раз для окончательной проверки, прежде чем делать выводы.

## Минимум, максимум и размах

Простейшими характеристиками распределения, которые можно вычислить, являются **минимум** и **максимум**. Вместе они формируют **размах**.

Значения минимума и максимума соответствуют лучшему и худшему показателям производительности или самому быстрому и самому медленному результатам измерений. Размах позволяет понять, какие значения мы можем получить для этого бенчмарка.

### Практические рекомендации

Если запускать простой бенчмарк в стерильном окружении, размах может получиться небольшим, например (15,181 мс, 15,226 мс). Если большая точность вам не нужна и вы просто хотите сравнить два распределения, можно взять любое число из этого интервала, например 15,2 мс, и работать с ним, другие статистические характеристики не требуются. Бенчмарк с размахом (15,181 мс, 15,226 мс), скорее всего, окажется быстрее, чем бенчмарк с размахом (629,4 мс, 653,2 мс). Если размах большой (разница между минимумом и максимумом значительна), нужны дополнительные параметры распределения.

## Среднее арифметическое

**Среднее арифметическое** значение — это самый понятный способ агрегировать числа: нужно просто сложить все числа и разделить результат на количество слагаемых. Обычно оно обозначается  $\bar{x}$  или  $\mu$ :

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

Среднее арифметическое — один из самых популярных статистических параметров. Многие разработчики при исследованиях производительности используют только его. Как проще всего сравнить производительность двух алгоритмов? Можно измерить длительность обоих несколько раз, высчитать для каждого среднее арифметическое и сравнить их! В самых простых случаях это работает прекрасно. Например, средние арифметические значения {99, 104, 105, 108, 114} и {503, 765, 653, 741, 593} равняются 106 и 651. Первый метод очевидно быстрее.

Однако нельзя быть уверенными заранее, что это работает. Со средним арифметическим может быть связано много проблем. Одна из самых распространенных — сложные формы распределений и крайне высокие значения. Например, среднее арифметическое {95, 101, 304, 97, 295, 314} равняется 201, а среднее арифметическое {150, 125, 110, 5000, 115} — 1100, что может выглядеть странно, поскольку значения среднего арифметического далеки от результатов, полученных нами в распределениях. Рассмотрим еще один параметр, который поможет решить эту проблему.

### Практические рекомендации

Среднее арифметическое значение — подходящая отправная точка для исследования распределения. В простых случаях, особенно если размах выборки небольшой, может быть достаточно просто проверить среднее арифметическое. Но иногда оно может направить вас по неверному пути: некоторые особенности распределений способны сделать это значение бесполезным. Во многих простых случаях, когда разница между распределениями хорошо заметна, соотношение между распределениями и средним арифметическим одно и то же. Это вызывает ложную уверенность в том, что достаточно просто сравнить средние арифметические. Однако никогда не следует использовать для анализа только это значение, если вы не знаете форму распределения.

## Медиана

**Медиана** — еще один способ описать среднее значение выборки. Чтобы ее найти, нужно рассортировать все значения и взять средний элемент. Если размер выборки является четным числом, то медианой будет среднее арифметическое между двумя средними элементами. Например, медианой {1, 4, 7, 15, 20} является 7, а медиана

{1, 4, 7, 8, 15, 20} равна  $(7 + 8) / 2 = 7,5$ . Таким образом, медиана разделяет нижнюю и верхнюю части результатов измерения.

Медиана решает проблему крайне высоких и крайне низких значений, которая мешает использовать среднее арифметическое. Представьте, что некий бенчмарк загружает файл из Интернета. Все итерации прошли нормально, кроме одной, закончившейся превышением лимита времени. Таким образом, мы получили следующую выборку —  $x: \{150, 125, 110, 5000, 115\}$ . Средним арифметическим является 1100, но это число не поможет описать эти данные. Медиана равняется 125, что гораздо ближе к среднему времени загрузки в реальности. Кстати, некоторые говорят «среднее», имея в виду медиану или другие средние значения, такие как среднее арифметическое. Чтобы избежать путаницы, я всегда буду использовать термины «среднее арифметическое» и «медиана», а не просто «среднее».

### Практические рекомендации

Какой параметр стоит использовать для описания результатов измерения — медиану или среднее арифметическое? К счастью, в большинстве простых случаев эти значения близки и можно выбрать любое из них. Если между ними значительная разница, требуется дополнительный анализ: нельзя выбрать только одно значение — нужны и медиана, и среднее арифметическое, и другие параметры. Даже если значения близки, мы все равно не знаем формы распределения и не можем описать его по одному числу.

## Квантили, квартили и процентиля

**q-квантили** — это точки, разделяющие выборку на  $q$  равных интервалов.

Мы уже знакомы с **2-квантилем** — это медиана, делящая выборку пополам. Например, 2-квантиль {1, 2, 3, 4, 5, 6, 7, 8, 9} равняется 5.

Другой широко распространенный вид квантиля называется **4-квантиль** или **квартиль**. Квартили — это три значения  $Q_1, Q_2, Q_3$ , делящие выборку на четыре равные части. Второй квартиль  $Q_2$  равняется медиане. Например, 4-квантили выборки {1, 2, 3, 4, 5, 6, 7, 8, 9} — это 3, 5 и 7.

Размах и квартили формируют **пятичисловую сводку**: {минимум,  $Q_1$ , медиана,  $Q_3$ , максимум}. Эти пять значений обычно используются в качестве краткой формы демонстрации выборки: она не описывает форму распределения, но дает общее представление о нем. Например, пятичисловая сводка {1, 2, 3, 4, 5, 6, 7, 8, 9} — это {1, 3, 5, 7, 9}.

Разница между верхним квартилем  $Q_3$  и нижним квартилем  $Q_1$  называется межквартильным диапазоном (interquartile range, IQR):

$$\text{IQR} = Q_3 - Q_1.$$

**Процентили** — это 100-квантили:  $k$ -й процентиль  $p_k$  представляет собой значение, отделяющее нижние  $k$  процентов результатов измерения от верхних. Медиану и квартили можно выразить через процентили:

$$p_{25} = Q_1; p_{50} = Q_2 = \bar{x}; p_{75} = Q_3.$$

Иногда точности процентилей недостаточно и нужны 1000-квантили, или **промилле**. Термин «промилле» обычно не используется, вместо них применяются процентили. Например, 99,9-й процентиль соответствует 999-му промилле. Мы можем продолжать увеличивать точность: с помощью 99,95-го процентиля обозначается 9995-й 10 000-квантиль.

Количество  $q$ -квантилей равно  $(q - 1)$ . Однако иногда вводят два дополнительных ложных квантиля — 0-й и  $q$ -й, равняющиеся минимуму и максимуму соответственно. Таким образом, пятичисловая сводка может быть выражена в процентилиях таким образом:  $p_0, p_{25}, p_{50}, p_{75}, p_{100}$ . Технически это неверно (0-го и 100-го процентилей не существует), но такой вид используется во многих статьях и постах в блогах, поскольку он более строгий.

Такие значения процентилей, как  $p_{80}, p_{95}, p_{99}$  и  $p_{99,9}$ , часто применяются при анализе производительности веб-приложений. Многие думают, что значения вроде  $p_{99}$  очень редко влияют на пользователей и о них не надо беспокоиться. Но представьте веб-страницу, отправляющую 300 запросов к дополнительным ресурсам, например к изображениям, CSS- и JavaScript-файлам. Вероятность того, что длительность каждого запроса меньше 99-го процентиля, равна  $1 - 0,99^{300} \approx 0,26$ . Вероятность 26 % в 3,7 раза лучше, чем 95 %, но все же это внушительное число. Вот простое упражнение: откройте популярный сайт, например [facebook.com](https://www.facebook.com) или [amazon.com](https://www.amazon.com), проверьте, сколько запросов там обрабатывается, и высчитайте вероятность получения  $p_{90}, p_{95}, p_{99}, p_{99,9}, p_{99,99}$  для одного из них.

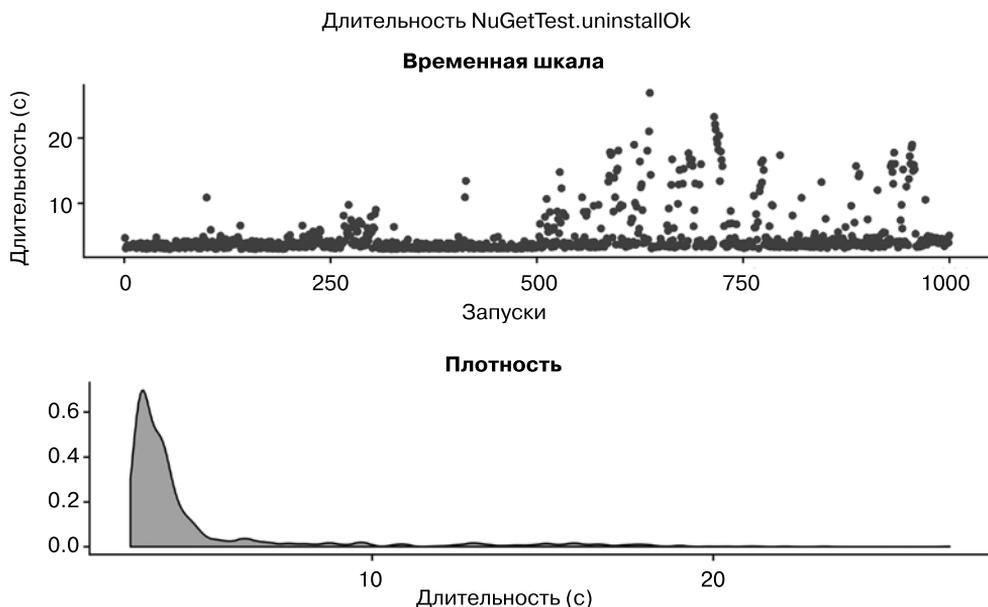
### Практические рекомендации

Пятичисловая сводка (размах и квартили) — распространенный способ описания распределения. Если размах велик и важны большие значения, нам может потребоваться большая точность, которой можно достичь с помощью процентилей. Именно так часто описывают длительность веб-запросов.

## Выбросы

**Выбросы** — это результаты, слишком высокие или низкие по сравнению с другими. Мы будем называть их **верхним** и **нижним выбросами** соответственно.

Типичное распределение производительности показано на рис. 4.3. Это распределение 1000 локальных запусков теста `NuGetTest.uninstallOk` в Rider. Тест проверяет, можем ли мы корректно удалить NuGet-пакет. Он включает в себя несколько операций с диском, поэтому мы ожидаем появления выбросов. Среднее арифметическое равно 4,938 с, но иногда тест длится до 26,930 с. Много других примеров выбросов из жизни можно найти в [Gregg, 2014b].



**Рис. 4.3.** Распределение с выбросами

Есть много разных способов определить, какие значения слишком высоки или низки. Один из самых популярных методов — границы Тьюки (Tukey fences)<sup>1</sup>:

- нижняя граница —  $Q_1 - 1,5 \cdot IQR$ ;
- верхняя граница —  $Q_3 + 1,5 \cdot IQR$ .

Все значения, не достигающие нижней границы, — это нижние выбросы. Все значения, превышающие верхнюю границу, — верхние выбросы. В этих формулах 1,5 —

<sup>1</sup> Это не единственный тест на выбросы, есть много других методов — тест шести сигм, критерий Шовене, критерий Граббса, Q-тест Диксона, критерий Пирса и др.

самый популярный множитель IQR, но вы можете использовать другое значение, если хотите установить другой уровень чувствительности к выбросам.

Важно понимать, почему появляются выбросы. Есть два вида верхних выбросов.

- **Случайный шум** (нежелательные выбросы).

В главе 2 говорилось, что измерения производительности не обходятся без шума. По разным причинам возникает много случайных ошибок, от других процессов, запущенных параллельно с бенчмарком, до ошибок квантования аппаратного таймера (об этом подробнее — в главе 9). Мы не можем полностью избавиться от шума, но можем очистить данные и убрать нежелательные выбросы, поскольку они не несут полезной информации и мешают получить точное распределение производительности.

- **Истинные эффекты** (нужные выбросы).

В некоторых бенчмарках мы ожидаем выбросов. Обычно очень высокие значения можно наблюдать при операциях ввода-вывода, сетевых запросах, запросах к базе данных и т. д. Информация о подобных выбросах важна, поскольку они появятся и в производстве. Это основная часть реального пространства производительности, которую необходимо анализировать. Нам важны эти выбросы и нужен их полный список.

В большинстве случаев в распределениях производительности наблюдаются только верхние выбросы. Однако иногда появляются и нижние. Вот два примера.

- **Ошибки.**

Представьте, что вы отправляете веб-запрос, но сеть оказывается недоступной. Подобный запрос будет завершен мгновенно — в результате получается необычно малая длительность выполнения. Такие ошибки также нужно разбирать и анализировать, это входит во многие виды анализа производительности и надежности, например *метод утилизации, насыщения и ошибок* (USE) (см. [Gregg, 2017]). Если вы придерживаетесь политики повторных попыток (retry policy), подобные значения могут превратиться в обычные значения или верхние выбросы, поэтому, если не анализировать ошибки отдельно, можно пропустить важную информацию.

- **Быстрые пути.**

Во многих программах применяются разные стратегии кэширования. Это полезно для производительности приложений, потому что так можно быстрее обрабатывать повторяющиеся запросы. Но это не очень полезно, если нужно измерить время обработки запроса без кэширования. Если невозможно отключить кэширование или производить аннулирование кэша (<http://thecodelesscode.com/case/>) после каждой итерации, следует рандомизировать запросы, чтобы не получать кэшированные результаты. В этом случае нижние выбросы могут уведомить о том, что мы попали на «быстрый путь» и пропустили нужные вычисления.

### Практические рекомендации

Рекомендуется делить данные на две группы: выбросы и все остальное. Затем можно проанализировать изначальную выборку с выбросами, измененную выборку без выбросов и полный список выбросов. Например, значения  $p_{95}$ ,  $p_{99}$ ,  $p_{99,9}$  требуют выборки, включающей выбросы. При использовании выборки, исключающей выбросы, многие статистические характеристики распределения, такие как среднее арифметическое, станут более стабильными и надежными. Анализ нужных выбросов (которые можно объяснить с помощью истинных эффектов) очень важен, он является частью пространства производительности. Решение по поводу того, какой фрагмент данных использовать (включая или исключая выбросы), необходимо принимать, основываясь на выбранных параметрах и бизнес-целях.

## Диаграммы размаха

**Диаграмма размаха (box plot)**, известная также как **диаграмма вида «ящик с усами» (whisker plot)**, представляет собой компактное средство, показывающее одновременно минимум,  $Q_1$ ,  $Q_2$ ,  $Q_3$ , максимум, нижнюю и верхнюю границы и выбросы.

Один из самых распространенных видов диаграммы размаха — это **диаграмма размаха Тьюки (Tukey box plot)**. Пример подобной диаграммы приведен на рис. 4.4, А. Она показывает расположение  $Q_1$  и  $Q_3$ . Линия внутри «ящика» обозначает медиану. От «ящика» отходят линии («усы»), обозначающие нижнюю и верхнюю границы. Выбросы показаны точками, лежащими вне «усов».

У диаграммы размаха много вариаций. Обычно «ящик» с линией всегда описывает  $Q_1$ ,  $Q_2$ ,  $Q_3$ , но «усы» могут показывать разные значения — это зависит от используемого алгоритма обнаружения выбросов. «Усы» часто сокращаются до ближайшего значения из выборки (например, если нет значения, точно равного  $Q_1 - 1,5 \cdot IQR$ , мы заканчиваем нижний «ус» на самом малом значении, превышающем нижнюю границу). Поэтому «усы» на рис. 4.4 разной длины, а положения нижней и верхней границ не совпадают с определенными по формуле Тьюки. Если у нас нет значений между  $Q_3$  и самым нижним из верхних выбросов, верхний «ус» можно совсем убрать. Существует также много видов визуальных вариаций<sup>1</sup> (объяснения с примерами разных видов диаграмм размаха можно найти в [Wickham, 2011] и [Ribessa, 2017]).

<sup>1</sup> Например, классическую диаграмму размаха можно улучшить с помощью дополнительной информации и преобразовать в диаграмму размаха переменной ширины, зубчатую диаграмму, диаграмму в форме вазы, в форме боба, в форме улья, диаграмму области наивысшей плотности, диаграмму размаха процентилей, диаграмму буквенных значений и другие виды диаграммы размаха.

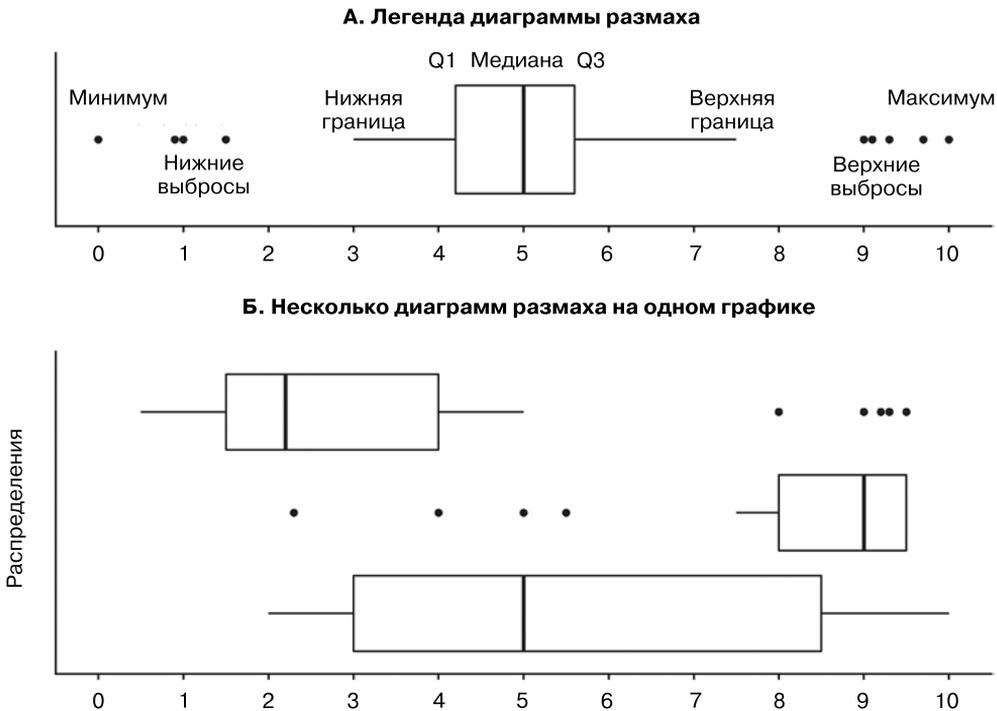


Рис. 4.4. Примеры диаграмм размаха

### Практические рекомендации

Диаграммы размаха очень эффективны, когда нужно сравнить много разных распределений одновременно (см. рис. 4.4, Б). Точной модели каждого из распределений вы не получите — окончательные выводы о конкретных парах требуют дополнительного анализа. Однако получите некоторые начальные идеи по поводу пятичисловых сводок для каждого распределения и сможете выдвинуть первую гипотезу о данных (которую нужно будет проверить позже). Существуют разные вариации диаграмм размаха, поэтому обращайте внимание на условные обозначения.

## Частотные трассы

**Частотная трасса (frequency trail)** — это прекрасная визуализация, придуманная Бренданом Греггом в [Gregg, 2014a]. Это сочетание графика плотности и гуг-графика. У классического графика плотности есть один серьезный недостаток — он

не показывает выбросы. Если у вас есть несколько крайне высоких значений, они могут стать невидимыми. Часть частотной трассы, взятая из rug-графика, решает эту проблему: она выделяет полный список выбросов, что очень важно для анализа распределения. Если у нас много разных распределений, имеет смысл соединить несколько частотных трасс в каскадный график, показав их на одном изображении. Примеры каскадных частотных трасс (frequency trail waterfall plot) приведены на рис. 4.5. Цветовая палитра может быть любой, но довольно часто используется инвертированная черно-белая палитра, поскольку она похожа на обложку альбома *Unknown Pleasures* группы Joy Division.

### Практические рекомендации

Частотная трасса — хорошая альтернатива графикам плотности, когда вы хотите рассмотреть форму распределения и список выбросов одновременно.

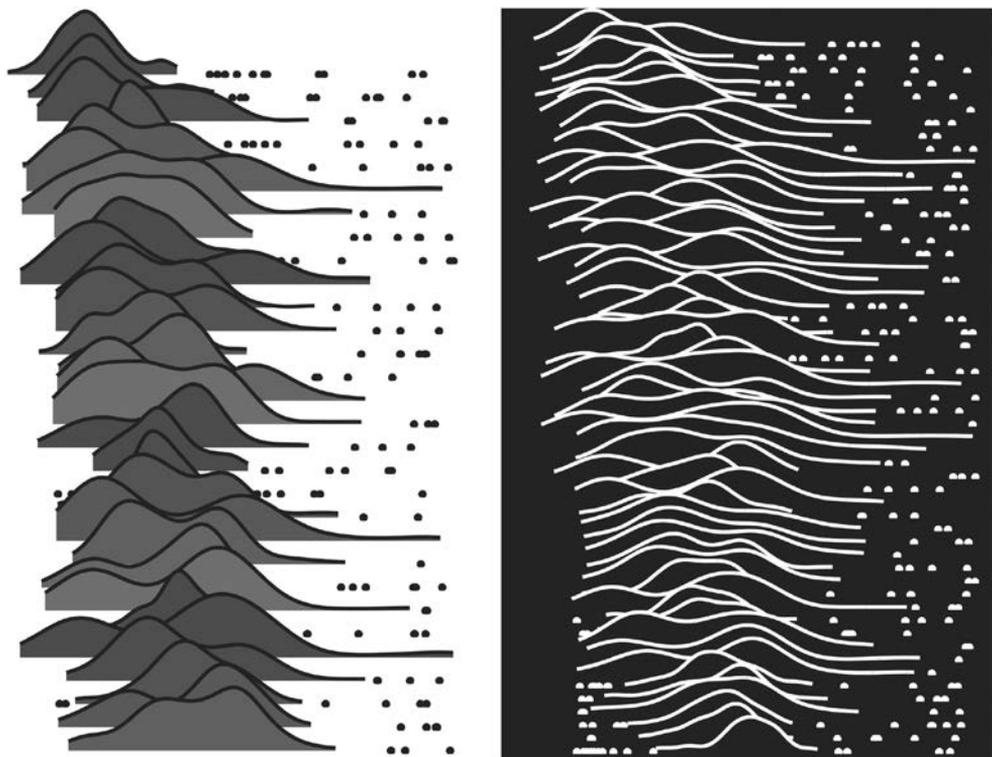


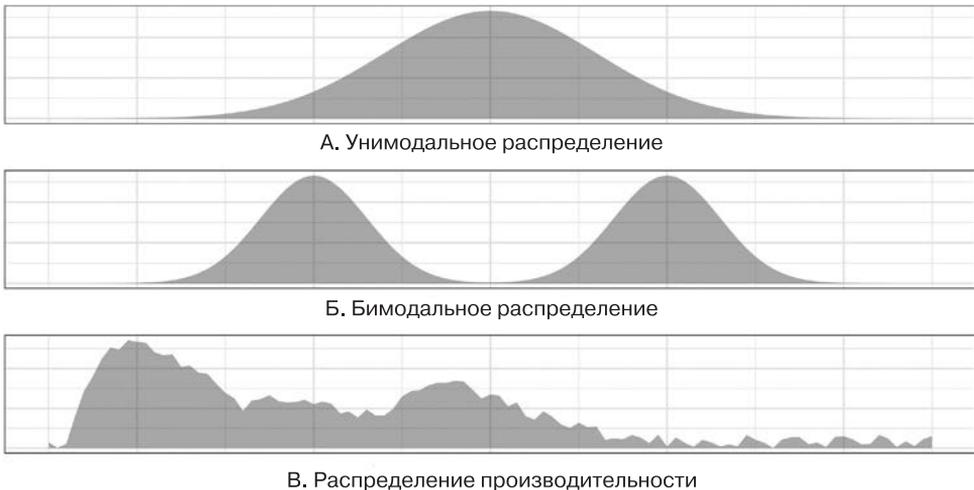
Рис. 4.5. Каскадные графики частотных трасс

## Моды

Обычно графики плотности не выглядят плоскими, на них есть низкие и высокие области. Локальный максимум графика плотности известен как **мода**. Это точка, вокруг которой много результатов измерений. На гистограмме она будет представлена столбиком, который выше своих соседей.

Если у графика плотности один локальный максимум, это распределение называют **унимодальным** (рис. 4.6, А), если два локальных максимума — **бимодальным** (рис. 4.6, Б). Мы называем распределение **мультимодальным**, когда число локальных максимумов больше одного (бимодальное распределение — частный случай мультимодального).

В реальной жизни многие распределения производительности выглядят как сочетания мультимодального распределения, случайного шума и набора выбросов (рис. 4.6, В).



**Рис. 4.6.** Унимодальное, бимодальное распределение и распределение производительности

Таким образом, не всегда возможно сказать, сколько у нас мод. Однако обычно можно различить простые, унимодальные, и сложные, мультимодальные, распределения. Обсудим, как определять мультимодальные распределения. Если вам неинтересна конкретная реализация, можете пропустить дальнейший материал.

Существует много алгоритмов для определения мультимодального распределения. К сожалению, большинство классических академических алгоритмов плохо

работают на реальных данных. Ситуация ухудшается при небольшом размере выборки (менее 30–40 измерений). Проведя множество экспериментов, я наконец нашел приемлемо работающий подход. Один из приемов, отменно работающих с распределениями производительности, описан в [Gregg, 2015] и основан на модальных значениях (mvalues). Если у нас есть гистограмма  $h$  с количеством столбиков  $k$ , названных  $h_1, h_2, \dots, h_k$  ( $i$ -й столбик содержит  $h_i$  измерений), модальное значение  $h_m$  определяется следующим образом:

$$h_m = \frac{|h_2 - h_1| + |h_3 - h_2| + \dots + |h_k - h_{k-1}|}{\max(h_1, h_2, \dots, h_k)}.$$

В этой формуле мы суммируем все подъемы между соседними столбиками и делим их на количество измерений в самом высоком из них. Минимально возможное модальное значение равняется 2, что соответствует унимодальному распределению. Модальное значение идеального бимодального распределения равняется 4.

Модальные значения и многие другие способы определения мультимодальности сильно зависят от полученных гистограмм. На рис. 4.7, А, можно увидеть бимодальное распределение в виде гистограммы. Если посмотреть только на нее, можно с легкостью сказать, что оно бимодально, поскольку центры второго и четвертого столбиков соответствуют локальным максимумам графика плотности. На рис. 4.7, Б, можно увидеть то же распределение в виде другой гистограммы. Размер столбиков обеих гистограмм совпадает, но ответвления первого столбика различаются. В итоге вторая гистограмма выглядит унимодальной: каждый столбик содержит одинаковое количество значений из выборки из-за других ответвлений гистограммы.

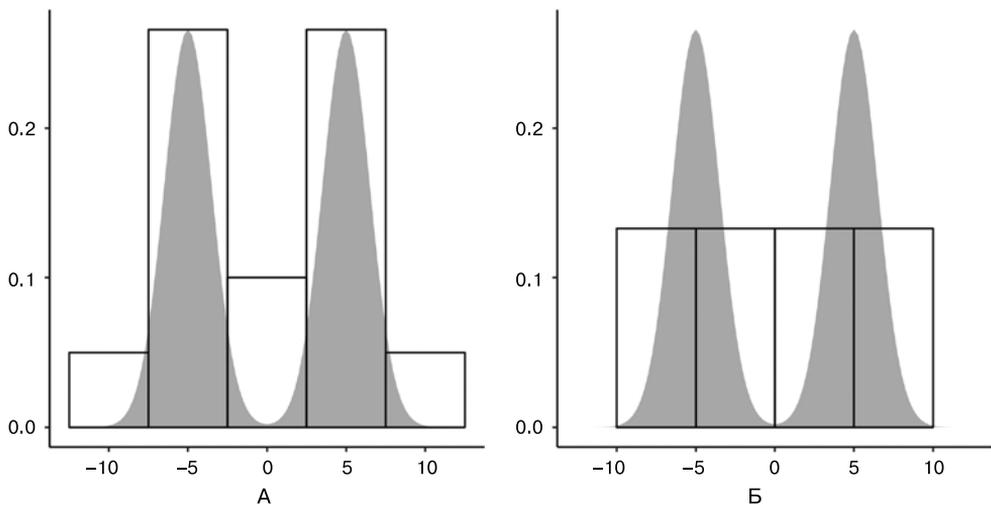


Рис. 4.7. Разные гистограммы для бимодального распределения

Построить правильную гистограмму очень важно. После многих безуспешных попыток я наконец придумал алгоритм для построения гистограмм, используемый в BenchmarkDotNet с v0.10.14<sup>1</sup>. Он выполнен по следующей схеме (конкретная реализация включает в себя много дополнительных проверок крайних случаев).

1. Удалить выбросы, основываясь на границах Тьюки.
2. Выбрать значение желаемой ширины столбика  $w$ . Рекомендуется применять нормальное референсное правило Скотта (Scott's normal reference rule) и разделить его на 2:

$$w = \frac{3,5s}{2\sqrt[3]{n}}.$$

3. Начать с гистограммы, содержащей один столбик со всеми значениями.
4. Найти столбик, который будет больше  $w$ . Если таких нет, гистограмма готова, перейти к этапу 6.
5. В выбранном столбике найти интервал шириной  $w$ , содержащий максимальное количество измерений. Вычислить среднее арифметическое  $c$  между позициями левой и правой точки. Это будет истинный центр нового столбика. Если позиции  $c - w$  и  $c + w$  находятся внутри изначального столбика, добавить в гистограмму новую точку разделения. В противном случае передвинуть новый столбик внутрь изначального столбика и добавить одну точку разделения, не соответствующую границам изначального столбика. Далее перейти к этапу 4.
6. Вычислить модальное значение и сравнить его с порогами. Если модальное значение меньше 2,8, распределение, скорее всего, является унимодальным. Если оно находится в интервале [2,8; 3,2], распределение может быть как унимодальным, так и бимодальным. Интервал [3,2; 4,2] описывает ситуацию, в которой распределение, скорее всего, бимодальное, но может иметь и больше мод. Если модальное значение больше 4,2, распределение, скорее всего, имеет несколько мод. Пороговые значения (2,8; 3,2; 4,2) — это изначальные приблизительные числа, которые можно использовать для первых экспериментов. В случае изменений в формуле желаемой ширины столбика пороговые значения нужно подстроить под них.

За этим алгоритмом стоит очень простая мысль. Модальные значения работают неправильно, когда мода находится на границе между двумя столбиками, как на рис. 4.7, Б. То есть мы пытаемся найти лучший локальный максимум (этап 4) и создаем столбик с центром, равным моде. Теперь эта мода защищена от разделения, и мы ищем следующий лучший локальный максимум.

<sup>1</sup> См. <https://github.com/dotnet/BenchmarkDotNet/blob/v0.11.3/src/BenchmarkDotNet/Mathematics/Histograms/AdaptiveHistogramBuilder.cs>.

Это не классическая гистограмма, и у нее нет специального названия. У этого подхода нет формальных доказательств, но он был проверен на тысячах запусков BenchmarkDotNet с разными распределениями производительности. Оказалось, что он очень хорошо работает с реальными данными, в отличие от некоторых классических академических алгоритмов.

### Практические рекомендации

Одно из первых свойств распределения, которое нужно проверять, — это мультимодальность. Если распределение мультимодально, многие статистические параметры, например среднее арифметическое, не работают так, как задумано, и их нельзя использовать для выводов. В то же время процентильный анализ можно продолжать применять без изменений.

Модальные значения предоставляют полезный способ определения мультимодальных распределений. Он помогает распознать подозрительные распределения, которые, вероятно, нельзя сравнивать с обычными параметрами, такими как среднее арифметическое или медиана.

## Дисперсия случайной величины и стандартное отклонение

Измерения варьируются от итерации к итерации. Мы можем оценить размах значений с помощью **дисперсии случайной величины** (смещенная оценка):

$$s^2 = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}.$$

Здесь мы вычитаем значение среднего арифметического  $\bar{x}$  из каждого значения  $x_i$ , суммируем квадраты  $(x_i - \bar{x})$  и делим сумму на размер выборки  $n$ .

На практике вместо этого обычно используется **стандартное отклонение**. Это просто квадратный корень из дисперсии. Стандартное отклонение (смещенная оценка):

$$s = \sqrt{\frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}}.$$

Мы обозначаем стандартное отклонение буквой  $s$ , однако во многих текстах вы можете встретить также символ  $\sigma$ . В исходном коде стандартное отклонение часто обозначается как `StdDev` или `SD`.

Вы могли заметить уточнение «смещенная оценка» для предыдущих формул. Эти формулы были бы корректны, если бы собрать все измерения. Однако это невоз-

можно, поскольку мы можем продолжать проводить их без ограничений. Таким образом, нам приходится оценивать дисперсию и стандартное отклонение с помощью небольшой выборки. Поэтому появляется незначительная ошибка (смещение). Ее можно исправить с помощью поправки Бесселя, которая заменяет  $n$  в делителе на  $n - 1$ . Дисперсия (несмещенная оценка):

$$s^2 = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n - 1}.$$

Стандартное отклонение (несмещенная оценка):

$$s = \sqrt{\frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n - 1}}.$$

Поправка Бесселя становится источником путаницы и недопонимания: какой делитель следует использовать,  $n$  или  $n - 1$ ? В теории лучше  $n - 1$ . С практической точки зрения обычно это неважно. Когда количество наблюдений  $n$  небольшое (менее 5–10), погрешности огромны, а вычисленные значения дают лишь приблизительное представление о настоящей дисперсии и стандартном отклонении. Когда количество наблюдений  $n$  довольно большое (свыше 10–15), разница между  $1/n$  и  $1/(n - 1)$  становится меньше важной вам точности. Поправка Бесселя существует не напрасно, в некоторых статистических приложениях она может быть довольно важна, но *обычно* в ходе реальных исследований производительности вам не нужно о ней беспокоиться.

### Практические рекомендации

Стандартное отклонение можно использовать в качестве параметра нестабильности. Оно показывает, насколько велика разница между результатами измерения. Низкое значение говорит о том, что большинство результатов близки к среднему арифметическому, а высокое — что результаты могут быть далеки от него.

При сравнении двух распределений большое стандартное отклонение может сообщить вам о том, что средние арифметические значения сравнивать нельзя. Например, если средние арифметические двух распределений равны 50 и 52 с, но стандартное отклонение для каждого из них  $\approx 15$  с, нельзя сделать никаких выводов о том, какой алгоритм быстрее. В следующем подразделе мы узнаем, как интерпретировать абсолютное значение стандартного отклонения.

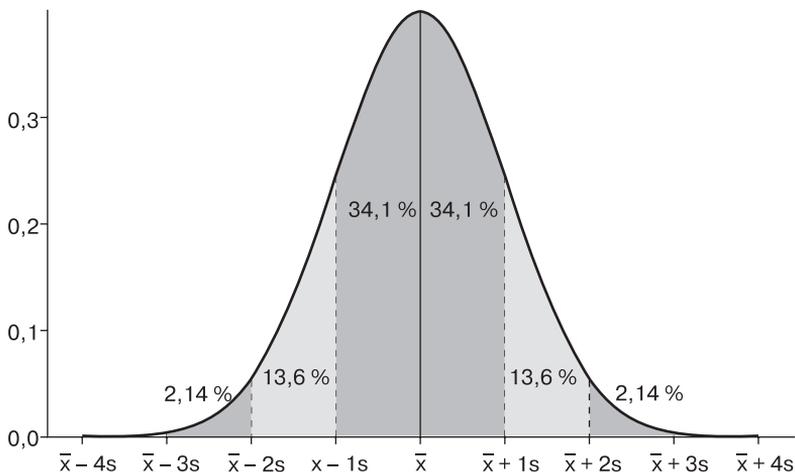
Такие выражения, как «дисперсия велика» или «стандартное отклонение велико», означают одно и то же, но первое употребляется чаще, поскольку оно короче. В то же время на практике чаще используется стандартное отклонение, поскольку оно выражается в тех же единицах, что и результаты измерений, и применяется во многих полезных формулах (некоторые из них будут приведены в следующих подразделах).

Значения среднего арифметического и стандартного отклонения — важные параметры, но все же они не описывают форму распределения. В [Matejka, 2017] можно найти изображения совершенно разных распределений с одинаковыми значениями  $\bar{x}$  и  $s$ .

Выбросы могут испортить стандартное отклонение. Если высчитывать стандартное отклонение выборки без выбросов, вы получите более повторяемое значение, но можете потерять важную информацию о дисперсии. Обычно полезно исключить выбросы перед расчетами, но все же изучить их перед этим.

## Нормальное распределение

Нормальное распределение — одно из самых известных классических распределений, о которых важно знать. Вы можете увидеть его график плотности в форме колокола на рис. 4.8.



**Рис. 4.8.** Нормальное распределение

У нормального распределения есть несколько важных свойств.

- Распределение симметрично и унимодально.
- Среднее арифметическое равно медиане.
- В интервале  $[\bar{x} - 1s; \bar{x} + 1s]$  находятся  $\approx 68\%$  значений.
- В интервале  $[\bar{x} - 2s; \bar{x} + 2s]$  находятся  $\approx 95\%$  значений.
- В интервале  $[\bar{x} - 3s; \bar{x} + 3s]$  находятся  $\approx 99,7\%$  значений.

Последнее свойство известно как *правило трех сигм*. В нем утверждается, что почти все значения ( $\approx 99,7\%$ ) в нормальном распределении лежат в пределах трех стандартных отклонений от среднего арифметического.

### Практические рекомендации

Нормальное распределение является хорошей ментальной моделью для интуитивного понимания разных параметров, таких как среднее арифметическое и стандартное отклонение, унимодальных распределений. Например, если у нас есть выборки  $x$  и  $y$ , которые можно описать с помощью нормальных распределений, можно сказать, что выборки почти не накладываются друг на друга, если  $|\bar{x} - \bar{y}| < 3s_x + 3s_y$  (размахи 99,7 % значений распределения не накладываются). В то же время, если  $|\bar{x} - \bar{y}| > s_x + s_y$  (размахи 68 % значений распределения накладываются), важно пересечение распределений. Реальные распределения производительности обычно не являются нормальными, но вы все равно можете использовать эти формулы, чтобы получить начальное представление о взаимодействиях унимодальных распределений. Если они мультимодальны, необходим дополнительный анализ графиков плотности.

## Коэффициент асимметрии

**Коэффициент асимметрии распределения (skewness)** вычисляется следующим образом:

$$\gamma = \frac{\left( (x_1 - \bar{x})^3 + (x_2 - \bar{x})^3 + \dots + (x_n - \bar{x})^3 \right) / n}{s^3}.$$

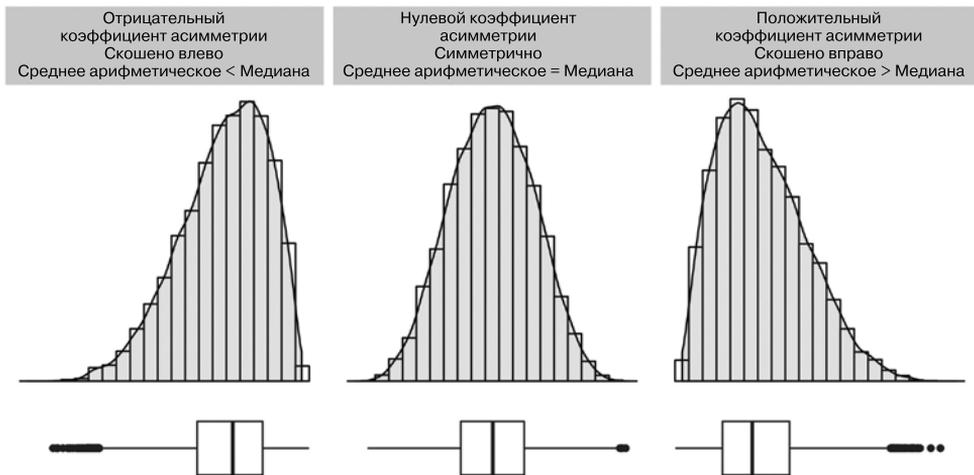
Абсолютное значение этого коэффициента показывает, насколько асимметрично данное распределение. Знак коэффициента асимметрии показывает вид асимметрии и позволяет различать скошенное влево и скошенное вправо распределения. Существуют и другие формулы коэффициента асимметрии, которые можно интерпретировать таким же образом. Одна из простейших формул — **коэффициент асимметрии медианы Пирсона**:

$$\gamma_{\text{median}} = \frac{3(\bar{x} - Q_2)}{s}.$$

Из этой формулы очевидно, что знак коэффициента асимметрии можно легко оценить, сравнивая среднее арифметическое  $\bar{x}$  и медиану  $Q_2$ .

- Если среднее арифметическое меньше медианы, распределение скошено влево и коэффициент асимметрии меньше 0.
- Если среднее арифметическое равно медиане, распределение симметрично и коэффициент асимметрии равен 0.
- Если среднее арифметическое больше медианы, распределение скошено вправо и коэффициент асимметрии больше 0.

Соответствующие графики плотности и размаха приведены на рис. 4.9.



**Рис. 4.9.** Распределение с разными значениями коэффициента асимметрии

Коэффициент асимметрии нормального распределения равен 0, поскольку оно симметрично. Заметьте: то, что коэффициент асимметрии равен 0, не всегда означает, что распределение идеально симметрично. Большая часть реальных распределений производительности скошена вправо (коэффициент асимметрии положителен).

### Практические рекомендации

Коэффициент асимметрии помогает получить представление о симметрии распределения, не глядя напрямую на графики плотности. Сочетание отрицательного коэффициента асимметрии и большого стандартного отклонения необычно для распределений производительности и может свидетельствовать о том, что требуется дополнительный анализ. Выбросы могут исказить значения коэффициента асимметрии, поэтому их следует исключить из расчетов. Коэффициент ненадежен при небольшом размере выборки ( $n < 15$ ) и мультимодальных распределениях.

## Коэффициент эксцесса распределения

**Коэффициент эксцесса (kurtosis)** измеряет «островершинность». Его можно вычислить следующим образом:

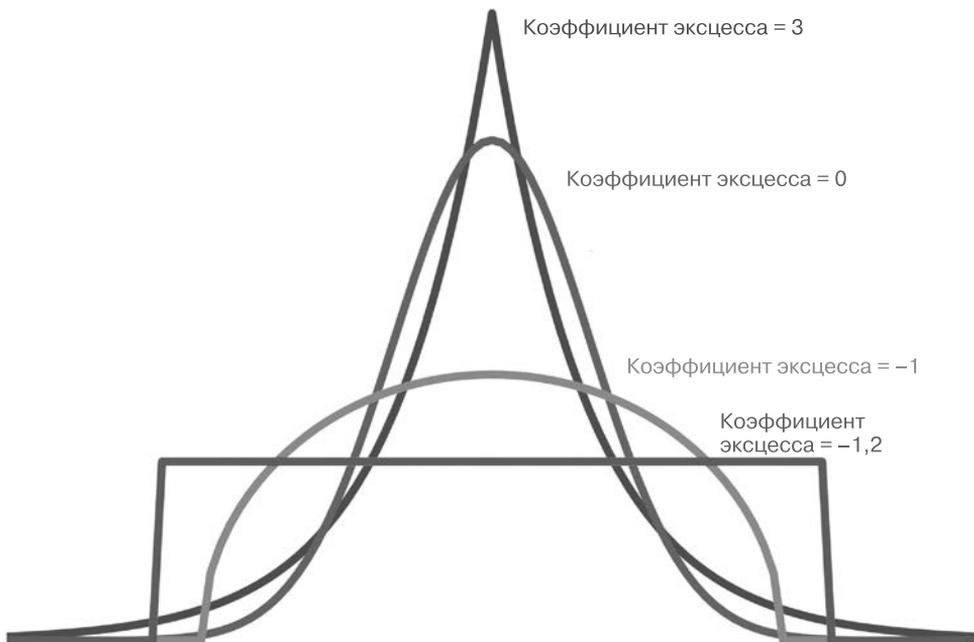
$$\kappa = \frac{\left( (x_1 - \bar{x})^4 + (x_2 - \bar{x})^4 + \dots + (x_n - \bar{x})^4 \right) / n}{s^4}$$

Высокий коэффициент эксцесса означает, что вершина распределения острая, низкий — что она плоская. Коэффициент эксцесса нормального распределения равен 3. Нормальное распределение часто используется в качестве базы для сравнения с другими распределениями, но 3 не является подходящим референтным значением. Поэтому решено было ввести **избыточный коэффициент эксцесса (excess kurtosis)**:

$$\kappa_{\text{excess}} = \frac{\left( (x_1 - \bar{x})^4 + (x_2 - \bar{x})^4 + \dots + (x_n - \bar{x})^4 \right) / n}{s^4} - 3.$$

Избыточный коэффициент эксцесса нормального распределения равен 0, что очень удобно. Разница между коэффициентом эксцесса и повышенным коэффициентом тоже часто вызывает путаницу. Во многих статьях, книгах, постах в блогах и программах избыточный коэффициент эксцесса обозначают просто как коэффициент эксцесса. Поэтому, если вы видите выражение «коэффициент эксцесса нормального распределения», невозможно заранее назвать его значение: в зависимости от предпочтений автора им может быть как 0, так и 3.

Ясность по поводу формы распределения при разных значениях избыточного коэффициента эксцесса должен внести рис. 4.10. Коэффициент эксцесса описывает центральную вершину распределения: высокое значение этого коэффициента соответствует более острой вершине, а низкое — плоской.



**Рис. 4.10.** Распределение с разными значениями повышенного коэффициента эксцесса

### Практические рекомендации

Коэффициент эксцесса — это еще одно число, помогающее нам представить распределение, не глядя на график. Когда вы видите где-то значение коэффициента эксцесса, проверьте условные обозначения — это может быть повышенный коэффициент. Выбросы могут исказить значения коэффициента эксцесса, поэтому их следует исключить из расчетов. Коэффициент ненадежен при небольшом размере выборки ( $n < 15$ ) и мультимодальных распределениях.

## Стандартная ошибка и доверительные интервалы

Говоря о среднем арифметическом значении, мы высчитываем среднее арифметическое выборки, но оно не является истинным средним арифметическим распределения. На самом деле фиксированного значения истинного среднего арифметического не существует, поскольку набор измерений бесконечен, мы можем выполнить столько измерений, сколько захотим. Однако можно предположить, что истинное среднее арифметическое существует и соответствует среднему арифметическому невероятного огромного набора измерений.

Давайте узнаем, как вычислять погрешность между значениями среднего арифметического выборки и истинного среднего арифметического. Это делается с помощью **стандартной ошибки**, которая является частным деления стандартного отклонения на квадратный корень из размера выборки  $s/\sqrt{n}$ .

Стандартную ошибку можно интерпретировать как меру точности: чем она меньше, тем точнее оценка истинного среднего арифметического. Как можно видеть из формулы, стандартная ошибка зависит от стандартного отклонения и размера выборки. Если стандартное отклонение велико, становится сложно правильно определить истинное среднее арифметическое, потому что результаты измерений слишком сильно варьируются. Большой размер выборки дает меньшую стандартную ошибку. Если стандартное отклонение показывает разрыв между разными значениями в распределении, то стандартная ошибка показывает разрыв между значениями среднего арифметического в разных выборках. Таким образом, она является также мерой повторяемости: если запустить весь эксперимент многократно и получить разные распределения для одного и того же бенчмарка, разница между полученными значениями будет коррелировать со стандартной погрешностью.

Теперь мы можем вычислить **размер ошибки (margin of error)**, который является произведением стандартной ошибки и критического значения  $t^*$ :

$$t^* \left( s/\sqrt{n} \right).$$

Критическое значение  $t^*$  — это магическая константа, зависящая от размера выборки и **уровня значимости** (выраженного в процентах). В табл. 4.1 приведены критические значения самых распространенных доверительных интервалов при разных размерах выборки.

**Таблица 4.1.** Критические значения доверительных интервалов

<b>n</b>	<b>80 %</b>	<b>90 %</b>	<b>95 %</b>	<b>98 %</b>	<b>99 %</b>	<b>99,9 %</b>
2	3,078	6,314	12,706	31,821	63,657	636,619
3	1,886	2,920	4,303	6,965	9,925	31,599
4	1,638	2,353	3,182	4,541	5,841	12,924
5	1,533	2,132	2,776	3,747	4,604	8,610
6	1,476	2,015	2,571	3,365	4,032	6,869
7	1,440	1,943	2,447	3,143	3,707	5,959
8	1,415	1,895	2,365	2,998	3,499	5,408
9	1,397	1,860	2,306	2,896	3,355	5,041
10	1,383	1,883	2,262	2,821	3,250	4,781
11	1,372	1,812	2,228	2,764	3,169	4,587
12	1,363	1,796	2,201	2,718	3,106	4,437
13	1,356	1,782	2,179	2,681	3,055	4,318
14	1,350	1,771	2,160	2,650	3,012	4,221
15	1,345	1,761	2,145	2,624	2,977	4,140
16	1,341	1,753	2,131	2,602	2,947	4,073
17	1,337	1,746	2,120	2,583	2,921	4,015
18	1,333	1,740	2,110	2,567	2,898	3,965
19	1,330	1,734	2,101	2,552	2,878	3,922
20	1,328	1,729	2,093	2,539	2,861	3,883
100	1,290	1,660	1,984	2,365	2,626	3,392
1000	1,282	1,646	1,962	2,330	2,581	3,300
10 000	1,282	1,645	1,960	2,327	2,576	3,292

**Доверительный интервал среднего арифметического** — это интервал вокруг него с радиусом, равным размеру ошибки. Это означает, что разность между любой точкой из этого интервала и средним арифметическим будет меньше допустимого предела погрешности или равна ему:

$$\left[ \bar{x} - t^* \frac{s}{\sqrt{n}}; \bar{x} + t^* \frac{s}{\sqrt{n}} \right].$$

По определению 99 % всех доверительных интервалов с уровнем значимости 99 % включают в себя истинное среднее арифметическое. Доверительные интервалы часто интерпретируют неправильно, что приводит к неверным выводам. Вот самая распространенная ошибка: неверно то, что истинное среднее арифметическое, скорее всего, находится в доверительном интервале, но если его там нет, оно должно быть рядом с ним. На самом деле истинное среднее арифметическое может быть далеко от доверительного интервала конкретной выборки. Уровень значимости 99 % говорит о том, что такие ситуации редки, но не говорит ничего о расстоянии между доверительным интервалом и истинным средним арифметическим.

В распределениях производительности стандартное определение доверительного интервала не работает в том виде, в каком оно обычно представлено. Если распределение сильно скошено и у него очень высокие выбросы, определить истинное среднее арифметическое довольно сложно. На практике вы легко можете попасть в ситуацию, в которой у 80 из 99 % доверительных интервалов нет общих точек. Она может улучшиться, если мы значительно увеличим размер выборки, но это может оказаться непрактично: общее время эксперимента также значительно увеличивается, не давая ощутимых преимуществ. Гораздо эффективнее просто исключить из выборки выбросы и описать их отдельно. В простых случаях уровень значимости 99,9 % обычно обеспечивает довольно высокую точность, которую можно использовать для анализа.

Стандартная погрешность помогает понять, как размер выборки влияет на точность. Многие думают, что, если вдвое увеличить размер выборки, точность также увеличится вдвое, но это не так. Допустим, мы меняем размер выборки со 100 до 400. Если стандартное отклонение у обеих выборок одинаковое, стандартная ошибка изменится с  $s/\sqrt{100} = s/10$  до  $s/\sqrt{400} = s/20$ . Таким образом, увеличение размера выборки в четыре раза сокращает стандартную ошибку вдвое. Хотя любые 100 серий итераций занимают одно и то же время в эксперименте, они вносят различный вклад в точность. Изменение размера выборки со 100 до 200 сокращает погрешность на  $\approx 41$  %, но изменение с 5100 до 5200 сокращает ее всего на  $\approx 1$  %.

### Практические рекомендации

Стандартная погрешность является мерой точности и повторяемости результатов бенчмарка. В случае распределений производительности доверительные интервалы работают не так, как задумано, но они все равно являются хорошим параметром для начальной оценки разницы между средним арифметическим выборки и истинным средним арифметическим.

На практике рекомендуется уровень значимости 99,9 %. Для  $n > 30$  можно использовать  $t^* \approx 3,6$  в качестве приблизительного критического значения. Если вы хотите выбрать другой доверительный интервал, можете взять значение из табл. 4.1 (ее расширенную версию легко найти в Google). Обычно не стоит волноваться по поводу

точного значения  $t^*$ , потому что для работы достаточно приблизительного значения доверительного интервала. Если вы хотите вычислить точное значение, рекомендую использовать уже существующие решения (например, у BenchmarkDotNet есть для этого API, основанный на приблизительных значениях из [ACM209] и [ACM395]).

Стандартная погрешность также помогает выбрать оптимальный размер выборки. При изменении размера выборки с  $n_1$  до  $n_2$  стандартная погрешность снизится на  $\sqrt{n_2/n_1}$ . При небольшом значении  $n$  каждая дополнительная итерация значительно улучшает точность. В какой-то момент оказывается бессмысленно платить временем ожидания за точность, поскольку влияние точности дополнительных итераций становится слишком незначительным.

## Центральная предельная теорема

Центральная предельная теорема (central limit theorem) гласит, что, если взять много выборок и вычислить среднее арифметическое для каждой из них, из этих значений сформируется приблизительно нормальное распределение. Эта теорема работает, только если размер выборки в каждом случае достаточно велик.

Самое прекрасное в центральной предельной теореме — это то, что она действует даже для распределений, не являющихся нормальными. Изначальный набор данных может иметь множество выбросов и сложную форму распределения, но теорема все равно сработает.

Зачастую люди делают неверные выводы из этой теоремы. Давайте обсудим несколько распространенных ошибок.

- Центральная предельная теорема работает некорректно при небольших размерах выборки. Например, если в каждой выборке вы сделаете только одно измерение, то распределение, основанное на значениях среднего арифметического, будет иметь ту же форму, что и исходное распределение.
- Если брать небольшое количество выборок ( $n < 100$ ), мы не увидим нормального распределения на графике плотности значений среднего арифметического.
- Если проводить много итераций, исходное распределение не станет нормальным и мы не сможем интерпретировать среднее арифметическое, дисперсию, коэффициент асимметрии и коэффициент эксцесса так, как интерпретировали бы при нормальном распределении.
- Размах значений среднего арифметического по всем выборкам не всегда узок. Мы все равно можем получить огромную разницу между этими значениями в разных выборках. У нормального распределения, основанного на значениях среднего арифметического, собственное стандартное отклонение, зависящее от размера выборки. Его можно выразить через стандартную погрешность.

Еще одно прекрасное объяснение центральной предельной теоремы можно найти в [Minitab, 2013].

### Практические рекомендации

Мы знаем, что хороший бенчмарк должен быть повторяемым, но этого не всегда легко достичь, если у распределения высокая дисперсия. Теорема центрального предела утверждает, что при правильном размере выборки значения среднего арифметического из разных выборок распределяются нормально. Обычно в каждой выборке должно быть как минимум 30 итераций. Если у нас большие выбросы, следует увеличить требования к минимальному размеру выборки.

Таким образом можно оценить ожидаемую разницу между экспериментами. Представьте, что вы хотите сравнить производительность двух методов, но *разница между средними арифметическими этих алгоритмов в одном эксперименте* меньше, чем *разница между средними арифметическими одного алгоритма в разных экспериментах*. Ситуацию можно улучшить, увеличив размер выборки в каждом эксперименте.

## Подводя итог

Описательная статистика предоставляет большой набор параметров и подходов для исследования распределений.

- **Среднее арифметическое, стандартное отклонение, коэффициент асимметрии и коэффициент эксцесса.**

Эти значения помогают получить первое впечатление от выборки. Среднее арифметическое — это самый простой способ организации данных. Во многих случаях оно может привести вас к неверным выводам, но обычно это хорошая точка отсчета. *Дисперсия* (или *стандартное отклонение*, которое является квадратным корнем из *дисперсии*) показывает разброс данных. *Коэффициенты асимметрии* и *эксцесса* являются мерами асимметрии и острровершинности распределения. Эти значения легко могут быть искажены из-за *выбросов* (очень высоких или низких значений). Одним из самых популярных способов определения выбросов являются *границы Тьюки*, но существуют и альтернативные способы (например, в [Gregg, 2014b] описан тест шести сигм). *Нормальное распределение* — хорошая ментальная модель для этих значений.

- **Квантили.**

Квантили делят *размах* (интервал между минимумом и максимумом) на равные части. Самые популярные типы квантилей — это *медиана* (делит данные на две части), *квартили* (делят данные на четыре части) и *процентили* (делят данные

на 100 частей). Распределение можно описать с помощью *пятичисловой сводки*: минимум,  $Q_1$ , медиана,  $Q_3$ , максимум или  $p_0, p_{25}, p_{50}, p_{75}, p_{100}$  (технически нулевого и сотого процентилей не существует, но их часто используют для единообразия вместо значений минимума и максимума).

- **Точность.**

Для высокой точности критичен *размер выборки*. Невозможно сделать надежные выводы о распределении, основываясь всего на нескольких измерениях. Рекомендуется изначально задавать размер выборки от 15 до 30 и менять его, основываясь на полученных результатах. *Стандартная ошибка* может применяться в качестве меры точности: она прямо пропорциональна стандартному отклонению (с большим разбросом сложно достичь высокой точности) и обратно пропорциональна размеру выборки (точность повышается при большем количестве измерений). *Доверительный интервал среднего арифметического* является приблизительным значением истинного среднего арифметического. Если выборка слишком широка, нельзя доверять ее среднему арифметическому.

- **Моды.**

В реальности многие распределения производительности являются *мультимодальными*. Это значит, что у распределения несколько локальных максимумов. В этом случае типичные параметры, например среднее арифметическое, менее полезны. Очень важно распознавать такие распределения и разбираться с ними по отдельности. Одна из самых полезных методик распознавания — использование модальных значений.

- **Визуализация.**

Визуализация — полезная техника, помогающая быстро разобраться в форме распределения. *Временной график* — самый прямой способ представить выборку. Он просто демонстрирует значение выборки для каждой итерации. *rug-график* — это сжатая версия временного графика, она представляет собой одномерный график со всеми результатами измерений. *Гистограмма* — это столбчатая диаграмма, показывающая форму распределения. Она состоит из столбиков, демонстрирующих относительное число измерений за каждый небольшой интервал. *График плотности* — это гладкая версия гистограммы, показывающая форму распределения с меньшим количеством визуального шума. *Частотная трасса* является комбинацией графика плотности и rug-графика. Она эффективна для выделения выбросов на графике плотности. *Каскадный график* — это сочетание многих наложенных друг на друга графиков на одном изображении. Он эффективен для исследования множества графиков плотности и частотных трасс для одного бенчмарка. *График размаха* показывает минимум,  $Q_1$ ,  $Q_2$ ,  $Q_3$ , максимум, нижнюю и верхнюю границы и выбросы одновременно. Он очень полезен при сравнении нескольких распределений разных бенчмарков одновременно. Существует также много других полезных типов графиков.

### Практические рекомендации

Проверять все возможные статистические характеристики каждый раз для каждого бенчмарка — занятие довольно времязатратное. Поэтому имеет смысл проверять только самые важные параметры, выбранные в соответствии с вашими целями. Прежде всего рекомендую проверять, мультимодально ли распределение, и рассматривать список выбросов. В случае мультимодальных распределений имеет смысл изучить график плотности. Если распределение унимодально, мы можем удалить выбросы и посмотреть на три значения: среднее арифметическое, стандартное отклонение и стандартную ошибку. Среднее арифметическое предоставляет изначальную оценку средней производительности, стандартное отклонение помогает оценить разброс значений, а стандартная погрешность показывает точность.

Если нужно сравнить одновременно много распределений, мы можем рассмотреть графики размаха или сравнить пятичисловые сводки. Лучший способ исследовать распределение — изучить гистограмму или график плотности. При большом количестве выбросов лучше изучить график частотных трасс. Если важны самые худшие варианты и у нас слишком много выбросов или большая дисперсия, имеет смысл проверить процентиля ( $p_{95}$ ,  $p_{99}$ ,  $p_{99,9}$ ). Для того чтобы прийти к каким-то выводам, основываясь на доверительном интервале, нужен подходящий размер выборки — не менее 30 (если распределение очень скошено или имеет много выбросов, требуется больший размер выборки).

Статистическое заключение (процесс понимания характеристик распределения, основанный на описательной статистике) в основном строится на опыте. Проведя несколько статистических исследований, вы поймете, как быстро отбирать самые важные параметры для текущей задачи. Вы даже сможете вывести собственные эмпирические правила, помогающие интерпретировать их корректно и приходиться к релевантным выводам.

Умение работать с одним распределением является важным навыком для следующей темы — анализа.

## Анализ производительности

Мы уже знаем, как анализировать одно распределение и вычислять базовые статистические характеристики, такие как среднее арифметическое, стандартное отклонение и квартили. Пора узнать о том, как их использовать при анализе нескольких распределений и оптимизации процесса бенчмаркинга. В этом разделе мы обсудим следующие важные темы.

- **Сравнение распределений.**

Вы узнаете, как сравнить два распределения с помощью эвристик и статистических тестов, например t-теста Уэлча и U-теста Манна — Уитни. Мы рассмотрим много важных понятий, таких как нулевая и альтернативная гипотезы, ошибки 1-го и 2-го рода и p-значения.

- **Регрессионные модели.**

Вы узнаете, как научиться понимать взаимосвязь между входными данными и производительностью методов. Для этого требуется знание статистических приемов, таких как полиномиальная регрессия и приближения с помощью кривых. Мы также обсудим, как анализировать алгоритмическую сложность и работать со сложными взаимозависимостями. Производительность зависит не только от входных данных, но и от окружения. Мы рассмотрим базовые способы работы с категориальными переменными и поиска факторов, влияющих на производительность.

- **Произвольная остановка.**

Статистика — мощный инструмент для анализа существующих данных. Однако ее можно применять и во время процесса бенчмаркинга. Например, вместо того чтобы заранее фиксировать количество итераций, мы можем остановить бенчмарк при достижении желаемых характеристик распределения.

- **Пробные эксперименты.**

Вместо того чтобы угадывать идеальное количество вызовов метода для каждой итерации, мы можем провести серию пробных итераций до основных измерений и найти оптимальное количество вызовов.

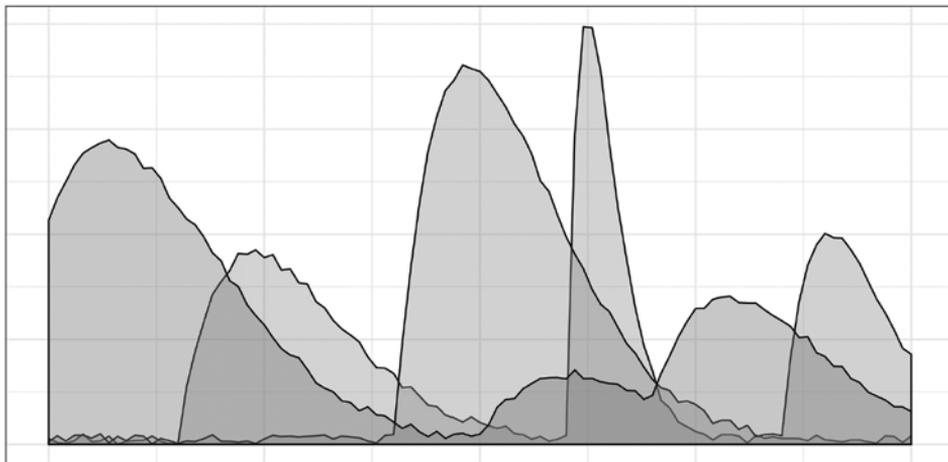
Анализ производительности — чрезвычайно важный для бенчмаркинга навык. Без него результаты бенчмарка будут всего лишь цифрами, из которых нельзя сделать выводов. Более того, такие подходы, как произвольная остановка и пробные эксперименты, помогают минимизировать длительность всего эксперимента и получить приемлемую точность. Начнем с самой распространенной задачи — сравнения двух распределений.

## Сравнение распределений

Допустим, у вас есть два метода и вы хотите узнать, какой из них быстрее. При бенчмаркинге мы можем собрать выборки замеров производительности  $x$  и  $y$  для обоих методов. После этого надо сравнить два набора чисел. Сравнение распределений — одна из основных задач в анализе производительности, и задача непростая. На рис. 4.11 можно увидеть графики плотности для трех разных методов. Можете ли вы по ним сказать, какой из методов быстрее?

В области производительности часто приходится искать компромиссы между различными сценариями работы программы. Иногда один метод может казаться быстрее другого на одной выборке, но в другой выборке мы получим противоположную ситуацию. Самыми распространенными проблемами, мешающими сравнивать распределения, являются мультимодальность и выбросы. Но, даже если мы получили унимодальные распределения без выбросов, задача сравнения может оказаться сложной из-за большой дисперсии и накладывающихся друг на друга

размахов. Давайте узнаем, как статистика может помочь решить эти проблемы и автоматизировать сравнение распределений.



**Рис. 4.11.** Распределения, которые сложно сравнивать

При сравнении выборок замеров производительности  $x$  и  $y$  можно получить четыре результата.

**1.  $X$  быстрее  $y$ .**

В реальности это не означает, что первый метод во всех случаях быстрее второго. Но это означает, что, возможно, стоит предпочесть первый метод, если нужна лучшая производительность.

**2.  $Y$  быстрее  $x$ .**

Здесь та же ситуация: мы можем притвориться, что второй метод действительно быстрее первого, и использовать эту информацию, принимая бизнес-решения, но это не значит, что так будет всегда.

**3. Статистически значительной разницы между  $x$  и  $y$  не существует.**

Этот вывод не означает, что у обоих методов одинаковые характеристики производительности. Он значит, что мы просто не можем сказать, что один метод определенно быстрее другого.

**4. Размеры выборок слишком малы, чтобы сделать надежный вывод.**

Это не значит, что найти самый быстрый метод невозможно, просто нужно больше данных, чтобы принять решение. Некоторые статистические методы просто неприменимы к выборкам малого размера.

Четвертый случай не очень интересен, потому что в этой ситуации просто требуется собрать больше данных. Самое интересное — как отличить первые два случая от третьего. То есть главный вопрос, на который мы хотим ответить: «Существует ли статистически значимая разница между двумя распределениями?» Основываясь на этом вопросе, мы можем выдвинуть две **гипотезы**.

- **Нулевая гипотеза  $H_0$** : статистически значимой разницы нет.
- **Альтернативная гипотеза  $H_1$** : статистически значимая разница есть.

Программистам часто трудно запомнить, как выбрать каждую из них. Лично мне нравится использовать другие названия, основанные на результатах поисков.

- **Отрицательная гипотеза**: нет, мы не нашли разницы.
- **Положительная гипотеза**: ура, мы нашли разницу.

К сожалению, такие названия никто не употребляет. Почти во всех статьях и записях в блогах пишут «нулевая» и «альтернативная», поэтому их стоит запомнить. Вот несколько мнемонических приемов, которые могут вам помочь.

- **Правило первой буквы.**
  - Нулевая гипотеза: нет ничего интересного.
  - Альтернативная гипотеза: ага, есть что-то интересное.
- **Есть ли статистически значимая разница?**
  - Нулевая гипотеза: нет, ее нет.
  - Альтернативная гипотеза: ага, есть.

Любые выводы, к которым мы приходим, описывают собранные данные, но не нашу теорию. Невозможно доказать, что для *распределений* верна  $H_0$  или  $H_1$ , основываясь на *выборках* результатов измерений. При этом нужно принять бизнес-решение, основываясь на полученных выборках (например, какой метод должен использоваться для получения оптимальной производительности). Поэтому мы можем вести себя так, будто  $H_0$  или  $H_1$  верна, но нужно понимать, что некоторые из наших выводов могут быть неправильными.

Тесты, о которых мы поговорим, позволяют отвергнуть нулевую гипотезу. В зависимости от результата ( $H_0$  отвергнута или нет) могут быть допущены два вида ошибок.

- **Ошибка 1-го рода**:  $H_0$  верна, но отвергнута.
- **Ошибка 2-го рода**:  $H_0$  неверна, но не отвергнута.

Лично мне не нравятся обозначения «1-го рода» и «2-го рода». Я предпочитаю использовать термины «ложноположительная» и «ложноотрицательная».

- **Ошибка 1-го рода — ложноположительная (false positive):**
  - вывод о том, что у нас **положительный** результат, **ложно**;
  - мы совершили ошибку, решив, что **положительная** гипотеза верна;
  - разницы *нет*, а мы думаем, что она *есть*.
- **Ошибка 2-го рода — ложноотрицательная (false negative):**
  - вывод о том, что у нас **отрицательный** результат, **ложно**;
  - мы совершили ошибку, решив, что **отрицательная** гипотеза верна;
  - разница *есть*, а мы думаем, что ее *нет*.

К сожалению, обозначения «1-го рода» и «2-го рода» широко распространены, поэтому полезно будет запомнить, какая из них какая. Вот еще несколько мнемонических приемов.

- **Мальчик, который кричал: «Волки!»** (<https://stats.stackexchange.com/a/17399>):
  - первая ошибка, совершенная жителями деревни (когда они поверили мальчику), была ошибкой 1-го рода;
  - вторая ошибка, совершенная жителями деревни (когда они не поверили мальчику), была ошибкой 2-го рода.
- **Правило важности:**
  - 1-го рода более важная (мы можем *принять* неверное решение);
  - 2-го рода менее важная (мы можем *упустить возможность принять* верное решение).

Классическая форма всех возможных результатов эксперимента приведена в табл. 4.2.

**Таблица 4.2.** Виды ошибок

	$H_0$ верна	$H_0$ неверна
$H_0$ не отброшена	Ошибок нет	Ошибка 2-го рода
$H_0$ отброшена	Ошибка 1-го рода	Ошибок нет

Такое представление может запутать некоторых разработчиков. Попытаемся упростить эту таблицу. В статистике мы всегда работаем с  $H_0$ , потому что таковы законы математики: мы можем только отвергнуть или не отвергнуть  $H_0$ , но не можем делать

выводов насчет  $H_1$ . Таким образом, «нельзя отвергнуть  $H_0$ » — распространенный вывод в статистике. Он прост, но не для всех звучит понятно. Когда нужно интерпретировать результат, мы мысленно переводим его в «мы думаем, что  $H_0$  верна», то есть мы получили отрицательный результат — у нас нет ничего интересного. По аналогии « $H_0$  отвергнута» можно перевести в «мы думаем, что  $H_0$  неверна» или «мы думаем, что  $H_1$  верна», то есть положительный результат — мы нашли разницу между  $x$  и  $y$ . С таким объяснением табл. 4.2 можно преобразовать в табл. 4.3.

**Таблица 4.3.** Виды ошибок (альтернативная версия)

	<b>Отрицательная гипотеза верна</b>	<b>Положительная гипотеза верна</b>
Мы думаем, что <b>отрицательная</b> гипотеза верна	Истинно отрицательная (true negative)	Ложноположительная (false negative)
Мы думаем, что <b>положительная</b> гипотеза верна	Ложноотрицательная (false positive)	Истинно положительная (true positive)

Эта таблица не так формальна, как табл. 4.2, но выглядит более понятной и единообразной. Теперь мы знакомы с основными понятиями — «гипотезы» и «ошибки» и пора перейти к выводам!

В самых простых случаях, особенно когда один метод в несколько раз быстрее другого, разница между двумя распределениями очевидна. Но если мы хотим автоматизировать сравнение распределений, нам нужны формулы. Вот несколько возможных **эвристических тестов**, которые можно применить для проверки того факта, что  $x$  быстрее, чем  $y$ .

- **Проверка на диапазоны**  $x_{\max} < y_{\min}$ .

Во многих простых случаях тесты распределений вообще не накладываются друг на друга. В подобных ситуациях мы можем сравнить максимум первого распределения и минимум второго. Если выборки достаточно велики (этот способ плохо работает, если  $n \leq 5$ ), скорее всего, первый метод быстрее второго.

- **Тест Тьюки**  $Q_3(x) + 1,5 \cdot IQR_x < Q_1(y) - 1,5 \cdot IQR_y$ .

Проверку на диапазоны легко могут испортить выбросы. Если  $x$  содержит одно очень высокое значение, которое входит в размах  $y$ , два размаха накладываются друг на друга. Эту проблему можно решить, исключив выбросы. Здесь не нужно даже находить их все. Можно просто сравнить верхнюю границу Тьюки для первого распределения и нижнюю границу Тьюки для второго.

- **Тест трех сигм**  $\bar{x} + 3s_x < \bar{y} - 3s_y$

Мы знаем о том, что 99,7 % значений в нормальном распределении находятся внутри интервала  $\pm 3s$  от среднего арифметического. Таким образом, мы можем

сравнить верхнюю границу интервала для первого распределения и нижнюю границу для второго. Этот тест прекрасно подходит для распределений, близких к нормальным, но хуже работает при более сложных распределениях, например мультимодальных.

У этих простых тестов очень невысок уровень ошибок 1-го рода (ложноположительных): думая, что существует статистически значимая разница ( $H_0$  ложна,  $H_1$  верна), мы, скорее всего, правы. Однако высок уровень ошибок 2-го рода (ложноотрицательных): при наложении размахов распределений друг на друга мы, вероятнее всего, не сможем определить, какой метод будет быстрее, даже при наличии статистически значимой разницы. Это обычная ситуация при работе с небольшими улучшениями производительности, например 1–10 %. Таким образом, для подобных случаев нужен более продвинутый статистический инструмент.

Существует множество **статистических тестов**, которые могут помочь в различных ситуациях. При бенчмаркинге самые надежные результаты предоставляют два теста:

- **t-тест Уэлча.**

Помогает сравнить значения средних арифметических  $x$  и  $y$ . В теории его можно применять только к нормальным распределениям. На практике он часто выдает достоверные результаты для унимодальных распределений при достаточно больших размерах выборок. Обычно для получения достоверного результата необходимо как минимум 30–40 результатов измерений в каждой выборке;

- **U-тест Манна — Уитни.**

Помогает проверить тот факт, что случайно выбранный результат измерений из одной выборки больше случайно выбранного результата измерений из другой. Тест не требует нормальности распределения, поэтому его можно применять к любым распределениям производительности, даже к мультимодальным распределениям разных форм. Он совершенно не работает с выборками крайне малого размера — в каждой из них должно быть минимум пять измерений.

Подобные тесты не дают бинарного результата. Они выдают значение от 0 до 1, называемое *p-значением*. Статистический тест можно интерпретировать как функцию от двух выборок:

```
double StatisticalTest(double[] x, double[] y)
{
    // Вычисления
    return pValue;
}
```

Для таких тестов рекомендуется использовать порог для сравнения: вместо проверки того, что первый метод быстрее второго, мы проверяем, является ли верным утверждение «разница в производительности между двумя методами больше

данного значения». Порог может быть относительным (например, 1 % от точки отсчета) или абсолютным (например, 15 мс). Такой подход позволяет уменьшить количество ошибок первого рода (ложноположительных), поскольку он более устойчив к естественному шуму. Поэтому нужно модифицировать запись метода:

```
double StatisticalTest(double[] x, double[] y, double threshold = 0.0)
{
    // Вычисления
    return pValue;
}
```

У этих тестов есть разные вариации. Проверяя то, что разность  $x - y$  не равна нулю или другому фиксированному значению, мы используем **двусторонний критерий**. Когда проверяем то, что разность  $x - y$  выше порога, используем **односторонний критерий**. Проверка того, что абсолютная разность  $|x - y|$  выше порога, — это **тест на эквивалентность**. Если мы уже знаем, как проводить односторонний тест, то тест на эквивалентность можно применять, основываясь на методе **двух односторонних критериев**: можно выполнить два теста на односторонний критерий и проверить то, что разность  $x - y$  или  $y - x$  выше порога.

Полученное магическое р-значение регулярно становится источником сложностей и недопонимания. Общее правило, используемое во многих исследованиях, звучит так: «Если р-значение меньше 0,05,  $H_0$  можно отбросить». Вот несколько фактов, которые помогут вам больше узнать о р-значениях.

- **Если р-значение < 0,05, это не означает, что  $H_1$  верна.**

Это означает, что мы наблюдаем необычные результаты. Даже если статистически значимой разницы нет, р-значение все равно может быть малым. Это нормальная ситуация.

- **Если р-значение > 0,05, это не означает, что  $H_1$  верна.**

Это означает, что мы не можем отбросить  $H_0$ , основываясь на данных выборках. Если р-значение равно 0,20, нельзя делать никаких выводов об  $H_0$  и  $H_1$  — для этого нужно больше экспериментов.

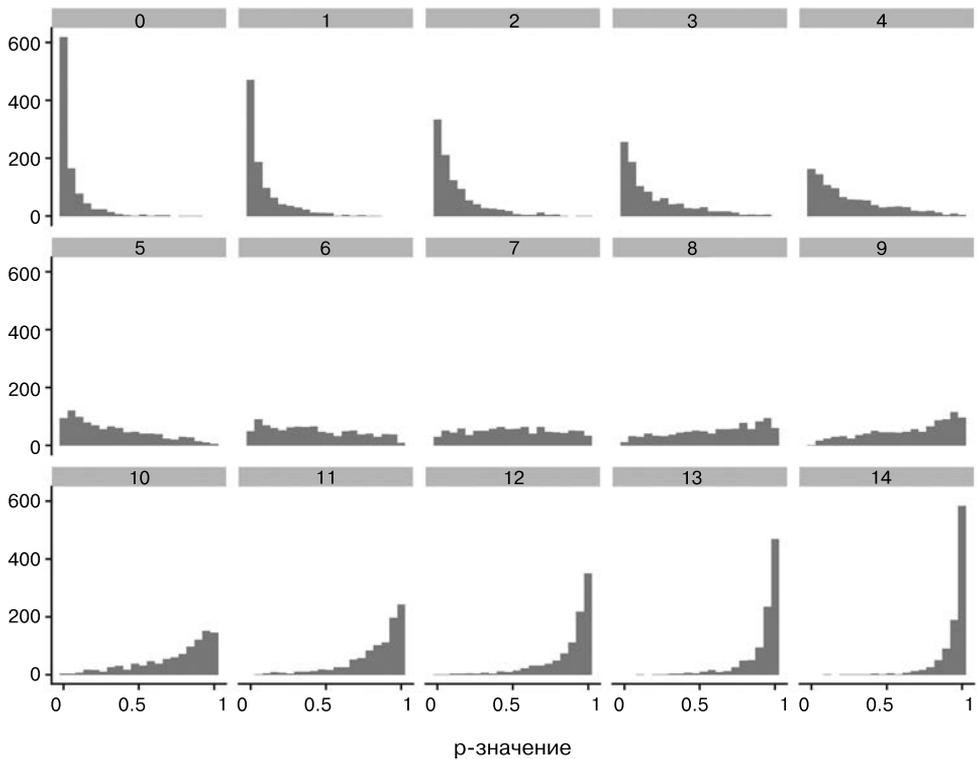
- **0,05 — это необязательное значение.**

Это просто исторически сложившийся порог р-значения, но использовать именно это число не обязательно. Его *не рекомендуется* увеличивать, но можно попробовать меньшие числа. Обычно при бенчмаркинге можно взять 0,01 или даже 0,001.

- **р-значения корректно работают только при серии экспериментов.**

Недостаточно провести один эксперимент с р-значением < 0,05, чтобы отбросить  $H_0$ . Нужно собрать другие выборки, повторить статистический тест и получить много небольших р-значений подряд, чтобы удостовериться в том, что  $H_0$  ложна.

Важно также понимать распределение р-значений. Представьте два нормальных распределения  $x$  и  $y$ , где истинная разность между средними арифметическими  $d = 7$ , а стандартное отклонение для обоих распределений  $s = 10$ . Рассмотрим пороговые значения от 0 до 14 и повторим следующий эксперимент 1000 раз для каждого значения: возьмем выборки из каждого распределения ( $n = 20$ ) и проверим тот факт, что разность  $x - y$  выше порога  $t$ , с помощью *одностороннего t-теста Уэлча*. Таким образом, нулевая гипотеза  $H_0$  выражается с помощью неравенства  $d \leq t$ , а альтернативная гипотеза  $H_1$  — с помощью  $d > t$ . Гистограммы, показывающие распределения р-значений для разных порогов, приведены на рис. 4.12.



**Рис. 4.12.** Распределения р-значений для разных порогов

Обсудим некоторые графики с этого рисунка подробнее.

- $t = 0$ ,  $H_0$  ложна, поскольку  $d > 1$ , распределение скошено вправо.

Когда порог значительно ниже истинной разности между средними арифметическими, большинство р-значений близки к нулю. Однако тут наблюдается много больших р-значений. Даже при пороге, равном нулю, около 30 % р-значений оказываются выше 0,05. Таким образом, мы можем отбросить  $H_0$  и сказать, что

истинная разность между средними арифметическими выше нуля, только если проведем несколько экспериментов.

- **$t = 7$ ,  $H_0$  верна, поскольку  $d = t$ , распределение равномерно.**

Когда порог равен истинной разности между средними арифметическими, р-значения распределяются равномерно. Поэтому мы с одинаковой вероятностью можем наблюдать р-значения, равные 0,05 и 0,95.

- **$t = 14$ ,  $H_0$  верна, поскольку  $d < t$ , распределение скошено влево.**

Когда порог значительно выше истинной разности между средними арифметическими, большая часть р-значений близка к 1. Около 70 % р-значений выше 0,95.

В этом случае довольно сложно подтвердить статистические гипотезы, поскольку стандартное отклонение очень велико (больше, чем истинная разность между средними арифметическими), а размеры выборок слишком малы. В простых случаях, скорее всего, вы увидите значения, близкие к 0 или 1, что позволяет с легкостью выбрать правильную гипотезу.

Магический порог р-значения 0,05 известен как  $\alpha$  (уровень альфа или уровень значимости). Теперь мы знаем, как интерпретировать его по-другому. Поскольку р-значения распределяются равномерно, когда истинная разность равна порогу ( $H_0$  верна), вероятность получения р-значения  $< \alpha$  равна  $\alpha$ . Подобная ситуация является ошибкой 1-го рода (ложноположительной):  $H_1$  ложна, а мы считаем, что верна. Таким образом,  $\alpha$  является вероятностью получения ошибки 1-го рода в этом случае. Уменьшая  $\alpha$ , можно уменьшить количество ошибок 1-го рода.

Тому, кто работает со статистическими тестами, основанными на р-значении, можно дать три основных совета.

- Всегда запускайте статистический тест несколько раз на разных выборках. Достоверный вывод можно сделать, только основываясь на получении одинаковых результатов несколько раз подряд.
- Если у вас слишком много р-значений, лежащих между 0,01 и 0,99, вероятно, размера выборки недостаточно для статистически значимого вывода. Попробуйте его увеличить.
- Когда вы уверены в том, что между  $x$  и  $y$  существует ощутимая разница, и хотите это доказать, можете использовать очень небольшую  $\alpha$ , например 0,001: ее должно быть достаточно, чтобы определить статистически значимую разницу с малым количеством ошибок 1-го рода (ложноположительных). Когда разница между  $x$  и  $y$  мала (например, меньше 1 %), а стандартное отклонение велико, может быть сложно доказать, что эта разница значима, при малой  $\alpha$ . Однако, если вы это сделали, вероятность того, что ошиблись, довольно мала, поскольку  $\alpha$  отвечает за количество ошибок 1-го рода (ложноположительных). Например, в эксперименте с бозоном Хиггса  $\alpha = 3 \cdot 10^{-7}$ , что означает очень низкую вероятность получения ложноположительных результатов.

Теперь мы знаем, как выполнять фундаментальную задачу анализа производительности — сравнение двух распределений. Пора выяснить, как анализировать несколько распределений.

## Регрессионные модели

Еще один важный вопрос для анализа производительности заключается в том, как производительность метода зависит от параметров ввода и окружения. В статистике существует подход, названный **регрессионным анализом**, помогающий ответить на этот вопрос.

В сфере разработки ПО термин «регресс» имеет отрицательное значение — это ситуация, когда раньше функция работала хорошо, а теперь не работает или работает неправильно. Регресс производительности означает, что раньше что-то работало быстро, а теперь медленно. В статистике у термина «регрессия» другое значение. Изначально его ввел Фрэнсис Гальтон. Одно из его самых известных исследований описывает феномен, когда у высоких родителей в основном появляются дети более низкого роста. Этот эффект он назвал регрессией к среднему значению (понятие хорошо освещено также в [Kahneman, 2013]) и употреблял данный термин в отношении биологии. Позже термин «регрессия» перешел в статистику. Он используется для описания взаимозависимостей между разными переменными, например данными ввода и производительностью метода.

В анализе производительности регрессионные модели помогают исследовать пространство производительности. С помощью регрессионной модели, построенной на основе нескольких выборок, мы можем понять, как данные ввода влияют на производительность, и экстраполировать этот результат для прогнозирования производительности в реальных ситуациях. Одним из самых распространенных случаев использования регрессионных моделей в информационных технологиях является **асимптотический анализ**. Рассмотрим следующие три метода:

```
public int GetLength(int[] a)
{
    return a.Length;
}
```

```
public int ArraySum(int[] a)
{
    int n = a.Length;
    int sum = 0;
    for (int i = 0; i < n; i++)
        sum += a[i];
    return sum;
}
```

```

public void BubbleSort(int[] a)
{
    int n = a.Length;
    for (int i = 0; i < n; i++)
        for (int j = 0; j < n - i; j++)
            if (a[j] > a[j + 1])
            {
                var temp = a[j];
                a[j] = a[j + 1];
                a[j + 1] = temp;
            }
}

```

Первый выдает значение длины массива, второй вычисляет сумму его элементов, а третий сортирует числа в массиве с помощью пузырьковой сортировки. При асимптотическом анализе мы можем описать производительность этого метода с помощью обозначения «*O* большого». Можем сказать, что **алгоритмические сложности** метода таковы:

- `GetLength` —  $O(1)$  (постоянная сложность времени);
- `ArraySum` —  $O(n)$  (линейная сложность времени);
- `BubbleSort` —  $O(n^2)$  (квадратичная сложность времени).

Такие взаимозависимости можно визуализировать с помощью графиков рассеяния. В двумерном варианте одна ось показывает метрики производительности, а другая — нужную переменную ввода. На рис. 4.13 можно увидеть значения  $O(1)$ ,  $O(n)$  и  $O(n^2)$  для разных значений  $n$ .

Алгоритмическую сложность часто неправильно интерпретируют, поэтому обсудим несколько распространенных ошибок.

- **Алгоритмическая сложность — это не длительность метода.**

Она просто определяет верхнюю границу длительности метода, что работает даже для больших значений  $n$ . Например,  $O(n^2)$  означает, что существует такая константа  $C$ , при которой длительность метода меньше, чем  $C \cdot n^2$ , при любом значении  $n$ . На практике полезно знать, как быстро будет расти длительность при росте  $n$ . Константа  $C$  может иметь довольно высокое значение. Например, мы можем задать  $C = 100$ , что означает: `ArraySum` будет занимать меньше  $100n$  с. Может показаться очевидным, что он будет занимать меньше 100 с при  $n = 1$ , но главное здесь то, что это условие будет соблюдаться и при больших значениях  $n$ . Сложность `BubbleSort` равна  $n^2$ , то есть  $100n$  нельзя использовать в качестве верхней границы длительности. Конечно, `BubbleSort` занимает менее 100 с при  $n = 1$  и менее 200 с при  $n = 2$ , но существуют такие высокие значения  $n$ , что `BubbleSort` будет занимать больше  $100n$  с.

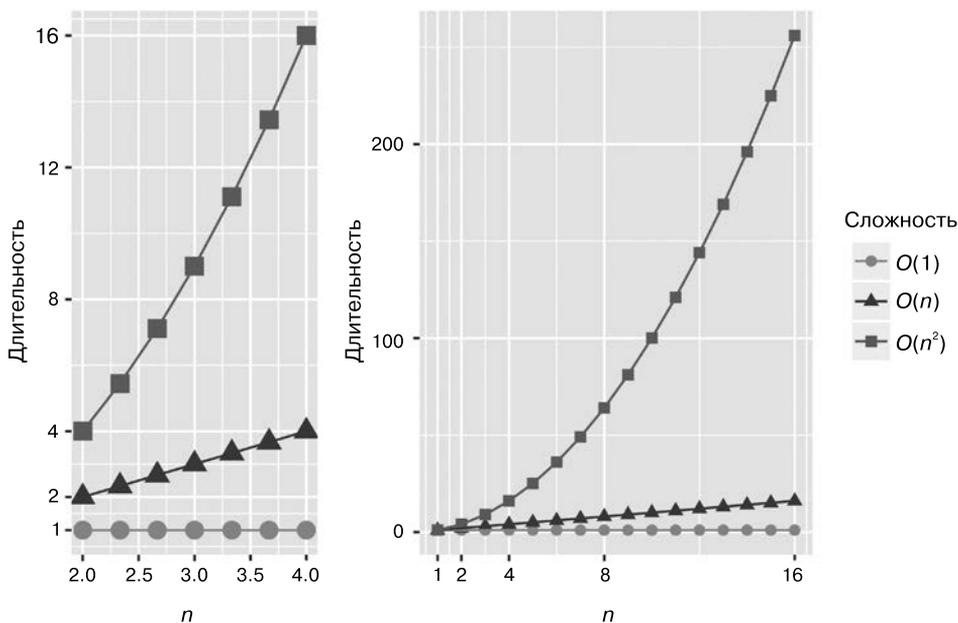


Рис. 4.13. Графики рассеяния алгоритмических сложностей

- Если метод имеет алгоритмическую сложность  $O(n)$ , это не означает, что при небольших значениях  $n$  он всегда работает быстрее, чем при высоких.

Сложность помогает понять, как работает метод при больших значениях  $n$ , но ничего не говорит о производительности при небольших значениях  $n$ . То есть если метод оптимизирован для случаев, где  $n = 2^k$ , то при  $n = 255$  он может работать медленнее, чем при  $n = 256$ .

- Если у двух методов алгоритмические сложности равны  $O(n)$  и  $O(n^2)$ , это не означает, что первый всегда быстрее.

Это означает, что второй метод будет медленнее при высоких значениях  $n$ , но насчет небольших значений ничего точно сказать нельзя. Например, если первый метод занимает  $50n$  мс, а второй —  $1n^2$  мс, первый будет работать медленнее при  $n < 50$ .

В реальности взаимосвязь между длительностью метода и данными ввода может быть запутанной. Допустим, у нас есть выражение массива `array.OrderBy(x => x).Take(1)`. Какова алгоритмическая сложность этого метода? В .NET Core 2.1 внутренняя реализация использует алгоритм `quickselect`. Его сложность в наилучшем и среднем случаях равна  $O(n)$ , но в наихудшем —  $O(n^2)$ . Это означает, что, если числа в массиве расположены по конкретной закономерности (например, 2 4 6 8 10 5 3 7 1 9), производительность будет гораздо хуже, чем в среднем случае. В табл. 4.4 приве-

дены соответствующие измерения для двух случаев: `Equal` (все числа равны нулю) и `QsWorst` (наихудший случай для алгоритма `quickselect`).

**Таблица 4.4.** Производительность `quickselect`

<i>n</i>	Случай	Среднее арифметическое, мкс	Стандартное отклонение, мкс
1000	<code>Equal</code>	42,16	0,1068
1000	<code>QsWorst</code>	8853,04	84,8771
10 000	<code>Equal</code>	415,93	0,9477
10 000	<code>QsWorst</code>	876 433,01	4960,2892

Как видите, при увеличении *n* в 10 раз, с 1000 до 10 000, длительность `Equal` возрастает в 10 раз, а длительность `QsWorst` — в 100 раз, что можно объяснить сложностями  $O(n)$  и  $O(n^2)$ . Поведение было улучшено (<https://github.com/dotnet/corefx/pull/32389>), и теперь `QsWorst` всегда имеет сложность  $O(n)$ , потому что просто вычисляет минимальный элемент (это исправление доступно в .NET Core 3.0). То есть реальная производительность зависит не только от количества элементов в массиве, но и от содержимого массива и версии среды исполнения.

Однако в более простых случаях часто есть возможность построить регрессионную модель и объяснить, как производительность зависит от данных ввода. Регрессионная модель предоставляет больше полезной информации о производительности метода, чем алгоритмическая сложность: она не определяет верхнюю границу, а позволяет построить функцию, выдающую оценку производительности, основанную на параметрах метода.

Простейшая из таких функций — **линейная регрессионная модель**. Она полезна, когда вы уверены в том, что между параметрами и производительностью существует линейная зависимость. Подобная модель выражается с помощью следующей формулы:

$$\text{длительность} = \alpha_0 + \alpha_1 n,$$

где  $\alpha_0$  и  $\alpha_1$  — константы.

Эта модель может быть полезна для того, чтобы сделать прогноз, когда зависимость действительно линейна. Однако иногда она может оказаться квадратичной<sup>1</sup>. В этом случае можно использовать **квадратичную регрессионную модель**:

$$\text{длительность} = \alpha_0 + \alpha_1 n + \alpha_2 n^2.$$

<sup>1</sup> Существует интересный блог «Случайно квадратичный», где рассказывается о ситуациях, когда у алгоритма была квадратичная сложность, но она была неочевидна: <https://accidentallyquadratic.tumblr.com>.

Интересный факт о линейной регрессионной модели — это частный случай квадратичной регрессии. То есть, если мы не уверены в том, линейный алгоритм или квадратичный, можно построить квадратичную модель и проверить  $\alpha_2$ . Если это значение близко к нулю, скорее всего, алгоритм линеен. Если оно далеко от нуля, он нелинеен, но мы не знаем его степени. К счастью, мы можем построить и **полиномиальную регрессионную модель**:

$$\text{длительность} = \alpha_0 + \alpha_1 n + \alpha_2 n^2 + \alpha_3 n^3 + \alpha_4 n^4 + \dots$$

Если коэффициенты  $\alpha_3, \alpha_4 \dots$  близки к нулю, скорее всего, модель квадратична. Такие уравнения можно строить с помощью **метода наименьших квадратов**<sup>1</sup>. Регрессия не всегда полиномиальна. Ее можно выразить любой функцией. Проблема поиска такой функции известна как **подбор эмпирической кривой**<sup>2</sup>. Вы можете представить кривую с помощью графика рассеяния, выдвинуть гипотезу о типе регрессии, например  $O(n \log n)$  или  $O(\sqrt{n})$ , и построить соответствующую модель.

Распространенной проблемой при анализе регрессии является **лжевзаимозависимость**. Она возникает в ситуациях, когда построенная кривая идеально подходит под имеющиеся данные, но не показывает истинной взаимозависимости между производительностью метода и его параметрами. Риск лжевзаимозависимости высок при небольшом размере выборки. Например, построить идеальную линейную модель всегда возможно, если у вас всего две точки (их можно просто соединить линией). Если точки три, можно построить идеальную квадратичную модель, даже если истинной моделью является логарифмическая или кубическая. На самом деле любое количество точек  $k$  позволяет построить идеальную полиномиальную модель степени  $k - 1$ . Таким образом, имея 1000 точек, мы можем построить полиномиальную модель степени 999, но она вряд ли будет правильной. Чтобы избежать лжевзаимозависимости, всегда проверяйте, как эта модель работает с данными, не используемыми для построения регрессионной модели. Этот подход известен как **перекрестная проверка**.

Еще один важный вид анализа производительности — попытка ответить на вопрос о том, как производительность зависит от окружения. Здесь мы обычно работаем с **категориальными переменными**. Их можно интерпретировать как значение из enum (заранее определенный набор нечисловых значений). Например, можно рассмотреть тип JIT (LegacyJIT или RyuJIT), среду исполнения (.NET Framework, .NET Core или Mono) или операционную систему (Windows, Linux или macOS). В самом простом случае вы уже знаете фактор окружения, который хотите проверить. Например, в JetBrains Rider типичным важным для производительности фактором является операционная система. На рис. 4.14 показаны результаты из-

<sup>1</sup> Применение этого метода и других похожих алгоритмов можно найти в пакете NuGet MathNet.Numerics. См. <https://numerics.mathdotnet.com>.

<sup>2</sup> Самое верное объяснение того, как подбор кривой работает в реальности, можно найти здесь: <https://xkcd.com/2048>.

мерения производительности для теста, расширяющего стандартную заготовку ASP.NET и производящего на ней операции.

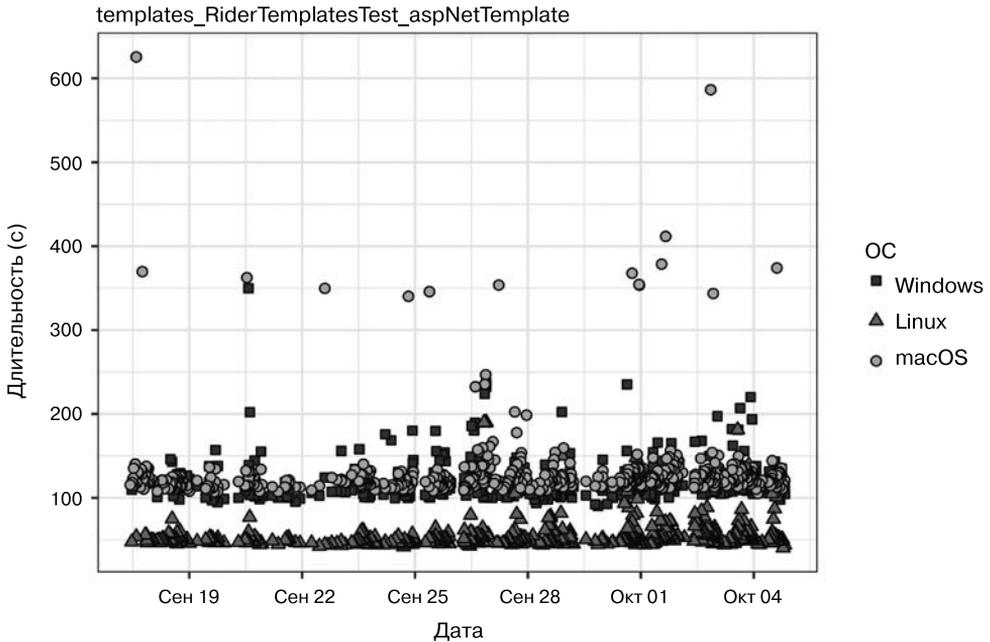


Рис. 4.14. Кластеризация производительности по типу ОС

Разные операционные системы обозначены разными формами и цветами. Как видите, у нас есть очевидная **кластеризация**: тест работает гораздо быстрее в Linux, чем в Windows и macOS. Хорошая визуализация может помочь выдвинуть начальную гипотезу о факторах, влияющих на производительность. Далее можно провести статистический тест на выборках из разных ОС. Например, мы можем воспользоваться односторонним U-тестом Манна — Уитни, проверяющим тот факт, что разница между выборками для macOS и для Linux статистически значительна с порогом 60 с.

Однако нам не всегда известно, какие факторы действительно влияют на производительность. Допустим, у нас есть сотни характеристик каждого измерения, но мы не знаем, какие из них важны. В этом случае можно сделать следующее.

1. Найти кластер в одном измерении производительности. Поскольку данные одномерные, нам не нужны продвинутое алгоритмы обнаружения кластеров. Рекомендуется использовать простой метод, например **оптимизацию естественных перерывов Дженкса**. После этого нужно получить несколько выборок, между которыми будет статистически значимая разница.

2. Пронумеровать все значения для каждой характеристики окружения. Если в одной и той же выборке представлены разные значения одной характеристики, ее можно исключить из анализа: она не отвечает за кластеризацию. Не забудьте о возможных выбросах: значение должно появляться в выборке много раз, чтобы мы могли сказать, что оно в ней представлено. Если конкретное значение представлено во всех выборках, такие характеристики также можно исключить.
3. После этого мы должны получить небольшой список подозрительных характеристик. Далее можно забыть об изначальной кластеризации и проводить статистические тесты для сравнения значений оставшихся характеристик.
4. Теперь мы получили список подозрительных факторов, возможно влияющих на производительность. Нужно проверить каждый из них, проведя дополнительные измерения в нужном окружении и повторив статистический тест.

У этого метода довольно высок уровень ошибок 2-го рода (ложноотрицательных), также вы можете пропустить какие-то эффекты кластеризации. Но зато у него очень низок уровень ошибок 1-го рода (ложноположительных), поэтому нам не угрожает ложная тревога. В то же время, если у нас есть очевидная кластеризация, мы, вероятно, ее найдем. Вы можете придумать собственные проверки, основываясь на целях своего бизнеса и на той части пространства производительности, которую составляет окружение. Можете даже использовать подходы, основанные на машинном обучении, но в реальности простые проверки и эвристические правила способны быть гораздо эффективнее. При разработке важных программ нужны не все существующие эффекты кластеризации, а только самые основные, которые очевидны при взгляде на график рассеяния. Такие эффекты легко обнаружить при простейших проверках, которые можно быстро выполнить, не прибегая к сложным математическим приемам.

Регрессионные модели — очень полезная для понимания пространства производительности техника. Она позволяет определить взаимозависимость между данными ввода, окружением и производительностью. Зная, как их использовать, вы можете спрогнозировать длительность метода в разных условиях.

## Произвольная остановка

Типичный бенчмарк содержит много магических чисел, включая встроенное количество итераций. У процесса бенчмаркинга есть уникальное свойство: мы можем произвести сколько угодно измерений. С одной стороны, это хорошо, поскольку, если не хватает данных о производительности, всегда можно выполнить дополнительные итерации. С другой — это плохо, потому что невозможно собрать все измерения. Здесь и появляются проблемы. Если у нас бесконечное количество измерений, сколько итераций нужно выполнить? Десяти хватит? Или нужно десять

тысяч? Обычно разработчики устанавливают количество итераций, основываясь на том, сколько они готовы ждать. Если итерация занимает 10 мс, можно сделать это 100 раз, а если 5 мин — всего один раз. Большинство разработчиков не хотят ждать слишком долго, поэтому бесконечное количество оказывается довольно маленьким числом.

Обычно разработчики выбирают его случайным образом: «Сделаем 100 итераций, думаю, этого хватит». Это не лучшая стратегия, потому что, скорее всего, случайное число меньше, чем нужно (низкая точность), или больше, чем нужно (слишком долго ждать результатов). У этой проблемы существует решение: можно выбрать магическое число *адаптивно* в процессе запуска. В статистике этот подход известен как **последовательный анализ**.

Рассмотрим часть гипотетического журнала записей исследования производительности.

- Запустим бенчмарк 5 раз.
- Кажется, 5 раз недостаточно, поскольку дисперсия слишком велика. Давайте попробуем запустить бенчмарк 100 раз.
- Теперь с дисперсией все в порядке, но запускать бенчмарк 100 раз слишком долго. Попробуем 20 раз.
- Теперь с дисперсией все по-прежнему в порядке, а запуски занимают приемлемое количество времени.

У этого исследования есть одна основная проблема — плохо выбранные цели. Вот описанные цели:

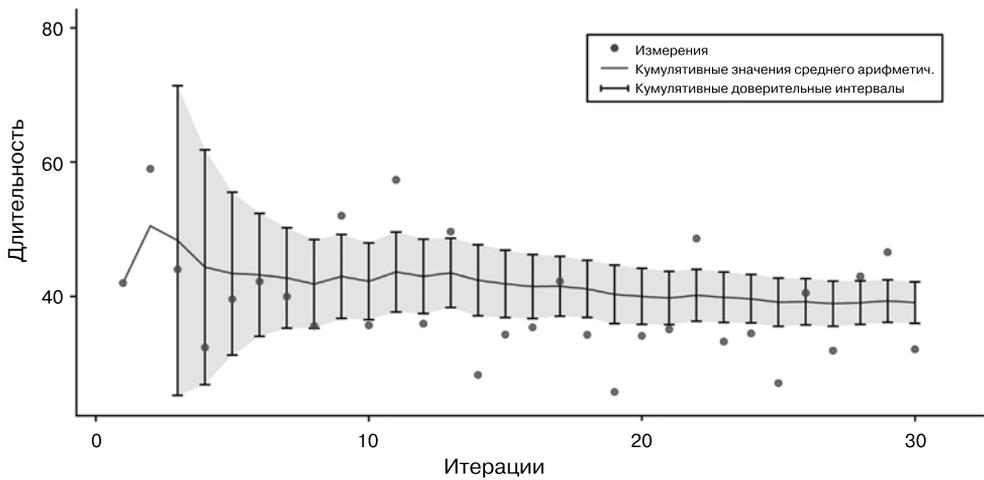
- мы хотим запустить бенчмарк 5 раз;
- мы хотим запустить бенчмарк 100 раз;
- мы хотим запустить бенчмарк 20 раз.

Однако лучше было бы поставить следующую цель: мы хотим получить низкую стандартную погрешность (меньше 2,5 с), а количество итераций должно быть как можно меньше.

Таким образом, вы все равно используете магические числа. Но очень важно, какие именно. Нужно спрашивать не «Сколько итераций нужно произвести?», а «Какие характеристики распределения мне нужны?». При разработке бенчмарка нужно учитывать нужные значения метрик будущих распределений. Когда эти условия будут выполнены, можно остановить процесс.

Произвольная остановка требует сбора **кумулятивных метрик**. Это промежуточные статистические характеристики, вычисляемые заново после каждой итерации.

На рис. 4.15 приведен пример временного графика с кумулятивными метриками и доверительными интервалами. Такие графики могут помочь понять взаимосвязь между размером выборки и конечными метриками. Как видите, если остановить процесс после нескольких итераций, доверительный интервал окажется очень большим и на его основе нельзя будет сделать достоверные выводы. После первых десяти итераций доверительный интервал уменьшается, но все еще остается довольно большим (он равен [36,53; 47,97] при кумулятивном среднем арифметическом 42,25). После 30 итераций доверительный интервал равен [35,98; 42,19] при кумулятивном среднем арифметическом 39,08.



**Рис. 4.15.** Временной график с кумулятивными значениями среднего арифметического и доверительными интервалами

Получив кумулятивные метрики, можно, основываясь на них, формулировать **критерии остановки**. Вот несколько вариантов.

- Критерии остановки итераций для прогрева могут быть основаны на отклонениях. Мы знаем, что первая итерация может проходить с осложнениями. Обычно вторая итерация занимает меньше времени, чем первая, потому что производится в разогретом состоянии. Но одной итерации для полного прогрева может быть недостаточно. Третья итерация может оказаться быстрее второй, потому что выполняется в еще более разогретом состоянии. Пока каждая итерация занимает меньше времени, чем предыдущая, идет процесс прогрева. Когда начинают отклонения, можно предположить, что прогрев окончен (это неверно для общего случая). Таким образом, можно ждать появления отклонений после его окончания.
- Критерии остановки для реальных итераций, которые будут использоваться в итоговых результатах, могут быть основаны на стандартной погрешности.

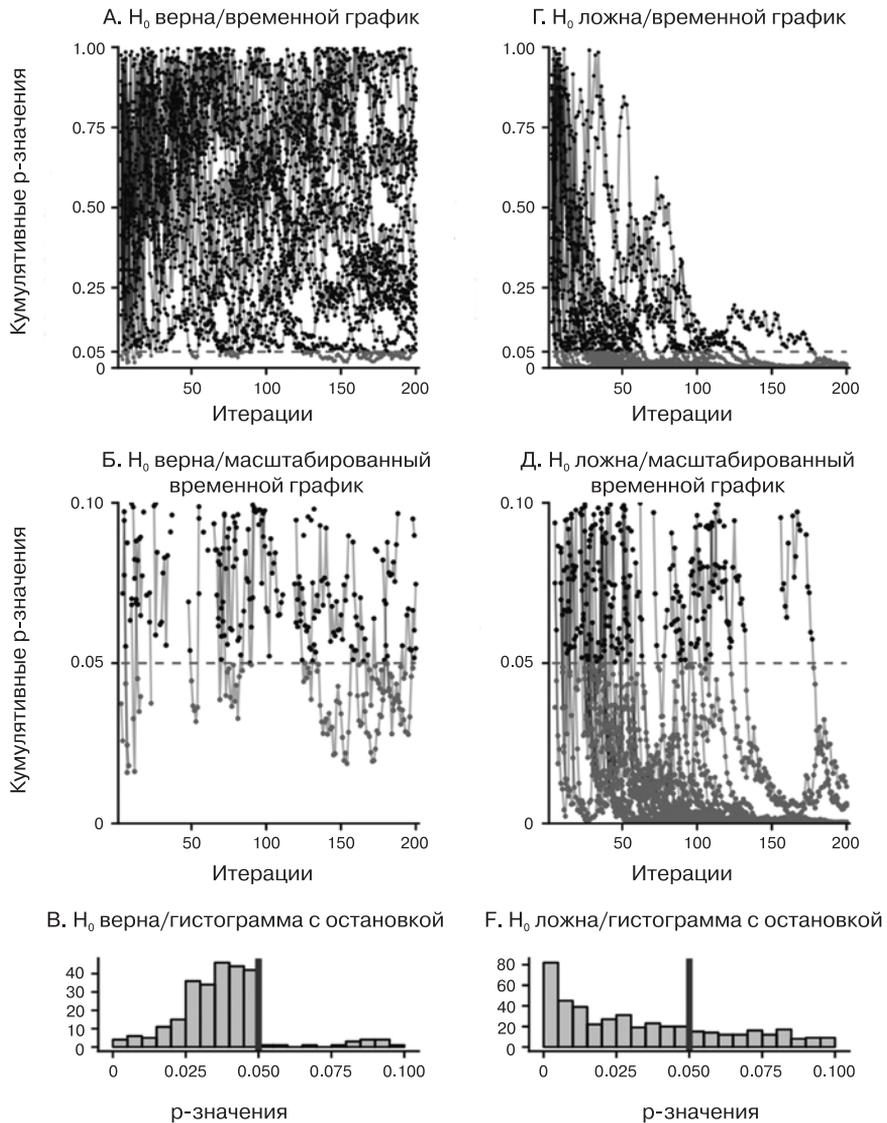
Например, можно обозначить абсолютный или относительный порог стандартной погрешности и ждать его достижения. Поскольку стандартная ошибка равна  $s/\sqrt{n}$ , она уменьшается при увеличении размера выборки<sup>1</sup>. Таким образом, почти всегда можно найти размер выборки со стандартной погрешностью меньше данного значения.

- Критерий остановки любой итерации может представлять собой логическую формулу с несколькими условиями. Например, рекомендуется устанавливать верхний предел количества итераций. Если вы не достигли своих требований после 100 итераций, скорее всего, еще несколько десятков ничего не дадут: лучше остановить эксперимент и изучить распределение и статистические метрики. После этого вы сможете понять, что достичь желаемых характеристик распределения за разумное время невозможно или что вам нужны особые критерии остановки для этого конкретного бенчмарка.

Вы можете взять вышеупомянутые критерии или создать собственные, основываясь на целях своего бизнеса. Однако к метрикам, используемым в критериях остановки, предъявляется важное требование: кумулятивные метрики должны формировать сходящийся ряд. Например, не стоит применять желаемые результаты статистических тестов: при использовании критериев остановки, основанных на  $p$ -значениях, может значительно увеличиться уровень ошибок 1-го рода (ложноположительных).

На рис. 4.16, А, можно увидеть график кумулятивных  $p$ -значений, основанный на  $t$ -тесте Уэлча, для 20 экспериментов, где  $H_0$  верна (статистически значимой разницы нет). Эта картинка напоминает случайный шум, поскольку такие  $p$ -значения распределены равномерно. На рис. 4.16, Б, можно увидеть те же эксперименты, но масштаб графика сужен до интервала  $p$ -значений  $[0,00; 0,10]$ . Иногда функция кумулятивного  $p$ -значения ныряет под порог 0,5 и выныривает из-под него. При изначально фиксированном размере выборки мы получим равномерно распределенные  $p$ -значения в качестве результата. Однако если остановить процесс, как только появляется  $p$ -значение  $< 0,05$ , мы получим слишком много небольших  $p$ -значений, что приведет к ложному отбрасыванию  $H_0$ . На рис. 4.16, В, представлена гистограмма таких  $p$ -значений. Как видите, в интервале  $[0,00; 0,05]$  находится скошенное влево распределение, что нетипично для  $p$ -значений, полученных в результате верных экспериментов. Информация об ожидаемом распределении  $p$ -значений помогает подтвердить ваши собственные результаты и проверить чужие исследования. Пример подобной верификации вы найдете в [Lakens, 2014a].

<sup>1</sup> Предполагаем, что стандартное отклонение незначительно меняется при дополнительных итерациях. Единственное исключение из этого правила подразумевает, что новые итерации занимают больше времени, чем предыдущие. В этом случае бенчмарк нестабилен и обсуждать его распределение бессмысленно.



**Рис. 4.16.** Кумулятивные р-значения

На рис. 4.16, Г–Е, можно увидеть тот же эксперимент, где  $H_0$  ложна (статистически значимая разница есть). В этом случае функция кумулятивного р-значения, нырнув под порог 0,5, остается ниже его. В этом эксперименте довольно маленькая разница между средними арифметическими, поэтому иногда нужно много измерений для получения достоверного результата, но в итоге мы получаем р-значение  $< 0,05$ , помогающее правильно отбросить  $H_0$ .

Опциональная остановка является полезной техникой для минимизирования времени эксперимента и получения достоверных результатов. Однако при неправильном использовании она может увеличить уровень ошибок 1-го рода (ложноположительных).

## Пробные эксперименты

В главе 2 говорилось, что измерить производительность очень быстрых методов чрезвычайно сложно. Типичным решением в таких случаях является большое количество вызовов методов при каждой итерации. Но как выбрать количество вызовов? Коллективный опыт говорит, что для получения приемлемых результатов итерация должна длиться минимум 100 мс (или 1 с, если нужна хорошая повторяемость). Если метод занимает несколько микросекунд, требуются миллионы вызовов, если же несколько минут, хватит и одного. Возможно, придется предпринять несколько попыток, прежде чем вы определите нужное количество вызовов. Такие попытки угадать становятся скучной рутинной работой, которую можно автоматизировать. Настройка параметров бенчмаркинга перед самими измерениями называется *пробным экспериментом*.

Существует много стратегий поиска идеального количества вызовов. Например, можно начать с одного и попытаться измерить его длительность. Если этот вызов продолжается меньше определенного минимального времени итерации, можно попробовать два вызова. Если длительность двух вызовов все равно слишком мала, можно попробовать четыре, восемь и т. д., пока не будет получена требуемая длительность. Просто разделить минимальное время итерации на длительность одного вызова для получения количества вызовов нельзя: погрешность для очень быстрых методов может быть огромной, что испортит это вычисление (мы легко можем получить примерное время 1000 нс для операции в 10 нс).

Вот упрощенный журнал запусков типичного микробенчмарка в BenchmarkDotNet:

```
Jitting 1:      1 op,      248000 ns,    248.00 µs/op
Jitting 2:     16 op,     521000 ns,     32.56 µs/op
Pilot  1:     16 op,      7000 ns,    437.50 ns/op
Pilot  2:     32 op,     10000 ns,    312.50 ns/op
Pilot  3:     64 op,     16000 ns,    250.00 ns/op
Pilot  4:    128 op,     31000 ns,    242.18 ns/op
Pilot  5:    256 op,     63000 ns,    246.09 ns/op
Pilot  6:    512 op,    128000 ns,    250.00 ns/op
Pilot  7:   1024 op,   305000 ns,    297.85 ns/op
Pilot  8:   2048 op,   500000 ns,    244.14 ns/op
Pilot  9:   4096 op,   998000 ns,    243.65 ns/op
Pilot 10:   8192 op,  2189000 ns,    267.21 ns/op
...
Pilot 18: 2097152 op, 523762000 ns,    249.74 ns/op
```

Обсудим его подробно.

- *Jitting 1 (компиляция 1)* — это первая итерация фазы компиляции. Во время нее компилятор JIT генерирует собственный код для метода. BenchmarkDotNet проводит один запуск данного метода и измеряет его длительность. В этом примере `1 op` означает «1 операция», что по определению равно одному вызову. Как видите, одна итерация занимает 248 000 нс.
- *Jitting 2 (компиляция 2)* — это вторая итерация фазы компиляции. Мы уже знаем, что данный метод довольно быстр, поэтому переключаемся в другой режим бенчмарка, где у нас 16 последовательных вызовов метода внутри тела цикла. Это управляемое вручную развертывание цикла помогает достичь более высокой точности в нанобенчмарках. Во время этой итерации компилятор JIT генерирует собственный код для описанного цикла. Шестнадцать вызовов метода занимают 521 000 нс, что означает: один вызов занимает примерно 32,56 мкс.
- *Pilot 1 (проба 1)* — пришло время пробного этапа. Прежде всего мы пытаемся повторить итерацию с 16 вызовами. Она занимает 7000 нс вместо 521 000 нс! У первого вызова в компиляции были огромные ограничения, но теперь мы лучше оцениваем примерное среднее время вызова — 437,5 нс.
- *Pilot 2 (проба 2)* — 7000 нс недостаточно для получения достоверных результатов. Увеличим число вызовов вдвое и измерим длительность 32 операций. Они занимают 10 000 нс. Это число не равно  $2 \cdot 7000$  нс, поскольку предыдущая итерация была испорчена из-за естественного шума. Увеличение числа вызовов снижает влияние шума и позволяет получать лучшее примерное среднее время вызова — 312,5 нс. Продолжим увеличивать число вызовов, пока общее время итерации не достигнет приемлемого значения.
- *Pilot 18 (проба 18)* — после 18 пробных итераций длительность одной итерации равна 523 762 000 нс (0,52 с). Таким образом, среднее время вызова составляет 249,74 нс. Это значительно лучше первого приблизительного значения, которое равнялось 248 000 нс. Продолжать увеличивать количество вызовов бессмысленно, потому что точность не улучшается: мы достигли достоверной и повторяемой оценки длительности одного вызова. Если использовать больше вызовов, общее время эксперимента будет увеличено без улучшения точности. Следовательно, можно продолжить выполнять 2 097 152 вызова за одну итерацию во время этапов прогрева и самого эксперимента при сборе результатов измерений, которые сформируют итоговое распределение производительности.

Конечно, для пробного эксперимента можно использовать и другие стратегии. Например, вызывать метод в цикле `while` до достижения минимального времени итерации. Не используйте этот подход для реальных измерений: итерация с неравным количеством вызовов может испортить результаты. Такой цикл `while` требует отдельной стадии прогрева: первый эксперимент может быть испорчен такими эффектами холодной загрузки, как загрузка сборки или компилирование.

Пробный эксперимент — полезная техника для поиска лучших параметров бенчмарка и достижения компромисса между точностью и общим временем бенчмаркинга.

## Подводя итог

В этом разделе мы рассмотрели два важных подхода к анализу группы распределений.

- **Сравнение распределений.**

Когда хотим сравнить два распределения, мы работаем с двумя гипотезами:  $H_0$  (разницы *нет*) и  $H_1$  (разница *есть*). Выводы могут включать в себя два типа ошибок: 1-го рода (ложноположительная — разницы *нет*, а мы думаем, что *есть*) и 2-го рода (ложноотрицательная — разницы *есть*, а мы думаем, что *нет*). В простейших случаях мы можем воспользоваться простыми эвристическими (проверка на принадлежность диапазону, тест Тьюки или тест трех сигм) или статистическими тестами: t-тест Уэлча (работает только для унимодальных распределений, близких к нормальным), U-тест Манна — Уитни (работает для любых распределений). Такие тесты создают р-значение, которое нужно сравнить с порогом уровня  $\alpha$ , типичное значение которого 0,05. При получении большого количества небольших р-значений (меньших  $\alpha$ ) в серии экспериментов, скорее всего, верна  $H_1$  (разница между распределениями есть). Если верна  $H_0$ , р-значения распределяются равномерно, и это означает, что  $\alpha$  является уровнем ошибок 1-го рода (ложноположительных).

- **Регрессионные модели.**

Регрессионные модели помогают определять взаимосвязи между данными ввода, окружением и производительностью. Асимптотический анализ помогает выразить алгоритмическую сложность с помощью обозначения «О большого», например,  $O(n^2)$  или  $O(n \log n)$ . Во многих случаях можно использовать полиномиальные модели, например линейную или квадратичную, но в некоторых требуется сложный подбор эмпирической кривой. Когда мы хотим понять, как окружение влияет на производительность, нужно работать с категориальными переменными (например, ОС Windows, Linux или macOS). Мы можем найти самые важные факторы окружения с помощью кластеризации и с помощью статистических тестов проверить, действительно ли они влияют на производительность.

Мы также обсудили два подхода адаптивного бенчмаркинга.

- **Произвольная остановка.**

Вместо того чтобы угадывать идеальное количество итераций, можно определить критерии остановки: итерация должен длиться до момента достижения желаемых свойств распределения. Для этого не следует использовать р-значения,

поскольку это может значительно увеличить уровень ошибок 1-го рода (ложноположительных).

- **Пробные эксперименты.**

Некоторые экспериментальные параметры, например количество вызовов при каждой итерации, можно определить заранее. В пробном эксперименте, выполняемом до основного, можно провести серию итераций с разными характеристиками, чтобы определить лучшие параметры бенчмарка, соответствующие требованиям к точности.

Адаптивный бенчмаркинг помогает правильно разработать бенчмарк, достичь желаемой точности и минимизировать общую длительность бенчмарка. Эти подходы уже много лет успешно используются в BenchmarkDotNet. Но даже при наличии BenchmarkDotNet все равно нужно понимать концепцию адаптивного бенчмаркинга — эта библиотека не разработает бенчмарк за вас. BenchmarkDotNet предоставляет некоторые значения по умолчанию для нужных требований к распределениям, но это работает нормально только в простых случаях. В сложных ситуациях вам нужно настраивать эти числа или даже определять собственные статистические критерии.

Однако знание всех техник анализа не защищает вас от ошибок и неверных выводов. Давайте узнаем, как статистика может обмануть вас и заставить принять неверное решение в сфере бизнеса.

## Как лгать с помощью бенчмаркинга

Заголовок этого раздела был подсказан великой книгой Даррелла Хаффа *How to Lie with Statistics* («Как лгать с помощью статистики») (см. [Huff, 1993]). В ней содержится множество примеров, показывающих, как легко можно одурачить людей, представляя им данные особым образом. Когда мы говорим о бенчмаркинге, эта тема становится весьма важной, поскольку по результатам бенчмарка очень легко прийти к неверным выводам, даже если вас никто не пытается обмануть.

У этого раздела две цели.

- **Защита от других.**

Во многих отчетах о производительности, которые можно найти в статьях, записях в блогах, ответах на StackOverflow и обсуждениях на GitHub, часто содержатся запутывающие числа и графики, которые могут подтолкнуть вас к неверному решению. Полезно знать о том, как распознавать разные обманные технологии.

- **Защита от себя.**

Даже работая с собственными бенчмарками, довольно легко неверно интерпретировать результаты и обмануться. Если вы хотите предотвратить подобные ситуации, стоит узнать о самых распространенных ошибках, совершаемых разработчиками.

Если вы думаете, что, зная статистику, имеете достаточно мощную защиту, я настойчиво рекомендую вам прочесть [Kahneman, 2013], где демонстрируется, как плохо человеческая интуиция справляется с довольно простыми статистическими задачами. Одна из главных идей этой книги заключается в следующем: у человеческого разума есть две системы — система 1 (быстрая, но не очень умная) и система 2 (медленная, но умная). Первые мысли о чем-либо появляются в системе 1, мы получаем их мгновенно, но зачастую они неверны. Если как следует обдумать предмет, система 2 даст более точный и верный ответ, но это займет некоторое время. К сожалению, люди, принимая решения, не всегда думают как следует и используют ответы системы 1. Это может привести к неверным выводам о результатах бенчмарка.

В этом разделе попытаемся активизировать нашу систему 2 и узнаем, как использовать ее в бенчмаркинге. Мы рассмотрим самые распространенные способы солгать с помощью бенчмаркинга и обсудим, на что нужно обращать внимание, чтобы распознать ложь.

## Ложь с помощью маленьких выборок

При анализе сырых данных интуиция — ваш злейший враг. Она пытается везде найти закономерности и находит, даже если их нет. Вот упражнение: основываясь на следующих результатах измерения, скажите, какой метод быстрее?

A: 58 ms 62 ms 57 ms 60 ms 66 ms  
 B: 61 ms 67 ms 70 ms 77 ms 73 ms

Если вы мыслите как большинство, то скажете: «А быстрее B», поскольку в каждой колонке значение A меньше значения B.

Придется признаться: я сгенерировал все десять чисел, основываясь на одном и том же бенчмарке со следующим исходным кодом:

```
static long Measure()
{
    var data = new byte[64 * 1024 * 1024];
    var stopwatch = Stopwatch.StartNew();
    var fileName = Path.GetTempFileName();
    File.WriteAllBytes(fileName, data);
    File.Delete(fileName);
}
```

```

    stopwatch.Stop();
    return stopwatch.ElapsedMilliseconds;
}

```

Это одно из моих самых любимых полей для экспериментов: метод создает файл с 64 Мбайт данных и удаляет его. Теперь мы можем сгенерировать десять чисел, как показано ранее:

```

Console.Write("A: ");
for (int i = 0; i < 5; i++)
    Console.Write(Measure() + " ms ");
Console.WriteLine();
Console.Write("B: ");
for (int i = 0; i < 5; i++)
    Console.Write(Measure() + " ms ");

```

Все еще может казаться, что вероятность получения таких результатов довольно низкая. Давайте посчитаем. Вероятность того, что один результат будет меньше другого, — около 50 % (операции ввода-вывода не выдают стабильных значений производительности, поэтому получение равных результатов маловероятно). Вероятность того, что каждое число из ряда А будет меньше, чем соответствующее число из ряда В, равна  $(1/2)^5$ , или 3,125 %. Это немаленькое число. Допустим, 22 читателя решат запустить этот фрагмент кода. Вероятность того, что никто не получит такого странного результата, равна  $(1 - 0,03125)^{22}$ , или 49,7 %. Это означает, что с вероятностью 50,3 % хотя бы один из них получит результат, выглядящий как «А быстрее В». Это очень похоже на парадокс дня рождения, который утверждает, что с вероятностью 50 % у двоих из находящихся в комнате 23 человек день рождения в один день (больше об этом — в [Azad, 2007]).

Довольно часто в маленькой выборке содержатся вводящие в заблуждение аномалии в данных, похожие на закономерности. Если вы будете много заниматься бенчмаркингом, то станете часто получать неординарные результаты в маленьких выборках из-за случайного шума. Будет соблазнительно сделать выводы на основе этих результатов, и они могут привести к неверным бизнес-решениям. Знание статистики поможет защититься от подобных ситуаций и правильно подтверждать все гипотезы в области производительности.

При незначительном размере выборки большая часть статистических метрик ненадежна, поскольку невозможно вычислить правильные значения истинного распределения, основываясь на нескольких измерениях. Невозможно понять, является ли распределение мультимодальным или унимодальным, можно пропустить выбросы, нельзя получить правильное значение стандартного отклонения и т. д. Маленькие выборки можно использовать для получения первого впечатления об измерениях, например: «метод занимает несколько секунд» или «метод занимает несколько микросекунд». Но этого недостаточно, чтобы сделать осмысленный вывод о распределении. Например, если разница между двумя методами 10–20 %, ее нельзя правильно определить при  $n = 5$ .

## Ложь с помощью процентов

Допустим, вы улучшили производительность: метод, длившийся 200 мс, теперь продолжается 100 мс. Как описать это изменение с помощью процентов? Зависит от исходной точки. Если исходная точка 200 мс, мы получаем  $(200 - 100) / 200 \cdot 100\%$  — улучшение на 50 %. Если исходная точка — 100 мс, то  $(200 - 100) / 100 \cdot 100\%$  — улучшение на 100 %. Пропорция та же, а результат различается: 50 против 100 %.

Кто-то скажет, что это обман и исходной точкой всегда должно быть начальное значение (состояние «до»). Вот еще один прием: можно позволить читателям самим выбирать исходную точку. Обычно людям не нравится выполнять сложные вычисления в уме, поэтому они пытаются выбрать простейшую исходную точку для вычислений. Допустим, вы улучшили производительность в 2,5 раза. Сравните два предложения: «Метод, занимавший **250** с, теперь занимает **100** с» и «Метод, занимавший **100** с, теперь занимает **40** с».

В обоих случаях наблюдается улучшение в 2,5 раза. Но многие мысленно переводят его в 150 % в первом случае и в 60 % — во втором. В качестве исходной точки гораздо проще использовать 100 с, поскольку это самый естественный делитель в случае процентов. Конечно, потратив несколько секунд на размышления, вы поймете, что первая интуитивная догадка была неправильной. Так и работают система 1 и система 2 по Канеману! Обычно людям не нравится везде применять вычисления — они лишь быстро просматривают текст. Поэтому для многих улучшение с 250 до 100 более впечатляющее, чем со 100 до 40.

Операции с процентами часто становятся источником неверных выводов. Допустим, у проекта был хороший уровень производительности в мае. Используемая метрика — запросы в секунду (RPS). В июне с точки зрения RPS наблюдалось ухудшение на 40 %. В июле мы улучшили положение и получили ускорение на 50 % *в сравнении с июнем*. Картина такова:

Май : Исходная точка  
Июнь : -40 %  
Июль : +50 %

Вопрос: что можно сказать об изменениях производительности с мая по июль? Вероятно, первое, что приходит вам в голову: «Производительность в июле была лучше, поскольку ускорение на 50 % перекрывает замедление на 40 %». А теперь посчитаем. Если в мае метод выдавал около 100 RPS, замедление на 40 % означает, что в июне было  $100 \cdot (1 - 0,4) = 60$  RPS. Ускорение на 50 % означает, что в июле было  $60 \cdot (1 + 0,5) = 90$  RPS:

Май : Исходная точка		100 RPS
Июнь : -40 %		60 RPS
Июль : +50 %		90 RPS

Как видите, по сравнению с маем все еще происходит замедление.

Вот вам еще одна головоломка из области производительности (постарайтесь ответить как можно быстрее). Допустим, мы решили оптимизировать метод и у нас есть два альтернативных улучшения. После бенчмаркинга оказалось, что первая оптимизация снижает длительность метода на 98 %, а вторая — на 99 %. Насколько вторая быстрее первой?

Обычно первое число, которое приходит в голову, — 1 %. Но правильный ответ — в два раза. Возможно, вы решили эту задачу правильно, потому что ждали подвоха. Но многие часто интерпретируют такие ситуации неверно, когда пытаются быстро читать результаты бенчмаркинга и не подозревают о ловушке.

Многие отчеты о производительности используют подобные трюки, чтобы создать *впечатление*, что ситуация лучше или хуже, чем на самом деле. Хотя в таких отчетах нет заведомо ложных данных, описанные манипуляции могут заставить вас прийти к неверным выводам.

## Ложь с помощью пропорций

Если вы уверены, что один метод быстрее другого, следующий логичный вопрос: «Насколько быстрее?» Типичный подход заключается в том, чтобы разделить значение среднего арифметического выборки первого метода на значение среднего арифметического выборки второго метода. Но в целом это не очень хорошо работает, потому что в такой ситуации нельзя описать ответ с помощью одного числа. Правильный подход состоит в том, чтобы построить распределение пропорции  $z$ :

$$z_1 = \frac{x_1}{y_1}, z_2 = \frac{x_2}{y_2} \dots z_n = \frac{x_n}{y_n}.$$

Это парный метод, то есть нужны выборки равных размеров. В результате вы получаете еще одно распределение со своими собственными статистическими метриками: средним арифметическим, дисперсией и т. д.

Рассмотрим следующие выборки:

$$x = \{200, 200, 200, 200, 200\}, y = \{100, 100, 100, 100, 10\ 000\}.$$

Выборка  $x$  суперстабильна — все ее элементы равны 200. Выборка  $y$  также довольно стабильна — почти все ее элементы равны 100, но есть один большой выброс. Теперь построим распределение пропорции:

$$z = \{2, 2, 2, 2, 0,02\}.$$

Насколько  $x$  быстрее  $y$ ? Рассмотрим два способа вычисления — пропорцию средних арифметических и среднее арифметическое пропорции:

$$\frac{\bar{x}}{\bar{y}} \approx 0,1; \bar{z} \approx 1,6.$$

Первый ответ говорит о том, что  $x$  в 10 раз *быстрее*  $y$ , а второй — что  $x$  в 1,6 раза *медленнее*  $y$ . Какой из них лучше? На самом деле оба плохи, потому что в этом случае ответ нельзя описать одним числом. Лучший ответ содержит информацию о распределении пропорции. Например, мы можем представить его следующим образом:

$$\min(z) = 0,02; \max(z) = 2; Q_2(z) = 2; \bar{z} \approx 1,6; s_z \approx 0,89; n_z = 5.$$

Выполнив быстрый анализ, можно понять, что в большинстве случаев  $y$  быстрее  $x$ , но иногда  $x$  может быть значительно быстрее. Мы также знаем, что размер выборки пропорции равен пяти, чего недостаточно для осмысленных выводов. Вероятно, вам нужно больше данных.

В большинстве реальных бенчмарков значения  $\bar{x}/\bar{y}$  и  $\bar{z}$  довольно близки, а выборка  $z$  узкая, поэтому часто используются такие фразы, как «улучшение в 10 раз». Так говорить нормально, если вы уже проверили распределение пропорции и знаете, что разница между  $z_{\min}$  и  $z_{\max}$  невелика. Предоставлять слишком много метрик в каждом отчете о производительности — неудачный ход: такие отчеты трудно читать и понимать. Следует выделять только одну важную метрику и предоставлять способ проверки полного списка статистических характеристик. К сожалению, разработчики быстро привыкают к узким размахам и забывают проверить распределение пропорции, прежде чем переходить к финальным выводам.

Мы можем также не предоставлять масштабированный результат и предлагать читателю самостоятельно оценить его. Взгляните на следующую таблицу и попробуйте быстро сравнить производительность методов А и В:

	Mean	Skewness	Kurtosis	StdDev
A	523ms	0.34	2.64	752ms
B	929ms	0.39	2.31	983ms

Вероятно, первое впечатление было примерно таким: «А работает вдвое быстрее, чем В» из-за колонки Mean. Колонки Skewness и Kurtosis в этом случае не дают полезной информации, но они прячут колонку стандартного отклонения: читатель может перестать читать табличку из-за скучных колонок. А между тем колонка стандартного отклонения содержит важную информацию: в ней очень высокие значения. Размеры выборок и стандартные погрешности не представлены, поэтому у нас недостаточно данных для каких-либо осмысленных выводов об А и В. Разницу между средними арифметическими (406 мс) легко объяснить плохими

выборками: такое значение очень просто получить, если дисперсия велика, а размеры выборок малы. Нельзя сказать, что А быстрее В, без нормального статистического теста или графика плотности, основанного на более крупных выборках. Однако многие разработчики прекращают анализировать результаты после колонки Mean и приходят к недостоверным выводам.

## Ложь с помощью графиков

Графики прекрасно подходят для визуализации данных. С их помощью можно быстро понять форму распределения. Однако они могут и навредить, заставляя вас приходиться к неверным выводам.

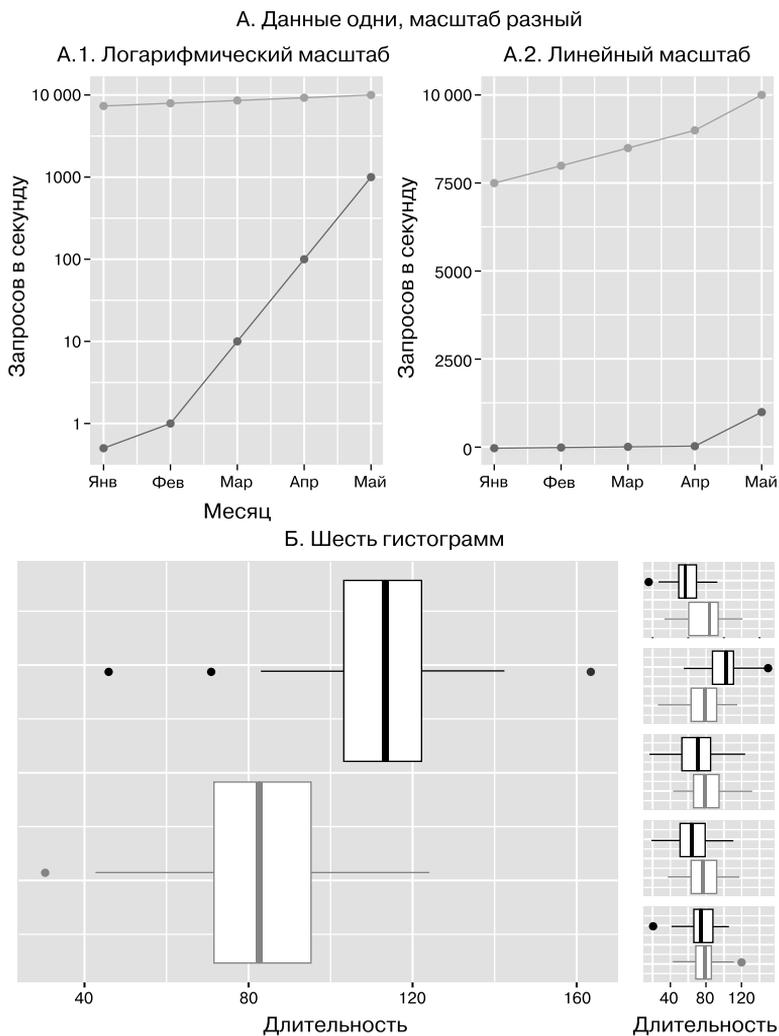
Обсудим несколько распространенных способов лжи с помощью графиков.

- **Изменение масштаба.**

На рис. 4.17, А, можно увидеть два графика разных масштабов для одинаковых данных. Здесь мы измеряем параметр «запросы в секунду» для двух веб-серверов за несколько месяцев. Один сервер изначально намного быстрее второго, и оба улучшают этот параметр каждый месяц. Первый график (*слева*) создает неверное впечатление: кажется, что более медленный сервер почти догнал более быстрый и в следующем месяце значения параметра сравняются. Это впечатление объясняется логарифмическим масштабом. Он полезен для разных графиков производительности, но не в этом случае. Лучше использовать обычный линейный масштаб, представленный на графике *справа*. Там видно, что более медленный сервер только в начале своего пути оптимизации. Впечатляющее ускорение в 10 раз объясняется очень низкой производительностью в январе (0,1 RPS). По второму графику очевидно, что улучшения производительности в феврале, марте и апреле смехотворно малы по сравнению с ростом показателя более быстрого сервера. В мае медленный сервер все еще в 10 раз хуже быстрого, и добиться еще одного ускорения в 10 раз в следующем месяце будет довольно сложно.

- **Выделение данных.**

Допустим, мы хотим сравнить производительность двух методов. Мы провели шесть разных экспериментов и нарисовали шесть диаграмм размаха (рис. 4.17, Б). Одна диаграмма выделена и нарисована крупно, остальные — мельче. Это распространенная техника при большом количестве диаграмм и нехватке места. В этом случае нужно как следует обдумать, какую диаграмму выделить. Взглянув на рис. 4.17, Б, вы можете решить, что эксперименты, соответствующие верхней диаграмме размаха, занимают больше времени, потому что она выделена. Однако если вы потратите больше времени и рассмотрите все диаграммы, то поймете, что сказать, какой метод быстрее, невозможно: в разных экспериментах получены противоположные данные.



**Рис. 4.17.** Ложь с помощью графиков

● **Соккрытие данных.**

Иногда у нас есть ненужные данные, которые мы не хотим выделять. В этом случае можно выбрать особенную форму визуализации. Например, если слишком много выбросов, которые мы не хотим показывать, можно выбрать график плотности вместо графика частотных трасс. График плотности — популярная форма визуализации, его использование совершенно нормально. Но мы знаем об одном его свойстве: он скрывает выбросы. Данные показаны честно, но это *не все данные*. Если распределение мультимодально, но мы никому не хотим

говорить об этом, можно выбрать диаграмму размаха вместо графика плотности распределения. В этом случае также используется распространенный и честный способ визуализации, но выбран он потому, что скрывает информацию, которой мы не хотим делиться. График каждого вида показывает только определенные свойства распределения — компактного и точного способа продемонстрировать все возможные характеристики не существует, особенно если распределений много. То есть мы всегда скрываем какую-либо информацию. Обычно, закончив анализ, мы пытаемся найти подход к визуализации, подчеркивающий самые интересные части пространства производительности. Однако можно намеренно выбрать график, который их скрывает.

Есть много разных способов лгать с помощью графиков (интересные примеры обманных графиков приведены в [Wainer, 1984]). Хорошая визуализация — это сложная задача, обычно занимающая много времени и сил. Часто у исследователя мало времени, и он просто выбирает случайный график. Еще одна распространенная ситуация: исследователь умеет рисовать только один вид графиков и использует его повсюду, вместо того чтобы искать подходящую визуализацию в каждом конкретном случае. В подобной ситуации высок риск случайного появления обманного графика. При чтении отчетов других людей всегда обращайтесь внимание на визуализацию и причины создания конкретного вида графика.

## Ложь с помощью слепого прочесывания данных

Представьте, что мы немного улучшили производительность и очень хотим продемонстрировать положительное влияние этого улучшения на реальные сценарии. Мы устанавливаем бенчмарк, собираем 100 пар выборок, проводим статистические тесты и вычисляем  $p$ -значения. К сожалению, только в двух случаях  $p$ -значения получаются  $< 0,05$ , чего недостаточно, чтобы сказать, что появилась статистически значимая разница. Мы знаем, что несколько небольших  $p$ -значений, когда  $H_0$  является верной, — это нормально, поскольку они распределены равномерно. Мы еще никому не показывали все результаты эксперимента и все еще хотим доказать, что полученное улучшение производительности имеет значение. Как убедить в этом других? Может быть, показать только пары выборок с  $p$ -значениями  $< 0,05$ ?

Описанная техника известна как  **$p$ -взлом**. Это не очень хороший инструмент, но, к сожалению, им часто злоупотребляют при различных научных исследованиях. Мы уже обсудили другой подобный пример в разделе «Произвольная остановка»: закончить итерацию после достижения небольшого  $p$ -значения — надежный способ поддержать  $H_1$  и показать, что эффект значительный, даже если  $H_1$  является ложной.

Хотя многие *намеренно* используют  $p$ -взлом (знают, что  $H_1$  ложна, но хотят показать, будто она верна), его эффект может случайно испортить ваши выводы,

даже если вы этого не хотите. *Ненамеренный* р-взлом происходит, когда вам очень хочется принять  $H_1$ , основываясь на нескольких небольших р-значениях без дополнительных проверок<sup>1</sup>.

Спасти от ненамеренного р-взлома могут несколько методик. Одна из моих любимых — **поправка Холма — Бонферрони**. Ее суть проста: получив набор р-значений от разных экспериментов, нужно рассортировать их в нисходящем порядке и ранжировать рассортированный массив. После этого умножить каждое р-значение на его ранг. Пример подобной поправки приведен в табл. 4.5. В изначальном наборе р-значений есть два значения меньше 0,05: 0,009 и 0,015. После применения поправки они превращаются в 0,063 и 0,090, что выше уровня  $\alpha = 0,05$ . Некоторые значения могут стать больше 1, но об этом не нужно волноваться, пока сравниваете их с  $\alpha$ .

**Таблица 4.5.** Поправка Холма — Бонферрони

р-значение	Ранг	Исправленное р-значение
0,962	1	0,962
0,673	2	1,346
0,313	3	0,939
0,120	4	0,480
0,042	5	0,210
0,015	6	0,090
0,009	7	0,063

Р-взлом — это пример **слепого прочесывания данных**. Все подобные техники основаны на простом принципе. Допустим, у нас нет статистически значимого эффекта, но мы хотим продемонстрировать, что он есть. В этом случае почти невозможно достичь нулевого уровня ошибок 1-го рода (ложноположительных). Если произвести очень много статистических экспериментов, мы должны получить несколько нетипичных результатов. Включение только таких экспериментов в итоговый отчет позволяет убедить других людей в неверных результатах.

У слепого прочесывания данных много вариаций. Еще один распространенный пример связан с проблемой **множественного сравнения в кластеризации**. Выражение «Кто ищет, тот всегда найдет» идеально описывает этот подход. Представьте, что у нас есть набор выборок производительности в разных окружениях. Каждое окружение описано с помощью сотен характеристик, от версии RubyJIT до модели SSD. Если разбить выборки по каждой характеристике и проводить статистические тесты на разных подвыборках, мы, вероятно, получим несколько характеристик

<sup>1</sup> В [Lakens, 2014b] Дэниел Лакенс описывает интересный эффект под названием «биполярное расстройство р-значений».

с низкими  $p$ -значениями. Это может привести к неверному выводу о том, что эти характеристики влияют на производительность. К счастью, подобную гипотезу легко проверить: нужно провести дополнительные эксперименты в двух окружениях, разбитых по выбранной характеристике, и повторить статистический тест на новых выборках.

Слепое прочесывание данных — неэтичный подход, который позволяет подтолкнуть других к неверным выводам на основе реальных данных. Если вы не доверяете исследователю, то всегда пытаетесь повторить описанный эксперимент и проверить, можно ли воспроизвести результаты (хорошее исследование производительности должно включать в себя достаточно информации для его воспроизведения). Если вы получили полный набор сырых данных, также можете проанализировать их самостоятельно и проверить распределение  $p$ -значений: вы уже знаете, как оно выглядит со слепым прочесыванием данных и без него.

## Подводя итог

В этом разделе мы обсудили несколько инструментов, позволяющих лгать при помощи бенчмаркинга.

- **Маленькие выборки.**

При небольшом размере выборки высока вероятность получить неординарные результаты. Вы можете легко пропустить выбросы или неверно вычислить стандартное отклонение. Обычно статистические тесты невозможно применить к маленьким выборкам.

- **Проценты.**

Если мы хотим корректно вычислить разницу в производительности с точки зрения процентов, необходимо отталкиваться от правильной исходной точки (обычно это состояние «до»). Неверно складывать или вычитать проценты из разных экспериментов, такие результаты не дают осмысленных чисел.

- **Пропорции.**

Пропорцию двух распределений в целом нельзя описать одним числом. Нужно работать с распределением пропорции. Во многих простых случаях пропорция значений среднего арифметического выдает правильный ответ, но это недостоверно без анализа распределения — его легко могут испортить выбросы или высокое стандартное отклонение.

- **Графики.**

Графики могут дать неверное впечатление о данных. Например, можно использовать особый масштаб, чтобы выделить или скрыть важную часть пространства производительности.

- **Слепое прочесывание данных.**

Когда  $H_0$  верна, уровень ошибок 1-го рода (ложноположительных) обычно выше нуля. Если провести достаточно экспериментов, вы найдете выборки с низкими р-значениями, подтверждающие  $H_1$ . Демонстрация только таких экспериментов может убедить других в неверных результатах. Эта техника известна как р-взлом. Существуют и другие методики, основанные на поиске чего-то необычного в пространстве производительности. Например, если у вас есть сотни характеристик окружения для небольшого набора экспериментов, вы, скорее всего, найдете несколько предположительно влияющих на производительность.

Все описанные способы солгать не содержат заведомо ложных данных, напротив, они основаны на реальных измерениях. Вот два типа выводов.

- **Прямой путь.**

Отчет содержит неверные выводы. Например, можно представить неверно вычисленные параметры или попытаться доказать  $H_1$ , основываясь на р-взломанных выборках.

- **Косвенный путь.**

Отчет не содержит никаких выводов, просто представляет данные по-особенному. Однако форма представления заставляет интуицию работать против читателя, что может привести к неверным выводам. Этот подход гораздо более эффективен, поскольку собственным выводам мы обычно больше доверяем, чем чужим<sup>1</sup>.

В этом разделе мы не осветили все возможные способы солгать с помощью бенчмаркинга, поэтому будьте начеку и всегда внимательно анализируйте распределения производительности перед тем, как делать выводы. Не доверяйте своей интуиции и все перепроверяйте дважды.

## Выводы

В этой главе мы рассмотрели следующие темы.

- **Описательная статистика.**

Вы узнали обо многих метриках, с помощью которых можно описать распределение, от среднего арифметического и стандартного отклонения до коэффициента асимметрии и доверительного интервала. Вы не обязаны помнить, как

<sup>1</sup> Больше информации об этом эффекте приведено в следующей статье из «Википедии»: [https://en.wikipedia.org/wiki/Confirmation\\_bias](https://en.wikipedia.org/wiki/Confirmation_bias).

их вычислять, но стоит запомнить, как их интерпретировать. Также узнали обо многих полезных техниках визуализации, от гистограмм и графиков плотности до гистограмм размаха и частотных трасс. Хорошая визуализация значительно упрощает процесс исследования.

- **Анализ производительности.**

Вы узнали о нескольких приемах анализа производительности. Два распределения можно сравнить с помощью статистических тестов, а регрессионные модели способны помочь вам понять, как производительность зависит от данных ввода и окружения. Адаптивные техники, такие как произвольная остановка и пробные эксперименты, используют статистику при бенчмаркинге и помогают оптимизировать измерения с точки зрения длительности и точности эксперимента.

- **Как лгать с помощью бенчмаркинга.**

Вы также узнали о множестве обманных методов, способных заставить неверно интерпретировать результаты. Так что теперь сможем распознать их при исследовании производительности и избежать распространенных ошибок в собственных исследованиях.

Эта глава не является полным введением в статистику. Это просто практическое руководство с самыми полезными техниками для реальных распределений производительности. Но мы не обсудили многие статистические методы и подходы, которые также могут пригодиться при различных исследованиях. Если вы хотите больше узнать о статистике, рекомендую прочесть такие книги, как [Downey, 2014], [Freedman, 2007], [Wasserman, 2010] и [Boslaugh, 2012].

Заметьте, что эта глава не содержит теории классической статистики — это руководство для практикующего специалиста в сфере производительности, которая должна помочь проанализировать измерения производительности, правильно интерпретировать результаты и оптимизировать процесс бенчмаркинга. Поэтому некоторые темы раскрыты не полностью и не все утверждения математически точны. Однако это не должно стать проблемой при реальном исследовании производительности. Гораздо важнее просто ознакомиться с основными понятиями.

## Источники

[ACM209] *Ibbetson D.* Algorithm 209: Gauss // Magazine Communications of the ACM 6 (10), 1963. ACM: 616. <https://dl.acm.org/citation.cfm?id=367664>.

[ACM395] *Hill G. W.* Algorithm 395: Student's T-Distribution // Magazine Communications of the ACM 13 (10), 1970. ACM: 617–619. <http://dl.acm.org/citation.cfm?id=355599>.

- [Azad, 2007] *Azad K.* Understanding the Birthday Paradox. 2007. April 26. <https://betterexplained.com/articles/understanding-the-birthday-paradox/>.
- [Boslaugh, 2012] *Boslaugh S.* Statistics in a Nutshell: A Desktop Quick Reference. 2nd ed. O'Reilly Media, Inc., 2012.
- [Downey, 2014] *Downey A. B.* Think Stats: Exploratory Data Analysis. 2nd ed. O'Reilly Media, Inc., 2014. <http://greenteapress.com/thinkstats/>.
- [Freedman, 2007] *Freedman D., Pisani R., Purves R.* Statistics. 4th ed. WW Norton & Company, 2007.
- [Gregg, 2014a] *Gregg B.* Frequency Trails: Introduction. 2014. February 2. [www.brendangregg.com/FrequencyTrails/intro.html](http://www.brendangregg.com/FrequencyTrails/intro.html).
- [Gregg, 2014b] *Gregg B.* Frequency Trails: Detecting Outliers. 2014. February 2. [www.brendangregg.com/FrequencyTrails/outliers.html](http://www.brendangregg.com/FrequencyTrails/outliers.html).
- [Gregg, 2015] *Gregg B.* Frequency Trails: Modes and Modality. 2015. June 17. [www.brendangregg.com/FrequencyTrails/modes.html](http://www.brendangregg.com/FrequencyTrails/modes.html).
- [Gregg, 2017] *Gregg B.* The USE Method. 2017. August 24. [www.brendangregg.com/usemethod.html](http://www.brendangregg.com/usemethod.html).
- [Huff, 1993] *Huff D.* How to Lie with Statistics. WW Norton & Company, 1993.
- [Kahneman, 2013] *Kahneman D.* Thinking, Fast and Slow. Farrar, Straus and Giroux, 2013.
- [Lakens, 2014a] *Lakens D.* What P-Hacking Really Looks Like: A Comment on Masicampo & LaLande (2012). 2014. September 30. <http://daniellakens.blogspot.com/2014/09/what-p-hacking-really-looks-like.html>.
- [Lakens, 2014b] *Lakens D.* The Probability of P-Values as a Function of the Statistical Power of a Test. 2014. May 29. <http://daniellakens.blogspot.com/2014/05/the-probability-of-p-values-as-function.html>.
- [Matejka, 2017] *Matejka J., Fitzmaurice G.* Same Stats, Different Graphs: Generating Datasets with Varied Appearance and Identical Statistics Through Simulated Annealing // CHI 2017 Conference Proceedings: ACM SIGCHI Conference on Human Factors in Computing Systems, 2017. ACM: 1290–1294. [www.autodeskresearch.com/publications/samestats](http://www.autodeskresearch.com/publications/samestats).
- [Minitab, 2013] Explaining the Central Limit Theorem with Bunnies & Dragons // The Minitab Blog, 2013. October 15. <http://blog.minitab.com/blog/michelle-paret/explaining-the-central-limit-theorem-with-bunnies-and-dragons-v2>.

[Ribeca, 2017] *Ribeca S.* Further Exploration #4: Box Plot Variations. 2017. September 27. <http://datavizcatalogue.com/blog/box-plot-variations/>.

[Wainer, 1984] *Wainer H.* How to Display Data Badly // *American Statistician*, 1984. № 38 (2): 137–147.

[Wasserman, 2010] *Wasserman L.* All of Statistics: A Concise Course in Statistical Inference. Springer Science & Business Media, 2013.

[Wickham, 2011] *Wickham H., Stryjewski L.* 40 Years of Boxplots // *American Statistician*, 2011. July. <http://vita.had.co.nz/papers/boxplots.pdf>.

# 5

## Анализ и тестирование производительности

Первый принцип — не надо обманывать себя, это сделать проще всего.

*Ричард Фейнман, 1974*

В большинстве случаев бенчмаркинг представляет собой исследование производительности. Бенчмарки дают нам новую информацию о программном обеспечении и аппаратных средствах, которую можно далее использовать для разных видов оптимизации производительности.

Добившись желаемого уровня производительности, человек обычно хочет сохранить его. А еще никто не хочет попасть в ситуацию, когда другой участник команды случайно портит то, что вы улучшили. Как это предотвратить? А как обычно предотвращают порчу базы кода? Пишут тесты! Если нам не нужен регресс производительности, необходимо ее *тестировать!* Подобные тесты могут быть частью процесса непрерывной интеграции, поэтому никакое ухудшение производительности не пройдет незамеченным!<sup>1</sup>

Итак, выглядит все очень просто: пишем тесты производительности и получаем результат! Прекрасно же звучит? К сожалению, в реальности все сложнее. В тестах производительности недостаточно просто измерять метрики производительности кода — надо знать, как обрабатывать эти значения. Бенчмарк без анализа — не бенчмарк, а просто программа, выдающая числа. Результаты бенчмарка всегда нужно анализировать.

При запуске бенчмарка локально весь релевантный исходный код у вас под рукой: можете его читать, вносить в него изменения. Можете совершать дополнительные действия в зависимости от состояния исследования. Можете изучить полученные данные и принять решение о следующем шаге. Когда бенчмарк становится тестом производительности, данный процесс следует автоматизировать. Это гораздо сложнее, потому что при автоматизации должны учитываться будущие изменения в исходном коде. Вы не знаете будущего, не знаете, какие метрики производительности

---

<sup>1</sup> В теории.

получите завтра, не можете изучить будущие графики распределения и принять неавтоматизированные решения по поводу грядущих проблем. Все должно быть автоматизировано! А это очень сложно: необходимо предвидеть возможные проблемы и писать алгоритмы для анализа, не зная данных. Нужно разработать не только набор бенчмарков, но и набор уведомлений и сигналов тревоги, которые сообщат о возникновении проблем.

Эта глава называется «Анализ и тестирование производительности», а не просто «Тестирование производительности». Эти темы являются смежными: тестирование производительности требует глубокого понимания методов ее анализа. В то же время техники анализа производительности можно применять не только для тестирования, но и для обычных бенчмарков (не включающих в себя уведомлений) и исследований производительности. Все проблемы и их решения мы будем обсуждать в контексте тестирования производительности, но нужно помнить о том, что почти все это можно использовать и для бенчмаркинга в целом. Мы осветим следующие темы.

- **Цели тестирования производительности.**

Какие проблемы мы стремимся решить? Чего конкретно хотим, говоря о тестах производительности? Необходимо четко понимать цели, прежде чем начинать работу. Следует понимать, чего мы хотим достичь.

- **Виды бенчмарков и тестов производительности.**

Существует множество видов тестов производительности. Необходимо решить, как будет выглядеть ваш тест и что конкретно он должен измерять. Например, это может быть нагрузочное испытание, проверяющее, как работает веб-сервер при высокой загрузке. Или тест пользовательского интерфейса, выявляющий, отвечают ли механизмы контроля и работают ли они без задержек. Или асимптотический тест, подтверждающий, что алгоритмическая сложность метода —  $O(N)$ . Или функциональный тест, измеряющий длительность одной операции. Знание этих видов позволяет выбрать, как писать тест производительности в каждой отдельной ситуации.

- **Аномалии производительности.**

Длительность теста не выражается одним числом — это всегда какое-то распределение. Иногда оно выглядит странно. Например, оно может оказаться мультимодальным или иметь крайне высокую дисперсию. Распределения необычной формы называются *аномалиями производительности*. Они не всегда представляют собой проблему, но поиск таких аномалий обычно помогает найти много проблем, которые иначе не обнаружить.

- **Стратегии защиты.**

Когда проводить тесты производительности, до или после слияния с основной ветвью системы контроля версий? Нужно ли выполнять их при каждом под-

тверждении изменения или достаточно раза в день? Сколько времени следует потратить на тестирование производительности и какие ухудшения можно обнаружить в каждом конкретном случае? Можем ли мы использовать полностью автоматизированную логику компьютерного интерфейса? Или нужно всегда все делать вручную? Что можно предпринять, если выпущен продукт с проблемами в производительности? Существуют разные стратегии защиты от ухудшения производительности, у каждой из них есть свои плюсы и минусы, каждая помогает решать конкретный набор проблем.

- **Пространство производительности.**

При каждом тесте можно измерять множество метрик. Можно найти общее физическое время, проверить аппаратный счетчик или количество запусков механизма управления памятью. Можно собирать эти метрики по одной ветви или по нескольким. Есть много способов получить значения производительности, и о них нужно знать, поскольку это поможет вам выбрать те, которые пригодятся больше всего.

- **Уведомления и сигналы тревоги.**

С функциональными тестами все просто, поскольку они обычно детерминированы. Если у вас состояние гонки, тест всегда будет выдавать один и тот же результат. Когда тест «зеленый», все понятно. В зависимости от своих требований вы легко можете проверить его с помощью операторов подтверждения отсутствия ошибок.

В случае тестов производительности все сложнее. Вспомните, результат теста представляет собой набор чисел. Новые числа после каждого запуска появляются даже на одном и том же устройстве. Более того, в некоторых случаях приходится сравнивать данные с разных устройств. Стандартное отклонение может быть огромным, поэтому бывает сложно или даже невозможно обнаружить ухудшение на 5–10 %. Очень важно определить критерии оповещений о проблеме и ответить на простой вопрос: «*Когда тест становится “красным”?*»

- **Разработка с ориентацией на производительность (PDD).**

Этот подход похож на разработку с ориентацией на тестирование (TDD) с одним исключением: вместо обычных функциональных тестов мы пишем тесты производительности. Суть проста: не стоит начинать оптимизацию прежде, чем напишете соответствующие «красные» тесты производительности. Звучит действительно просто, но это очень полезный подход — если следовать ему, можно сохранить массу времени и нервов.

- **Культура производительности.**

К сожалению, тесты производительности не будут нормально работать, если участникам команды неважна сама производительность. Нужна особая культура внутри команды и в целом компании. Тестирование производительности связано не только с технологиями, но и с отношениями.

Универсального подхода, позволяющего бесплатно получить систему тестирования производительности в любом проекте, не существует. Самый подходящий *для вас* подход будет зависеть от *ваших* требований к производительности и от компьютерных и человеческих ресурсов. В этой главе вы узнаете основные сведения о тестах производительности, которые помогут разобраться, какие методы могут оказаться полезными для ваших проектов и вашей команды.

Многие примеры в этой главе основаны на истории разработки IntelliJ IDEA, ReSharper и Rider. Я буду упоминать эти проекты без дополнительных примечаний.

Начнем с целей тестирования производительности!

## Цели тестирования производительности

В современном мире мы часто выпускаем новые версии ПО. Пытаемся исправить старые ошибки и реализовать превосходные новые функции. Однако иногда они работают хуже, чем мы ожидали. Впрочем, это нормальная ситуация: трудно писать новый код, не вызывая новых проблем. Так и должно быть. Будем надеяться, что пользователи это понимают и будут ждать новой версии с исправлениями. Но во многих случаях ломать или замедлять старые функции практически непроситительно. Для меня, как специалиста по производительности, худший отзыв пользователя звучал так: «Новая версия вашего ПО работает так медленно, что пришлось откатиться к предыдущей версии» или даже «Пришлось перейти на продукцию ваших конкурентов». *Иногда производительность ухудшается* — именно эту проблему мы собираемся решить в этой главе. Определив задачу, перейдем к постановке целей.

### Цель 1: предотвращение ухудшения производительности

Наша основная цель — *предотвратить ухудшение производительности*. Некоторые разработчики могут перепутать ее с целью «ускорить ПО» или «сделать так, чтобы пользователи были довольны нашей производительностью». Будьте внимательны! Предотвращение ухудшения производительности не относится к общему уровню производительности или удовольствию пользователей. Это означает, что каждая версия ПО должна работать *так же быстро, как и предыдущая, или еще быстрее*.

**Ремарка 1.** В программировании всегда необходимы компромиссы. Невозможно постоянно улучшать производительность всех функций программы. Иногда приходится что-то замедлять, чтобы ускорить другую часть, например тратить время на загрузку кэша при запуске, что позволит в дальнейшем быстро обрабатывать запросы. Компромисс может быть осознанным решением, и это абсолютно нор-

мально. Однако во многих случаях разработчики замедляют функции ненамеренно. В объемных программах трудно измерить влияние даже маленьких изменений на производительность всего продукта. Поэтому наша цель на самом деле такова: *предотвратить случайное ухудшение производительности*.

**Ремарка 2.** В этой книге нет четкого общего определения ухудшения производительности. Вы должны определить это понятие сами для себя, поскольку оно зависит от целей и требований вашего бизнеса. Если вы читаете эту главу, вероятно, у вас уже есть какие-то проблемы с производительностью или вы ожидаете их появления в будущем. Попробуйте адаптировать термин «ухудшение производительности» под свою конкретную ситуацию. Вот несколько очень упрощенных примеров того, как определение может зависеть от контекста.

- *Иногда ухудшение даже на 1 % может представлять собой огромную проблему.* Допустим, у нас есть веб-сервер, обрабатывающий запросы. Он развернут в облаке, и мы платим провайдеру облачного сервера за временные ресурсы по фиксированной ставке. В нашем сферическом примере в вакууме каждый запрос всегда занимает 100 мс. Ухудшение на 1 % означает, что после изменений получится 101 мс на запрос. Если запросов миллиарды, общее время обработки заметно возрастет<sup>1</sup>. А главное, что и наши счета также вырастут на 1 %.
- *Иногда даже ухудшение на 500 % — не проблема.* У нас есть сервер, показывающий статистику действий пользователей. Допустим, нам не нужна статистика в режиме реального времени, достаточно обновлять ее раз в день. Таким образом, у нас есть утилита консоли, обновляющая статистический отчет и размещающая его. С помощью `stop`<sup>2</sup> мы запускаем ее каждый день в 2:00. Время работы утилиты — 1 мин, поэтому отчет готов в 2:01. Один разработчик из вашей команды решил добавить сложные вычисления: теперь отчет содержит новую полезную информацию, но общее время его создания — 6 мин. Он готов в 2:06. Это проблема? Скорее всего, нет, поскольку аналитики просмотрят его только утром. Если время работы утилиты увеличится до 10 часов, возможно, проблема появится, но лишних 5 мин в этом случае погоды не сделают.
- *Иногда невозможно говорить об ухудшении в смысле процентов.* Из-за сложного многоуровневого иерархического кэша 20 % запросов занимают 100 мс, 35 % — 200 мс и 45 % — 300 мс. После внесения некоторых изменений 20 % запросов

<sup>1</sup> Очень маленькие изменения на критических путях могут значительно повлиять на производительность. Один мой знакомый привел прекрасный пример из системы производства, когда один запрос `.EndsWith('/')` вызвал уменьшение количества запросов в секунду на 20 %: эта метрика изменилась примерно с 55 000 до 38 000. Проблему решили с помощью очень простой оптимизации: запрос `EndWith` заменили на `[variable.Length - 1] == '/'`.

<sup>2</sup> `Stop` — это синхронизируемый планировщик работ в компьютерных операционных системах типа Unix.

занимают 225 мс, 35 % — 180 мс и 45 % — 260 мс. Это изменения в хорошую или плохую сторону? Есть ли в этом случае ухудшение производительности? (Попробуйте вычислить среднее время обработки в обоих случаях.) В общем, это еще одна проблема компромиссов: невозможно ответить на вопрос, не зная бизнес-требований.

Мы обсудим разные критерии ухудшения производительности в разделе «Уведомления и сигналы тревоги в сфере производительности».

**Ремарка 3.** В объемных программах очень трудно предотвратить все возможные случаи ухудшения производительности. «Предотвратить все случаи ухудшения производительности» звучит как «предотвратить все ошибки» или «проверить все уязвимые места в области безопасности». Теоретически это возможно. Но на практике требуется слишком много ресурсов и сил. Можно написать тысячи тестов производительности и купить сотни серверов непрерывной интеграции для их непрерывного запуска. Это поможет предотвратить *большую часть проблем*, но, скорее всего, не все. Также в некоторых случаях ухудшение производительности может не влиять на цели бизнеса, поэтому не всегда имеет смысл его исправлять. Так что, говоря «предотвратить все случаи ухудшения производительности», мы обычно имеем в виду «предотвратить большую часть, которая имеет значение».

## Цель 2: обнаружение непредотвращенных случаев ухудшения

Поскольку предотвратить все случаи ухудшения производительности почти невозможно, у нас есть вторая цель: *обнаружить непредотвращенные случаи ухудшения*. Тогда мы можем их исправить и восстановить изначальную производительность. Такие проблемы можно обнаружить в тот же день, на той же неделе, в том же месяце и даже спустя год. Мы обсудим, какие проблемы можно обнаружить в разные моменты, в разделе «Стратегии защиты». Самое главное здесь то, что мы хотим обнаружить их до того, как их найдут пользователи/клиенты и начнут нам жаловаться.

## Цель 3: обнаружение других типов аномалий производительности

Ухудшение производительности не единственная проблема, которая может возникнуть. В этой главе мы обсудим так называемые аномалии производительности, включающие в себя кластеризацию, высокую дисперсию и другие виды странных распределений производительности. Обычно (но не всегда) подобные аномалии помогают обнаружить разные проблемы в бизнес-логике. Если вы создаете систему

для анализа производительности, имеет смысл проверить пространство производительности и на наличие таких аномалий. Интересный момент: некоторые из них обнаруживаются в ходе одной проверки, поэтому вам не придется анализировать всю историю производительности или сравнивать операции подтверждения.

## Цель 4: снижение уровня ошибок 1-го рода

Если вы пропустили главу, посвященную статистике (глава 4), я объясню эту цель простыми словами. Ошибка 1-го рода (*ложноположительный* результат) означает, что ухудшения производительности нет, но тест выявляет ложные проблемы. Последствия: разработчики впустую тратят время на исследования. Это не только трата самого ценного нашего ресурса — времени разработчиков, но и существенный демотивирующий фактор. Несколько ошибок 1-го рода за месяц — нормально. Более того, стоит ожидать появления подобных ошибок — слишком сложно реализовать идеальную систему тестирования производительности совсем без них. Однако, если вы получаете несколько ложноположительных результатов в день, разработчикам станет на них наплевать. И это будет логично: зачем тратить время на бессмысленные исследования каждый день? Однако среди ложных проблем могут быть и реальные, но вы их не заметите: разработчики проигнорируют все тревожные уведомления, потому что они, скорее всего, ложные. Вся идея будет скомпрометирована: тесты производительности не будут приносить пользы, а вместо этого начнут отвлекать участников команды.

Поэтому необходимо отслеживать ошибки 1-го рода. Если их слишком много, имеет смысл уменьшить требования к производительности и ослабить критерии ухудшения. Лучше пропустить несколько реальных проблем, чем получить совершенно бесполезный набор тестов производительности.

## Цель 5: снижение уровня ошибок 2-го рода

Ошибка 2-го рода (*ложноотрицательный* результат) означает, что ухудшение производительности есть, но мы его не обнаружили. Последствия: пользователи могут получить серьезные проблемы с производительностью при следующем обновлении. В этом случае мы не решаем нашу основную проблему — не предотвращаем ухудшения. Поскольку предотвратить все возможные случаи ухудшения невозможно, мы можем только попытаться уменьшить количество подобных ситуаций.

Это похоже на следствие первой цели, но я решил выделить его в отдельную цель, поскольку уровень ошибок 2-го рода также является метрикой, описывающей систему тестирования производительности. Недостаточно просто написать ряд тестов производительности, и пусть работают как хотят. Нужно отслеживать успешность платформы производительности. Например, можно создавать ежемесячный отчет

в духе: «В январе обнаружили 20 проблем с производительностью и исправили их до релиза. Три проблемы были обнаружены с помощью тестов производительности после релиза, и о двух проблемах сообщили в феврале недовольные пользователи». Такие отчеты позволяют:

- оценить эффективность тестов производительности;
- обнаружить слабые места и фрагменты кода, нуждающиеся в дополнительных тестах производительности;
- при своевременном обнаружении большого числа проблем замотивировать команду на написание новых тестов;
- решить, что, если не было значительных проблем (как обнаруженных, так и не обнаруженных), вам, вероятно, не нужны тесты производительности для этих проектов и тратить на это время в будущем не стоит.

## Цель 6: автоматизация всего перечисленного

Сформулировать правильные критерии ухудшения и добиться низкого уровня ошибок 1-го и 2-го рода нелегко. Иногда вам может захотеться отследить производительность вручную вместо того, чтобы написать надежную систему тестов производительности. Например, тесты могут выдавать тысячи чисел, которые собирает и показывает служба мониторинга. Далее вы или кто-то из ваших коллег каждый день проверяете отчеты о производительности, вручную ищете проблемы и сообщаете остальным участникам команды о результатах. Это неудачный подход, поскольку с человеческим фактором всегда много проблем: ответственный за мониторинг может заболеть, уйти в отпуск, заняться другими делами. В этом случае тревожные уведомления не будут получены, даже если появятся серьезные проблемы. Кроме того, человек может пропустить сообщение о проблеме из-за невнимательности.

К сожалению, автоматизировать все тяжело. В объемных проектах почти невозможно реализовать надежную автоматизированную систему мониторинга производительности с низким уровнем ошибок 1-го и 2-го рода. Иногда вам *приходится* анализировать какие-то данные вручную. В этом случае можно попытаться автоматизировать все, что можно автоматизировать. Допустим, у нас есть длинный интеграционный тест, обычно занимающий 5 мин. После каких-то изменений он продолжается 6 мин, о чем главный аналитик получает уведомление. Теперь он будет это исследовать. Как поможет автоматизация? Вот несколько идей.

### ● Автоматические отчеты.

Можно сгенерировать весь отчет о проблеме автоматически. Такой отчет может включать в себя ссылки на операции подтверждения (если у вас есть веб-сервис, позволяющий делать обзор базы кода), список авторов этих изменений, историю производительности теста, ссылки на другие тесты из того же набора, где появились проблемы с производительностью (они могут быть связаны), и т. д. Суть тут в том, что аналитику не придется искать дополнительные данные, вся

нужная информация будет собрана автоматически. Можно даже автоматически создавать ошибку в системе мониторинга ошибок и с легкостью обнаруживать все проблемы с производительностью.

- **Автоматическое деление пополам.**

Не всегда возможно запускать все тесты производительности для каждой операции подтверждения. Представьте, что один из ежедневных тестов стал «красным», а в этот день произошло  $N = 127$  операций подтверждения от десяти разных людей. Как найти операцию, в которой возникла проблема? Разумно начать делить эти операции пополам. Проверим операцию 64 (для упрощения предположим, что у нас линейная история без ветвей). Если тест «красный», значит, проблема возникла до этой операции и нужно проверить операцию 32. Если тест «зеленый», значит, проблема возникла после нее и нужно проверить операцию 96. Если продолжить этот процесс, мы сможем найти проблемную операцию после  $\log_2(N)$  итераций (в идеальном мире без ветвей). Деление пополам вручную — просто трата времени разработчиков. Этот процесс также можно автоматизировать: отчет должен включать в себя конкретную операцию подтверждения и имя ее автора (он должен начать исследовать проблему).

- **Автоматические снимки состояния.**

Один из первых шагов в подобных исследованиях — профилирование. Получив медленный тест, мы можем автоматически создать снимок состояния производительности до и после изменения. В этом случае аналитик может просто загрузить оба снимка и сравнить их. Это позволит найти проблему, даже не загружая источники, и выстраивать ее локально: многие глупые ошибки реально найти только по снимкам состояния.

- **Автоматический пошаговый анализ.**

Если появляется ухудшение на 1 мин в длинном интеграционном тесте, скорее всего, проблема в одной подсистеме, а не во всем проекте. Тогда можете измерить отдельные шаги для обоих случаев и автоматически сравнить их. После этого уведомление (или ошибка) может содержать дополнительную информацию, например: «кажется, проблема заключается в этих двух шагах, в остальных ухудшения не наблюдается».

- **Автоматическое непрерывное профилирование.**

Если у вас есть набор серверов с сервисами, иногда страдающими от случайных спадов производительности, можно попытаться профилировать их автоматически. Если ограничения подобного профилирования слишком велики, можно случайным образом профилировать только часть набора. Например, выбрать 10 % серверов и профилировать их в течение 30 с, затем выбрать еще 10 % и т. д. Можно менять точные числа и получить снимок состояния профиля в момент воспроизведения проблемы (возможно, это получится не с первого раза). Рандомизированный подход помогает снизить ограничения профилирования в системе производства.

Попытайтесь придумать свои способы автоматизировать рутинную работу. Вручную следует делать только то, что нельзя автоматизировать и что требует творческого подхода. Если в серии исследований производительности есть общие процессы, нужно попытаться автоматизировать их. Это позволит сберечь время разработчиков и упростить процесс исследования для людей, у которых нет конкретных навыков в области производительности.

## Подводя итог

Давайте подведем итог. Наша основная проблема в том, что производительность иногда ухудшается. Если мы правильно понимаем, что значит «ухудшение производительности», то можем попытаться предотвратить случайное ухудшение (цель 1). К сожалению, предотвратить все случайности невозможно, поэтому следует вовремя обнаружить непредотвращенные случаи ухудшения (цель 2) и другие виды проблем с производительностью (цель 3). Также мы хотим снизить уровень ошибок 1-го рода (ложноположительных — ухудшения нет, но мы обнаружили ложные проблемы) (цель 4) и ошибок 2-го рода (ложноотрицательных — необнаруженные случаи ухудшения) (цель 5). Все, что можно автоматизировать, должно быть автоматизировано (цель 6).

Мы определились с проблемами и целями. Пора узнать, какие виды тестов производительности можно выбрать.

## Виды бенчмарков и тестов производительности

Существует много техник, которые могут использоваться в качестве тестов производительности. В этом разделе мы кратко обсудим некоторые из них:

- **тесты холодной загрузки** — ситуации, когда важно время загрузки;
- **тесты разогретого состояния** — ситуации, когда приложение уже запущено;
- **асимптотические тесты**, определяющие асимптотическую сложность, например  $O(N)$  или  $O(N^2)$ ;
- **тесты длительности и выработки** — вместо того чтобы спросить: «Сколько времени занимает обработка  $N$  запросов?» — мы спрашиваем: «Сколько запросов можно обработать за временной интервал?»;
- **модульные и интеграционные тесты** — если у вас уже есть обычные тесты (не предполагавшиеся в качестве тестов производительности), можно использовать их обычную длительность для анализа производительности;

- **мониторинг и телеметрия** — просмотр изменения производительности в режиме реального времени;
- **тесты с внешними взаимозависимостями** — тесты, включающие что-то из внешнего мира, что мы не можем контролировать;
- **другие виды тестов производительности** — тесты предельной нагрузки, пользовательского интерфейса, нечеткие тесты и т. д.

Все эти виды тестов могут применяться не только для тестирования производительности, но и для обычного бенчмаркинга. Начнем с тестов холодной загрузки.

## Тесты холодной загрузки

Существуют разные виды тестов холодной загрузки в зависимости от того, какая часть ПО является холодной. Вот список некоторых уровней холодной загрузки.

- **Холодная загрузка метода.**

При первом запуске метода может происходить множество времязатратных процессов на разных уровнях, от компиляции JIT и загрузки сборки на уровне среды исполнения до первых вычислений статических характеристик на уровне логики приложения.

- **Холодная загрузка функции.**

Разница во времени между холодным и разогретым выполнением метода может быть настолько мала, что ею можно пренебречь. Однако она может оказаться значительной, если речь идет о тысячах методов и множестве сборок. Из-за этого пользователь может столкнуться с задержками при запуске функции в первый раз, особенно если она включает в себя много методов, которые до этого не вызывались.

- **Холодная загрузка приложения.**

Время загрузки важно для многих видов приложений. И крайне важно, если это приложения для Рабочего стола и мобильного телефона. Идеальной является та ситуация, когда пользователь моментально получает готовое приложение после двойного щелчка на ярлыке или другого вида запуска. Любая задержка заставит его нервничать. Представьте ситуацию, когда вам нужно быстро внести несколько правок в файл. Вы открываете его в любимом текстовом редакторе и... И ждете несколько секунд, пока он инициализируется. Если вы часто редактируете файлы и каждый раз закрываете редактор, это ожидание может раздражать. Для некоторых время загрузки важно настолько, что они могут предпочесть текстовый редактор с небольшим количеством функций, но который загружается мгновенно, тому, у которого много функций, но который запускается несколько секунд.

- **Холодная загрузка ОС.**

Если ваш бенчмарк взаимодействует с различными ресурсами ОС, для теста холодной загрузки может понадобиться физический перезапуск.

- **Новый образ ОС.**

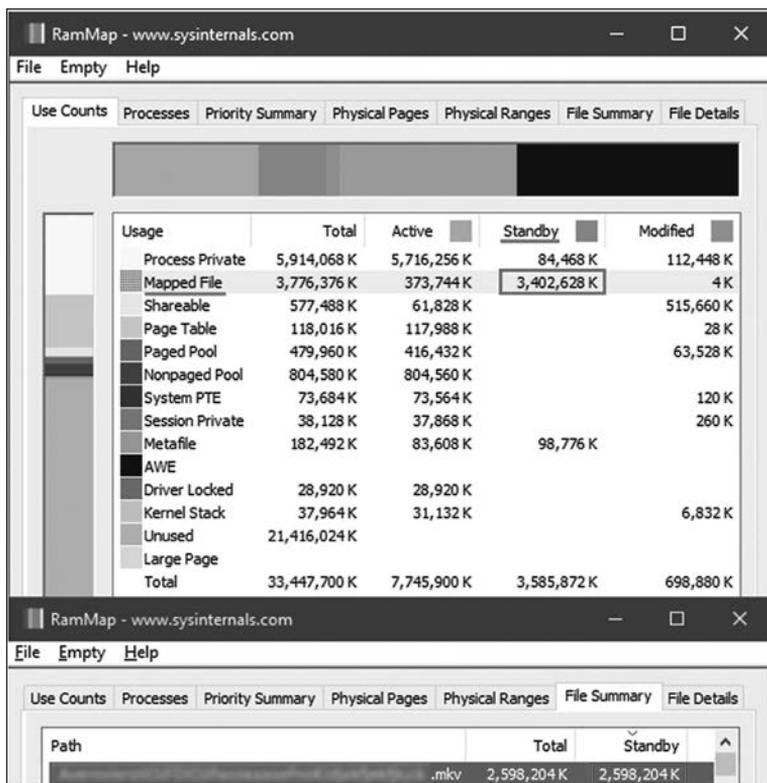
Иногда перезагрузки операционной системы недостаточно, может понадобиться новый образ. Старые запуски тестов могут внести в диск изменения, которые окажутся значимыми для последующих запусков. Например, Rider использует набор агентов TeamCity для запуска сотен конфигураций сборки тестов каждый день. TeamCity обновляет образы агентов раз в несколько дней — тут и начинается веселье. Иногда мы получаем значительную разницу в производительности между последним (разогретым) запуском теста на старом образе и первым (холодным) — на новом (без изменений в базе исходного кода). Мы не запускаем каждый раз новую установку ОС, потому что у этого метода большие ограничения инфраструктуры, а описанные проблемы встречаются нечасто.

Попробуйте выполнить следующее упражнение. Возьмите устройство с установленной на нем Windows и перезагрузите его. Откройте видеофайл с любимым фильмом в любимом видеоплеере, посмотрите его и закройте плеер. Затем запустите утилиту RAMMap (<https://docs.microsoft.com/en-us/sysinternals/downloads/rammap>) (часть набора Sysinternals). Она позволяет выполнять продвинутый анализ использования физической памяти и предоставляет много деталей нижнего уровня. Проверьте категорию Режим ожидания для Отмеченного файла на вкладке Количество использований (мы обсудим все эти категории в главе 8). Использование памяти должно быть высоким. Затем откройте вкладку Список файлов и отсортируйте файлы по колонке Режим ожидания. Затем найдите на этой вкладке файл с фильмом. Вы должны увидеть большое количество использованной для него памяти Режим ожидания (мою копию RAMMap вы видите на рис. 5.1).

Как такое возможно? Мы закрыли плеер. Больше приложений, использующих этот файл, нет. Почему его видно в RAMMap? И что означает Режим ожидания?

Категорию Режим ожидания можно представить как кэш памяти. После закрытия плеера, который загрузил весь файл с фильмом в основную память, нет необходимости моментально очищать память. Мы можем отметить ее как свободную (поэтому ее не видно в Диспетчере задач в качестве части обычной памяти) и очистить позже, когда другое приложение запрашивает дополнительное расположение ячеек памяти. Однако, если мы решим снова посмотреть кино, видеоплеер может еще раз использовать файл из списка Режим ожидания. Загрузка пройдет быстрее, поскольку не нужно снова загружать фильм в память. С одной стороны, это прекрасно: производительность улучшается для всех запусков плеера, кроме первого. С другой — так сложнее написать тест производительности или бенчмарк для холодной загрузки плеера. В этом конкретном случае можно очистить список Режим

ожидания вручную<sup>1</sup>. Однако трудно отследить все ресурсы, которые в общем могут быть использованы повторно, и вручную очищать их каждый раз. Перезагрузка системы — универсальный способ создать стерильное окружение для настоящей холодной загрузки.



**Рис. 5.1.** RAMMap показывает большой объем использования памяти в Режиме ожидания для закрытого файла

При запуске теста производительности или бенчмарка для холодной загрузки нужно четко понимать, что конкретно должно быть холодным. В большинстве случаев надо перезапускать все приложение или даже перезагружать ОС *перед каждой итерацией*. Это не всегда приемлемо, поскольку так каждая итерация занимает слишком много времени, поэтому программисты ищут другие решения, позволяющие охладить окружение без полной перезагрузки. Например, можно очистить ресурсы ОС с помощью встроенного API вместо того, чтобы перезапускать ее, или выполнять каждый вызов метода в новом AppDomain.

<sup>1</sup> В утилите RAMMap откройте меню Очистка и щелкните на пункте Очистка списка режима ожидания. В этом меню можно очистить и другие списки памяти.

## Разогретые тесты

Писать тесты для холодной загрузки всегда трудно, потому что невозможно сделать несколько итераций подряд: приходится перезагружать все приложение (или даже операционную систему) перед каждой итерацией. Гораздо проще писать разогретые тесты, и они популярнее, поскольку во многих приложениях, особенно для веб-сервисов, обычно не нужно беспокоиться о том, сколько времени занимает загрузка. Производительность разогретого приложения интереснее.

Однако правильные разогретые тесты также требуют некоторой подготовки. Самое важное — отсутствие побочных эффектов: все итерации должны начинаться из одного и того же состояния. К сожалению, большинство бенчмарков меняют окружение, поэтому его нужно восстанавливать. Вот несколько распространенных способов сделать это.

**Восстановление состояния в методах установки/очистки.** Допустим, мы хотим измерить метод `List<int>.Sort()`:

```
void ListSortBenchmark()
{
    list.Sort();
}
```

Вне зависимости от изначального состояния список `list` будет отсортирован после первой итерации. Проводить бенчмаркинг сортировки уже отсортированного списка неинтересно. Поэтому нужно выбрать референтное начальное состояние, которое будет восстанавливаться после каждой итерации. Допустим, начальное состояние — массив в обратном порядке. Вот пример метода установки:

```
void IterationSetup()
{
    for (int i = 0; i < list.Count; i++)
        list[i] = list.Count - i;
}
```

Он решает проблему восстановленного состояния, но теперь появляется другая: метод `IterationSetup` нужно вызывать перед каждым вызовом бенчмарка. Это может повлиять на измерения. Обычно мы пишем код примерно так — с итерациями `IterationCount`:

```
var stopwatch = Stopwatch.StartNew();
for (int i = 0; i < IterationCount; i++)
{
    ListSortBenchmark();
}
stopwatch.Stop();
long sum = stopwatch.ElapsedMilliseconds;
long average = sum / IterationCount;
```

Теперь нужно вызывать `IterationSetup()` перед каждой итерацией. Мы можем записать это следующим образом:

```
var stopwatch = Stopwatch.StartNew();
for (int i = 0; i < IterationCount; i++)
{
    IterationSetup(); // Измерения внутри сборки
    ListSortBenchmark();
}
stopwatch.Stop();
long sum = stopwatch.ElapsedMilliseconds;
long average = sum / IterationCount;
```

В этом случае длительность `IterationSetup()` будет включена в `ElapsedMilliseconds` и увеличит среднее время (метод установки может занимать много времени). Лучше исключить из измерений `IterationSetup()`:

```
long sum = 0;
for (int i = 0; i < IterationCount; i++)
{
    IterationSetup(); // Измерения снаружи сборки
    var stopwatch = Stopwatch.StartNew();
    ListSortBenchmark();
    stopwatch.Stop();
    sum += stopwatch.ElapsedMilliseconds;
}
long average = sum / IterationCount;
```

Такой подход может быть хорош для макробенчмарков (если сортируется огромное количество элементов), но в случае микробенчмарков (допустим, `list.Count < 100`) мы можем получить серьезные ошибки из-за перерывов между измерениями по таймеру. В главе 2 говорилось, что микробенчмарки надо запускать много раз, поскольку разрешения таймера `Stopwatch` недостаточно для наносекундных операций: если попытаться измерить длительность одного запроса `ListSortBenchmark`, `ElapsedMilliseconds` выдаст неверное значение. В предыдущем примере цикл увеличивает количество ошибок вместо того, чтобы снизить его! Более того, запросы `IterationSetup` между измерениями могут вызвать дополнительные побочные эффекты. Например, если этот метод выделяет память, это может вызвать внезапную сборку мусора в процессе измерений.

В подобных случаях может быть полезно оценить ограничения отдельно. Например, можно написать что-нибудь в таком духе:

```
public void SetupRunCleanup()
{
    Setup();
    Run();
    Cleanup();
}
public void SetupCleanup()
{
    Setup();
    Cleanup();
}
```

Потом можно получить `Duration(Run)` в качестве `Duration(SetupRunCleanup)` — `Duration(SetupCleanup)`. Этот прием не всегда удается (особенно если `Setup` и `Cleanup` требуется память для многих объектов и у них сложные распределения производительности), но в простых случаях обычно срабатывает.

Еще один фактор, способный повлиять на бенчмарк, — кэш процессора. Он воздействует на программу просто: недавно прочитанные данные могут читаться намного быстрее, чем те, которые давно никто не читал. В `ListSortBenchmark` нужно выбрать оптимальную стратегию для состояния кэша процессора. При первой сортировке массива процессор загружает содержимое списка (или его часть, если он большой) в кэш. Следующие итерации будут проходить быстрее, поскольку элементы (или некоторые из них) уже находятся в кэше. Здесь нужно выбрать между холодным и разогретым состояниями. Решение зависит от того, как вы будете применять метод `Sort` в реальном приложении. Если работаете с элементами перед сортировкой, то получаете разогретый список: с бенчмарком все нормально, поскольку он также использует такой список. Если же не трогаете элементы перед сортировкой, в реальности список остается холодным. В этом случае бенчмарк требует аннулирования содержимого кэша и в методе установки (мы обсудим, как это делается, в главе 7).

**Подготовка нескольких начальных состояний заранее.** Если у нас достаточно памяти и количество итераций невелико, можно подготовить несколько копий бенчмарка заранее. Допустим, мы хотим запустить его `IterationCount` раз (это константа) со списками одного размера `ListSize` (также константа). В этом случае можно создать массив списков и заполнить все копии списка одними и теми же данными:

```
private List<int>[] lists = new List<int>[IterationCount];

public void GlobalSetup()
{
    for (int i = 0; i < IterationCount; i++)
    {
        lists[i] = new List<int>(ListSize); // У всех списков одинаковый
                                           // размер и одинаковые элементы
                                           // "в обратном порядке":

        for (int j = 0; j < ListSize; j++)
            lists[i].Add(ListSize - j);
    }
}
```

Затем берем новый список для каждой итерации:

```
public void ListSortBenchmark()
{
    var stopwatch = Stopwatch.StartNew();
    for (int i = 0; i < IterationCount; i++)
```

```
        lists[i].Sort(); // Мы используем lists[i] вместо той же
                        // копии списка
    stopwatch.Stop();
    long sum = stopwatch.ElapsedMilliseconds;
    long average = sum / IterationCount;
}
```

У этого подхода тоже есть свои недостатки. Учитывая то, как создаются списки, такие объекты склонны к тому, чтобы находиться в приблизительной однопоточной памяти. Поэтому всего мусора в кэше процессора недостаточно, чтобы уберечь результаты от скошенности. Более удачный подход для подобного теста — создать все списки и убедиться, что объем используемой ими памяти больше максимального размера всего доступного кэша процессора минимум в десять раз. Затем нужно создать еще один список со случайным равномерным распределением чисел и повторить запуск с ним, чтобы получить индексы. Поскольку вы все время запускаете одну и ту же последовательность, влияние на память сократится до списка индексов (таким образом, результаты бенчмарка меньше зависят от него), в то же время обеспечивая замусоренность кэша равномерного распределения. Мы обсудим эту тему подробнее в главе 8.

**Восстановление состояния внутри бенчмарка.** Мы уже обсуждали похожую проблему в главе 2 (раздел «Неравноценные итерации»), пытаясь измерить метод `List.Add`. У него есть побочный эффект: перед каждым запуском `List.Add` и после него мы получаем разное количество элементов. Когда пропускной способности списка не хватает на лишний элемент, следующий запрос `List.Add` вызовет изменение размера внутреннего массива, что занимает слишком много времени и портит результаты. Если мы хотим написать бенчмарк, который можно повторить, все побочные эффекты необходимо убрать. Одно из возможных решений — измерять пару `List.Add/List.Remove`:

```
public void AddRemoveBenchmark()
{
    List.Add(0);
    List.RemoveAt(list.Count - 1);
}
```

Удачно ли это решение? Ответ зависит от того, чего вы хотите достичь. Рассмотрим несколько возможных целей.

- *Мы хотим узнать длительность `List.Add`.*

На самом деле мы хотим получить информацию о длительности `List.Add` и использовать ее для решения реальной проблемы, например для написания быстрого алгоритма. Решение этой проблемы, а не сама информация и есть наша истинная цель. Это имеет значение, поскольку правильный способ измерения `List.Add` зависит от того, как вы собираетесь его применять.

- *Мы хотим добавить в список много элементов и узнать, сколько времени на это потребуется.*

В этом случае, вероятно, нужно измерить добавление  $N$  элементов, а не одного. Вспомните, не все запросы `Add` одинаковы — некоторые из них могут вызвать изменение размера внутреннего массива. Вы можете изменить начальную пропускную способность, начальное состояние, количество элементов и т. д. Если нужно узнать длительность операции по добавлению  $N$  элементов, нужно измерить ее. Затраты производительности на один запрос `Add` вам не нужны, потому что их нельзя просто умножить на  $N$  (в большинстве случаев), чтобы получить результат.

- *Мы хотим внести несколько правок в реализацию `Add` и проверить, ухудшится или улучшится производительность после этого.*

Любые изменения производительности в методе `Add` повлияют и на производительность пары `Add/Remove`. Будет трудно понять, насколько правки влияют на метод `Add` (количественные изменения), но можно будет увидеть, станет лучше или хуже (качественные изменения). Кроме того, по-прежнему нужно тщательно проверять случаи изменения размера внутреннего массива.

- *Мы собираемся использовать список в качестве стека (при операциях `Push/Pop`) с известной максимальной пропускной способностью и хотим узнать длительность средней операции.*

В этом случае бенчмарк `Add/RemoveAt` является удачным решением, поскольку разницы между `Add` и `RemoveAt` не будет — эти методы нужно измерять совместно.

Как видите, все зависит от цели. Существует много способов применения быстрых операций, таких как `list.Add`, но производительность алгоритма зависит от того, как именно вы его используете. Обычно получить референтную длительность операции нельзя, поскольку она зависит от способа применения. Всегда задавайте себе вопросы: зачем вам информация о производительности метода, как вы будете его использовать?<sup>1</sup> Если вы сначала ответите на них, это поможет разработать хороший бенчмарк и решить, в каком случае нужен тест холодной загрузки, а в каком — разогретый тест (или оба одновременно).

## Асимптотические тесты

Иногда провести все тесты на больших наборах данных невозможно. Но их можно провести на нескольких маленьких наборах и экстраполировать результаты.

Рассмотрим пример. В IntelliJ IDEA существует много инспекций программного кода (как в любом IDE). С точки зрения пользователя инспекция — это логика,

<sup>1</sup> Если возможных способов использования несколько, нужно рассмотреть их все.

показывающая проблемы вашего кода, от ошибок в компиляции и потенциальной утечки памяти до неиспользуемого кода и орфографических ошибок. С точки зрения разработчика инспекция — это алгоритм, который нужно применить к исходному коду. Различные алгоритмы независимы и не влияют друг на друга. Когда IntelliJ IDEA анализирует файл, он применяет к каждому файлу все инспекции. Поскольку их очень много, они должны быть эффективными. Даже одна неоптимальная инспекция может стать причиной проблем с производительностью во всем IDE.

Но как же решить, какая инспекция является неоптимальной? Существует простое правило: сложность правильной инспекции должна быть  $O(N)$ , где  $N$  — длина файла. Если сложность инспекции равна ( $N^2$ ), при обработке больших файлов мы получим проблемы с производительностью.

Поэтому метрика здесь — не время, а сложность вычислений. У этого подхода есть пара важных **преимуществ**.

- **Переносимость.**

Результаты почти никогда не зависят от устройства: мы должны получать одинаковые результаты и на медленных, и на быстрых устройствах.

- **Бенчмарки занимают меньше времени.**

Влияние на производительность инспекций может быть заметно только на объемных файлах. Существуют тысячи инспекций. Ждать, пока мы измерим каждую из них на каждом объемном файле из данных теста, очень долго. Асимптотический подход позволяет получить достоверные результаты за меньшее количество времени. Мы можем применить инспекцию к нескольким небольшим файлам, измерить длительность анализа и вычислить асимптотическую сложность. Таким образом можно проверить, достаточно ли быстро работает инспекция, не используя больших файлов.

Есть у этого подхода и два важных **недостатка**.

- **Много итераций.**

Регрессионную модель нельзя построить за одну-две итерации. Если мы хотим создать достоверную модель, выдающую правильные результаты, придется провести много итераций.

- **Сложная реализация.**

Построить хорошую регрессионную модель нелегко. Если вам повезет, функция производительности окажется полиномиальной. Если нет, ее нельзя будет аппроксимировать с помощью аналитической функции. Даже если тип функции известен и вам нужно только найти коэффициент, построить такую модель с небольшой погрешностью не всегда просто.

Таким образом, асимптотический анализ не является палочкой-выручалочкой для всех видов бенчмарков, но он может быть очень полезен, когда нужны измерения для большого количества данных ввода, а ждать долго не хочется.

## Тесты длительности и выработки

Существует много способов измерить один и тот же код. Итоговые выводы зависят от вопроса, на который мы хотим ответить, и от применяемых метрик. Допустим, мы обрабатываем запросы, неважно, какие и как. Рассмотрим пару вопросов (и соответствующих метрик), которые можно использовать в этой ситуации.

- **А:** «Сколько времени ( $T$ ) нужно для обработки  $N$  результатов?»

Метрикой здесь является *длительность* обработки  $N$  запросов (временной интервал между началом и окончанием обработки).

- **В:** «Сколько запросов ( $N$ ) мы можем обработать за фиксированный отрезок времени  $T$ ?»

Здесь метрикой является *выработка*. Такой случай называется также *планированием пропускной способности* или *анализом масштабируемости*.

Эти метрики могут показаться слишком абстрактными. Взглянем на образцы кода, измеряющего каждую из них. Полная инфраструктура измерений может быть очень большой. Мы рассмотрим только небольшие и простые бенчмарки, чтобы проиллюстрировать сказанное.

- **А.** В первом случае фиксировано  $N$ . Поэтому нужно провести  $N$  итераций и измерить время между началом и окончанием:

```
// Длительность
var stopwatch = Stopwatch.StartNew();
for (int i = 0; i < N; i++)
    ProcessRequest();
stopwatch.Stop();
var result = stopwatch.ElapsedMilliseconds;
```

- **В.** Во втором случае фиксировано  $T$ . Мы не знаем, сколько запросов сможем обработать, поэтому будем делать это, пока не закончится время. В реальности это обычно сложный многопоточный код, но мы можем написать и очень простой однопоточный бенчмарк:

```
// Выработка
var stopwatch = Stopwatch.StartNew();
int N = 0;
while (stopwatch.ElapsedMilliseconds < T) {
    N++;
    ProcessRequest();
}
var result = N;
```

Если есть линейная зависимость между  $N$  и  $T$ , разницы между подходами нет. Однако она может быть огромной, если зависимость нелинейная.

Допустим, мы знаем точную формулу для  $T(N)$ :

$$T(N) = C \log_2(N),$$

где  $C$  — константа. Начальным значением  $C$  было 2, но после рефакторизации им стало 4. Вы видите значения  $T$  для обоих случаев и разных  $N$  (32, 64, 128, 256, 512, 1024) в табл. 5.1.

**Таблица 5.1.** Зависимость  $T = C \log_2(N)$  для  $C = 2$  и  $C = 4$

$N$	$\log_2(N)$	$T_{C=2}$	$T_{C=4}$
32	5	10	20
64	6	12	24
128	7	14	28
256	8	16	32
512	9	18	36
1024	10	20	40

Представьте, что руководитель спрашивает вас о спаде производительности: «Насколько медленнее все сейчас работает?» Затем представьте, что он — не очень хороший руководитель и не желает ничего слышать о нелинейных зависимостях и логарифмах<sup>1</sup>. Вам нужно дать ответ в виде одного числа.

Вычислим его для обоих случаев.

- **А** — проверим, сколько времени  $T$  занимает обработка  $N = 1024$  запросов. При  $C = 2$  получится  $T = 20$  с. При  $C = 4$  будет  $T = 40$  с. Спад производительности равен  $40 / 20$  с, то есть она уменьшилась в 2 раза.
- **В** — проверим, сколько запросов  $N$  можно обработать за  $T = 20$  с. При  $C = 2$  получится  $N = 1024$ . При  $C = 4$  будет  $N = 32$ . Спад производительности равен  $1024 / 32$ , то есть она уменьшилась в 32 раза.

Так каков же ответ: медленнее в 2 или 32 раза? В общем, одного правильного ответа не существует. Если нужно описать ситуацию в общем, следует предоставить в качестве ответа модель — в нашем случае  $T = C \log_2(N)$ . Если хотите описать конкретный случай, четко определите его.

<sup>1</sup> Конечно, не все руководители так себя ведут. Многие из них — прекрасные люди с отличными профессиональными навыками, глубоко вовлеченные в процесс разработки. К сожалению, наш гипотетический руководитель не таков.

Обычно целевая метрика зависит от ваших бизнес-целей. Если бизнес-цель — обработать  $N = 1024$  запроса как можно быстрее, нужно использовать метод длительности (А). Если бизнес-цель — обработать максимально много запросов за  $T = 20$  с, требуется применить метод выработки (В). Если у вас другие цели, нужно разработать набор соответствующих им бенчмарков или тестов производительности. Это означает, что вы измеряете нужный случай и берете правильный набор метрик.

Если посмотреть на табл. 5.1, можно подумать, что планирование пропускной способности (метод выработки) близко к асимптотическому анализу. Это не всегда верно. Асимптотический анализ требует нескольких измерений для построения модели производительности. Планирование пропускной способности может быть реализовано с помощью одного измерения. Однако можно использовать асимптотический анализ для планирования пропускной способности: знание значений  $T$  для  $N = 32 \dots 1024$  позволяет предвидеть  $T$  для больших значений  $N$ , например 2048, 4096, 8192 и т. д., не выполняя реальных измерений.

## Модульные и интеграционные тесты

Некоторые боятся тестирования производительности, потому что оно выглядит слишком запутанным: нужно много заниматься подготовкой (особенно для тестов холодной загрузки/разогретого состояния/предельной нагрузки), выбрать правильные метрики производительности, возможно, выполнить сложные вычисления, особенно при асимптотическом анализе, и т. д. У меня для них хорошие новости: если у вас есть обычные интеграционные тесты, их можно использовать в качестве тестов производительности! Существует много классификаций тестов. В книге будет употребляться термин «интеграционные тесты» для всех немодульных тестов: функциональных, сквозных, тестов отдельных элементов, приемочных тестов, тестов API и т. д. Основным свойством подобных тестов, важным для тестирования производительности, является длительность: интеграционные тесты обычно работают гораздо дольше, чем мгновенные модульные тесты. На самом деле вы можете использовать любой из своих тестов (даже обычный модульный), который занимает значительное количество времени (допустим, больше 10 мс). Если тест занимает несколько микросекунд или наносекунд, его нельзя применять в чистом виде, поскольку естественные погрешности слишком велики. Нужно превратить подобные тесты в настоящие бенчмарки. Если тест занимает более 10 мс (или даже несколько секунд или минут, так даже лучше), мы можем попытаться использовать его в качестве теста производительности без дополнительных изменений.

Это может показаться странным, поскольку в ходе этих тестов мы не контролируем точность, не производим много итераций, не вычисляем статистику и не делаем ничего, что обычно выполняем при бенчмаркинге. Эти тесты *были разработаны*, чтобы проверить правильность вашей программы, а не производительность. Кажется, что сырая длительность модульных и интеграционных тестов не может использоваться при анализе производительности.

А вот мне кажется странным иметь столько данных о производительности и не применять их. Да, погрешность большая, точность низкая, результаты нестабильные, все ужасно. Но это не означает, что нельзя *попытаться* их использовать. Каждая итерация тестов производительности влечет за собой затраты, поскольку потребляет ресурсы непрерывной интеграции и увеличивает время ожидания. С практической точки зрения хороший набор тестов производительности всегда является компромиссом между точностью и общим временем. Модульные и интеграционные тесты все равно будут проводиться, поскольку надо будет проверить правильность бизнес-логики. Мы все равно получим длительность этих тестов без лишних хлопот. Это тоже данные о производительности. Более того, эти данные мы получаем *без затрат*. Если каким-то образом возможно добыть полезную информацию из этих данных, мы определенно должны это сделать!

Несколько слов о терминологии, использованной в оставшейся части этого раздела. Мы больше не можем говорить «тест производительности», потому что теперь все тесты считаются таковыми. В этом контексте введем несколько дополнительных терминов (они не являются официальными, но какое-то время мы будем их применять).

- **Явные тесты производительности.**

Эти тесты были разработаны для оценки производительности. Явные тесты могут требовать специальных аппаратных средств и сложной логики исполнения с прогревом, большим количеством итераций, вычислением метрик и т. д. Результатом такого теста является вывод о производительности, например: «тест работает в два раза медленнее, чем раньше» или «дисперсия слишком высока».

- **Неявные тесты производительности.**

Это обычные тесты, разработанные для проверки логики. У каждого запуска подобных тестов есть своя длительность и свое значение производительности, которое мы получаем в качестве побочного эффекта. Результатом такого теста является вывод о правильности — статус «зеленый» для правильной логики и «красный» для неправильной. Название «неявные тесты производительности» означает, что эти тесты разработаны не как тесты производительности, но мы можем их использовать в этом качестве.

- **Смешанные тесты производительности.**

Следующая мысль может показаться очевидной и не будет обсуждаться подробно, тем не менее я должен акцентировать: можно проверять логику и производительность одновременно. Например, мы можем написать длинный интеграционный тест предельной загрузки, охватывающий самые важные в плане производительности фрагменты кода. Подобный тест может проверять, все ли работает корректно даже при высокой загрузке (в таких ситуациях может возникнуть состояние гонки), а также нет ли спада производительности.

Теперь мы знаем, что можем использовать как явные тесты производительности (разработанные для измерения производительности), так и неявные (разработанные для других целей, но пригодные для измерения производительности). Однако между ними существует огромная разница. Сравним неявные и явные тесты производительности по нескольким факторам.

- **Долговременный агент непрерывной интеграции.**

При измерении производительности правильным будет запускать тесты каждый раз на одном и том же оборудовании. Очень сложно, а иногда и невозможно оценивать влияние изменений на производительность при сравнении данных «до» с одним агентом с данными «после» — с другого. Всегда лучше иметь постоянный агент непрерывной интеграции (или набор агентов) для явных тестов производительности. Это не обязательно, но настоятельно рекомендуется. В случае неявных тестов производительности это не требуется<sup>1</sup>, они должны корректно работать на любом агенте.

- **Виртуализация.**

Виртуализация — прекрасное изобретение, помогающее организовать гибкую облачную инфраструктуру. Однако виртуальное окружение губительно для точности явных тестов производительности. Невозможно узнать, кто еще запускает бенчмарки на том же оборудовании в то же самое время. Явные тесты производительности обычно требуют выделенного реального, а не виртуального агента. Неявные тесты производительности должны правильно работать в любом окружении<sup>2</sup>.

---

<sup>1</sup> Конечно, во всем существуют исключения. Неявные тесты производительности могут требовать конкретного окружения, например конкретной операционной системы, конкретного объема памяти, конкретного привода (HDD или SSD) или даже конкретной модели процессора. С помощью подобных тестов мы можем проверить множество утверждений, например: «Программа не должна зависнуть, если у нас всего 2 Гбайт RAM» или «Если процессор не поддерживает SSE 4.1, нужно задействовать старый медленный алгоритм вместо быстрого алгоритма по умолчанию, использующего современные инструкции для процессора».

<sup>2</sup> Это не всегда верно. Например, существует много платных программ с пробным периодом. Это означает, что сначала можно пользоваться ею бесплатно (допустим, 30 дней). После этого, если вы хотите продолжить с ней работать, нужно заплатить. Конечно же, умные мошенники находят обходной путь: устанавливают программу на виртуальном устройстве, используют ее 30 дней и создают новое виртуальное устройство с новым пробным периодом. Разработчики часто пытаются защитить свои программы от таких злоупотреблений. Очевидным решением является запрет на применение программы на виртуальных устройствах. Поэтому им нужно ввести метод, проверяющий, является ли окружение виртуальным, и написать тесты для этого метода. Единственный способ проверки данной логики — запускать эти тесты в разных виртуальных окружениях или вне их.

- **Количество итераций.**

Большинство явных тестов производительности требует нескольких итераций. Вспомните, что производительность метода — это не число, а распределение. Мы не можем оценить погрешности и построить доверительный интервал после одной итерации. А без погрешностей и дисперсии не можем сравнить две проверки. Конечно, иногда тест может быть слишком затратным (занимать слишком много времени), поэтому вы не можете позволить себе запускать его несколько раз. Неявные тесты производительности обычно требуют только одной итерации<sup>1</sup>.

- **Легкость в написании.**

Неявные тесты производительности писать легко<sup>2</sup>. Я имею в виду, что любой метод, каким-то образом вызывающий ваш код, может стать тестом. У разных команд разные стандарты кода, но большинство из них сходятся во мнении, что исходный код должен весь проверяться тестами. Некоторые хорошие методики разработки включают в себя написание тестов (например, перед тем как написать исправление ошибки, нужно создать «красный» тест для нее и с помощью исправления добиться, чтобы он «позеленел»). Обычно вы получаете тесты в качестве артефакта процесса разработки. Вы пишете тесты, поскольку они упростят вашу жизнь в будущем и придадут вам уверенности в качестве кода. Большинство модульных тестов однозначны: они могут быть только «красными» или «зелеными». Более того, когда тест «зеленый», это обычно очевидно. Создавая метод `Mu1(x, y)`, который должен перемножать два числа, вы знаете ожидаемый результат. `Mu1(2, 3)` должен выдавать 6. Не 5 и не 7, существует лишь один правильный ответ — 6. Когда мы пишем явные тесты производительности и создаем уведомления, это всегда запутанно. Например, вчера `Mu1` занимал 18 нс, а сегодня 19 нс. Это регресс или нет? Как это проверить? Сколько итераций нужно? Как оценивать ошибки? И самый главный вопрос: тест «зеленый» или «красный»? Если у вас есть четкие ответы на все вопросы

<sup>1</sup> Это тоже неверно. Простой пример: в тесте появилось состояние гонки, которое приводит к его падению в 1 % случаев. Если мы запустим тест всего один раз, он может пройти успешно. На сервере непрерывной интеграции такой тест будет капризным, потому что может менять свой статус с «зеленого» на «красный» без каких-либо причин или изменений. Простое решение: запустить подобный тест (с потенциальным состоянием гонки) 100 раз. Если он капризный, после 100 итераций он с большой вероятностью упадет.

<sup>2</sup> Признаюсь, в этом разделе много примечаний, в которых я пытался вас обмануть. Я просто хотел показать, что исключения существуют всегда. Однако не собираюсь объяснять все исключения для каждого случая, поскольку их слишком много. В этой книге я стремлюсь показать только общие идеи, принципы и подходы. Писать о тестировании производительности сложно, потому что для каждого примера есть много контрпримеров. На одну ситуацию, в которой какой-либо факт работает хорошо, приходится сотни ситуаций, в которых тот же факт не работает. Если вы видите предложение, с которым не согласны, представьте, что к нему есть примечание с дополнительными разъяснениями.

об уведомлениях, спросите об этом же коллег по команде. Вы уверены, что у них та же точка зрения? Писать тесты производительности так сложно, потому что здесь нет четких правил. Вам нужно выбрать собственные уведомления, которые будут удовлетворять вашей цели в области производительности. Это сложно, поскольку не существует абсолютно «зеленого» статуса или одного правильного метода написания уведомлений. Есть только компромиссы.

- **Время исполнения.**

Кстати, о компромиссах: самый интересный из них — между точностью и временем исполнения. Тесты производительности не были бы так занятны, если бы у нас было неограниченное количество времени. Я бы хотел иметь возможность проводить миллиарды итераций каждого из моих бенчмарков или тестов производительности. К сожалению, этот мир жесток и таких возможностей у нас нет. Существует естественный верхний предел полного времени исполнения набора тестов. Он может равняться 10 с, 10 мин, 2 ч или 2 дням — это зависит от вашего рабочего процесса. Но в любом случае предел есть. Нельзя потратить несколько месяцев или лет на запуск одного набора тестов. Было бы прекрасно, если бы можно было запустить все тесты производительности за несколько часов. Если общее время ограничено, а тестов слишком много, вы можете позволить себе очень небольшое количество итераций, может быть, 100, или 10, или всего одну. Порой приходится довольствоваться одной этой итерацией. Неявные тесты производительности должны быть максимально быстрыми, обычно им незачем повторять одно и то же много раз. В случае явных тестов производительности каждая дополнительная итерация может увеличить точность. Конечно же, существуют желаемый уровень точности и рекомендуемое количество итераций. Обычно нет смысла платить за дополнительные итерации временем исполнения после этого момента.

- **Дисперсия и погрешности.**

Поскольку явные тесты производительности разработаны для получения достоверных результатов производительности, мы готовы на все, чтобы их стабилизировать: используем реальное выделенное оборудование, запускаем много раз и вычисляем статистику. В случае неявных тестов производительности нам обычно неважны дисперсия и погрешности: мы можем запускать их на виртуальном устройстве, или каждый раз выбирать новый агент непрерывной интеграции, или всегда запускать только один раз и т. д. Дисперсия и погрешности обычно очень велики.

Имеет ли смысл анализировать производительность обычных тестов, то есть неявных тестов производительности, если она так нестабильна? Общий ответ: это зависит от разных факторов. Более конкретный ответ: невозможно узнать, если не попробуешь. В разделе «Аномалии производительности» далее в этой главе мы обсудим разные подходы, которые с легкостью можно применять к неявным тестам производительности. При работе с огромной базой кода невозможно по-

крыть все методы с помощью явных тестов: не хватит времени и ресурсов. Однако, если кто-то сделал простую ошибку (большинство ошибок просты) и получил огромный регресс производительности (в большинстве случаев регресс из-за простых ошибок огромен), вы сможете легко обнаружить ее с помощью обычных модульных и интеграционных тестов, используя их в качестве неявных тестов производительности.

## Мониторинг и телеметрия

В этом подразделе поговорим о двух дополнительных и интересных техниках анализа производительности.

- **Мониторинг** — это типичное решение для веб-серверов: мы можем наблюдать за индикатором деятельности сервера с помощью специальных инструментов, например Zabbix ([www.zabbix.com/](http://www.zabbix.com/)) или Nagios ([www.nagios.org/](http://www.nagios.org/)).
- **Телеметрия** — это широко распространенная в разработке ПО<sup>1</sup> технология, позволяющая собирать информацию об использовании пользовательских приложений. Такие данные обычно анонимны и не включают в себя никакой личной информации. Однако они могут содержать важные сведения о производительности различных операций. Обычный мониторинг прекрасно подходит для веб-сервисов, а телеметрия — основной инструмент для мониторинга приложений для Рабочего стола (может быть полезна и для клиентской стороны веб-сервисов). Существует специальный API для телеметрии от Microsoft (<https://docs.microsoft.com/en-us/azure/application-insights/app-insights-windows-desktop>), но мы можем создать и собственный набор инструментальных средств.

Например, Mozilla Firefox (<https://wiki.mozilla.org/Performance/Telemetry>) собирает данные об использовании памяти и длительности операций.

Конечно, телеметрия может включать в себя только общие данные об использовании без какой-либо статистики по производительности. Например, .NET Core CLI Tools с помощью телеметрии (<https://docs.microsoft.com/en-us/dotnet/core/tools/telemetry>) собирает информацию о применении .NET Core SDK<sup>2</sup>. Полученные наборы данных открыты и доступны для всех, но в них нет никакой информации о производительности.

Строго говоря, мониторинг и телеметрия не являются видами бенчмарков или тестов производительности. В списке требований к бенчмаркингу из главы 1 первое

<sup>1</sup> Телеметрия использовалась с XIX века в разных сферах, включая метеорологию, нефтегазовую промышленность, автогонки, транспорт, сельское хозяйство и т. д. Интересные примеры можно найти в «Википедии»: <https://en.wikipedia.org/wiki/Telemetry>.

<sup>2</sup> Эта функция включена по умолчанию, но ее можно отключить с помощью переменной окружения `DOTNET_CLI_TELEMETRY_OPTOUT`.

и одно из важнейших — это повторяемость. Об этом забудьте! Каждую секунду у вас будет новая ситуация, внешний мир постоянно меняется. Для таких данных трудно писать уведомления, но существует несколько полезных методов.

- **Распространенные тенденции.**

Точный анализ провести сложно, но можно отследить распространенные тенденции. Например, сравнить статистические данные (среднее арифметическое,  $p_{90}$ ,  $p_{99}$  и т. д.) длительности загрузки веб-страницы на прошлой неделе (с предыдущей версией вашего веб-сервиса) и на текущей (с обновленной версией веб-сервиса). Если видите статистически значимую разницу, нужно начинать исследование производительности.

- **Пороги.**

Если у вас высокие требования к длительности некоторых операций, можно ввести пороговые значения и отправлять данные телеметрии в случае их превышения. Представьте, что вы разрабатываете приложение для Рабочего стола и хотите, чтобы загрузка оставалась быстрой. Допустим, 1 с на современных устройствах (можете собрать информацию и о них) — верхний предел. Конечно, у пользователя в то же время могут быть запущены какие-то сложные процессы, поэтому, допустим, порог — 2 с. Если время загрузки более 2 с, отправляется уведомление телеметрии. Вероятно, вы начнете получать несколько таких уведомлений ежедневно, потому что контролировать пользовательское окружение невозможно. Однако, если после публикации новой версии начнут приходить десятки или сотни уведомлений, нужно начинать расследование этой проблемы.

- **Мониторинг вручную.**

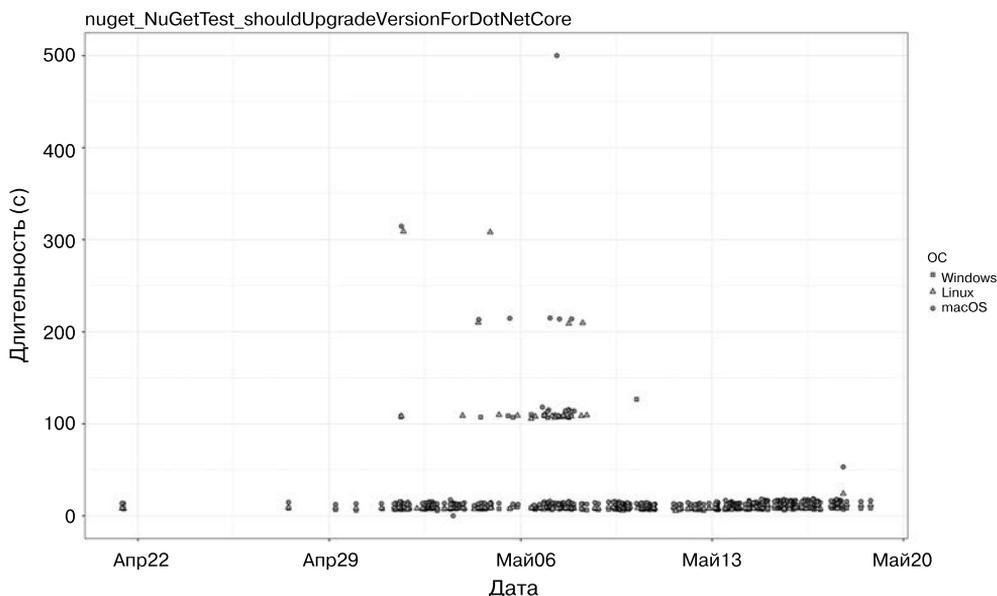
Трудно предсказать все, что может пойти не так. Автоматизировать анализ графика производительности и написать систему, автоматически уведомляющую обо всех подозрительных моментах, еще труднее. Аномалии производительности мы обсудим позже в этой главе. Таким образом, распространенной практикой является то, что особый человек или группа людей исследуют графики производительности. Популярные сервисы требуют мониторинга 24 часа 7 дней в неделю: в случае возникновения любых проблем (не только с производительностью, но и с доступностью и бизнес-логикой) реакция должна быть моментальной. К сожалению, автоматизировать этот процесс почти невозможно. Но для облегчения жизни можно использовать информационные панели и системы оповещений.

## Тесты с внешними взаимозависимостями

Иногда мы получаем сильно воздействующий на производительность сценарий, в котором использовано что-то из внешнего мира. Он влияет на итоговое распределение производительности. К сожалению, внешний мир мы контролировать не можем. Рассмотрим пару примеров.

● **Внешние сервисы.**

В Rider есть тесты, проверяющие такие функции NuGet, как установка, удаление или восстановление. Логика этого теста проста: мы просто проверяем, возможно ли корректно проводить эти операции в решениях разного масштаба. Большая часть тестов использует локальное хранилище NuGet, но некоторые из них задействуют серверы nuget.org и myget.org. Основной целью этих тестов является проверка правильности логики, но их можно применять и как тесты производительности. На рис. 5.2 приведен типичный график производительности для одного из наших тестов NuGet. Двадцать второго марта 2018 года сайт nuget.org не работал (см. [Kofman, 2018]). Шестнадцатого апреля 2018 года сайт api.nuget.org попал в России в черный список (<https://github.com/NuGet/NuGetGallery/issues/5806>). Шестого мая 2018 года в NuGet Gallery были серьезные проблемы с поисковым API (см. [Akinshin, 2018]). Мы узнали об этих инцидентах мгновенно, поскольку постоянно наблюдаем за графиками производительности. С одной стороны, использовать подобные тесты для настоящего тестирования на предмет ухудшения производительности сложно: мы получим ложноположительные результаты (тест производительности «красный», но изменений в базе кода нет). С другой — все эти проблемы связаны с поведением, которое видят пользователи продукта. И о них неплохо узнавать как можно скорее.



**Рис. 5.2.** График производительности теста NuGet в Rider

● **Внешние устройства.**

Много лет назад я занимался одним интересным проектом. Мы с коллегами работали над программой, которая связывается с OWEN TRM 138

([www.owen.ru/uploads/re\\_trm138.pdf](http://www.owen.ru/uploads/re_trm138.pdf)). Это прибор для промышленных измерений с восемью каналами, измеряющий разные характеристики, например температуру, силу тока и напряжение. Если присоединить его к восьми разным точкам детали устройства и измерить в них температуру, программа может экстраполировать данные и построить 2D-карту температурной поверхности. Все работает в реальном времени: если пользователь меняет какие-то точки соединения, карта моментально вычисляет все заново. Визуализация в режиме реального времени была очень важной функцией, поэтому мы проверяли временные интервалы между изменениями в экспериментальной установке и новой визуализацией. И к сожалению, иногда сталкивались с непредсказуемыми задержками: OWEN TRM 138 выдавал данные на несколько секунд позже. То есть было почти невозможно произвести достоверные измерения производительности, поскольку задержки были *непредсказуемы*. В итоге мы перестали измерять весь цикл и начали заниматься отдельными стадиями: сбором данных, экстраполяцией, созданием картинки и т. д. Это решило проблему, поскольку измерения стадий, независимых от оборотов, были довольно стабильными.

Общий совет: если какой-то фактор внешнего мира влияет на производительность и ситуацию нельзя контролировать, попробуйте его изолировать. Увидеть всю картину и получить распределение производительности целых операций (мониторинга или телеметрии) все равно полезно, но на их основе нельзя создать надежных тестов производительности. Для таких стадий нужно измерять те стадии теста, которые вы можете контролировать (не взаимодействующие с внешним миром).

## Другие виды тестов производительности

Существует огромное количество подходов, которые можно использовать для написания тестов производительности. В этом разделе вы найдете лишь обзор возможных техник, мы не будем подробно рассматривать их. Однако существует еще несколько видов стоящих упоминания тестов производительности: тесты предельной загрузки, тесты пользовательского интерфейса и случайные тесты.

- **Тесты предельной загрузки.**

Всегда нужно знать ограничения вашего ПО. Обычно полезно проверить их с помощью тестов производительности. Говоря о тестах предельной загрузки, мы обычно имеем в виду интеграционные тесты. Такое тестирование особенно полезно для веб-сервисов, поддерживающих огромное количество пользователей одновременно. Типичной ошибкой при бенчмаркинге серверных приложений является сосредоточенность только на состоянии без загрузки (мы отправляем на сервер один запрос и измеряем время ответа). В реальности много пользователей отправляют запросы одновременно. Самое интересное — то, что способ обработки этих запросов сервером зависит от их объема. К счастью, существуют программы для автоматизации этого процесса, например JMeter, Yandex.Tank, Pandora, LoadRunner, Gatling.

- **Тесты пользовательского интерфейса.**

Создавать корректную инфраструктуру для тестов пользовательского интерфейса не всегда просто, поскольку ее обычно нельзя запустить в «безголовом» режиме. Для них нужно графическое окружение. Например, в базе кода IntelliJ IDEA существуют тесты пользовательского интерфейса, проверяющие, отвечает ли интерфейс IDE. В процессе непрерывной интеграции эти тесты запущены на выделенных агентах, соединенных с физическими 4К-мониторами.

Существует также много библиотек и платформ, которые могут помочь вам автоматизировать тестирование интерфейса продукта (например, Selenium).

- **Нечеткие тесты.**

Мы уже знаем, что пространство производительности запутанно и длительность метода может зависеть от множества факторов. Допустим, у нас есть алгоритм, обрабатывающий список целых чисел и производящий вычисления. Мы создали более быструю версию этого алгоритма и теперь хотим подтвердить, что она действительно работает быстрее. Как их сравнить? Разумеется, мы можем создать референтный набор списков и измерить оба алгоритма на каждом списке из этого набора. Даже если новый алгоритм покажет прекрасные результаты на всех этих заранее сгенерированных списках, мы не можем быть уверены в том, что он в любом случае будет быстрее изначального алгоритма. А вдруг существует крайний случай, который может испортить производительность новой версии? К сожалению, мы не можем пронумеровать все возможные списки целых чисел и проверить каждый. В подобных случаях можно попробовать технику фаззинга (нечеткого тестирования). Ее суть проста: нужно генерировать случайные списки, пока не найдем вводные данные, которые создадут проблемы.

Очень упрощенная версия может выглядеть следующим образом:

```
for (int i = 0; i < N; i++)
{
    var list = GenerateRandomList();
    var statistics = RunBenchmark(NewAlgorithm, list);
    if (HasPerformanceProblem(statistics))
        ReportAboutProblem(list);
}
```

*Фаззинг* — полезный метод, используемый в разных областях разработки ПО. Его можно применять даже для поиска ошибок в RyuJIT (подробности см. в [Wargen, 2018]). Если мы можем найти ошибки в компиляторе JIT, не замеченные разработчиками и прошедшие все модульные тесты, то определенно можем попробовать это и в бенчмаркинге.

Вот еще одна ситуация: пользователь жалуется на проблемы с производительностью, вы знаете, что они, скорее всего, связаны с конкретными значениями параметров, но не знаете точных значений, вызвавших проблемы, а получить информацию о настройках пользователя невозможно. Если вы не можете перепроверить все возможные настройки, попробуйте найти их с помощью фаззинга.

Он также может стать частью процесса непрерывной интеграции: можно генерировать новые данные ввода каждый раз и проверять, не появятся ли феномены в области производительности.

Однако у фаззинга есть один серьезный недостаток. Он не соответствует одному из главных требований бенчмаркинга — требованию повторяемости. Нечеткие бенчмарки представляют собой отдельный вид, имеющий одну цель: найти нежелательные результаты. Однако каждый запуск нечеткого бенчмарка нужно делать повторяемым с помощью сохранения данных ввода или случайного начального числа, используемого для генерирования данных.

## Подводя итог

Существует много видов бенчмарков и тестов производительности. В этом разделе мы обсудили лишь некоторые из них. Если честно, все *виды* тестов производительности нельзя считать именно *видами*. Это скорее *концепции, идеи* или *подходы*, которые можно сочетать в любом порядке. Например, можно использовать асимптотический анализ для *планирования пропускной способности* веб-сервера в *разогретом состоянии* при *повышенной загрузке*. Конечно же, вы не обязаны применять все описанные категории тестов к каждому продукту, можно выбрать лишь некоторые из них или придумать собственные виды тестов производительности, необходимые при ваших проблемах. Главное правило довольно простое: разрабатывайте тесты, отвечающие вашим бизнес-целям и требующие разумного количества времени. Если вы пишете бенчмарки или тесты производительности, то должны четко понимать, какие проблемы хотите решить. Обычно поиск проблемы занимает больше половины времени, потраченного на поиск решения. Основываясь на этом понимании, вы можете выбрать лучшие техники или их сочетания, подходящие для конкретной ситуации.

## Аномалии производительности

Простыми словами, аномалия производительности — это ситуация, в которой пространство производительности выглядит странно. Что это означает? Можете выбрать собственное определение. Это ситуация, когда вы смотрите на график производительности и говорите: «Он выглядит необычно и подозрительно. Кажется, с ним что-то не так. Нужно исследовать эту проблему и понять, почему получился такой график».

Аномалия — это не проблема, которую необходимо исправить. Это характеристика пространства производительности, о которой вам следует знать. Все аномалии можно разделить на две группы: **временные** и **пространственные**. Временная аномалия предполагает, что у вас есть история (набор поправок или операций

подтверждения), которую вы анализируете. Например, вы можете найти проблему, появившуюся после недавних изменений исходного кода. Пространственную аномалию можно выявить за один обзор. Например, она может быть основана на разнице между окружениями или странном распределении производительности одного теста.

В этом разделе обсуждаются самые распространенные аномалии производительности:

- **ухудшение** — раньше что-то работало быстро, а теперь медленно;
- **ускорение** — раньше что-то работало медленно, а теперь быстро;
- **временная кластеризация** — что-то вдруг изменилось в нескольких тестах одновременно;
- **пространственная кластеризация** — показатели производительности зависят от одного параметра в окружении теста;
- **повышенная длительность** — тест занимает слишком много времени;
- **повышенная дисперсия** — разница между последовательными измерениями без каких-либо изменений слишком высока;
- **повышенное количество выбросов** — в распределении слишком много очень высоких значений;
- **мультимодальные распределения** — у распределения несколько мод;
- **ложные аномалии** — ситуация, когда пространство производительности выглядит странно, но волноваться на самом деле не о чем.

В каждом подразделе, в котором рассматривается аномалия, есть небольшой пример с таблицей, иллюстрирующей проблему. После этого подробно обсуждается сама аномалия, а также то, почему так важно ее обнаружить. В некоторых подразделах есть краткая классификация видов аномалии.

В двух последних подразделах мы обсудим проблемы, которые можно решить с помощью поиска аномалий, и я дам рекомендации по поводу того, что делать с аномалиями производительности.

Начнем с одной из самых известных аномалий — ухудшения производительности.

## Ухудшение

**Ухудшение производительности** — это ситуация, в которой тест работает медленнее, чем обычно. Это **временная** аномалия, поскольку ухудшение можно обнаружить с помощью сравнения результатов нескольких проверок.

*Пример.* В табл. 5.2 проиллюстрирована история производительности одного теста. Сравните показатели до и после 20 мая.

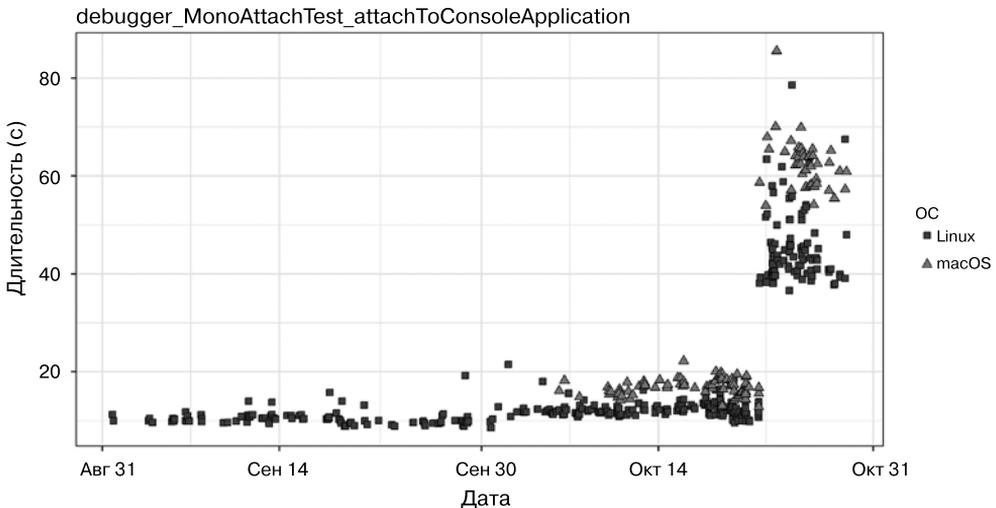
**Таблица 5.2.** Пример ухудшения

День	17 мая	18 мая	19 мая	20 мая	21 мая	22 мая
Время	504 мс	520 мс	513 мс	2437 мс	2542 мс	2496 мс

Ухудшение производительности — одна из самых распространенных аномалий. Когда говорят о тестировании производительности, одной из типичных целей является предотвращение ухудшения производительности. Иногда это единственная цель (до того как люди начинают исследовать пространство производительности и обнаруживают интересные вещи).

Есть два основных вида ухудшения производительности:

- **обрыв** — ситуация, когда наблюдается статистически значимый спад производительности после операции подтверждения (рис. 5.3);



**Рис. 5.3.** Аномалии производительности: обрыв

- **уклон** — появление серии небольших ухудшений производительности (рис. 5.4). Каждое из них сложно обнаружить, но вы можете наблюдать спад производительности, если просмотрите историю за какой-либо период. Например, производительность в данный момент может оказаться в два раза хуже, чем

месяц назад, но вы не можете указать на операцию подтверждения, которая все нарушила, потому что произошло слишком много таких операций с небольшим влиянием на производительность.

Конечно, не всегда просто сказать, какой у вас тип ухудшения — обрыв, уклон или что-то среднее и есть ли ухудшение вообще. Однако разница между обрывом и уклоном важна, поскольку она влияет на то, когда и как вы сможете обнаружить ухудшение: обрыв можно найти на конкретной операции подтверждения (даже перед слиянием), а уклон — при ретроспективном анализе.

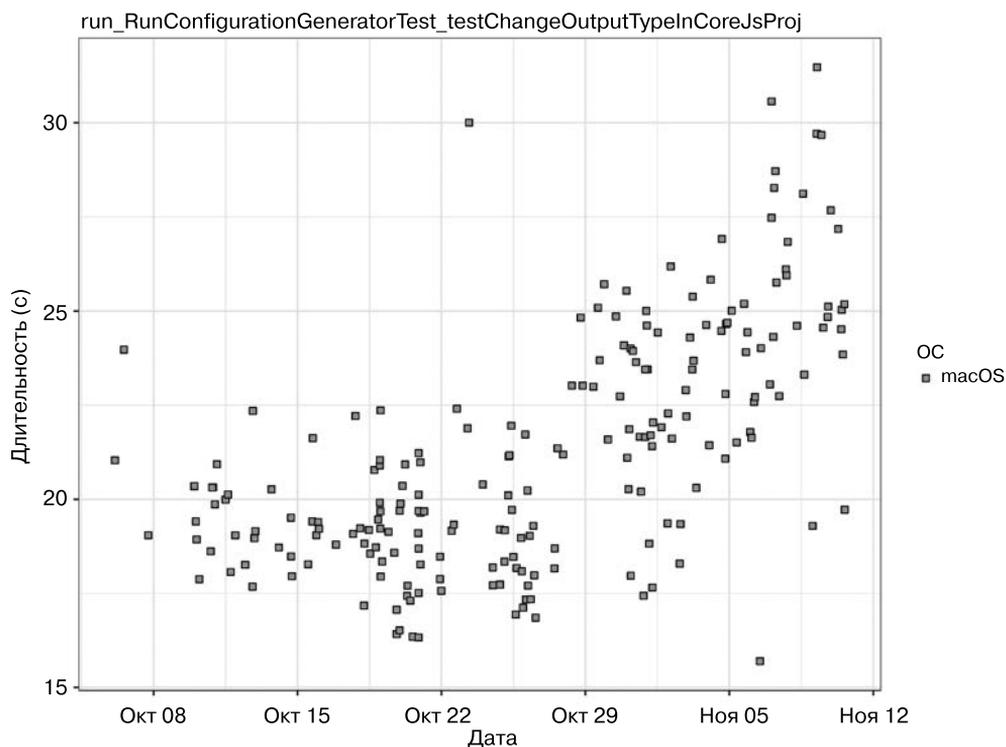


Рис. 5.4. Аномалия производительности: уклон

## Ускорение

**Ускорение производительности** — это ситуация, в которой тест работает быстрее, чем раньше. Это **временная** аномалия, поскольку ускорение можно обнаружить при сравнении результатов нескольких проверок.

*Пример.* В табл. 5.3 приведена история производительности одного теста. Сравните показатели до и после 8 апреля.

**Таблица 5.3.** Пример ускорения

День	5 апреля	6 апреля	7 апреля	8 апреля	9 апреля	10 апреля
Время	954 мс	981 мс	941 мс	1 мс	2 мс	1 мс

Очень важно различать ожидаемое и неожиданное ускорения.

- **Ожидаемое ускорение** — полезная аномалия. Например, вы создали оптимизацию, подтвердили ее и видите, что многие тесты работают гораздо быстрее, чем прежде. Волноваться не о чем! Однако все равно имеет смысл отследить подобные аномалии по следующим причинам.
  - *Отслеживание эффекта от оптимизации.* Даже если вы уверены в том, что оптимизация работает, проверить это все равно не помешает. Разумеется, сначала нужно провести локальные проверки, но лучше иметь несколько стадий подтверждения — это снижает риск того, что какая-нибудь проблема окажется незамеченной. Также вы получите более качественный обзор улучшенных функций.
  - *Повышение морального духа команды.* Отслеживание подобного ускорения может быть полезно для поддержания морального духа вашей команды. Реализовав новую функцию, вы сразу видите результат работы. Но когда вы постоянно исправляете проблемы с производительностью, отсутствие обратной связи может сказываться удручающе<sup>1</sup>. Люди должны видеть положительный эффект от своей работы. Один график производительности со значительными улучшениями может сильно обрадовать разработчика.
- **Неожиданное ускорение** — это всегда подозрительно. Можно встретить много разработчиков, которые скажут что-то наподобие: «Я ничего не менял, но теперь ПО работает быстрее. Ура!» К сожалению, неожиданное ускорение часто означает наличие ошибки. Я часто наблюдал, как разработчик *случайно* выключил какую-нибудь функцию и получил улучшение производительности. Подобные ситуации могут незамеченными пройти все тесты, но графики производительности их выявят! Исследование неожиданных ускорений не улучшит производительность, но может помочь найти какие-то ошибки.

## Временная кластеризация

**Временная кластеризация** — это ситуация, в которой у нескольких тестов одновременно наблюдаются значительные изменения в производительности. Это **временная** аномалия, поскольку ее можно обнаружить, сравнив несколько результатов проверок.

<sup>1</sup> Если что-то работает медленно, пользователи постоянно на это жалуются. Но обычно, если что-то работает довольно быстро, никто вам об этом не скажет.

*Пример.* В табл. 5.4 показана история производительности трех тестов. Сравните результаты за октябрь и ноябрь у Test1 и Test2.

**Таблица 5.4.** Пример временной кластеризации

День	29 октября	30 октября	31 октября	1 ноября	2 ноября
<b>Test1</b>	1,4 с	1,3 с	1,4 с	<b>2,9 с</b>	<b>2,8 с</b>
<b>Test2</b>	4,3 с	4,2 с	4,4 с	<b>8,8 с</b>	<b>8,7 с</b>
<b>Test3</b>	5,4 с	5,3 с	5,4 с	5,4 с	5,3 с

Одной из целей тестирования производительности является автоматизация. Простое сообщение «где-то здесь проблема» — это хорошо, но недостаточно. Нужно представить все данные, которые могут помочь расследовать проблему быстро и просто.

Один из способов сделать это — мониторинг изменений, разбитых на группы. Если после изменения появляется 100 тестов с проблемами, это не значит, что нужно создать 100 ошибок в программе для мониторинга ошибок и исследовать их все по отдельности. Скорее всего, у вас появилось несколько проблем (или даже всего одна), влияющих на много тестов. Поэтому нужно найти группы тестов, скорее всего столкнувшихся с одной и той же проблемой.

Обсудим несколько возможных типов групп.

- **Ухудшение набора.**

В большинстве проектов есть иерархия тестов. Можно иметь несколько проектов внутри одного решения, несколько классов тестов внутри одного проекта, несколько тестов методов внутри одного класса и несколько наборов параметров для ввода в одном методе. При поиске ухудшения производительности или других аномалий стоит попробовать выделить наборы тестов<sup>1</sup> с одинаковыми проблемами.

Рассмотрим пример, проиллюстрированный в табл. 5.5. Здесь два набора, А и В, в каждом из них по три теста. До и после каких-то изменений мы провели измерения. Для всех тестов получились разные значения измерений, но некоторые из них можно объяснить естественным шумом. Вы можете заметить, что дельта производительности в наборе В незначительна — около 1 % (обычные колебания для обычных модульных тестов). В то же время в тестах из набора А наблюдается значительное увеличение времени — около 10–18 %. Тот факт, что ухудшилась производительность всех тестов набора одновременно, заставляет предполагать, что со всем набором одна и та же проблема.

<sup>1</sup> У разных разработчиков разные определения термина «набор». В контексте проекта или команды у вас может быть четкое определение. Например, вы можете сказать, что набор — это класс тестов, маркированный атрибутом TestFixture в проекте NUnit. В этой книге мы используем более высокий уровень абстракции и говорим, что набор — это группа тестов, находящихся на одном месте в иерархии тестов. Например, набор может быть группой тестов в одном проекте или одним тестом с разными комплектами параметров для ввода (кейсами).

Таблица 5.5. Пример ухудшения набора

Набор	Тест	Время (до), мс	Время (после), мс	Дельта, мс
A	A1	731	834	103
	A2	527	623	96
	A3	812	907	95
B	B1	345	349	4
	B2	972	966	-6
	B3	654	657	3

- **Парное ухудшение/ускорение.**

Это еще одна очень распространенная проблема. В наборе часто есть какая-то логика инициализации. Это может быть явная загрузка или неявная ленивая инициализация. В этом случае тест может работать медленно не из-за своего кода, а из-за того, что он включает в себя логику инициализации. Посмотрим на пример в табл. 5.6. Как видите, до изменения все тесты методов занимают около 100 мс, кроме Foo, продолжительность которого 543 мс. После изменения Foo длится 104 мс (ускорение), Bar — 560 мс (ухудшение), другие тесты не потерпели статистически значимых изменений. В подобных случаях можно предположить, что поменялся порядок тестов: до изменений Foo был первым в наборе, после изменений первым стал Bar. Это не всегда верно, но гипотезу следует проверить. Почему это может быть важно? Логика инициализации всегда следует убирать из тестов в отдельный метод. Это не только полезно, но и важно с точки зрения производительности. Большое отклонение от начального состояния может скрывать реальные проблемы с производительностью в тестах. Давайте выполним вычисления с округленными значениями из примера. Если тест занимает 100 мс, а загрузка — 400 мс, вместе это составляет 500 мс. Ухудшение на 30 мс — это 30 % от времени теста (значительное изменение) и всего 6 % от общего времени, что можно проигнорировать из-за высокого

Таблица 5.6. Пример ухудшения набора

Тест	Время (до), мс	Время (после), мс	Дельта, мс
Foo	543	104	-439
Bar	108	560	452
Baz	94	101	7
Qux	103	105	2
Quux	102	99	-3
Quuz	98	96	-2

уровня погрешностей. Если в одном из тестов прописана логика установки, это не ошибка, но это просчет разработчиков. От него лучше избавиться (если это возможно).

- **Связанные между собой изменения во временном ряду.**

Если вы можете обнаружить корреляцию между двумя временными рядами в своих тестах, будет интересно проверить, всегда ли она существовала. В табл. 5.7 приведен пример измерений времени ожидания и выработки. Время ожидания — просто длительность операций, выработка — количество запросов в секунду (RPS). Мы запускаем эти тесты на разных агентах с разными аппаратными средствами, поэтому тут нельзя применить обычный анализ ухудшения. Однако можем заметить закономерность:

$$\text{выработка} \approx 2 \text{ с} / \text{время ожидания.}$$

Например, если время ожидания 0,1 с, мы получаем:

$$\text{выработка} = 2 \text{ с} / 0,1 \text{ с} = 20.$$

Эту закономерность можно объяснить распараллеливанием: на каждом агенте есть по два потока, обрабатывающих запросы. Подобная закономерность наблюдается на всех агентах, за исключением Agent4. Поэтому можно предположить, что там что-то не так с распараллеливанием. Конечно, эту проблему можно обнаружить и иначе. Однако анализ корреляции помог сформулировать гипотезу, которую мы будем исследовать в дальнейшем (что-то не так с *временем ожидания/выработкой*), и получить важную дополнительную информацию (эта проблема наблюдается только на Agent4). Все это может сберечь много рабочего времени исследователей, поскольку все подобные подозрительные закономерности можно собрать автоматически. Еще один пример анализа можно найти в [AnomalyIo, 2017].

**Таблица 5.7.** Пример связанных между собой изменений во временном ряду

День	Агент	Время ожидания, мс	Выработка, RPS
12 января	Agent1	100	20,12
13 января		105	19,01
14 января	Agent2	210	9,48
15 января		220	8,98
16 января	Agent3	154	12,89
17 января		162	12,41
18 января	Agent4	<b>205</b>	<b>4,95</b>
19 января		<b>209</b>	<b>5,02</b>

## Пространственная кластеризация

**Пространственная кластеризация** — это ситуация, в которой производительность некоторых тестов заметно зависит от каких-либо параметров теста или окружения. Это **пространственная** аномалия, поскольку ее можно обнаружить с помощью одной проверки.

*Пример.* В табл. 5.8 приведена средняя длительность трех тестов в зависимости от операционной системы. Сравните длительность Test1 и Test2 в Windows и Linux/macOS.

**Таблица 5.8.** Пример пространственной кластеризации

Операционная система	Test1, с	Test2, с	Test3, с
Windows	5,2	9,3	1,2
Linux	0,4	0,6	1,4
macOS	0,4	0,7	1,2

Иногда довольно заметно, что производительность теста зависит от каких-либо характеристик окружения. В других случаях это не так очевидно. Более того, некоторые внешние факторы могут неожиданно влиять на производительность только конкретных тестов. Если вы проверяете свой продукт на разных устройствах с разным окружением, хорошо бы при этом проверить разницу между результатами измерений производительности одного и того же теста в разном окружении.

Рассмотрим пример. Одна и та же версия ReSharper должна работать в разных версиях Visual Studio (VS). Например, ReSharper 2017.3 должен работать в VS 2010, VS 2012, VS 2013, VS 2015 и VS 2017. У команды ReSharper есть набор интеграционных тестов, выполняющихся во всех версиях Visual Studio. Нередко какие-то изменения снижают производительность только в конкретной версии Visual Studio. Более того, если работать только с помощью одной проверки (не рассматривая историю производительности), можно обнаружить, что некоторые тесты работают быстро в VS 2010, VS 2012, VS 2013 и VS 2015 и медленно — в VS 2017. Искать и пытаться исследовать такие ситуации довольно полезно.

Еще один пример связан с Rider. Rider должен быстро работать во всех поддерживаемых операционных системах. Он использует .NET Framework для Windows и Mono для Linux/macOS. У большинства тестов наблюдается одна и та же длительность в разных операционных системах, но некоторые показывают большие отклонения. На рис. 5.5 показаны результаты измерений производительности для шаблона NET Core ASP.NET MVC (создать решение по заготовке, восстановить пакеты NuGet, собрать его, провести анализ и т. д.). Как можно увидеть на рисунке, эти тесты быстрее работают в Windows, чем в Linux и macOS. Также здесь высокая дисперсия, но это мы обсудим в следующем подразделе. Аномалия кластеризации может быть применена к одной проверке вместо нескольких. Она не показывает

проблем, появившихся при недавних изменениях, но может показать, какие проблемы существуют в данный момент (и могли появиться давно).

В главе 4 мы обсудили проблему сравнения нескольких распределений. Она становится очень серьезной, когда мы говорим о кластеризации. Чем больше параметров мы рассматриваем, тем больше вероятность того, что мы наткнемся на псевдокластеризацию. Если включить в набор слишком много параметров (а включить можно все, от значения `GCPrGroup` и свободного места на диске до времени суток<sup>1</sup> и фазы Луны<sup>2</sup>), вы определенно обнаружите параметр, якобы влияющий на производительность. В этом случае можно попытаться применить популярный метод векторного квантования из кластеризации методом *k*-средних (примеры см. в [AnomalyIo, 2015]) к нейронным моделям и машинному обучению (некоторые из методов кластеризации были освещены в главе 4).

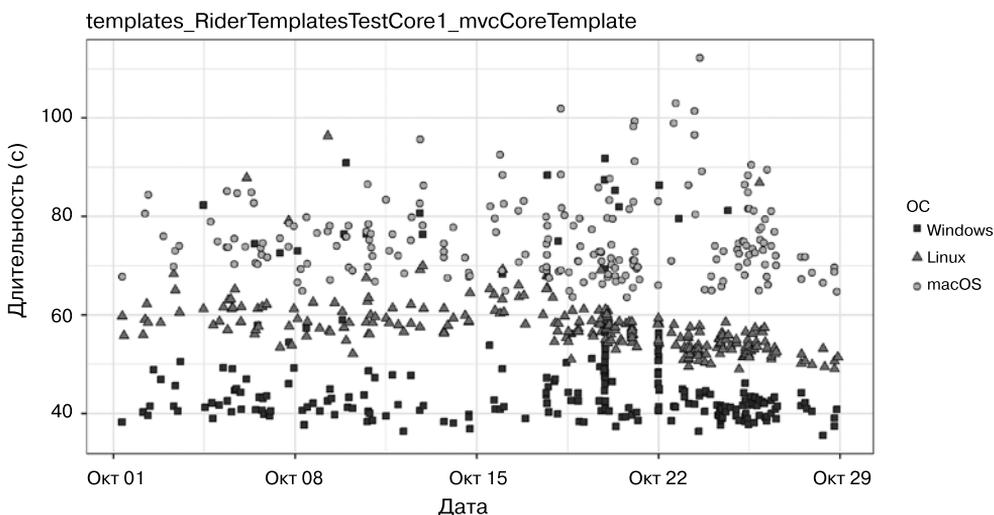


Рис. 5.5. Аномалия производительности: пространственная кластеризация

## Высокая длительность

**Высокая длительность** — это ситуация, когда некоторые тесты занимают слишком много времени. Слишком много может быть как в относительном (гораздо больше, чем большинство тестов), так и в абсолютном плане (секунды, минуты или даже

<sup>1</sup> Время суток может быть очень важным параметром при отслеживании производительности популярного веб-сервиса.

<sup>2</sup> В программистском фольклоре фаза Луны является последним разумным объяснением аномалии, когда все остальные правдоподобные гипотезы уже отброшены.

часы). Обычно это **пространственная** аномалия, поскольку мы ищем самый медленный тест за одну проверку.

*Пример.* В табл. 5.9 приведены примеры из списка пяти самых медленных тестов. Сравните первый и пятый тесты.

**Таблица 5.9.** Примеры высокой длительности

Место	Тест	Время, с
1	Test472	18,54
2	Test917	16,83
3	Test124	5,62
4	Test952	0,42
5	Test293	0,19

Прежде всего попытайтесь ответить на следующие вопросы.

- Какова максимально приемлемая длительность одного теста?
- Какова максимально приемлемая длительность всего набора тестов?
- Проверьте длительность тестов вашего проекта. Какова типичная длительность всего набора тестов? Найдите самый медленный тест (или группу таких тестов). Можно ли протестировать то же самое за меньшее время?

Если вы можете запустить все свои тесты быстро, это всегда превосходно. Если мы говорим об обычных модульных тестах, типичной является ситуация, когда тысячи тестов длятся всего несколько секунд. Но с интеграционными тестами и тестами производительности дело обстоит хуже. Иногда они могут занимать несколько минут и даже часов.

Если вы собираетесь ускорить набор тестов, это не означает, что нужно применять какие-то безумные оптимизации. Есть много примеров, когда общая длительность выполнения набора тестов была значительно уменьшена с помощью небольшого изменения. В [Kondratyuk, 2017] один разработчик сменил localhost на 127.0.0.1 и тем ускорил набор тестов в 18 раз. В [Songkick, 2012] длительность выполнения набора тестов уменьшили с 15 ч до 15 с при помощи серии различных улучшений. В [Bragg, 2017] время выполнения набора тестов было сокращено с 24 ч до 20 с.

Если длительность всего набора тестов является вашей болевой точкой и влияет на процесс разработки, вот пара классических техник для ее минимизации.

- **Запускайте тесты параллельно, если это возможно.**

Если вам важно только общее время сборки, нужно попытаться запускать тесты параллельно. Будьте осторожны: в этом случае вы не получите достоверных

результатов производительности. Запускать произвольные тесты параллельно не всегда возможно, поскольку они могут работать с одним и тем же статическим классом или с одними и теми же ресурсами, например файлами на диске.

- **Заменяйте интеграционные тесты модульными, если это возможно.**

Если у вас есть готовая платформа для интеграционных тестов, обычно гораздо проще написать интеграционный тест вместо модульного. Модульные тесты требуют усилий: нужно корректно изолировать часть системы, симулировать другие части, сгенерировать смоделированные данные и т. д. Обычно в интеграционных тестах этого не требуется — вся система с реальными данными готова к проверкам. Однако, если вы хотите проверить только одну функцию, рекомендованным способом является модульный тест. Если запустить модульные тесты перед интеграционными, увеличенное количество проверок функций с помощью дополнительных модульных тестов может улучшить и время сборки: если модульные тесты упали, фазу интеграционных тестов можно пропустить.

## Высокая дисперсия

**Высокая дисперсия** — это ситуация, когда у некоторых тестов слишком большая дисперсия. Слишком большая — относительно других тестов (намного больше, чем у большинства), относительно среднего арифметического (например, среднее арифметическое — 50 с, дисперсия — 40 с) или абсолютно (в секундах, минутах или даже часах). Это может быть как **временная** (если вы анализируете историю производительности), так и **пространственная** аномалия (если анализируете несколько итераций в процессе одной проверки).

*Пример.* В табл. 5.10 приведена длительность нескольких вызовов одного и того же теста при одной и той же проверке (никаких изменений не вносилось). Найдите минимальное и максимальное значения.

**Таблица 5.10.** Пример высокой дисперсии

Индекс вызова	Время, с
1	2,34
2	54,73
3	5,15
4	186,94
5	25,70
6	92,52
7	144,41

Еще один пример из набора тестов IntelliJ IDEA представлен на рис. 5.6. Это тест предельной загрузки с большим количеством потоков. Он занимает 100–1000 с для Linux/Windows и 1000–4000 с для macOS.

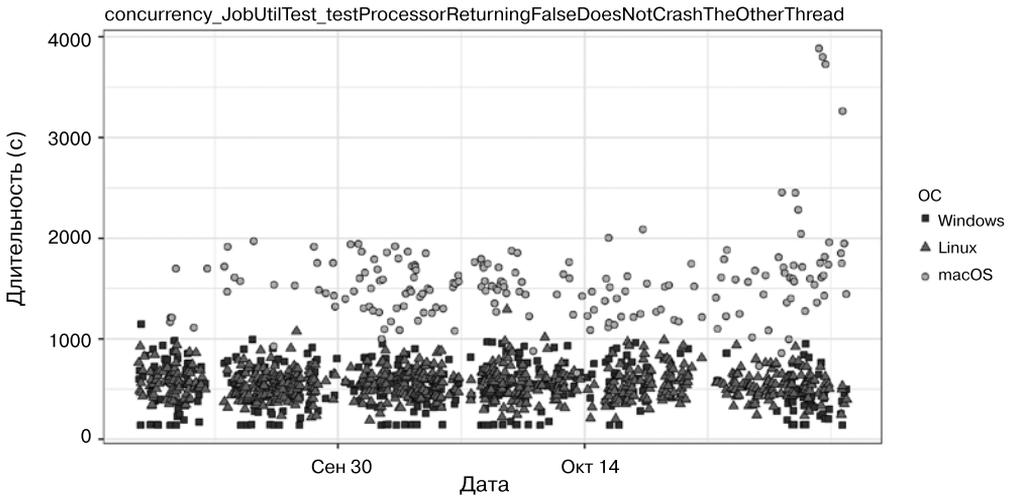


Рис. 5.6. Аномалия производительности: дисперсия

## Высокие выбросы

**Высокие выбросы** — это ситуация, когда значения выбросов слишком велики (намного больше среднего арифметического) или значений выбросов слишком много (например, значительно больше, чем раньше). Это может быть как **временная** (если вы анализируете историю производительности), так и **пространственная** аномалия (если анализируете несколько итераций теста в процессе одной проверки).

*Пример.* В табл. 5.11 указана длительность нескольких вызовов одного и того же теста при одной и той же проверке (никаких изменений не вносилось). Найдите выброс.

Это нормально, если появляется несколько выбросов. Однако есть *ожидаемые* и *неожиданные* выбросы. Если быть точным, может существовать ожидаемое число выбросов. Например, производя много операций ввода-вывода, вы определенно получите выбросы, но их количество при одной и той же конфигурации будет постоянным. При разных конфигурациях число ожидаемых выбросов может меняться. При считывании данных с диска, скорее всего, вы получите разные распределения для Windows + HDD и Linux + SSD. Но для фиксированной конфигурации обычно их количество постоянно (например, 10–15 выбросов на 1000 итераций).

Таблица 5.11. Пример высоких выбросов

Индекс вызова	Время, мс
1	100
2	105
3	103
4	<b>1048</b>
5	102
6	97

Проверка количества выбросов — полезный прием для обнаружения дополнительных подозрительных изменений. Их наличие — это нормально, но вы всегда должны понимать, почему выбросы появились.

С выбросами могут быть связаны несколько проблем. Вот две из них.

- **Выбросов слишком много.**

Иногда при внесении изменений (например, при изменении API для считывания данных с диска) случайно увеличивается количество выбросов (например, до 40–50 вместо 10–15). В этом случае увеличивается и стандартное отклонение, поэтому у вас есть дополнительный способ обнаружения проблемы.

- **Чрезвычайно высокие выбросы.**

Выбросы всегда больше среднего арифметического значения. Обычно, если разница между максимальным выбросом и средним арифметическим очень большая (например, среднее арифметическое — 300 мс, максимум — 2600 мс) — это нормально. Но иногда эти значения необычайно велики (например, среднее арифметическое — 300 мс, максимум — 650 000 мс). Такая ситуация может быть признаком серьезной ошибки, способной навредить вашим пользователям.

## Мультимодальные распределения

**Мультимодальное распределение** — это распределение, у которого несколько мод (мы уже рассматривали эту тему в главе 4). Это может быть как **временная** (если вы анализируете историю производительности), так и **пространственная** аномалия (если анализируете несколько итераций теста в процессе одной проверки).

*Пример.* В табл. 5.12 приведена длительность нескольких вызовов одного и того же теста. Как видите, общее время около 100 или 500 мс.

Таблица 5.12. Пример мультимодального распределения

Индекс вызова	Время, мс
1	101
2	502
3	504
4	105
5	103
6	510
7	114

Обычно при запуске простых смоделированных бенчмарков таких ситуаций не наблюдается. Однако в реальных измерениях производительности они довольно широко распространены. Например, на рис. 5.7 можно увидеть результаты измерений `OutputLineSplitterTest_testFlushing` из набора тестов IntelliJ IDEA. Этот тест обычно длится до 10 с. Его название, в котором есть сочетание `testFlushing` — тест сброса, помогает предположить, что сброс результатов производится лишь в некоторых случаях, а не каждый раз. Это не всегда ошибка. Может быть, так задумано. Однако очень важно определять такие ситуации заранее, потому что в случае мультимодального распределения мы не можем использовать среднее значение (около 5 с для `testFlushing`). Мы уже обсуждали мультимодальные распределения и способы их определения в главе 4.

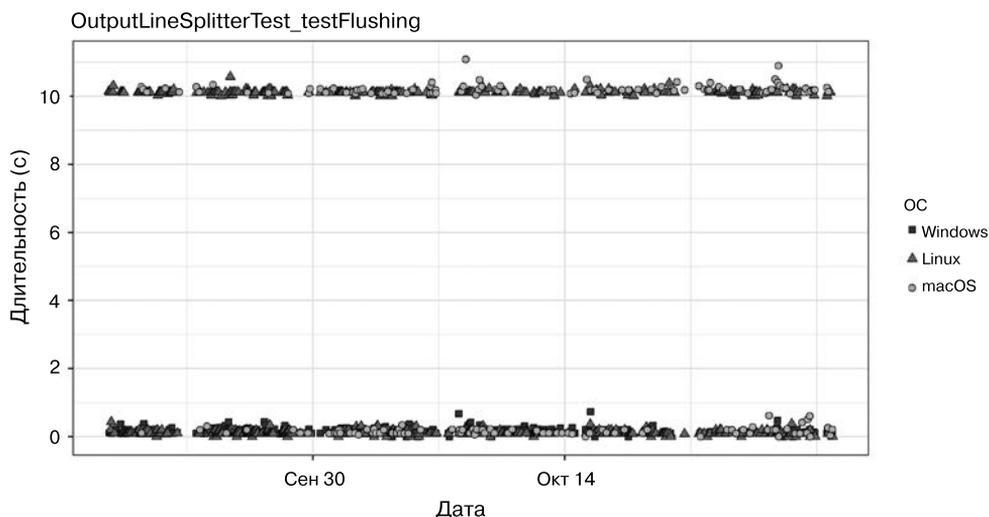


Рис. 5.7. Аномалия производительности: бимодальное распределение

## Ложные аномалии

**Ложная аномалия** — это ситуация, похожая на аномалию, но не связанная ни с какими проблемами. Ложная аномалия может быть как **временной** (если анализировать историю производительности), так и **пространственной** (если анализировать только результаты одной проверки).

*Пример.* Допустим, у нас есть тест, занимающий 100 мс:

```
public void MyTest() // 100 мс
{
    DoIt();           // 100 мс
}
```

Мы решили добавить объемные уведомления (200 мс), проверяющие, все ли в порядке:

```
public void MyTest() // 300 мс
{
    DoIt();           // 100 мс
    HeavyAsserts();  // 200 мс
}
```

На графике производительности мы увидим нечто похожее на ухудшение производительности (со 100 до 300 мс), но с производительностью нет никаких проблем. Это ожидаемое изменение длительности теста. Если у вас недавно появилась аномалия, полезно проверить сначала изменения в исходном коде. Изменения, найденные в теле теста в начале исследования, могут избавить от нескольких часов бессмысленной работы. Можно также сработать на упреждение и договориться с членами команды о том, что каждый, кто намеренно вносит изменения, способные повлиять на производительность, должен их как-то помечать. Например, тест можно снабдить специальным комментарием или атрибутом. Также вы можете создать общее хранилище (базу данных, веб-сервис или даже обычный текстовый файл) со всей информацией о таких изменениях. Неважно, что вы выберете, если все участники команды будут знать, как просмотреть историю намеренных изменений производительности для каждого теста.

Аномалия не всегда означает, что у вас проблема. Они часто появляются по естественным причинам. Если вы постоянно разыскиваете аномалии и исследуете каждую из них, важно знать о ложных аномалиях, не связанных ни с какими проблемами.

Обсудим некоторые распространенные причины появления таких аномалий.

- **Изменения в тестах.**

Это одна из самых распространенных ложных аномалий. Если вы вносите в тест изменения (добавляете или удаляете некоторую логику), очевидно, что

его длительность может измениться. Таким образом, если у вас появляется аномалия, похожая на ухудшение производительности теста, первым делом нужно проверить, не вносились ли в него изменения. Второе, что нужно проверить, — наличие изменений, намеренно ухудшающих производительность (например, можно пожертвовать производительностью ради точности).

- **Изменения порядка тестов.**

Порядок тестов можно изменить в любой момент. На это может быть несколько причин, включая переименование тестов. Это может быть ощутимо, если в первый тест набора включена логика инициализации. Допустим, в наборе пять тестов в следующем порядке (проверка А): Test01, Test02, Test03, Test04, Test05. Платформа для тестирования использует лексикографический порядок выполнения тестов. При проверке В мы переименовываем Test05 в Test00. Благоприятные последствия этого переименования показаны в табл. 5.13. Скорее всего, это пример аномалии спаренного ухудшения/ускорения: теперь вместо Test01 медленным стал Test00. Мы уже обсуждали, что логику инициализации лучше вынести в отдельный метод, но это не всегда возможно. Если мы знаем о подобном эффекте первого теста, но ничего с этим сделать не можем, то все равно получим уведомление об аномалии.

**Таблица 5.13.** Пример изменения порядка тестов

Проверка	Индекс	Название	Время, мс
А	1	<b>Test01</b>	<b>100</b>
	2	Test02	20
	3	Test03	30
	4	Test04	35
	5	<b>Test05</b>	<b>25</b>
В	1	<b>Test00</b>	<b>105</b>
	2	<b>Test01</b>	<b>20</b>
	3	Test02	20
	4	Test03	30
	5	Test04	35

- **Изменения в аппаратных средствах агента непрерывной интеграции.**

Если у вас есть возможность запускать тесты производительности на одном и том же агенте непрерывной интеграции (физическом устройстве) все время, это замечательно. Но этот агент может сломаться, а найти идентичную замену бывает нелегко. На производительность могут повлиять любые перемены

в окружении, от небольшого изменения в номере модели процессора до объема памяти RAM. Сравнить измерения с разных устройств всегда сложно, поскольку реальные изменения непредсказуемы. Если вы хотите применять нанобенчмарки, обычно вам нужен набор идентичных физических агентов непрерывной интеграции.

- **Изменения в ПО агентов непрерывной интеграции.**

Проблемы могут появиться и на том же агенте без замены аппаратных средств. Довольно часто администраторы устанавливают системные обновления. Это могут быть незначительные обновления системы безопасности или значительные обновления ОС (например, от Ubuntu 16.04 к Ubuntu 18.04). Любые изменения в окружении могут повлиять на производительность. Это приводит к тому, что на графике производительности отражается подозрительное ухудшение или ускорение без каких-либо изменений исходного кода.

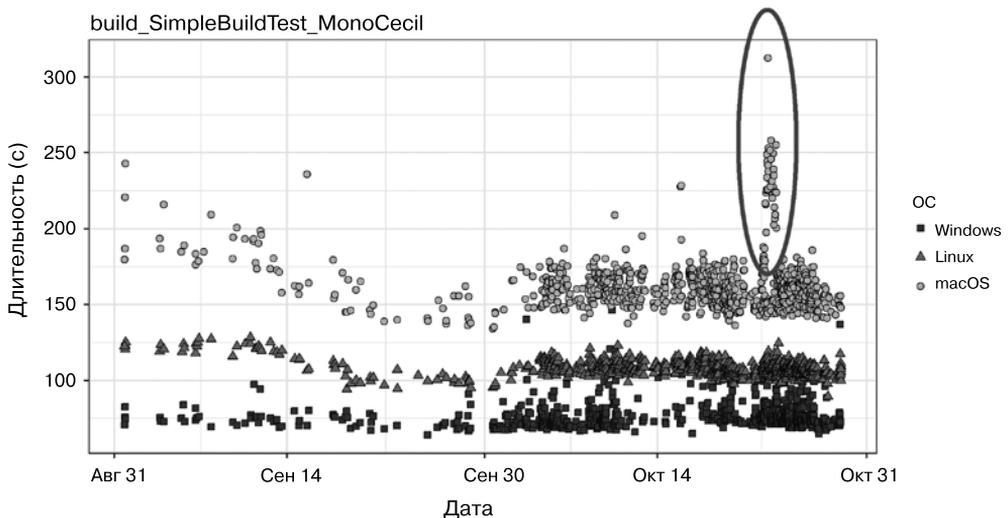
- **Изменения в наборе агентов непрерывной интеграции.**

Только у самых везучих есть возможность запускать тесты на наборе агентов непрерывной интеграции с выделенными идентичными устройствами. Гораздо чаще встречается динамический пул агентов: нельзя предсказать, какое окружение будет использоваться для следующего запуска набора тестов. В таком наборе агентов что-то постоянно меняется: одни устройства выключаются, другие подключаются к работе, некоторые устройства обновляются, часть занята разработчиками, исследующими производительность, и т. д. В такой ситуации повышается дисперсия из-за постоянных скачков между устройствами и возникают аномалии производительности, основанные на изменениях в наборе агентов. На рис. 5.8 показана аномалия производительности в тесте MonoCecil в Rider для агентов из macOS, появившаяся около 20 октября. В исходном коде ничего не поменялось, ухудшение было вызвано плановым обновлением всех агентов из macOS. Процесс обновления потребляет ресурсы процессора и диска и влияет на производительность тестов (это был не специальный тест производительности, а обычный, запущенный на обычных агентах из набора). Как только обновление завершилось, производительность вернулась к нормальному уровню (если можно сказать «нормальный» в отношении теста с такой дисперсией).

- **Изменения во внешнем мире.**

Если у вас есть какие-то внешние зависимости, они могут стать постоянным источником аномалий производительности. К сожалению, избавиться от них не всегда возможно. Когда зависимость становится частью тестируемой логики, она проникает в ваше пространство производительности. Классическим примером подобной зависимости является внешний веб-сервис. Например, вы что-то загружаете из Интернета или тестируете метод идентификации.

У меня была подобная проблема с тестами NuGet Restore в Rider, которые проверяли, можно ли корректно и быстро восстанавливать пакеты. Первая версия тестов использовала `nuget.org` в качестве источника всех пакетов NuGet. К сожалению, эти тесты были очень нестабильны. Раз в день возникала ситуация, когда один из тестов упал из-за медленных ответов `nuget.org`. В следующий раз мы создали зеркало `nuget.org` и разместили его на локальном сервере. После этого у нас почти не было падений, но дисперсия этих тестов все еще была очень велика. При финальной итерации мы использовали локальный источник пакетов (все пакеты были загружены на диск перед запуском набора тестов). Мы получили почти стабильные тесты с низкой дисперсией. Необходимо заметить, что это не простая реструктуризация кода теста. Мы пожертвовали частью логики (загрузка пакетов с удаленного сервера) ради уровня ложной аномалии.



**Рис. 5.8.** Ложная аномалия производительности: проблемы с агентом

### ● Любые другие изменения.

Мир постоянно меняется. Что угодно может произойти в любую минуту. Вы всегда должны быть готовы столкнуться с ложными аномалиями производительности. Специалист по производительности, ответственный за обработку аномалий, должен знать, какие виды ложных аномалий часто встречаются в инфраструктуре этого проекта. Первым делом перед исследованием производительности нужно проверить, не является ли аномалия ложной. Эта простая проверка поможет вам сэкономить время и предотвратить превращение ложной аномалии в ошибку 1-го рода (ложноположительную).

## Скрытые проблемы и рекомендации

Обычно аномалии производительности сообщают нам о различных проблемах проекта. Вот некоторые из них.

- **Ухудшение производительности.**

Это может показаться очевидным, но крупнейшая проблема при данной аномалии и есть ухудшение производительности. Обычно люди начинают тестировать производительность, стремясь предотвратить ухудшения.

- **Скрытые ошибки.**

Пропущенные уведомления являются ошибками в тестах, но похожие ошибки могут существовать и в рабочем коде. Если у теста высокая дисперсия, первое, о чем вы должны подумать: «Почему здесь такая дисперсия?» В большинстве случаев за ней скрывается недетерминированная ошибка. Например, это может быть состояние гонки или взаимная блокировка (с завершением в момент истечения времени, но без уведомления).

- **Медленный процесс сборки.**

Нужно слишком долго ждать, пока все тесты будут переданы на сервер непрерывной интеграции. Это обычное требование, которому должны соответствовать все тесты, после чего станет доступен установщик или развернут веб-сервис. Когда весь набор тестов занимает 30 мин или даже час, это приемлемо. Но если для этого требуется много часов, процесс разработки замедляется.

- **Медленный процесс разработки.**

Если тест стал «красным» и вы пытаетесь исправить ситуацию, нужно запускать его локально снова и снова после каждой попытки исправления. Если тест занимает 1 ч, за стандартный 8-часовой рабочий день у вас будет только восемь попыток. Более того, ждать результата теста сложа руки бессмысленно, поэтому разработчики часто переключаются на решение другой проблемы. Переключение контекста для разработчика всегда неприятно. К тому же большая продолжительность тестов подразумевает высокий уровень погрешности. Если тест занимает 1 ч, погрешность в несколько минут — это нормально. В подобной ситуации сложно выставить строгие уведомления (мы обсудим это позже).

- **Непредсказуемо большая длительность.**

Мы уже обсуждали большую длительность тестов и пришли к выводу: это не очень хорошо. Куда хуже, когда она непредсказуемо большая. Работать с производительностью таких тестов трудно. Если у вас есть ограничения времени (распространенное решение, поскольку тесты могут зависать), тест может быть нестабильным, поскольку его общая длительность *иногда* может превышать ограничение.

- **Трудно установить уведомления.**

Еще раз рассмотрим рис. 5.6. Вы видите график истории производительности теста распараллеливания из набора тестов IntelliJ IDEA. Некоторые из запусков могут занять 100 с (особенно в Windows), а некоторые — 4000 с (особенно в macOS). И те и другие значения можно наблюдать в результатах одной и той же проверки без каких-либо изменений. Представьте, что появляется ухудшение производительности. Как его определить? Даже если производительность ухудшается на 1000 с, это можно упустить, поскольку дисперсия слишком велика.

- **Пропущенные уведомления.**

Я много раз видел тесты с «зеленой» историей производительности, выглядевшие примерно так: 12,6; 15,4; 300; 14,3; 300; 16,1 с... Типичный пример: мы отправили запрос и ждем ответа. Ограничение времени ожидания — 5 мин, но уведомления о том, что ответ получен, нет. Через 5 мин мы просто прекращаем ждать и заканчиваем тест с «зеленым» статусом. Это может показаться глупой ошибкой, но таких ошибок в реальности очень много. Подобные тесты легко обнаружить, если поискать тесты с очень высокими значениями.

- **Неожиданные задержки в работе.**

Сталкивались ли вы когда-нибудь с такой ситуацией: операция, которая обычно производится мгновенно, вдруг заставляет приложение зависнуть на несколько секунд? Подобное всегда раздражает пользователей. Существует много причин такого поведения. Обычно их сложно исправить, потому что у вас нет стабильного воспроизведения. Однако некоторые из них также могут вызвать выбросы на графике производительности. Если у вас систематически появляются выбросы на сервере непрерывной интеграции, можно добавить журнал, найти проблему и исправить ее.

- **«Костыли» в логике теста.**

У вас когда-нибудь были нестабильные тесты с состоянием гонки? Как их лучше всего исправлять? Существует неверный, но популярный способ исправления: введение там и сям `Thread.Sleep`. Обычно это исправляет нестабильность — тест снова становится постоянно «зеленым». Однако исчезают только симптомы проблемы, а не она сама. После одобрения такого исправления становится сложно снова воспроизвести ее. Также сложно найти тесты с такими «умными» исправлениями<sup>1</sup>. К счастью, подобные «костыли» можно разглядеть на графиках производительности невооруженным глазом. Любые запросы `Thread.Sleep` или

---

<sup>1</sup> Конечно, способы найти их существуют. Например, мне нравится выявлять все использования `Thread.Sleep` в нашей базе кода. Если я нахожу такой запрос в тестовой базе, я его удаляю и наблюдаю, что происходит дальше. Обычно некоторые тесты становятся «красными» или нестабильными. После этого пытаюсь исправить обнаруженные ошибки.

другие приемы, предотвращающие состояния гонки или похожие проблемы, невозможно спрятать от хорошего специалиста по производительности.

- **Ложные аномалии.**

Основная проблема ложных аномалий очевидна — вы тратите время на исследование, но не получаете полезного результата.

Существует несколько основных рекомендаций по работе с аномалиями производительности.

- **Систематический мониторинг.**

Это самая важная рекомендация: нужно постоянно следить за аномалиями производительности. Поскольку у реального приложения их может быть сотни, можно использовать панель наблюдения: для каждой аномалии отсортировать все тесты по соответствующей метрике и посмотреть на верхнюю часть списка. Посмотрите на тесты с самой большой длительностью, дисперсией, выбросами, модальными значениями и т. д. Попробуйте понять, откуда взялись эти аномалии. Скрываются ли за ними проблемы? Можно ли эти проблемы исправить? Можете смотреть на панель наблюдения раз в месяц, но полезнее делать это ежедневно: в этом случае можно отследить новые аномалии, как только они появляются.

- **Серьезные аномалии нужно исследовать.**

Если систематически отслеживать аномалии, можно найти много серьезных проблем с кодом. Иногда даже обнаружить проблемы с производительностью, не проверяемые тестами производительности. Также можно выявить проблемы в бизнес-логике, не проверяемые функциональными или модульными тестами. Иногда оказывается, что проблем нет: аномалия может быть ложной или естественной (вызванной естественными факторами, которые невозможно контролировать, например производительностью сети). Если вы не знаете, откуда взялась конкретная аномалия, стоит ее исследовать. Если не можете сделать это сейчас, создайте ошибку в программе для мониторинга ошибок или добавьте эту аномалию в список исследований производительности. Если вы будете игнорировать найденные аномалии, то можете пропустить серьезные проблемы, которые обнаружатся только на стадии производства.

- **Берегитесь высокого уровня ложных аномалий.**

Если увеличивается число ошибок 1-го рода (ложноположительных), системе мониторинга аномалий становится невозможно доверять и она теряет ценность. Лучше пропустить несколько реальных проблем и увеличить количество ошибок 2-го рода (ложноотрицательных), чем перегрузить свою команду ложными сигналами тревоги, которые могут свести на нет все попытки улучшить производительность. При виде аномалии производительности первым делом необходимо проверить наличие естественных причин. Обычно такие проверки

не занимают много времени, но могут застраховать вас от бесполезных исследований. Вот несколько примеров проверок.

- **Проверка на изменения в тесте.** Если кто-то менял исходный код теста, проверьте эти изменения.
  - **Проверка на изменения в порядке тестов.** Просто сравните порядок тестов в текущей и предыдущей проверках.
  - **Проверка истории агентов непрерывной интеграции.** Вы использовали один и тот же агент для текущих и предыдущих результатов? Не вносили ли вы каких-нибудь изменений в программные или аппаратные средства агента?
  - **Проверка типичных источников ложных аномалий.** Если вы все время ищите аномалии производительности, то, вероятно, знаете самые распространенные причины ложных аномалий. Допустим, вы загружаете данные с внешнего сервера с 95 % рабочего времени. Если сервер не работает, вы пытаетесь связаться с ним, пока он снова не начнет работать. Подобное поведение часто может быть источником выбросов без каких-либо изменений. Если вы знаете, что какая-то группа тестов страдает от подобного феномена, первым делом нужно проверить в журнале сообщения о повторных попытках связаться с сервером.
- **Берегитесь привыкания к синдрому тревоги**

Если вы можете отследить все проблемы с производительностью — прекрасно. Но нужно понимать, сколько ошибок может исследовать ваша команда. Если в очереди слишком много аномалий производительности, процесс исследования становится бесконечным и изматывающим. Нельзя все время решать проблемы, связанные с производительностью, нужно ведь и новые функции разрабатывать, и ошибки исправлять.

## Подводя итог

Видов аномалий производительности слишком много для того, чтобы подробно рассказать обо всех в этой книге. Большую их часть можно легко обнаружить с помощью очень простых проверок. Обычно вам не нужны продвинутые техники, поскольку базовые способы проверок на предмет аномалий выявляют бóльшую часть проблем.

В Rider мы обычно рассматриваем только аномалии «высокая дисперсия» и «кластеризация». Первое применение нашего анализатора производительности заняло около 4 ч — это была программа на C#, загружавшая данные с сервера TeamCity с помощью R-скрипта, собиравшего эти данные и рисовавшего график производительности для самых подозрительных тестов. В то время я создал несколько десятков проблем, требующих исследования производительности, для разных

людей. В основном это были реальные проблемы, скрытые за тысячами модульных тестов. И до сегодняшнего дня мы продолжаем находить важные проблемы каждую неделю. Также у нас есть много продвинутых анализаторов, ищущих сложные проблемы с производительностью. Однако основные пункты — «высокая дисперсия» и «кластеризация» — поставляют нам огромные списки проблем, требующих исследования.

Я считаю, что проверять наличие аномалий производительности — нормально при реализации любого большого проекта, требующего тестов производительности. Это помогает находить значительные проблемы вовремя — до того как с ними столкнутся пользователи после следующего обновления ПО. Каждый проект уникален и имеет собственный набор аномалий производительности. Все зависит от вашей предметной области. Много интересных примеров проектов можно найти в Интернете. Рекомендую вам почитать о потоковых аномалиях в распределенных системах (см. [Chua, 2014]), аномалиях в связанных временных рядах (см. [AnomalyIo, 2017]) и других методах анализа аномалий производительности в разных случаях (см. [Ibidunmoye, 2016], [Dimopoulos, 2017], [Peiris, 2014]).

Универсального способа написания анализаторов, идеально работающих в любых проектах, не существует. Знание основных аномалий производительности позволяет проверить историю производительности набора тестов и написать анализаторы, подходящие для вашей программы.

## Стратегии защиты

Существует несколько способов предотвратить или обнаружить ухудшение производительности. В этом разделе обсудим несколько самых распространенных.

Вот список подходов, которые мы затронем.

- **Тесты до подтверждения** — поиск проблем с производительностью до слияния с основной ветвью.
- **Ежедневные тесты** — поиск проблем с производительностью в недавней истории.
- **Ретроспективный анализ** — поиск проблем с производительностью во всей истории.
- **Тестирование контрольных точек** — поиск проблем с производительностью в особые моменты жизненного цикла разработки.
- **Тестирование до релиза** — поиск проблем с производительностью прямо перед релизом.
- **Тестирование вручную** — поиск проблем с производительностью вручную.

- **Телеметрия и мониторинг после релиза** — поиск проблем с производительностью после релиза.

Я называю эти подходы стратегиями защиты от проблем с производительностью, но этот термин малоизвестен, поэтому могут использоваться и другие. Например, Джо Даффи в [Duffy, 2016] называет их кольцами тестов.

Мы рассмотрим следующие характеристики каждого подхода.

- **Время обнаружения** — когда можно обнаружить ухудшение производительности?
- **Длительность анализа** — сколько времени требуется для обнаружения проблемы?
- **Уровень ухудшения** — какое ухудшение можно обнаружить: высокое (50–100 % или больше), среднее (5–10 %) или низкое (менее 1 %)?<sup>1</sup>
- **Процесс** — автоматический, полуавтоматический или вручную? Что в каждом случае должны делать разработчики и как его автоматизировать?

## Тесты перед подтверждением

Этот подход мы используем в JetBrains. Его суть проста: нельзя подтверждать загрузку напрямую в основную ветвь<sup>2</sup>. Вместо этого нужно создать ветвь функции и запустить конфигурацию сборки, которая загрузит ее в основную. Эта конфигурация сборки запускает все тесты и загружает ее, только если все они оказываются «зелеными». Поэтому в основную ветвь не могут попасть стабильно<sup>3</sup> «красные» тесты. Этот механизм может использоваться не только для функциональных тестов, но и для тестов производительности. У этого подхода много вариантов, но суть все та же: автоматически проверять все изменения на наличие ухудшения производительности перед их загрузкой в основную ветвь.

- **Время обнаружения: вовремя.**

Лучшее в этом подходе — его простота: мы автоматически заранее обнаруживаем все ухудшения производительности. Нам не нужно решать новые проблемы с производительностью, потому что их нет (конечно, в теории).

<sup>1</sup> Конечно, это очень приблизительные оценки, просто для примера. Точная оценка зависит от требований вашего бизнеса и пространства производительности. В некоторых случаях 1 % может считаться высоким уровнем ухудшения, а 200 % — низким.

<sup>2</sup> Здесь мы имеем в виду главную ветвь. В вашем хранилище она может называться иначе, например «по умолчанию», «ствол», «релиз», dev или как-то еще.

<sup>3</sup> Это не решает всех проблем. Например, туда могут попасть нестабильные тесты (иногда оказывающиеся «красными»).

- **Длительность анализа: короткий.**

Если мы не ждем длительного времени загрузки изменений, тесты перед подтверждением должны работать быстро. Если типичный запуск набора тестов перед подтверждением занимает не более нескольких часов — прекрасно.

- **Уровень ухудшения: высокий.**

Конечно же, есть и ограничения. У нас нет возможности осуществить несколько итераций, поскольку все тесты нужно провести очень быстро. Поэтому мы можем распознать только сильные ухудшения (например, 50 или 100 %). Распознать небольшие ухудшения (5 или 10 %) почти невозможно. Если попытаться это сделать, увеличится общая длительность или количество ошибок 1-го рода (ложноположительных).

- **Процесс: автоматический.**

Я просто хочу повторить: больше всего в этом способе мне нравится то, что он полностью автоматизирован, то есть не требуются никакие действия человека.

## Ежедневные тесты

К сожалению, мы не можем всегда запускать все тесты для каждого подтверждения или слияния. Причина проста: некоторые из них, особенно интеграционные тесты или сложные тесты производительности, занимают слишком много времени. Распространенное решение в таком случае — ежедневные тесты. Это специальный набор тестов, запускаемых раз в день<sup>1</sup>. Конечно, вы можете выбрать любой период, например запускать ежедневные или даже ежемесячные тесты.

- **Время обнаружения: с опозданием на один день.**

С помощью ежедневных тестов мы обнаруживаем ухудшения производительности, когда они уже загружены в основную ветвь.

- **Длительность анализа: до одного дня.**

У ежедневных тестов нет ограничения в несколько часов на запуск. Мы можем использовать до 24 ч. Если этого недостаточно, можно попробовать еженедельные тесты и тратить до семи дней на один набор тестов.

- **Уровень ухудшения: средний.**

Поскольку у нас много времени, мы можем провести много итераций и обнаружить ухудшения производительности среднего размера, например 5–10 %.

---

<sup>1</sup> Некоторые команды называют их еженочными тестами, поскольку обычно запускают их ночью, когда агенты непрерывной интеграции свободны.

- **Процесс: полуавтоматический.**

Ежедневные тесты должны быть частью процесса непрерывной интеграции. Сервер сборки должен запускать их каждый день автоматически. Однако, если некоторые из них «покраснели», то есть появилось ухудшение производительности, инцидент нужно исследовать вручную. Обычно несколько участников команды все время следят за статусом ежедневных тестов и уведомляют команду, если обнаружена проблема.

## Ретроспективный анализ

Это один из моих любимых методов. Суть его такова: берем все архивные данные по всем тестам и анализируем.

- **Время обнаружения: с опозданием.**

К сожалению, некоторые ухудшения будут выявлены с опозданием, возможно, на неделю или месяц. Однако лучше ваша команда обнаружит подобные случаи через месяц, чем клиенты заметят их через несколько месяцев.

- **Длительность анализа: в зависимости от обстоятельств.**

Ограничений длительности нет, можно потратить сколько угодно времени. Если у нас недостаточно архивных данных, можно даже взять конкретные операции, собрать их и запустить еще несколько раз. В ретроспективном анализе возможно все!

- **Уровень ухудшения: низкий.**

Мы можем обнаружить любые ухудшения производительности, даже меньше 1%! На самом деле основным ограничением является наша готовность выделить на это ресурсы.

- **Процесс: полуавтоматический.**

Ситуация та же, что и с ежедневными тестами: ретроспективный анализ можно запустить автоматически, но все обнаруженные проблемы нужно будет исследовать вручную.

## Тестирование контрольных точек

Иногда вы знаете, что вносите опасные изменения. Так бывает при масштабной реорганизации кода, переписывании алгоритма, влияющего на производительность, или обновлении версии среды исполнения, например Mono или .NET Core. Если вы не уверены в том, что изменения не ухудшили производительность, можете за-

пустить тесты производительности в основной ветви и в своей ветви. После этого сравните результаты. Таким образом, у нас появляется контрольная точка (масштабное изменение, которое надо проверить) и мы хотим снизить риски.

- **Время обнаружения: вовремя.**

Этот метод позволяет предотвратить ухудшение производительности до загрузки в основную ветвь.

- **Длительность анализа: в зависимости от обстоятельств.**

В общем-то, единственным ограничением является срок загрузки в основную ветвь. Мы можем провести сколько угодно тестов, пока не убедимся, что загрузка будет безопасной.

- **Уровень ухудшения: низкий.**

Поскольку времени у нас много, можно проводить огромное количество итераций и найти даже самые небольшие ухудшения.

- **Процесс: почти полностью вручную.**

Проверка опасных изменений — это обязанность разработчика. Автоматизировать ее невозможно. Если вы подозреваете, что в вашей ветви могут появиться проблемы с производительностью, следует запустить тесты вручную. Если проблемы найдутся, необходимо исследовать их вручную. Тут нет никакой автоматизации, кроме запуска тестов и сравнения ветвей.

## Тестирование до релиза

Существует особая контрольная точка — релиз. Ваши клиенты будут недовольны, если после обновления ПО у них появятся проблемы с производительностью. Поэтому каждый релиз необходимо внимательно проверять перед публикацией. В некоторых проектах полный набор тестов может занять несколько дней. В таком случае у вас нет возможности запускать их каждый день или проверять каждую подозрительную ветвь. Но вы можете запускать этот набор один раз для каждой предвыпускной версии, чтобы убедиться, что не пропустили по-настоящему серьезных проблем.

- **Время обнаружения: с большим опозданием.**

Обычно разработчики запускают предвыпускные тесты производительности перед релизом и надеются, что проблем нет, — это просто дополнительная проверка. Однако, если вы обнаружите серьезную проблему с производительностью за несколько дней до релиза, это может быть очень неприятно, особенно если у вас жесткие сроки сдачи проекта.

- **Длительность анализа: в зависимости от обстоятельств.**

Все зависит от вас и от цикла релиза. Сколько времени у вас обычно есть между предвыпускной версией и самим релизом? Одни команды тратят на финальную стадию тестирования всего несколько дней, другие — несколько месяцев. Нужно найти приемлемый компромисс между тем, как быстро вы хотите выпустить продукт и насколько серьезным может быть ухудшение производительности.

- **Уровень ухудшения: в зависимости от обстоятельств.**

Он зависит от длительности анализа. Правило простое: чем больше времени потратите, тем более мелкие случаи ухудшения можно будет найти.

- **Процесс: почти полностью ручную.**

То же самое, что и в случае с обычными контрольными точками. Необходимо ручную запустить тесты перед релизом и так же ручную проверить отчет и исследовать все проблемы.

## Тестирование вручную

Конечно, ваш отдел контроля качества может тестировать ПО вручную. Обычно это не лучший вариант, поскольку требует многих человеко-часов, но он может помочь обнаружить какие-то проблемы с производительностью, не выявленные с помощью других тестов. Найдя новую проблему вручную, стоит написать новые тесты производительности.

- **Время обнаружения: с опозданием.**

Этот подход позволяет проверить изменения, уже загруженные в основную ветвь. Обычно тестирование вручную является частью рабочего процесса: можно проверить ежедневные сборки<sup>1</sup>, внутренние ключевые сборки, контрольные точки, версии для предварительного просмотра. Также обязательно проверить предвыпускную версию.

- **Длительность анализа: в зависимости от обстоятельств.**

Он всегда занимает слишком много времени. Точное количество потраченных на анализ часов зависит от требуемого качества продукта и способностей отдела контроля качества.

- **Уровень ухудшения: высокий.**

Обычно тестирование вручную позволяет обнаружить только значительные ухудшения производительности, поскольку небольшой спад трудно заметить невооруженным глазом.

---

<sup>1</sup> Или еженежные — разницы между этими терминами нет.

- **Процесс: полностью вручную.**

Начинаете тестировать ПО вручную, тестируете вручную и исследуете тоже вручную. Никакой автоматизации нет.

## Телеметрия и мониторинг после релиза

Многие думают, что работа над производительностью заканчивается после релиза. На самом деле это только начало. Невозможно заранее исправить все ошибки или решить все проблемы с производительностью. Некоторые из них можно увидеть сразу после релиза. Другие могут проявиться по прошествии большого количества времени: их нельзя обнаружить с помощью других стратегий защиты, поскольку им может потребоваться несколько релизов, чтобы стать статистически значимыми.

- **Время обнаружения: с опозданием по отношению к текущему релизу, но не слишком поздно по отношению к следующему.**

Исправить проблемы с производительностью никогда не поздно. Плохо пропустить их в текущем релизе, но гораздо хуже — ничего не сделать для их ликвидации. Вы постоянно будете получать от пользователей или клиентов отзывы со словами «работает слишком медленно». Собрать все проблемы с производительностью из каждого релиза очень важно. Это можно сделать несколькими способами.

- *Мониторинг.* В случае веб-сервиса можно отслеживать метрики производительности серверов в режиме реального времени. Их можно вручную сравнивать с ожидаемыми или установить автоматические уведомления о проблемах.
- *Телеметрия.* Если вы не можете отслеживать ПО (программы для Рабочего стола, мобильные приложения, встроенные системы, клиентская часть веб-страницы и т. д.), можно собирать данные телеметрии и регулярно их обрабатывать.
- *Программа для мониторинга ошибок.* Если у вас есть программа для мониторинга ошибок, группируйте все ошибки, связанные с производительностью, с помощью меток или специальных полей.
- *Новые тесты.* Проверить все случаи использования ПО с помощью тестов производительности почти невозможно. Всегда продолжайте писать тесты! Если вы станете делать это, возможно, обнаружите новые проблемы.
- **Длительность анализа, уровень ухудшения, процесс: в зависимости от обстоятельств.**

То, как вы собираете, анализируете и обрабатываете проблемы с производительностью после релиза, зависит только от вас.

## Подводя итог

Обзор всех стратегий защиты приведен в табл. 5.14 (ТиО означает «телеметрия и мониторинг», УУ — «уровень ухудшения»).

У каждого подхода есть свои плюсы и минусы. Вам решать, как тестировать свое ПО. Если вас сильно беспокоит производительность, имеет смысл применить несколько подходов (или все) или сочетать их. Конечно, мы не осветили все возможные варианты тестирования производительности — лишь обсудили некоторые основные направления. Вы можете найти подход, который окажется наилучшим в вашей конкретной ситуации.

**Таблица 5.14.** Обзор стратегий защиты

Стратегия	Время обнаружения	Длительность анализа	УУ	Процесс
Тесты перед подтверждением	Вовремя	Короткая	Высокий	Автоматический
Ежедневные тесты	С опозданием на один день	До одного дня	Средний	Полуавтоматический
Ретроспективный анализ	С опозданием	В зависимости от обстоятельств	Низкий	Полуавтоматический
Тестирование контрольных точек	Вовремя	В зависимости от обстоятельств	Низкий	Почти полностью ручную
Тестирование перед релизом	С большим опозданием	В зависимости от обстоятельств	В зависимости от обстоятельств	Почти полностью ручную
Тестирование ручную	С опозданием	В зависимости от обстоятельств	Высокий	Полностью ручную
ТиО после релиза	Слишком поздно	В зависимости от обстоятельств	В зависимости от обстоятельств	В зависимости от обстоятельств

## Подпространства производительности

В главе 1 мы говорили о пространствах производительности. Теперь пора узнать о подпространствах производительности. Они создаются благодаря разным факторам, способным повлиять на производительность. Информация об этих факторах может помочь вам завершить исследование производительности. В этом разделе обсудим самые важные из подпространств.

- **Подпространство метрик** — что мы измеряем: физическое время, асимптотическую сложность, значения аппаратных счетчиков или что-то еще?

- **Подпространство итераций** — сколько итераций производим?
- **Подпространство тестов** — сколько тестов анализируем в одном наборе?
- **Подпространство окружения** — сколько разных окружений используем?
- **Подпространство параметров** — какие значения параметров применяем?
- **Подпространство истории** — мы работаем с одной ветвью или изучаем все хранилище?

Обсудим их подробнее.

## Подпространство метрик

При анализе отчетов о производительности мы всегда работаем с некоей метрикой. Разные метрики могут представить разные картины производительности. Например, у двух тестов может быть одно значение по одной метрике и разные — по другой. Нужные метрики надо выбирать, основываясь на целях бизнеса. Если вы не знаете, какие из них для вас важнее, можете попробовать несколько вариантов и проверить, что полезнее измерять для своих исследований. Вот несколько возможных метрик.

- **Физическое время.**

Это точная длительность теста. Ее можно измерить с помощью Stopwatch или скопировать с сервера непрерывной интеграции.

- **Выработка.**

Сколько операций мы можем обработать за секунду?

- **Асимптотическая сложность.**

Какова асимптотическая сложность вашего алгоритма:  $O(N)$ ,  $O(N \log(N))$ ,  $O(N^3)$ ?

- **Аппаратные счетчики.**

Их множество. Можно использовать общие счетчики для всех случаев (например, «устаревшие инструкции») или конкретные счетчики для конкретных тестов (например, «уровень ошибок прогнозирования в ветви» или «ошибки в кэше L2»). Мы подробнее обсудим аппаратные счетчики в главе 7.

- **Метрики ввода-вывода.**

Можно собрать все метрики, предоставленные ОС для операций с сетью и диском. Часто это помогает правильно определить узкое место.

- **GC.CollectionCount.**

Это одна из моих любимых метрик. Одна из главных проблем метрик «время» и «счетчик» — дисперсия. Невозможно контролировать ОС и ее распределение

времени исполнения разных процессов. Если запустить тест десять раз, возможно, получится десять разных результатов. С помощью `GC.CollectionCount` вы получите стабильное значение. Рассмотрим пример:

```
var gcBefore = GC.CollectionCount(0);
var stopwatch = Stopwatch.StartNew();

// Простой код, занимающий много памяти
int count = 0;
for (int i = 0; i < 10000000; i++)
    count += new byte[1000].Length;
Console.WriteLine(count);

stopwatch.Stop();
var gcAfter = GC.CollectionCount(0);
Console.WriteLine($"Time: {stopwatch.ElapsedMilliseconds}ms");
Console.WriteLine($"GC0: {gcAfter - gcBefore}");
```

Запустите его несколько раз и запишите значения `Time` и `GC0`. Пример результата приведен в табл. 5.15. Несмотря на то что значение `Time` варьируется, значение `GC0` (количество сборов в `Generation 0`) одинаково для всех запусков. Мы обсудим метрики GC подробнее в главе 8.

**Таблица 5.15.** Физическое время и метрики `GC.CollectionCount`

Запуск	1	2	3	4	5
Время, мс	6590	6509	6241	7312	6835
GC0	16 263	16 263	16 263	16 263	16 263

**Ремарка.** Конечно же, у `GC.CollectionCount` есть ограничения. При работе с недетерминированным многопоточным алгоритмом вы получите разные значения даже для `GC.CollectionCount`. Но все равно это значение будет стабильнее, чем чистое физическое время. Если алгоритм не занимает память, эта метрика бесполезна, потому что всегда будет равен нулю<sup>1</sup>.

## Подпространство итераций

При проведении теста всегда можно выбрать количество итераций. Обсудим, когда нужна одна итерация, а когда несколько.

- **Одна итерация.**

Это самый распространенный и простой случай: мы всегда выполняем тест ровно один раз. С одной стороны, это прекрасно, поскольку ситуация очень

<sup>1</sup> Разве что вы хотите, чтобы он так и не занимал память, и в таком случае знаете, что даже 1 байт будет считаться регрессом.

простая: только одно измерение за проверку. История производительности также выглядит несложной — она представляет собой функцию от операции подтверждения к одному числу (для каждой метрики). С другой стороны, количество данных ограничено: нет никакой информации о распределении производительности для этого теста. Представьте, что для двух субсеквенциальных операций подтверждения вы получили следующие результаты: 50 и 60 мс. Есть ли тут проблема? Об этом ничего нельзя сказать, поскольку вы не знаете распределения.

- **Много итераций.**

Если вы проводите много итераций, у вас гораздо больше данных! С одной стороны, это прекрасно, потому что можно выполнить большой полезный анализ. С другой стороны, теперь вы практически обязаны его проводить. Дополнительные итерации не бесплатны: вы расплачиваетесь за них временем и ресурсами устройства. Решив проводить много итераций, вы должны понимать, как будете использовать эти данные (это поможет вам выбрать оптимальное количество итераций). Например, это позволяет сравнивать операции. Если ваши данные выглядят как 50 мс против 60 мс, нельзя сказать точно, есть ли ухудшение производительности. Если у вас есть выборка (50; 51; 49; 50; 52 мс) против (60; 63; 61; 49; 61 мс), можно сказать, что, скорее всего, происходит ухудшение. А если имеется выборка (50; 65; 56; 61; 58 мс) против (60; 48; 64; 53; 50 мс), можно сказать, что, вероятнее всего, ничего не изменилось.

## Подпространство тестов

Одиночный тест не всегда является единственным источником метрик. Можно использовать крупные или не очень крупные модули. Например, выбрать небольшую часть тестов или сгруппировать их несколько. Таким образом, есть следующие варианты.

- **Цельный тест.**

Это, скорее всего, самый распространенный способ. Вы пишете тест, который измеряет только то, что вам нужно. Такое тестирование может требовать предварительной подготовки, например возвращения программы в изначальное состояние, но один тест измеряет только что-то одно.

- **Стадия теста.**

В некоторых случаях разделение тестов может быть очень затратным. Допустим, у вас есть объемное приложение для Рабочего стола и вы хотите измерить время выключения — интервал между тем моментом, когда пользователь щелкает на кнопке закрытия, и тем, когда процесс этого приложения завершается. Подобные тесты требуют большой подготовительной работы. Например, вы можете потратить 5 мин на инициализацию (имитацию активной работы

в приложении) и всего 1,5 с на логику выключения. Если запускать приложение для теста 12 раз, весь тест займет более часа. Целый час тестирования ради одного теста в 1,5 с! Просто пустая трата времени и ресурсов устройства.

К сожалению, мы не можем заметно улучшить ситуацию для теста выключения. Но можем кое-что другое: использовать эти 5 мин инициализации с пользой для себя! У нас есть интеграционный тест, занимающий много времени и проводящий много разных операций. Введем стадии теста и измерим каждый тест по отдельности. Мы можем измерить время загрузки приложения и длительность нескольких типичных операций одних и тех же тестов. С одной стороны, это выглядит нечестно и нарушает правила классического модульного тестирования: вместо измерения каждой функции с помощью отдельного теста мы измеряем кучу разных параметров в одном тесте. С другой стороны, у нас нет выбора — не мы такие, жизнь такая! Тесты должны быть быстрыми. У нас нет возможности проводить тесты производительности очень быстро, но весь набор тестов должен занимать разумное количество времени. Тестовая стадия — полезная техника, которая может сберечь много вашего времени.

- **Набор тестов.**

При анализе многих тестов одновременно мы можем выполнить обширный дополнительный анализ. Очень важно проанализировать корреляцию. Например, если после каких-либо изменений производительность уменьшилась, полезно найти весь объем тестов с подобным ухудшением.

## Подпространство окружения

Огромная часть этой книги посвящена различным окружениям. Важных деталей так много: устройства, операционные системы, инструментальные средства сборки, среда исполнения, компилятор и т. д. Если у вас большой проект со множеством тестов и вы все время их проводите, наверное, у вас несколько агентов непрерывной интеграции. Один и тот же тест может выполняться на разных агентах. Даже если конфигурация (аппаратные средства + программное обеспечение) у них у всех совпадает, вы все равно получите разные результаты. Если у вас небольшой выбор агентов, можете вручную проверить наборы тестов в разных окружениях. Вы не будете знать точно, как конкретное изменение повлияет на производительность, пока не проверите его в разных окружениях. Подпространство окружения можно использовать при анализе следующих аномалий.

- **Пространственной кластеризации.**

Когда у вас есть метрики одного и того же теста с нескольких агентов, можно попытаться найти факторы, влияющие на производительность. Ими могут быть операционная система, модель процессора или любой другой параметр окружения.

- **Временных аномалий.**

При исследовании истории производительности одного теста может быть полезно сравнить длительность запусков теста на разных агентах непрерывной интеграции. Если ухудшение производительности или другая аномалия появились в момент смены агента, первым делом следует проверить разницу между окружениями агентов.

## Подпространство параметров

Один и тот же тест может проводиться с разными наборами параметров ввода. В зависимости от них можно получить разную длительность. Вот несколько вариантов, которые можно проверить.

- **Нетривиальные взаимозависимости.**

Допустим, у нас есть тест, обрабатывающий много запросов. Их можно обрабатывать в нескольких потоках. Как зависит производительность от уровня распараллеливания? При замене однопоточного варианта двухпоточным можно получить рост производительности в два раза. Однако смена четырех потоков на восемь может замедлить бенчмарк из-за неэффективной и объемной блокировки. Оптимальный уровень распараллеливания можно найти, только проверив несколько возможных значений.

- **Асимптотическая сложность.**

Допустим, у нас есть тест, проверяющий, содержится ли данная строка длиной  $M$  в тексте длиной  $N$ . Временная сложность зависит от скрытого за ним алгоритма. Например, это может быть  $O(NM)$  для тривиального варианта или  $O(N + M)$  для более сложного алгоритма. Если тест работает только при коротких поисковых запросах и не проверяет более длинные, можно легко пропустить какие-то важные случаи ухудшения. Знание сложности позволит вам экстраполировать метрики на большие объемы вводимых данных, не тестируя их по-настоящему.

- **Крайние случаи.**

Допустим, у нас есть тест с алгоритмом quicksort. В лучшем и нормальном случаях его сложность равна  $O(N \log N)$ , но в худшем случае она становится равной  $O(N^2)$ . Знание производительности в худшем случае тоже может очень пригодиться, особенно если есть риск атаки на производительность программы. Худшая производительность из возможных — еще один ценный результат, который можно получить при тестировании.

- **Размах длительности.**

Допустим, у нас есть тест, анализирующий текст с регулярным выражением. В этом случае длительность теста может варьироваться с большим размахом

в зависимости от сложности выражения и самого текста. Просто проверить несколько вариантов вводных данных недостаточно для получения надежных метрик измерения производительности. Для этого требуются сотни вариантов, соответствующих разным ситуациям из реальной жизни и крайним случаям. Кстати, о крайних случаях: существуют атаки «отказ в обслуживании регулярных выражений» (ReDoS), которые могут заметно замедлить код. Один из самых известных эксплойтов ReDoS в .NET Framework 4.5 против веб-приложений MVC описан в [Malerisch, 2015]: классы `EmailAddressAttribute`, `PhoneAttribute`, `UrlAttribute` содержали регулярные выражения, которые можно заставить вычислять экспоненциальное количество состояний с помощью специальных данных ввода. Это уязвимое место было исправлено в Бюллетене безопасности Microsoft MS15-101 (<https://docs.microsoft.com/en-us/security-updates/SecurityBulletins/2015/ms15-101>). Как видите, подпространства можно анализировать совместно: здесь имеется интересная проблема производительности, включающая подпространства окружения и производительности.

Анализировать подпространство параметров очень сложно, поскольку обычно проверить все возможные вводные данные нельзя. Но все равно стоит пытаться проверить разные варианты для одного и того же метода. Метрики бенчмарка для одного теста параметров ввода нельзя экстраполировать на всю производительность метода.

## Подпространство истории

Если мы говорим о тестировании производительности, одним из важнейших подпространств для нас является подпространство истории. Исходный код все время меняется. В некоторых популярных хранилищах появляются десятки или даже сотни новых данных (проверок) в день. В любой ситуации вы смотрите на набор данных. От него самого зависит, какой анализ можно к нему применить. Обсудим основные типы таких наборов.

- **Момент из истории (одна проверка).**

Если у вас только одна проверка, можете поискать пространственные аномалии, их может быть много. Ухудшения производительности не найдете, но можете обнаружить много проблем, важных для окружения вашего производства.

- **Линейная история (одна ветвь).**

Если у вас несколько проверок, можете поискать пространственные аномалии, например ухудшение/ускорение. Если найдете проблему, появившуюся в последнем релизе, можете разделить историю и найти операцию подтверждения с нужными изменениями.

- **Древовидная история (избранные ветви или все хранилище).**

Иногда имеет смысл проанализировать несколько ветвей или даже *все хранилище*. Количество измерений производительности всегда ограничено. Если вы ищете такие аномалии, как высокая дисперсия или высокие выбросы, то можете объединить историю производительности основной ветви и всех ветвей функций. Анализ смешанной истории может дать много ложноположительных результатов, а еще он обычно позволяет найти серьезные проблемы, которые трудно обнаружить в одной ветви, потому что измерений недостаточно.

## Подводя итог

Пространство производительности содержит в себе много подпространств, например подпространства метрик, итераций, тестов, окружения, параметров, истории и др. Каждое из них или их сочетание могут значительно влиять на производительность. Знание ситуации в некоторых точках целого пространства не позволяет экстраполировать результаты на все пространство. Понимание пространства производительности помогает проводить высококачественные исследования: вы можете обнаружить больше аномалий и найти факторы, влияющие на производительность. Конечно, невозможно внимательно проверить все пространство — возможных комбинаций слишком много. Богатый опыт в исследованиях поможет вам догадаться, какие факторы с большей вероятностью повлияют на производительность. Вы также можете найти интересные идеи в чужих историях — это способ улучшить эрудицию и интуицию в области производительности.

## Уведомления и сигналы тревоги в сфере производительности

Одна из основных сложностей в тестировании производительности — автоматизированное обнаружение проблем. При обычном локальном исследовании не всегда просто сказать, есть ли у вас проблема с производительностью. Пространство может быть очень сложным, а на сбор всех нужных метрик и их анализ нужно время. В мире тестирования производительности необходимо автоматизировать это решение. Есть два основных вида таких решений, которые можно назвать *уведомлениями* и *сигналами тревоги*.

Когда приходит уведомление, мы точно знаем, что с производительностью что-то не так. Их можно эффективно применять к 100 % автоматизированных процессов, например к тестированию перед одобрением. Если приходит уведомление о падении, значит, соответствующий тест «покраснел». Поэтому у него должен

быть низкий уровень ошибок 1-го рода (ложноположительных). К сожалению, полностью избавиться от ошибок почти невозможно, но их количество нужно минимизировать, иначе появятся нестабильные тесты.

Когда срабатывает сигнал тревоги, мы не знаем, точно ли что-то не так. Эта ситуация требует исследования вручную. Сигналы тревоги можно эффективно применять в ситуациях, в которых график производительности выглядит подозрительно. Подобные сигналы можно собрать на одну информационную панель, обрабатываемую разработчиками на регулярной основе. Обычно вы будете получать несколько ложных сигналов тревоги в день, поскольку это не мешает процессу разработки. Зачастую проверить эти сигналы и принять решение о том, что волноваться не стоит, можно очень быстро. В то же время с помощью этого подхода можно вовремя обнаружить серьезные проблемы, что снижает количество ошибок 2-го рода (ложноотрицательных). Сигналы тревоги хорошо подходят для таких аномалий, как кластеризация или высокая дисперсия: мы не можем позволить себе получать «красные» тесты для всех подобных аномалий. Более того, если у теста высокая дисперсия, сложно написать четкое уведомление об ухудшении производительности с низким уровнем ложноположительных результатов. Сигнал тревоги способен решить эту проблему: вы можете получить их несколько раз в неделю без разумной причины<sup>1</sup>, но также узнаете о том, когда кто-то действительно ухудшит производительность. Метод сигналов тревоги полезен и в компромиссных ситуациях, где мы жертвуем производительностью в одной области ради каких-то бонусов в других. В подобных случаях разработчиков определенно нужно ставить в известность об этом (зачастую изменения вносятся ненамеренно), но ситуацию придется решать вручную.

Уведомления и сигналы тревоги имеют похожие реализации, разница только в том, как именно мы сообщаем о результатах. В целом логика выглядит очень простой: мы вычисляем какую-то статистику (среднюю длительность теста, дисперсию, минимальное/максимальное время, P99 и т. д.) и сравниваем ее с *порогом*. И выбрать правильное пороговое значение — это самое сложное. В этом разделе обсудим четыре разных подхода (и рассмотрим их основные плюсы и минусы):

- **абсолютный порог** — жестко закодированное значение в исходном коде (например, 2 с, 5 мин);
- **относительный порог** — жестко закодированная пропорция по отношению к референтному значению (например, в два раза быстрее другого метода);
- **адаптивный порог** — сравнение текущей производительности с историей без жестко закодированных значений (например, не медленнее, чем вчера);

<sup>1</sup> Однако, я думаю, этому есть разумное объяснение: высокая дисперсия — это почти всегда плохо. Если вы будете постоянно получать ложные сигналы тревоги по поводу таких тестов, это может подтолкнуть вас к тому, чтобы снизить дисперсию.

- **вручную настроенный порог** — в этом случае специальный разработчик постоянно наблюдает за графиками производительности и ищет проблемы.

Обсудим каждый из них подробнее.

## Абсолютный порог

Наверное, это самый популярный тип порогов, поскольку у него самая простая реализация. Обычно она выглядит следующим образом:

```
const int TimeoutMs = 2000; // 2 с

[Fact] // метка xUnit
public void MyTest()
{
    var stopwatch = Stopwatch.StartNew();
    DoTest(); // нужная логика
    stopwatch.Stop();
    Assert.True(stopwatch.ElapsedMilliseconds < TimeoutMs);
}
```

Реализация зависит от платформы модульного теста.

- **NUnit, MSTest** — обе платформы предоставляют атрибуты [Timeout], которые позволяют установить максимальное время ожидания в миллисекундах.
- **xUnit** — версия xUnit 2.0 и последующие, например 2.1, 2.2, 2.3, не поддерживают время ожидания (<https://xunit.github.io/releases/2.0>), поскольку добиться стабильных измерений времени с распараллеливанием, включенным по умолчанию в xUnit 2.x, довольно сложно. Поэтому вам придется устанавливать время ожидания вручную, как в приведенном примере. В этом случае настоятельно рекомендуется отключить распараллеливание.

Однако вы всегда можете установить время ожидания в коде с помощью таймера. Кроме того, нужно будет задавать его вручную при поиске аномалий производительности. Например, вы можете провести 20 итераций, вычислить стандартное отклонение и сравнить его с порогом.

**Простая реализация.** Можете реализовать таймер с помощью нескольких строчек кода. В случае NUnit и MSTest обычно достаточно просто атрибута [Timeout]. В случае xUnit или сложной проверки нужны две строчки, включающие в себя Stopwatch (Start/Stop) и одну строчку с уведомлением.

Хотя реализация и проста, у этого подхода есть несколько важных минусов.

- **Неважная переносимость.**

Не все компьютеры одинаково быстры. Один тест может соответствовать времени ожидания 2000 мс на вашем устройстве в 100 % запусков, но упасть на

медленном устройстве вашего коллеги или в виртуальном окружении на сервере непрерывной интеграции.

- **Нестабильность.**

Когда время ожидания близко к реальной длительности теста, иногда тест может стать «красным» в зависимости от дисперсии длительности и от других процессов в ОС, потребляющих ресурсы, которые могут его замедлить.

- **Проблемы с поддерживаемостью.**

Когда я вижу тест с жестко закодированным абсолютным временем ожидания, то всегда смотрю на историю тестов. Обычно она выглядит примерно как в табл. 5.16. Можно увидеть, что разработчики постоянно меняют жестко закодированное значение в исходном коде. Это не очень правильно. Если ваша команда часто проводит подобные операции, проще увеличить время ожидания «красного» теста вместо того, чтобы исследовать реальные проблемы с производительностью.

**Таблица 5.16.** Пример истории проверок абсолютного времени ожидания

Проверка	Время ожидания	Комментарий
N	5000	Время ожидания увеличено, поскольку на моем устройстве тест работает слишком медленно
N – 1	3000	Изменение времени ожидания теста
N – 2	7000	Новые агенты непрерывной интеграции работают слишком медленно, увеличено время ожидания
N – 3	4562	Время ожидания снижено до минимального возможного значения
N – 4	5000	Тест нестабилен, в 3 % случаев он «красный», увеличено время ожидания

В то же время абсолютные пороги могут стать последним рубежом обороны от зависания тестов. Если тест обычно занимает несколько секунд, можно спокойно указать приблизительное время ожидания, например 1 мин. Если тест «покраснел» из-за него, это определенно хорошо, поскольку сообщает нам о серьезных проблемах, например:

- тест завис из-за мертвой блокировки. Время ожидания помогло сэкономить время агента непрерывной интеграции;
- тест занимает 1,5 мин вместо нескольких секунд из-за ошибки. Ура, уведомления помогли найти ухудшение производительности;
- дисперсия очень высока, тест может занимать от 1 с до 5 мин (вероятно, из-за фазы Луны). Обычно это означает, что в исходном коде есть серьезная ошибка. Подобные аномалии нужно исследовать.

Если мы хотим использовать точное абсолютное время ожидания, например 5 с, как в примере, лучше применять сигналы тревоги, а не уведомления. Можно вручную проверить все тесты, выдавшие несколько сигналов за неделю. Это не идеальное решение, но если у вас уже есть инфраструктура сигналов тревоги, его реализация очень проста.

Если вам не нравится идея применения абсолютного времени ожидания, есть и другие способы. Поговорим об относительных порогах.

## Относительный порог

С помощью относительных порогов мы пытаемся решить проблему переносимости. Их суть проста: пишем референтный (baseline) метод (или набор таких методов) и оцениваем его среднюю производительность. Есть несколько видов относительных порогов.

- **Относительная производительность метода.**

Можно ввести точку отсчета **Baseline** и измерять производительность всех методов по отношению к этой точке. Отметив изменения в исходном коде, вы можете вычислить производительность по отношению к точке отсчета вместо анализа абсолютных чисел.

- **Относительная производительность устройства или окружения.**

Метод точки отсчета можно использовать и для сравнения производительности разных устройств<sup>1</sup>, а также разных сред исполнения на одном и том же устройстве. Например, у Mono и .NET Core разные ограничения времени загрузки программы. В теории относительный порог не является правильным подходом, поскольку пропорция производительности разных методов может различаться для каждого устройства/окружения. На практике этот подход обычно работает для большинства простых случаев.

- **Проблемы с переносимостью.**

Вы должны понимать, что это неидеальное решение, но в простых случаях оно обычно работает неплохо.

- **Нестабильность.**

То же самое, что и в случае абсолютного порога: иногда вы будете получать ложные сигналы тревоги.

---

<sup>1</sup> Подобный подход применяется для некоторых тестов производительности в IntelliJ IDEA: <https://github.com/JetBrains/intellij-community/blob/181.5451/platform/testFramework/src/com/intellij/testFramework/CpuTimings.java>.

- **Проблемы с поддерживаемостью.**

Относительные пороги все равно жестко кодируются. В случае важных изменений, например, в тесте их нужно будет менять вручную.

## Адаптивный порог

Наверное, это самый полезный и самый сложный вид сигнала тревоги. Здесь нет жестко закодированных порогов, только история производительности данного теста. Она может включать в себя любые метрики, которые вы хотите собрать. В момент тестирования производительности текущее состояние сравнивается со всей историей.

- **Нет жестко закодированных значений.**

Больше не нужно хранить множество магических чисел в исходном коде. Можно даже не думать о том, насколько быстрым должен быть код. Алгоритм будет автоматически проверять, нет ли ухудшения производительности или других аномалий.

- **Медленная реакция на изменения в тесте.**

Если вы меняете логику теста, например добавляете несколько сложных уведомлений, нужно «переобучить» алгоритм и подождать, пока он «выучит» новую исходную точку. До этого момента вы будете получать ложные сигналы. Конечно, можно каким-то образом пометить тест как измененный или очистить историю производительности, но обычно это не так просто, как изменить жестко закодированный порог.

- **Нужен сложный алгоритм.**

Требуется вручную создать алгоритм, сравнивающий историю производительности и текущее состояние. К сожалению, универсального алгоритма, решающего эту проблему в целом или работающего во всех проектах, не существует. Есть несколько готовых решений, но нужно проверить, какое из них работает в вашем проекте. Не забудьте о возможных подводных камнях, например о проблеме произвольной остановки (мы обсуждали ее в главе 4).

## Вручную настроенный порог

Когда мы говорили о стратегиях защиты от аномалий производительности, последним шло тестирование вручную. Если нельзя полностью обеспечить тесты уведомлениями, всегда можно сгенерировать сигналы тревоги. Обнаружить все

подозрительные тесты не так-то просто, поскольку для этого требуется порог. Однако мы легко можем сгенерировать худшие из худших тесты.

Представим, что мы ищем тесты с высокой дисперсией, но не можем понять, когда она высока. Вычислим дисперсию каждого теста и отсортируем результаты. Мы можем генерировать топ-10 тестов с самой высокой дисперсией каждый день. Графики производительности этих десяти худших тестов следует проверять вручную, и один из разработчиков должен для каждого теста решить, есть здесь проблема или нет. Я называю это подходом, ориентированным на панель наблюдения.

Еще один пример: мы ищем ухудшение производительности, но не можем понять, когда это действительно происходит. Давайте вычислим разницу между средней производительностью за текущую и предыдущую недели. Да, я знаю, что среднее — это ужасная метрика и распределение будет слишком запутанным. Но если с тестом происходит что-то ужасное, обычно это видно на худших из худших тестах. Это называется вручную настроенным порогом, поскольку один из разработчиков должен проверить вручную каждый тест, чтобы сказать: «Мне кажется, он ненормален».

Этот подход не слишком точен и требует проверок отчетов вручную каждый день. Однако он может помочь обнаружить некоторые аномалии производительности, не найденные при отправке уведомлений. Поскольку здесь нет реальных уведомлений, итоговый уровень ошибок 1-го рода (ложноположительных) равен нулю. Уровень ошибок 2-го рода (ложноотрицательных) снижен, поскольку можно найти проблемы, пропущенные ранее. Конечно же, это снижение требует затрат. Вы тратите рабочее время участников своей команды.

Не рекомендуется использовать только этот метод тестирования производительности, поскольку он очень времязатратный и проверять все тесты ежедневно вручную невозможно. Но он может стать полезным дополнением к инфраструктуре автоматизированного тестирования, поскольку помогает найти сложные проблемы, поиск которых нельзя автоматизировать из-за того, что соответствующие проверки обычно имеют много ложноположительных результатов.

- **Справляется даже с очень сложными случаями.**

Можно выявить очень сложные проблемы, которые почти невозможно обнаружить с помощью алгоритма. Обычно опытный разработчик может сказать, есть ли проблема с производительностью, просто взглянув на график.

- **Полное отсутствие автоматизации.**

Нужно каждый день вручную проверять самые подозрительные тесты.

## Подводя итог

Если вы хотите создать надежную систему, помогающую справляться с любыми проблемами с производительностью, вам нужны и уведомления, и сигналы тревоги. Уведомления помогают автоматически с большой вероятностью предотвращать ухудшения до загрузки изменений. Сигналы тревоги помогают следить за всем набором тестов и сообщают о проблемах, которые нельзя обнаружить, выдавая незначительное количество ложноположительных результатов.

В обоих случаях вы можете использовать разные виды порогов. Абсолютные пороги — это самый простой способ реализации, что хорошо для начала, но не очень надежно в долгосрочной перспективе: у этого подхода много проблем с переносимостью, нестабильностью и поддерживаемостью. Относительный порог лучше: он решает некоторые из этих проблем. Адаптивные пороги прекрасны, но реализовать их непросто и нужно быть внимательнее в случае намеренного изменения производительности тестов. Вручную настраиваемый порог также является эффективной техникой, помогающей обнаружить проблемы, которые нельзя найти с помощью автоматических порогов, но требует отдельного специалиста по производительности, который систематически должен следить за графиками производительности.

Универсального подхода, который годится для любых проектов, не существует. Однако сочетания разных подходов к уведомлениям и сигналам тревоги могут защитить вас даже от самых сложных и неочевидных проблем с производительностью.

## Разработка с ориентацией на производительность

Возможно, вы знакомы с разработкой с ориентацией на тесты (TDD). Разработка с ориентацией на производительность (PDD) — это похожая техника с одним важным отличием: вместо обычных функциональных и интеграционных тестов используются тесты производительности. Обычно PDD выглядит следующим образом.

1. Определите задачу и цели по производительности.
2. Напишите тест производительности.
3. Измените код.
4. Проверьте новое пространство производительности.

В этом разделе мы подробно обсудим данный подход: как его нужно использовать и насколько полезным он может быть в ежедневной работе в области производи-

тельности. PDD — решение не для любой ситуации, но эта концепция может быть полезна, если вы хотите минимизировать риск возникновения проблем с производительностью.

## Определите задачу и цели в области производительности

Как мы уже знаем, любая работа, связанная с производительностью, должна начинаться с определения целей. PDD — это техника, подходящая только для конкретного набора целей. Ее стоит использовать, только если она подходит к вашей текущей задаче. Есть три основных вида задач/целей, которые можно решить с помощью PDD. Каждый вид (я дам им кодовые названия для удобства отсылок) должен начинаться с теста производительности.

- **Кодовое название:** «Оптимизации».

**Задача:** оптимизировать неэффективный код.

**Цель:** улучшить производительность.

Слепо оптимизировать разные части кода — не лучшая идея. Тест производительности может помочь подтвердить то, что вы действительно что-то оптимизировали, и оценить увеличение производительности.

- **Кодовое название:** «Функция».

**Задача:** реализовать новую функцию.

**Цель:** функция должна быть быстрой.

Когда функция уже реализована, всегда есть соблазн сказать что-то вроде: «Кажется, она работает достаточно быстро». Правильный тест производительности помогает заранее установить требования. Этот случай довольно близок к одной ситуации в классической TDD.

- **Кодовое название:** «Реструктуризация».

**Задача:** реструктуризация кода, чувствительного к уровню производительности.

**Цель:** поддерживать достигнутый уровень производительности (или улучшить его).

Довольно сложно сказать, появились ли какие-то случаи ухудшения производительности, если нет исходной точки. Она помогает подтвердить, что все в порядке.

В каждом случае задача должна соответствовать целям вашего бизнеса. «Улучшение производительности», «быстрая функция» и «тот же уровень производительности» — это абстрактные, неэффективные выражения. PDD заставляет формализовать цель и уточнить требуемые значения метрик.

## Напишите тест производительности

Это самая важная часть PDD. Не нужно делать ничего до получения надежного теста производительности (или набора тестов). «Оптимизации» и «Функция» должны начинаться с «красного» теста. «Реструктуризацию» нужно начинать с «зеленого» теста, который можно легко превратить в «красный».

Если вы не можете написать тест производительности, значит, что-то пошло не так. Обычно это означает, что у вас проблемы с целями. Например, вы хотите оптимизировать метод, поскольку он выглядит неэффективным. В этом случае нужно доказать, что он неэффективен, с помощью «красного» теста производительности. Требования к производительности должны быть четко определены. Если вы не можете написать «красный» тест, соответствующий требованиям к производительности, скорее всего, не нужны никакие оптимизации, поскольку вы не можете доказать, что метод неэффективен.

Помните о том, что в конце тест должен стать «зеленым». Если оптимизации выполнены, а он все еще «красный», может появиться соблазн поменять систему уведомлений. Осторожно: это скользкая дорожка! Да, иногда, получив новую информацию, действительно нужно что-то поменять в тесте. В этом случае также необходимо проверить, является ли тест «красным» до оптимизаций. PDD предполагает, что оптимизация — это всегда переход от «красного» теста производительности к «зеленому». Есть много случаев, когда этого перехода добиться невозможно. И это самое лучшее в PDD: она защищает вас от преждевременных или неверных оптимизаций!

Обсудим пять типичных этапов написания подобных тестов.

- **Этап 1: напишите нужный метод.**

Просто напишите метод, отражающий нужную ситуацию. Представьте, что создаете функциональный тест для своего кода. Как и в случае с обычными тестами, нужно попытаться изолировать логику и измерять только ту, которая имеет для вас значение. Если цель — «Оптимизации», нужно тестировать только ту логику, которую вы будете оптимизировать, и больше ничего. Если цель — «Функция», следует тестировать эту функцию (и только ее) заранее (как обычно делается в типичной TDD). Если цель — «Реструктуризация», нужно тестировать только часть архитектуры, которую вы хотите реструктурировать и которая важна для производительности. Всегда лучше иметь несколько тестов производительности. Если вам пришел в голову только один, попытайтесь его параметризовать. Если метод читает файл, попробуйте файлы разных размеров, если обрабатывает набор данных, попробуйте разные наборы.

- **Этап 2: соберите метрики.**

Как минимум нужно измерить сырую длительность теста. Однако лучше собрать метрики еще по нескольким параметрам, например аппаратным счетчикам, очистке диска и т. д. Выполните много итераций, накопите результаты и вычислите статистические значения. Запускайте тесты не только на своем устройстве для разработки, но и на устройствах коллег и на сервере.

- **Этап 3: изучите пространство производительности.**

Недостаточно просто собрать сырые метрики. Их нужно тщательно изучить. Проверьте, как выглядит распределение. У него одна мода или несколько? Что там с дисперсией? Как производительность зависит от параметров теста? Зависимость линейная или нет? Каково максимальное значение параметра, приводящее к разумной длительности теста производительности? Если вы будете регулярно заниматься PDD, то вскоре создадите собственный список пунктов, которые надо проверять. Изучение пространства производительности не требует большого количества времени, особенно если вы делаете это не впервые, но оно может сэкономить очень много времени в дальнейшем. Информация о каких-либо особенностях пространства производительности теста поможет найти сложные места в исходном коде, о которых вы должны знать.

- **Этап 4: напишите уведомления.**

Настало время отразить цели вашего бизнеса в уведомлениях. Помните о том, что в случае «Оптимизаций» тест должен быть «красным». Многие разработчики пропускают этот этап. У вас может появиться соблазн сказать: «Хорошо, теперь я знаю, сколько времени это занимает. Я могу оптимизировать код и проверить, сколько времени мне потребуется после этого. Потом я напишу уведомления». Это не очень хорошая практика: она может разрушить вашу цель. Если вы хотите оптимизировать метод дважды, напишите соответствующее уведомление. Если в процессе оптимизации обнаружите что-то новое (например, «Ого, я могу оптимизировать его десять раз!» или «Оптимизировать более 50 % просто невозможно»), то всегда можете изменить уведомление позже. Но вам все равно нужно выразить изначальное намерение в форме уведомлений. Я много раз видел, как разработчики говорят что-то в духе: «После таких безумных изменений я получил ускорение на 5 %, теперь загружу это в основную ветвь» (при этом 5 % ускорения не имеют никакой ценности для бизнеса, а безумные изменения калечат код и переводят его в состояние «невозможно поддерживать»). Изначальные уведомления не защитят вас от всех подобных случаев, но заставят подумать дважды, прежде чем загружать код, не решающий изначальной проблемы.

- **Этап 5: попробуйте поменять статус теста.**

Далее нужно проверить, написали ли вы правильные уведомления. В случае «Оптимизаций» попытайтесь превратить «красный» тест в «зеленый» с помощью комментариев к самой тяжелой части кода. В случае «Реструктуризации» попробуйте добавить несколько вызовов `Thread.Sleep` там и сям и убедитесь, что после этого тест стал «красным». В случае «Функции» проверьте пустую реализацию и реализацию с `Thread.Sleep`. Вы должны быть уверены, что правильно написали уведомления: в итоге тесты должны стать «зелеными» при успехе или «красными» при падении.

Как только вы получите хороший тест производительности с правильными уведомлениями и поймете, как выглядит пространство производительности, наступит время писать реальный код!

## Измените код

Вот сейчас требуется вспомнить изначальные цели и оптимизировать продукт, реализовать новые функции или провести реструктуризацию. Вы можете полностью сосредоточиться на задаче, не боясь создать новую проблему с производительностью.

Классический подход TDD предполагает, что вы должны написать код, заставляющий тест «покраснеть». Он может подойти и для PDD. Например, разрабатывая какую-то функцию, сначала можете написать простую реализацию. Она должна работать корректно, но может быть медленной. Вы должны получить ситуацию, где функциональные/интеграционные/модульные тесты — «зеленые», а тесты производительности — «красные». После этого можете начать оптимизировать код, пока не достигнете изначальных целей в сфере производительности. Подтвердить это должно быть очень просто, с помощью одного щелчка, поскольку у вас есть тесты производительности.

## Проверьте новое пространство производительности

Помните о том, что невозможно поставить автоматические уведомления для всех возможных проблем. Поэтому полезно проверять ту часть пространства производительности, на которую могут повлиять ваши изменения.

Еще один пример из моего личного опыта. Rider на Unix использует Mono в качестве среды исполнения процесса ReSharper. Каждая версия Rider основана на фиксированной встроенной версии среды исполнения Mono. Иногда нам приходится обновлять Mono до следующей стабильной версии. Мы никогда не знаем, как обновление может повлиять на производительность Rider. У нас множество тестов,

но проверить все участки огромного проекта, на которые могут повлиять изменения в среде исполнения, почти невозможно. Поэтому мы создаем две проверки с одной базой кода Rider и разными версиями Mono. После этого проводим несколько десятков запусков всего набора тестов на одном и том же оборудовании, но в разных операционных системах (Windows, Linux, macOS). Потом создаем панели наблюдения для разных метрик, которые сильнее всего различаются в результатах этих проверок. Затем я начинаю вручную исследовать верхние тесты на этих панелях и изучать их графики производительности. Моя любимая метрика — дисперсия: мы нашли множество проблем при изучении тестов с большой разницей в дисперсии на старой и новой версиях Mono. К сожалению, автоматизировать этот процесс почти невозможно из-за высокого уровня ошибок 1-го рода (ложноположительных). Однако иногда, наверное в одном тесте из 100, мы обнаруживаем очень серьезные проблемы, реально влияющие на продукт.

## Подводя итог

PDD — полезная техника, предоставляющая надежный способ выполнения заданий, зависящих от производительности. Она позволяет контролировать производительность кода при разработке и предотвращать многие ошибки и случаи ее ухудшения. Также она заставляет вас формализовать цели и писать много тестов производительности.

Однако у этого подхода есть один важный минус: он создает невероятный объем работы, большая часть которой, скорее всего, не нужна в большинстве проектов и типов кода. И если TDD можно использовать ежедневно, то постоянно применять PDD не рекомендуется. Вы должны быть уверены, что польза от PDD (снижение риска появления проблем с производительностью) стоит того времени и ресурсов, которые вы потратите на написание тестов производительности заранее.

## Культура производительности

Тестирование производительности — это процесс, состоящий из двух компонентов. Первый — это техническая часть, которую мы обсудили в предыдущих разделах. Она отвечает на вопрос о том, как реализуется тестирование. Второй компонент — это *культура производительности* (термин взят из прекрасной записи в блоге Джо Даффи, см. [Duffy, 2016]). Он отвечает на вопрос, как заставить тестирование производительности работать. Вы можете применить замечательный набор инструментальных средств для тестирования с прекрасными алгоритмами для обнаружения аномалий и хитро разработанными уведомлениями/сигналами тревоги. Но все это не будет работать, если у вашей команды низка культура производительности. *Тестирование производительности зависит не только от технологий,*

но и от отношения к нему сотрудников. В этом разделе мы обсудим некоторые из ключевых принципов культуры производительности.

- **Общие цели в области производительности:** у всех участников команды должны быть одни и те же цели в сфере производительности.
- **Надежная инфраструктура тестирования:** инфраструктура должна работать хорошо и разработчики должны ей доверять.
- **Чистота в области производительности:** вы не должны быть терпимыми к проблемам с производительностью и у вас должен быть пустой список неисследованных аномалий.
- **Личная ответственность:** каждый разработчик несет ответственность за производительность своего кода.

Как обычно, начнем с целей.

## Общие цели в области производительности

У всех участников команды должны быть одни и те же цели в сфере производительности. Они должны их четко понимать. Неважно, какие именно у вас цели.

Это нормально, если вам совсем неважна производительность, притом что всем участникам команды она тоже неважна. Это применимо не только к производительности, но и к любой цели бизнеса. Тяжело работать над одним продуктом в одной команде с людьми, у которых другие цели. Это вызывает множество проблем с коммуникацией и нарушает процесс работы.

Если цель вашего бизнеса — достойный уровень производительности, это должно быть очевидно всем разработчикам в команде. Помните, «хорошая производительность» — это не лучшее определение. Нужный уровень следует формализовать и выразить в виде каких-то метрик. В этой книге много глав, вновь и вновь объясняющих, почему важно формализовывать цели. Для этого есть причина. Часто бывает, что специалист по производительности говорит другому участнику команды что-то вроде: «После твоих последних изменений производительность ухудшилась. Можешь это исправить?» Если он отвечает: «Я слишком занят, исправлять не буду, все работает достаточно быстро», мы не можем сказать, имеет ли смысл решать эту проблему, поскольку нам неизвестны цели этой команды по производительности. Более того, в команде нет унифицированных бизнес-целей, которые всем ясны.

Если возникла такая ситуация, надо формализовать цели. Например, можно сказать, что веб-сервер должен обрабатывать минимум 1000 запросов в секунду. Или что любая операция в потоке пользовательского интерфейса не должна длиться больше 200 мс.

Стоит отметить, что некоторые команды способны работать без строгих формальных целей в области производительности. Я видел много случаев, когда у команды было эмпирическое понимание целей. Если вы можете работать без конфликтов в сфере производительности и все равно достигаете ваших целей, это прекрасно, продолжайте в том же духе!<sup>1</sup>

Неважно, какие у вас цели и как вы их выражаете, если все участники команды с ними согласны.

В [Duffy, 2016] (см. в этом источнике раздел «Управление: больше пряников, меньше кнутов») Джо Даффи сказал: «Если в команде низкая культура производительности — это проблема руководства. Точка. Разговор окончен». Это противоречивое утверждение, но, кажется, оно верно для большинства команд. Изначально культура производительности была нужна, чтобы помогать достичь целей в сфере производительности. Однако, если вам действительно важна производительность, она должна стать одной из целей руководства. Просто так ее не добиться: культура производительности требует тяжелой работы и множества разговоров с участниками вашей команды. У них у всех должны быть общие цели и взгляды, и руководство должно в это каким-то образом вкладываться. Вот еще одна цитата из этой записи: «Когда вся команда одержима производительностью, происходит волшебство».

## Надежная инфраструктура для тестирования производительности

Если разработчики не доверяют тестам производительности, эти тесты бессмысленны. Вот три самых важных требования.

- **Все тесты должны быть «зелеными».**

Если у вас постоянно появляются «красные» или нестабильные тесты, никому не будет дела до еще одного теста с проблемами в области производительности.

- **Уровень ошибок 1-го рода (ложноположительных) должен быть низким.**

Постоянно получая ложные сигналы тревоги, вы можете начать их игнорировать, поскольку будете все свое время тратить на бесплодные исследования.

---

<sup>1</sup> Вот высказывание Федерико Андреса Лолса о его работе в качестве разработчика в RavenDB: «Команды RavenDB ведут себя таким образом. Наша цель — быть самой быстрой базой данных, и все это понимают, даже если формально такой цели нет. Поэтому каждый выполняет свою часть работы и при возникновении сомнений задает вопросы эксперту по производительности в удобном ему часовом поясе. Но при этом улучшения производительности почти никогда не мешают реализации новой функции или правильности выполнения. Мы помечаем эту функцию, а затем эксперт разбирается, как сделать ее максимально быстрой после стабилизации».

- **Написать тест производительности должно быть легко.**

Написание тестов производительности — обычно необязательная задача. Если они требуют сложной рутинной работы, разработчики не захотят этого делать.

Если вы хотите заставить разработчиков использовать какой-то инструмент (например, инфраструктуру для тестирования производительности), он должен быть надежным и простым в применении. Они должны доверять ему и получать удовольствие от работы. Иначе ничего не получится.

## Чистота в области производительности

Существует известная криминологическая теория — так называемая теория разбитых окон (см. [Wilson, 1982]). Вот ключевое правило из этой статьи: *«Если в доме разбито окно и его не застеклили, вскоре разобьют и все остальные окна».*

Это правило применимо и к разработке программного обеспечения. Если у вас полно проблем с производительностью или много тестов с подозрительными аномалиями, которые никто не исследует, новые проблемы будут появляться постоянно.

Если вы добились чистоты в области производительности, применяйте два важных правила, чтобы ее сохранить.

- **Нулевая терпимость к проблемам с производительностью.**

Возникшую проблему надо сразу же исследовать. Попробуйте забыть о списках невыполненных задач и мыслях вроде: «Я сейчас слишком занят, взгляну на это на следующей неделе». Спустя неделю будет гораздо сложнее исследовать этот вопрос: могут появиться новые проблемы и «вскоре разобьют и все остальные окна». Конечно же, в идеале проблемы нужно исправлять немедленно. Однако во многих случаях это невозможно, поскольку у вас есть много других задач с более высоким приоритетом, которые нельзя отложить. Но с точки зрения нулевой терпимости к проблемам с производительностью неважно, что достичь идеала получается не всегда<sup>1</sup>.

---

<sup>1</sup> Вот еще одно высказывание Федерико Андреса Лолса о RavenDB: «RavenDB выбрали совершенно новый путь в период версии 3.0. Они наняли специального человека (назначили лично меня) для исследования всех потенциальных способов улучшения производительности... И хотя мы сделали много хорошего, большей частью нашей работы было раскрытие дефектов в архитектуре, которые нужно было исправить в версии 4.0. Команда стала поддерживать тему постоянных оптимизаций и быстро применять стандартные техники, но поскольку мы с Ореном работали над общей темой, которую выкладывали во внутренние и внешние каналы, появлялись улучшения в три раза здесь, в два раза там, на 30 % тут и т. д. Не проходило недели без одного-двух улучшений, и так где-то в течение года. Так культура довольно быстро сменилась».

- **Регулярные проверки списка аномалий производительности.**

Должен еще раз сказать: довольно сложно найти все проблемы автоматически. В любой момент могут появиться новые проблемы, не проверяемые тестами производительности со строгими уведомлениями. Поэтому очень полезно завести несколько сигналов тревоги и панелей наблюдения и регулярно их проверять.

Конечно, эти правила подходят только для проектов с соответствующими бизнес-целями. Чистота может значительно упростить поддержание производительности на достойном уровне. Если вы этого добились, гораздо проще поддерживать ее, чем пытаться найти самые важные проблемы посреди хаоса.

## Личная ответственность

Чистота в области производительности является зоной ответственности каждого разработчика. Во многих командах есть несколько разработчиков, хорошо разбирающихся в этой сфере, и все думают, что они должны решать все проблемы с производительностью. Почему?

Допустим, вам требуется подтвердить новую функцию. Если вы хотите, чтобы в хранилище был чистый код, вы несете за него ответственность. Представьте, что существует разработчик, ответственный за чистый код: вы загружаете грязный код, а он будет его за вас очищать — выполнять базовое форматирование, выбирать правильные названия переменных и т. д. Звучит смешно, правда? Никто не будет исправлять стиль вашего кода за вас.

Но почему же стало нормальным иметь знатока в области производительности, который должен решать все связанные с ней проблемы? Конечно, хорошо, когда кто-то знает много о производительности и оптимизации и может помочь вам в сложной ситуации. Но он не должен выполнять все задачи.

Вам должна быть важна производительность вашего кода. И должна быть важна чистота производительности. Это ваша личная ответственность.

## Подводя итог

Если бы мне надо было выбрать между командой разработчиков с хорошими навыками в области производительности и командой разработчиков с хорошей культурой производительности, я выбрал бы вторую. Если у разработчиков есть эта культура, они могут почитать книги и блоги о производительности, оптимизациях и устройстве среды исполнения, научиться использовать инструменты для профилирования и бенчмаркинга и начать применять полезные методы и техники.

Без культуры производительности их навыки могут не помочь в разработке продукта с небольшим количеством проблем с производительностью.

Общие цели в сфере производительности помогают вам общаться между собой. Надежная инфраструктура для тестирования помогает с легкостью решать ежедневные технические задачи. Чистота в области производительности помогает поддерживать продукт без «разбитых окон». Личная ответственность способствует улучшению и ускорению кода каждого разработчика. Все вместе это помогает вам создать в команде культуру производительности и разрабатывать прекрасное, быстрое и надежное программное обеспечение.

## Выводы

Анализ производительности — важнейший навык для любого специалиста в этой области. Он помогает проводить глубинные исследования производительности и создавать надежную инфраструктуру для тестирования. В этой главе мы обсудили самые важные для анализа производительности темы.

- **Цели тестирования.**

Основными целями являются предотвращение ухудшения производительности, обнаружение невыявленных случаев ухудшения и других проблем с производительностью, снижение уровня ошибок 1-го и 2-го рода (ложноположительных и ложноотрицательных) и автоматизация всего перечисленного. У вас могут быть и свои цели, но об этих основных необходимо помнить. Они подходят для большинства проектов.

- **Виды бенчмарков и тестов производительности.**

Их очень много, например тесты холодной загрузки, тесты разогретого состояния, асимптотические тесты, тесты длительности и выработки, тесты пользовательского интерфейса, модульные и интеграционные тесты, мониторинг и телеметрия, тесты с внешними взаимозависимостями, тесты предельной загрузки, нечеткие тесты и т. д. Хороший набор тестов производительности обычно включает в себя сочетание этих видов.

- **Аномалии производительности.**

Ухудшение не единственная проблема с производительностью, которая может возникнуть. Есть много и других аномалий, например ускорение, временная и пространственная кластеризация, высокие длительность, дисперсия, выбросы и мультимодальные распределения. Если вы хотите избавиться от всех проблем с производительностью, систематически проверяйте свой набор тестов. Возможно, вы получите много ложных аномалий, но отслеживать их все равно стоит.

- **Стратегии защиты.**

Существует много стратегий защиты от проблем с производительностью. Вот некоторые из них: тесты перед одобрением, ежедневные тесты, ретроспективный анализ, тестирование контрольных точек, тестирование перед релизом, тестирование вручную, телеметрия и мониторинг после релиза. Как обычно, имеет смысл использовать сочетание нескольких или всех этих подходов.

- **Пространство производительности.**

В большинстве исследований мы работаем с многомерным пространством производительности, в котором много подпространств: метрик, итераций, тестов, агентов непрерывной интеграции, окружения и истории. Понимание этих подпространств позволяет вам собрать больше данных для исследования и найти факторы, действительно влияющие на производительность.

- **Уведомления и сигналы тревоги.**

Уведомления — это автоматические проверки, задействуемые в тестах производительности с низким уровнем ложноположительных результатов. Сигналы тревоги — это сообщения о проблемах с производительностью, которые не могут использоваться напрямую как уведомления из-за высокого уровня ложноположительных результатов. И те и другие могут применять разные виды порогов: абсолютный, относительный, адаптивный и настроенный вручную.

- **PDD (разработка с ориентацией на производительность).**

Эта техника похожа на классическую TDD с тестами производительности вместо обычных модульных/функциональных/интеграционных тестов. Она помогает оптимизировать продукт, реализовывать новые функции или производить реструктуризацию, будучи уверенными в том, что вы не ухудшите производительность (или даже улучшите ее).

- **Культура производительности.**

Тестирование производительности зависит не только от технологий, но и от отношения к ней сотрудников. Ключевыми компонентами культуры производительности являются общие цели, хорошее руководство, надежная инфраструктура тестирования, чистота в области производительности и личная ответственность. Культура производительности необходима, если вы хотите заниматься ее тестированием.

Конечно, осветить все аспекты тестирования производительности в одной главе невозможно. Однако мы обсудили самые важные техники и идеи, которые помогут вам улучшить навыки исследования и начать проверять ваш продукт с помощью тестов производительности.

## ИСТОЧНИКИ

[Akinshin, 2018] *Akinshin A.* A Story About Slow NuGet Package Browsing. 2018. May 8. <https://aakinshin.net/blog/post/nuget-package-browsing/>.

[AnomalyIo, 2015] Anomaly Detection Using K-Means Clustering // Anomaly.io, 2015. June 30. <https://anomaly.io/anomaly-detection-clustering/>.

[AnomalyIo, 2017] Detect Anomalies in Correlated Time Series. Anomaly.io, 2017. January 25. <https://anomaly.io/detect-anomalies-in-correlated-time-series/>.

[Bragg, 2017] *Bragg G.* How We Took Test Cycle Time from 24 Hours to 20 Minutes. 2017. October 12. <https://medium.com/ingeniouslysimple/how-we-took-testcycle-time-from-24-hours-to-20-minutes-e847677d471b>.

[Chua, 2014] *Chong F., Chua T., Lim E.-P., Huberman B. A.* Detecting Flow Anomalies in Distributed Systems // Data Mining (ICDM), 2014 Ieee International Conference. IEEE: 100–109. <https://arxiv.org/abs/1407.6064>.

[Dimopoulos, 2017] *Dimopoulos G., Barlet-Ros P., Dovrolis C., Leontiadis I.* Detecting Network Performance Anomalies with Contextual Anomaly Detection // Measurement and Networking (M&N), 2017 IEEE International Workshop. IEEE: 1–6. <https://doi.org/10.1109/IWMN.2017.8078404>.

[Duffy, 2016] *Duffy J.* Performance Culture. 2016. April 10. <http://joeduffyblog.com/2016/04/10/performance-culture/>.

[Ibidunmoye, 2016] *Ibidunmoye O., Metsch T., Elmroth E.* Real-Time Detection of Performance Anomalies for Cloud Services // Quality of Service (IWQoS), 2016 IEEE/ACM 24th International Symposium. IEEE: 1–2. <https://doi.org/10.1109/IWQoS.2016.7590412>.

[Kofman, 2018] *Kofman S.* Incident Report – NuGet.org Downtime on March 22, 2018. March 22. <https://blog.nuget.org/20180322/Incident-Report-NuGet-org-downtime-March-22.html>.

[Kondratyuk, 2017] *Kondratyuk D.* How Changing ‘localhost’ to ‘127.0.0.1’ Sped Up My Test Suite by 18x. 2017. June 9. <https://hackernoon.com/how-changinglocalhost-to-127-0-0-1-sped-up-my-test-suite-by-1-800-8143ce770736>.

[Malerisch, 2015] Microsoft .NET MVC ReDoS (Denial of Service) Vulnerability – CVE-2015-2526 (MS15-101). Malerisch.net, 2015. September 10. <http://blog.malerisch.net/2015/09/net-mvc-redos-denial-of-service-vulnerability-cve-2015-2526.html>.

[Peiris, 2014] *Peiris M., Hill J. H., Thelin J., Bykov S., Kliot G., Konig C.* PAD: Performance Anomaly Detection in Multi-Server Distributed Systems // Cloud Computing (Cloud),

---

2014 IEEE 7th International Conference. IEEE: 769–776. <https://doi.org/10.1109/CLOUD.2014.107>.

[Songkick, 2012] From 15 Hours to 15 Seconds: Reducing a Crushing Build Time // Songkick, 2012. July 16. <https://devblog.songkick.com/from-15-hours-to-15-seconds-reducing-a-crushing-build-time-4efac722fd33>.

[Warren, 2018] *Warren M.* Fuzzing the .NET JIT Compiler. 2018. October 28. <http://mattwarren.org/2018/08/28/Fuzzing-the-.NET-JIT-Compiler/>.

[Wilson, 1982] *Wilson J. Q., Kelling G. L.* The Police and Neighborhood Safety: Broken Windows // *Atlantic Monthly*, 1982. 127 (2): 29–38.

# 6

## Инструменты для диагностики

Если у вас есть только молоток, то все выглядит, как гвоздь.

*Абрахам Маслоу*

Бенчмаркинг — только один из этапов исследования производительности. В этой главе вы найдете краткий обзор некоторых важных инструментов для диагностики, которые могут пригодиться при исследовании. Мы рассмотрим следующие виды инструментов.

- **Средство для бенчмаркинга.**

Этот инструмент автоматически исследует указанный метод и демонстрирует соответствующие метрики. Он сообщает вам, сколько времени занимает исполнение этого метода, но не всегда объясняет, почему у вас получились такие значения.

- **Профайлер производительности.**

Этот инструмент измеряет метрики производительности для каждого вызываемого метода внутри приложения. Он сообщает, где находится узкое место производительности этого приложения, и позволяет исследовать профили производительности, выдавая подробную информацию о потреблении ресурсов процессора для каждого метода.

- **Профайлер памяти.**

Этот инструмент измеряет использование памяти приложением. Он сообщает, сколько объектов были размещены, и позволяет исследовать снимки памяти, выдавая подробную информацию о графе «живых» и «мертвых» объектов в каждом классе.

- **Декомпилятор C#/VB.**

Этот инструмент показывает код сборки .NET на C#/VB (даже если у вас нет оригинального исходного кода).

- **Декомпилятор промежуточного языка.**

Этот инструмент показывает код сборки .NET на промежуточном языке для требуемых классов и методов.

- **Декомпилятор ASM.**

Этот инструмент показывает собственный код сборки или существующего процесса .NET для требуемых классов и методов.

- **Отладчики.**

Этот инструмент позволяет отлаживать сборки .NET. Отладчик особенно полезен, если может заодно показывать дизассемблированный код на C#/промежуточном языке/ASM и отлаживать внешний код (с символами или без них).

- **Инструмент для слежения за системой.**

Этот инструмент отслеживает все процессы в операционной системе и показывает производительность, память и другие метрики системы в целом, индивидуальных процессов и их потоков.

Инструменты будут сгруппированы следующим образом.

- **BenchmarkDotNet.**

Мы обсудим только одно средство для бенчмаркинга — BenchmarkDotNet. Это наиболее часто используемая библиотека, применяемая во многих популярных проектах с открытым и закрытым исходным кодом.

- **Инструменты Visual Studio.**

Visual Studio — это интерактивная среда разработки, но она содержит несколько важных встроенных инструментов, полезных для исследования производительности. Мы обсудим встроенный профайлер памяти/производительности и инструменты для отладки.

- **Инструменты JetBrains.**

У JetBrains множество различных инструментов, обеспечивающих продвинутую поддержку профилирования производительности/памяти и декомпиляции. Мы обсудим dotPeek, dotTrace, dotMemory, ReSharper и Rider.

- **Windows Sysinternals.**

Это набор независимых инструментов для Windows, способный упростить различные этапы исследования производительности и собрать метрики системы. Мы обсудим RAMMap, VMMap и ProcessMonitor.

- **Другие полезные инструменты.**

В экосистеме .NET существует и много других инструментов, которые также могут пригодиться в различных ситуациях. Мы обсудим ildasm, Monodis, ILSpy, dnSpy, WinDbg, PerfView, Mono Console Tools, perfcollect, Process Hacker и Intel VTune Amplifier.

Тема диагностических инструментов чрезвычайно обширна. Невозможно обсудить их все подробно в этой главе. Ее цель — обзор некоторых доступных инструментов.

Однако здесь нет пошаговых инструкций по использованию: вам придется самим их изучить. Можете выбрать любые инструменты, которые вам понравятся: можно найти их в Интернете или создать собственное программное обеспечение. В этой главе мы кратко обсудим часть функций некоторых инструментов, предназначенных для исследования производительности.

Для каждого из них будет дана полезная информация: адрес официального сайта, ссылки на полезные ресурсы, лицензия и поддерживаемые операционные системы. Пометка «бесплатно/платно» означает, что общая лицензия платная, но существуют и бесплатные варианты, например, для проектов с открытым исходным кодом, для студентов и преподавателей, для небольших команд и т. д. Полную информацию о бесплатных лицензиях и скидках можно найти на официальных сайтах.

## BenchmarkDotNet

BenchmarkDotNet — полезная библиотека .NET для бенчмаркинга с множеством функций, помогающих при разработке и исполнении бенчмарков и анализе результатов исследования. С гордостью могу сказать, что я руковожу проектом этой библиотеки. Я основал BenchmarkDotNet в 2013 году в качестве небольшого личного проекта. Сегодня это широко используемый проект с открытым исходным кодом при поддержке .NET Foundation. BenchmarkDotNet применяется для экспериментов с производительностью в самых популярных проектах на .NET, включая .NET Core. Вот пример:

```
using System;
using System.Security.Cryptography;
using BenchmarkDotNet.Attributes;
using BenchmarkDotNet.Running;

namespace MyBenchmarks
{
    [ClrJob(baseline: true), CoreJob, MonoJob, CoreRtJob]
    public class Md5VsSha256
    {
        private SHA256 sha256 = SHA256.Create();
        private MD5 md5 = MD5.Create();
        private byte[] data;

        [Params(1000, 10000)]
        public int N;

        [GlobalSetup]
        public void Setup()
        {
            data = new byte[N];
            new Random(42).NextBytes(data);
        }
    }
}
```

```

[Benchmark]
public byte[] Sha256() => sha256.ComputeHash(data);

[Benchmark]
public byte[] Md5() => md5.ComputeHash(data);
}

public class Program
{
    public static void Main(string[] args)
    {
        var summary = BenchmarkRunner.Run<Md5VsSha256>();
    }
}

```

Эта программа сгенерирует примерно такой результат:

BenchmarkDotNet=v0.11.0, OS=Windows 10.0.16299.309 (1709/Redstone3)  
Intel Xeon CPU E5-1650 v4 3.60GHz, 1 CPU, 12 logical and 6 physical cores

Frequency=3507504 Hz, Resolution=285.1030 ns, Timer=TSC

.NET Core SDK=2.1.300-preview1-008174

```

[Host]      : .NET Core 2.1.0-preview1-26216-03
              (CoreCLR 4.6.26216.04, CoreFX 4.6.26216.02), 64bit RyuJIT
Job-HKEEXO  : .NET Framework 4.7.1
              (CLR 4.0.30319.42000), 64bit RyuJIT-v4.7.2633.0
Core        : .NET Core 2.1.0-preview1-26216-03
              (CoreCLR 4.6.26216.04, CoreFX 4.6.26216.02), 64bit RyuJIT
CoreRT      : .NET CoreRT 1.0.26414.01, 64bit AOT
Mono        : Mono 5.10.0 (Visual Studio), 64bit

```

Method	Runtime	N	Mean	Error	StdDev	Ratio
Sha256	Clr	1000	8.009 us	0.0370 us	0.0346 us	1.00
Sha256	Core	1000	4.447 us	0.0117 us	0.0110 us	0.56
Sha256	CoreRT	1000	4.321 us	0.0139 us	0.0130 us	0.54
Sha256	Mono	1000	14.924 us	0.0574 us	0.0479 us	1.86
Md5	Clr	1000	3.051 us	0.0604 us	0.0742 us	1.00
Md5	Core	1000	2.004 us	0.0058 us	0.0054 us	0.66
Md5	CoreRT	1000	1.892 us	0.0087 us	0.0077 us	0.62
Md5	Mono	1000	3.878 us	0.0181 us	0.0170 us	1.27
Sha256	Clr	10000	75.780 us	1.0445 us	0.9771 us	1.00
Sha256	Core	10000	41.134 us	0.2185 us	0.1937 us	0.54
Sha256	CoreRT	10000	40.895 us	0.0804 us	0.0628 us	0.54
Sha256	Mono	10000	141.377 us	0.5598 us	0.5236 us	1.87
Md5	Clr	10000	18.575 us	0.0727 us	0.0644 us	1.00
Md5	Core	10000	17.562 us	0.0436 us	0.0408 us	0.95
Md5	CoreRT	10000	17.447 us	0.0293 us	0.0244 us	0.94
Md5	Mono	10000	34.500 us	0.1553 us	0.1452 us	1.86

Полную документацию последней версии BenchmarkDotNet можно найти на GitHub, поэтому я не буду описывать использование всех ее функций. Вместо этого хочу поговорить о философии инструментов для бенчмаркинга. Думаю, что хорошая библиотека для бенчмаркинга должна отвечать следующим требованиям.

- **Она должна выполнять за вас все рутинные задания.**

Обычный бенчмарк включает в себя много шаблонного кода. Пользователи не должны писать его каждый раз, когда хотят измерить производительность. Инструмент для бенчмаркинга должен автоматически проводить несколько итераций с несколькими вызовами метода в каждом. Ему требуется выполнить несколько итераций для прогрева и удалить их из отчета. Он должен изолировать бенчмарки друг от друга и запускать каждый из них в отдельном процессе. Если вы хотите проверить несколько разных окружений, он должен автоматически запустить бенчмарк в каждом из них и собрать все результаты. А еще автоматически оценить собственные ограничения и исключить их из результатов измерений. Всю грязную работу должна выполнять библиотека для бенчмаркинга. При исследовании пользователи должны иметь возможность сосредоточиться на измеряемой логике, а не на инфраструктуре для бенчмаркинга.

- **Она должна защищать вас от известных ошибок.**

Библиотека не должна позволять вам запускать бенчмарки в режиме *отладки* (без оптимизаций). Она должна контролировать инлайнинг и убедиться, что все бенчмарки пользуются одной и той же политикой по поводу инлайнинга. Должна применять лучший из доступных API для отметок времени. Лучшие методики бенчмаркинга, например прогрев и изоляция, должны быть включены в нее по умолчанию.

- **Она должна выбрать самый подходящий для вас режим бенчмаркинга.**

Следует применять подходы адаптивного бенчмаркинга. Библиотека должна использовать произвольную остановку, а не спрашивать пользователя о количестве итераций. Она должна находить лучшее значение при пробном эксперименте, а не спрашивать пользователя о количестве запросов метода при каждой итерации. По умолчанию пользователи не должны беспокоиться о параметрах инфраструктуры: библиотека обязана найти лучшие из возможных значений.

- **Она должна предусматривать различные конфигурации.**

Каждый эксперимент с бенчмарком уникален и имеет собственные требования. У пользователей должна быть возможность отключить все полезные функции. Например, если они хотят измерить холодный запуск, у них должна быть возможность отключить прогрев. Если они знают, что бенчмарки

не влияют друг на друга, то могут захотеть отключить изоляцию процессов для ускорения эксперимента. Несомненно, приятно, когда кто-то выбирает за вас количество итераций, но возможность установить его вручную тоже должна существовать.

- **У нее должен быть удобный для пользователей API.**

Это требование подойдет для любой библиотеки. API должен быть понятным и хорошо задокументированным. Он должен поддерживать разные подходы: некоторым пользователям нравится конфигурировать бенчмарки в командной строке, некоторым — использовать атрибуты, а кому-то — гибкий API. Библиотека должна предоставлять разные способы конфигурации процесса бенчмаркинга.

- **Она должна знать вашу статистику.**

Библиотека должна иметь возможность вычислять все базовые статистические характеристики, такие как среднее арифметическое, медиана, стандартное отклонение, доверительный интервал, квартили и процентиля, скошенность и эксцесс. Она должна уметь определять выбросы, проводить статистические тесты, например t-тест Уэлча или U-тест Манна — Уитни, и проверять распределения на мультимодальность.

- **Она должна помогать вам при анализе результатов.**

Если библиотека способна вычислить все возможные статистические метрики, это не значит, что она должна выдавать их все каждый раз. Ей требуется выделять все важные характеристики вычисленного распределения. Мы знаем, что можно получить большую разницу между средним арифметическим и медианой, но часто эти значения близки друг к другу. Если библиотека будет выдавать оба этих значения каждый раз, пользователи начнут игнорировать одно из них. Лучше показывать по умолчанию только среднее арифметическое, а медиану демонстрировать только тогда, когда это имеет значение. Мы знаем, что важно уметь отличать унимодальное распределение от мультимодального. Однако большинство простых распределений производительности унимодальны. Бессмысленно выдавать каждый раз: «Все в порядке, распределение унимодально». Лучше писать предупреждение в случае, если распределение мультимодально. Библиотека должна сообщать, не испорчено ли распределение выбросами. Основной отчет должен содержать только важные данные в самой компактной форме. Прекрасно, если библиотека может вычислить среднее арифметическое с максимально возможной точностью, но нужен ли вам результат 6,38319573993657 мс? Большинству пользователей важны только самые значительные цифры, поэтому достаточно оставить 6,383 мс. Библиотека может провести U-тест Манна — Уитни и выдать p-значение, но лучше вывести заключение, основываясь на нем (большинство пользователей не помнит, как правильно интерпретировать p-значения). Библиотека должна сообщать, когда

результат ненадежен из-за изначальных настроек, например из-за маленького размера выборки или недостаточного времени итерации. Итоговая таблица результатов должна быть максимально сжатой, но при этом содержать все важные числа и факты. Пользователи должны по ней быстро понять, что происходит с данными.

- **Она должна собирать информацию об окружении.**

Хороший отчет о производительности должен включать в себя самую важную информацию об окружении, например версию ОС, модель процессора, используемую среду исполнения, тип компилятора JIT и т. д.

- **Она должна предоставлять основные данные для диагностики.**

Библиотека для бенчмаркинга — это не профайлер и не компилятор, но она может выполнять некую базовую логику и предоставлять минимальные данные для диагностики. Например, измерять количество выделенной памяти, оценивать значения на аппаратных счетчиках, выдавать код на промежуточном языке для основных методов, генерировать файлы трассировки, основываясь на событиях ETW, проверять оптимизации среды исполнения, такие как инлайнинг или оптимизации завершающих вызовов, и т. д. Она должна помогать пользователям понять, почему они получили именно этот отчет о производительности и какие дополнительные инструменты им нужны.

- **Она должна генерировать много отчетов и рисовать графики.**

Информация о произведенных измерениях должна быть доступна в разных форматах, например CSV, JSON, XML, HTML, Markdown, AsciiDoc и др. Разработчики часто делятся друг с другом результатами исследований, поэтому библиотека должна поддерживать разные диалекты Markdown, которые могут быть опубликованы на GitHub, StackOverflow, JIRA или других сервисах. Распределение должно демонстрироваться с помощью разных графиков: гистограмм, временных графиков, графиков плотности, столбчатых графиков, диаграмм размаха, частотных трасс и т. д. Библиотека должна уметь генерировать любые отчеты, которые могут пригодиться при анализе производительности.

BenchmarkDotNet стала популярной, поскольку она пытается соответствовать всем этим требованиям. Конечно же, эта библиотека неидеальна. В ней есть ошибки, отсутствуют определенные функции. Однако BenchmarkDotNet улучшается с каждой версией благодаря вкладу сообщества пользователей.

Вы должны понимать, что ни одна библиотека для бенчмаркинга, включая BenchmarkDotNet, не является универсальным средством. Она не напишет за вас бенчмарк. Не проанализирует за вас отчеты. Она просто помогает создавать и исполнять бенчмарки. Таким образом, вам все равно нужно знать методологию

бенчмаркинга и помнить о подводных камнях. Вам все равно нужно знать о таких оптимизациях JIT, как DCE, VSE и свертывание констант, о естественном шуме и возможной высокой дисперсии, уметь проверять распределение вручную и анализировать его.

Волшебной библиотеки, которая решит за вас все проблемы, не существует: вы все равно несете всю полноту ответственности. BenchmarkDotNet просто позволяет пропустить шаблонную часть бенчмарка и сосредоточиться на коде. Это особенно полезно для начинающих, которые не знают о проблемах, которые мы обсуждали (или для тех, кто просто не хочет думать обо всем этом в данный момент). Библиотека не гарантирует правильности всех ваших бенчмарков. Но как минимум вам не нужно беспокоиться о распространенных дурацких ошибках в бенчмарках. Это удобный инструмент для самозагрузки бенчмарков, поэтому мы будем обсуждать ее в этой книге неоднократно.

URL: <https://github.com/dotnet/benchmarkdotnet>.

Открытый исходный код (MIT), бесплатно, кросс-платформенный инструмент.

Ресурсы: <https://benchmarkdotnet.org/>, [Sitnik, 2017a], [Sitnik, 2017b], [Sitnik, 2018].

## Инструменты Visual Studio

Visual Studio — самая популярная интерактивная среда разработки для .NET. Мы будем обсуждать ее как среду разработки, поговорим только о нескольких функциях, которые могут пригодиться при исследованиях производительности.

URL: <https://visualstudio.microsoft.com/vs/>.

Закрывает исходный код, бесплатно/платно, только для Windows.

## Встроенные профайлеры

У Visual Studio много различных режимов профилирования (рис. 6.1):

- использование процессора;
- использование памяти;
- потребление ресурса для XAML;
- использование сети для UWP Apps;
- использование GPU для Direct3D;
- использование энергии для UWP Apps.



собственный код, нужно отключить в настройках функцию Подавлять оптимизации JIT при загрузке модуля<sup>1</sup>.

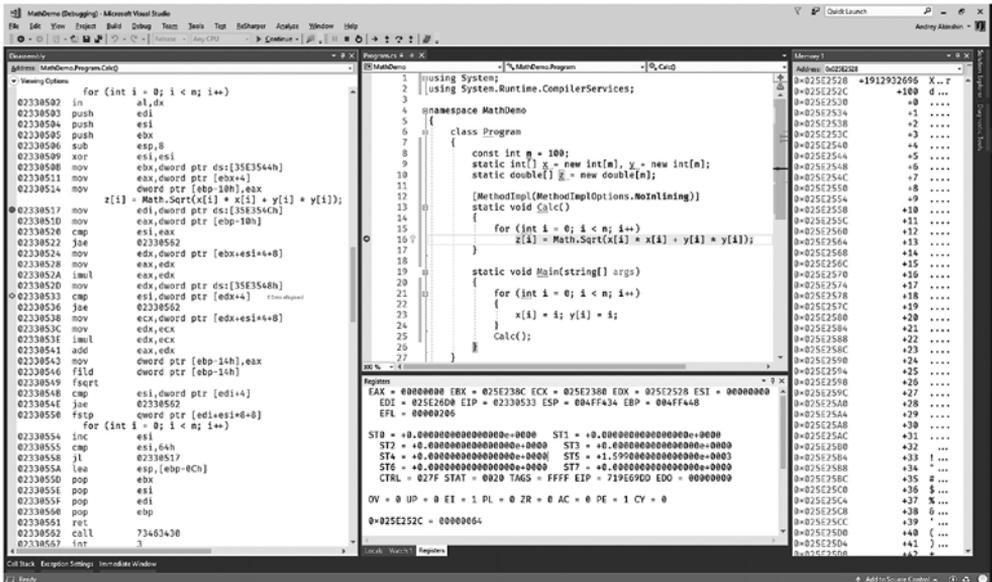


Рис. 6.2. Дизассемблированный вид в Visual Studio. Источник: <https://docs.microsoft.com/en-us/visualstudio/debugger/how-to-use-the-disassembly-window>

## Инструменты JetBrains

У JetBrains есть набор инструментов для разработки в .NET. В этом разделе мы обсудим некоторые функции для профилирования, декомпиляции и отладки.

### dotPeek

dotPeek — это бесплатный декомпилятор и средство для просмотра сборки для .NET. Вот некоторые его полезные функции (рис. 6.3).

- Декомпиляция в код на C# и промежуточном языке.
- Экспортирование декомпилированного кода в проекты Visual Studio и генерирование файлов PDB.

<sup>1</sup> Больше информации имеется в документации: <https://docs.microsoft.com/en-us/visualstudio/debugger/jit-optimization-and-debugging>.

- Поиск использования любого символа.
- Быстрая навигация по типу, символу и т. д.

URL: [www.jetbrains.com/decompiler/](http://www.jetbrains.com/decompiler/).

Закрытый исходный код, бесплатно, только для Windows.

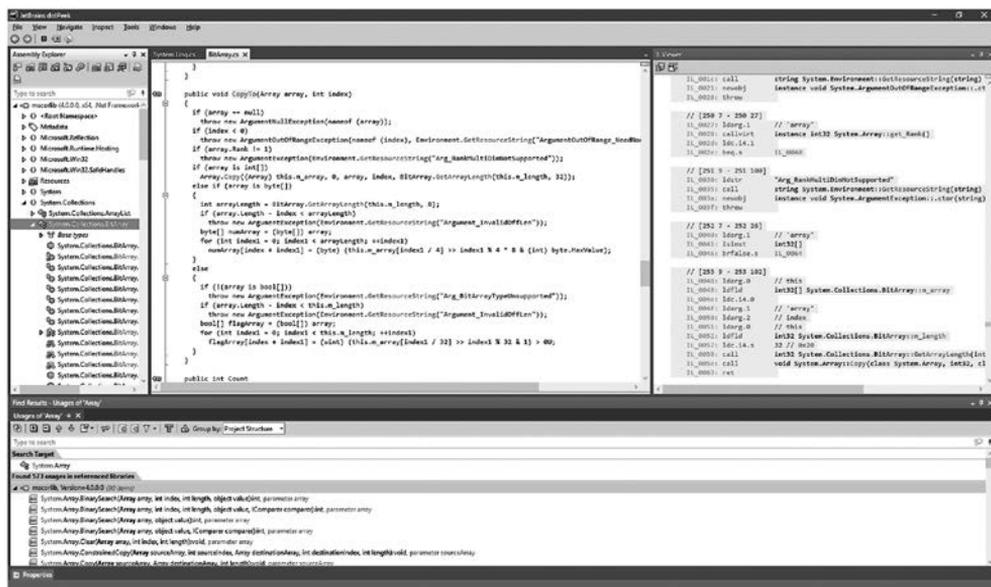


Рис. 6.3. dotPeek

## dotTrace и dotMemory

dotTrace и dotMemory — это профайлеры производительности и памяти для .NET. Вот несколько полезных функций обоих продуктов.

- **Поддержка разных приложений для .NET.**

Поддерживает разные виды приложений .NET Framework, включая приложения для Рабочего стола, IIS, IIS Express, сервисы Windows, UWP и т. д., и .NET Core.

- **Мощная визуализация.**

У обоих профайлеров много видов визуализации, что позволяет исследовать разные проблемы. Например, у dotMemory есть временный вид со сбором данных в реальном времени, ромбовидная диаграмма, график дерева вызовов

и много древовидных графиков, позволяющих исследовать взаимосвязи между объектами на снимке состояния.

- **Сравнение снимков состояния.**

Когда вы хотите оценить эффект какого-то конкретного изменения, можете сделать снимки состояния производительности или памяти до и после этого изменения и сравнить их. Это полезно, если вы хотите подтвердить тот факт, что изменение исправило проблему с производительностью или не привнесло ухудшений.

- **Много вариантов исполнения.**

dotTrace можно использовать как отдельное приложение для Рабочего стола, а также через командную строку или API для профилирования. Вы можете прикрепить его к локальным или удаленным приложениям (удаленное профилирование особенно полезно, если появилась проблема в веб-приложении на сервере).

Вот несколько особых характеристик dotTrace.

- **Разные режимы профилирования.**

dotTrace поддерживает следующие типы профилирования.

- **Сэмплирование.** Суть этого подхода проста: профайлер в стеке вызовов периодически проверяет все потоки. С помощью этой информации он может найти методы, на выполнение которых затрачивается слишком много времени, поскольку они будут часто появляться в зафиксированных стеках вызовов. У этого подхода минимальное из возможных количество ограничений, но он не совсем точен: профайлер может пропустить некоторые из быстрых методов и не способен вычислить количество вызовов каждого метода. Он полезен, если вы хотите найти узкое место в производительности без возникновения значительных ограничений профайлера.
- **Мониторинг.** В режиме мониторинга профайлер с помощью контрольно-проверочного кода получает специальные события входа и выхода для каждого метода. В итоге могут появиться дополнительные ограничения при каждом вызове, измеряемое время может быть искажено. Подход полезен, если вы хотите узнать точное число вызовов каждого метода.
- **Построчное профилирование.** Этот подход похож на мониторинг, но применяется не к методам, а к выражениям. У него больше ограничений, чем у мониторинга. Он полезен, если вы ищете самое медленное выражение в объемном методе.
- **Хронологическое профилирование.** В хронологическом режиме профайлер собирает временную информацию о стеках вызовов, данные о состоянии

потоков, выделении памяти, сборке мусора и операциях ввода-вывода. Результаты представляются с помощью Timeline Viewer, который демонстрирует записанные события на временной диаграмме. Это полезно, если вам важен хронологический порядок событий. Данный подход позволяет обнаружить зависание пользовательского интерфейса, переизбыток операций сборки мусора и ввода-вывода и конфликты при блокировке.

- **Поддержка сложных случаев.**

У dotTrace (рис. 6.4) есть множество дополнительных функций, например профилирование асинхронных вызовов, анализ медленных запросов HTTP, поисковых запросов SQL и операций файловой системы.

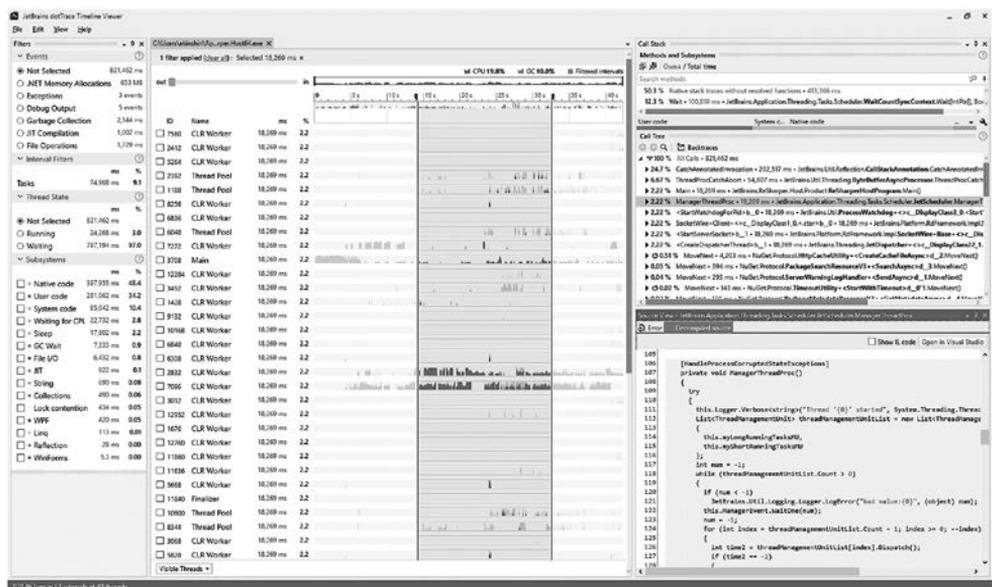


Рис. 6.4. dotTrace

Специальные функции dotMemory (рис. 6.5) включают в себя:

- **полезные автоматические инспекции.** dotMemory автоматически распознает распространенные проблемы с памятью на снимках состояния, например дублирование строк, массивы с разрывом, поврежденные обработчики событий или комплекты WPF и т. д.;
- **поддержку сырой разгрузки памяти.** Вы можете работать с сырыми разгрузками памяти Windows как с обычными снимками состояния, исследовать их с помощью стандартных окон просмотра и применять к ним инспекции.

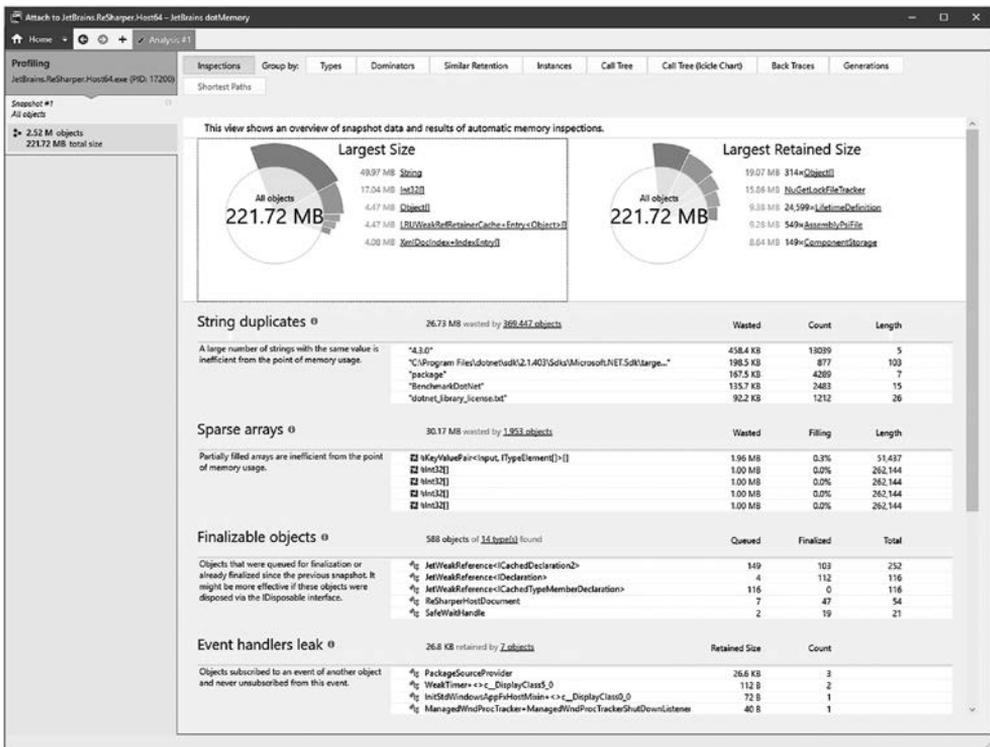


Рис. 6.5. dotMemory

dotTrace 2018.3 и dotMemory 2018.3 являются приложениями только для Windows, но следующие версии должны поддерживать профилирование в .NET Core и Mono в Linux и macOS.

URL: [www.jetbrains.com/profiler/](http://www.jetbrains.com/profiler/), [www.jetbrains.com/dotmemory](http://www.jetbrains.com/dotmemory).

Закрытый исходный код, бесплатно/платно, только для Windows.

## ReSharper

ReSharper – это расширение Visual Studio для разработчиков на .NET (рис. 6.6). У него много полезных функций, но я хочу выделить лишь одну из них – просмотр на промежуточном языке. Она позволяет просматривать код текущего файла на промежуточном языке в отдельном окне инструментов. Таким образом, вы можете проверить сгенерированный код на промежуточном языке, не переходя из Visual

Studio в другие программы. ReSharper и dotPeek используют один и тот же механизм декомпиляции.

URL: [www.jetbrains.com/resharper/](http://www.jetbrains.com/resharper/).

Закрытый исходный код, бесплатно/платно, только для Windows.

Ресурсы: [Balliauw, 2017a], [www.jetbrains.com/help/resharper/Viewing\\_Intermediate\\_Language.html](http://www.jetbrains.com/help/resharper/Viewing_Intermediate_Language.html).

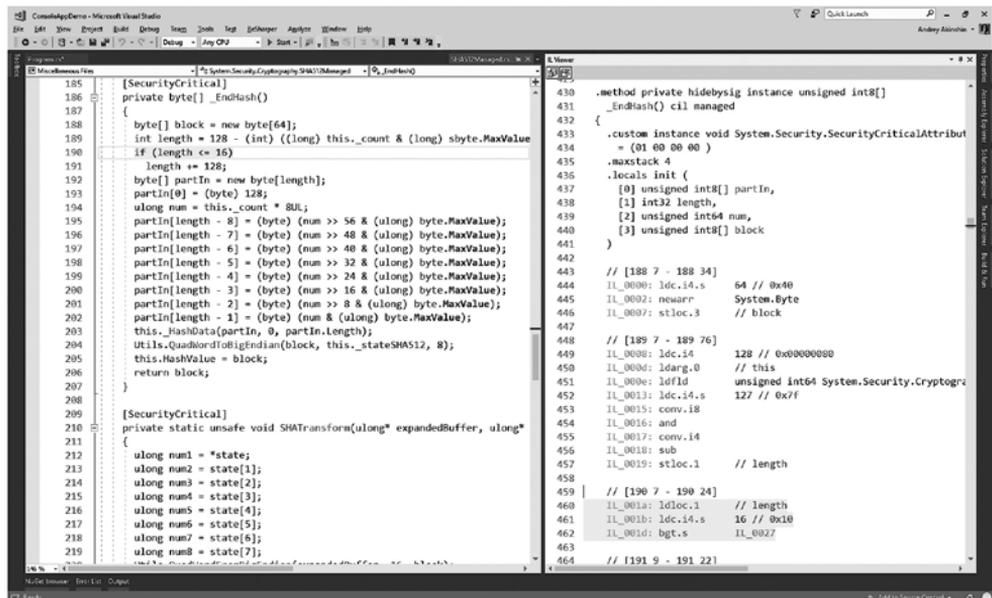


Рис. 6.6. Просмотр на промежуточном языке в ReSharper

## Rider

Rider — это быстрая и мощная кросс-платформенная интерактивная среда разработки на .NET. Мы не будем обсуждать Rider в качестве среды разработки. Рассмотрим только следующие его функции.

- **Встроенный декомпилятор.**

С помощью механизма dotPeek Rider может показывать декомпилированный код на C# для любых сторонних классов даже без символов.

- **Отладка внешнего кода.**

Даже работая с простым приложением для консоли, вы можете подсоединиться к любому приложению на .NET и отладить декомпилированный код любого класса без оригинального исходного кода или символов. Можно даже установить точки останова в декомпилированных ресурсах и проанализировать исполнение сторонних сборок. Большинство классических инструментов для .NET предназначены только для Windows, однако Rider поддерживает внешнюю отладку для Mono и .NET Core на Linux и macOS.

- **Встроенный профайлер.**

В Riderе содержится встроенный механизм dotTrace, позволяющий профилировать ваше приложение из интерактивной среды разработки.

URL: [www.jetbrains.com/rider/](http://www.jetbrains.com/rider/).

Закрытый исходный код, бесплатно/платно, кросс-платформенная среда разработки.

Ресурсы: [Balliauw, 2017b], [www.jetbrains.com/help/rider/Debugging\\_External\\_Code.html](http://www.jetbrains.com/help/rider/Debugging_External_Code.html).

## Windows Sysinternals

Windows Sysinternals — это набор сложных системных утилит для Windows. Он включает в себя множество различных инструментов, которые можно разделить на следующие группы.

- **Утилиты для файлов и дисков** — инструменты, способные получить подробную информацию о дисках (например, разрешения на ресурсы, использование диска, назначение диска, информацию о зашифрованных файлах) и инструменты для манипуляций с диском (например, для упорядочения операций с файлами для следующей перезагрузки, дефрагментации, работы с символическими ссылками).
- **Сетевые утилиты** — инструменты, работающие с Active Directory, именованными каналами, сокетом и удаленными компьютерами. Они также включают в себя PsPing, позволяющий измерять длительность и пропускную способность базовых сетевых операций.
- **Утилиты для процессов** — инструменты для мониторинга и контроля процессов, их потоков и указателей.
- **Утилиты безопасности** — инструменты для работы с пользователями, их сессиями и разрешениями.

- **Системная информация** — инструменты для сбора различной информации об операционной системе, процессах, памяти, устройствах и аппаратной составляющей.
- **Разное** — другие инструменты, помогающие в работе с реестром, кодировками, экранами и Рабочими столами.

В этом разделе мы обсудим несколько инструментов, которые могут пригодиться при исследованиях производительности: RAMMap, VMMap и Process Monitor.

URL: <https://docs.microsoft.com/en-us/sysinternals/>.

Закрытый исходный код, бесплатно, только для Windows.

## RAMMap

RAMMap демонстрирует подробный низкоуровневый обзор всех типов памяти в операционной системе (рис. 6.7). Он позволяет исследовать разные типы памяти (активную, в режиме ожидания, измененную и т. д.) для разных типов использования (приватных процессов, отмеченных файлов, общедоступных файлов и т. д.). У вас есть возможность анализировать память для каждого процесса, страницы физической памяти и диапазоны адресов.

Больше информации о разных видах памяти в Windows можно найти в [Rusinovich, 2017] и [Rusinovich, 2019].

URL: <https://docs.microsoft.com/en-us/sysinternals/downloads/rammap>.

The screenshot shows the RAMMap application window with the 'Physical Pages' tab selected. The main area displays a table of memory usage statistics. The table has columns for Usage, Total, Active, Standby, Modified, Modified no write, Transition, Zeroed, and Free. The data is as follows:

Usage	Total	Active	Standby	Modified	Modified no write	Transition	Zeroed	Free
Process Private	6,297,880 K	6,018,812 K	106,192 K	172,492 K		384 K		
Mapped File	7,653,148 K	1,021,600 K	6,631,536 K	12 K				
Shareable	492,072 K	104,072 K	4 K	387,996 K				
Page Table	107,524 K	107,440 K		84 K				
Page Pool	417,160 K	409,280 K		7,880 K				
Nonpaged Pool	642,684 K	642,664 K				20 K		
System PTE	77,180 K	77,060 K		120 K				
Session Private	43,064 K	42,792 K		272 K				
Metafile	642,164 K	247,876 K	394,156 K	48 K		84 K		
AWE								
Driver Locked	25,980 K	25,980 K						
Kernel Stack	48,200 K	41,936 K		6,264 K				
Unused	17,000,648 K	6,896 K		172 K			2,035,608 K	14,957,972 K
Large Page								
Total	33,447,704 K	8,746,408 K	7,131,888 K	575,340 K		84 K	404 K	2,035,608 K

Рис. 6.7. RAMMap

## VMMap

VMMap демонстрирует подробный низкоуровневый обзор памяти для определенного процесса (рис. 6.8). В отличие от RAMMap, который помогает исследовать память всей операционной системы, VMMap всегда работает с отдельным процессом. Он предоставляет расширенные данные по всем сегментам памяти, используемым этим процессом.

URL: <https://docs.microsoft.com/en-us/sysinternals/downloads/vmmap>.

VMMap - Sysinternals: www.sysinternals.com

File Edit View Tools Options Help

Process: JetBrains.ReSharper.Host64.exe  
PID: 2388

Committed: 1,183,888 K

Private Bytes: 723,636 K

Working Set: 794,604 K

Type	Size	Committed	Private	Total WS	Private WS	Shareable WS	Shared WS	Locked WS	Blocks	Largest
Total	6,116,352 K	1,184,888 K	723,636 K	795,604 K	657,188 K	137,416 K	31,536 K		5447	
Heap	443,280 K	440,852 K	34,176 K	158,576 K	3,768 K	134,668 K	30,612 K		2260	25,952 K
Mapped File	49,152 K	49,152 K	1,668 K	1,668 K		1,668 K			18	25,308 K
Shareable	26,856 K	4,096 K		1,064 K		1,064 K			29	20,484 K
Heap	151,300 K	129,776 K	125,712 K	98,224 K	98,220 K	4 K	4 K		405	16,192 K
Managed Heap	1,063,040 K	506,116 K	506,116 K	506,108 K	506,108 K				2344	353,216 K
Stack	68,560 K	4,440 K	4,440 K	2,676 K					302	1,024 K
Private Data	4,302,756 K	49,456 K	49,192 K	46,488 K	46,476 K	12 K		12 K	168	4,194,432 K
Page Table	12,808 K									60 K
Unavailable									109	137,387,537,472 K
Free	137,432,837,056 K									

Address	Type	Size	Committed	Private	Total WS	Private ...	Share...	Share...	Lock...	Blocks	Protection	Details
0000000000010000	Heap (Shareable)	64 K	64 K		4 K	4 K	4 K	4 K		2	Read/Write	Heap ID: 2 [COMPATIBILITY]
0000000000020000	Shareable	32 K	16 K		12 K		12 K	12 K		1	Read	
0000000000030000	Shareable	100 K	100 K		100 K		100 K	100 K		1	Read	
0000000000050000	Thread Stack	1,024 K	120 K	120 K	100 K	100 K				3	Read/Write/Guard	Thread ID: 14228
0000000000150000	Shareable	16 K	16 K		12 K		12 K	12 K		1	Read	
0000000000160000	Shareable	12 K	12 K		12 K					1	Read	
0000000000170000	Private Data	4 K	4 K		4 K	4 K				1	Read/Write	
0000000000180000	Heap (Private Data)	200 K	116 K	116 K	116 K	116 K				2	Read/Write	Heap ID: 1 [LOW FRAGMENTATION]
00000000001C0000	Heap (Private Data)	200 K	8 K	8 K	8 K	8 K				2	Read/Write	Heap ID: 3 [LOW FRAGMENTATION]
0000000000200000	Private Data	2,048 K	540 K	540 K	540 K	540 K				43	Read/Write	Thread Environment Block ID: 14229
0000000000400000	Heap (Private Data)	200 K	4 K	4 K	4 K	4 K				2	Read/Write	Heap ID: 5 [LOW FRAGMENTATION]
0000000000440000	Shareable	4 K	4 K		4 K		4 K			1	Read/Write	

Timeline... Heap Allocations... Call Tree... Trace...

Рис. 6.8. VMMap

## Process Monitor

Process Monitor — это многофункциональный инструмент мониторинга для Windows, показывающий файловую систему, реестр и деятельность процессов/потоков в режиме реального времени (рис. 6.9). Он позволяет просматривать все виды низкоуровневых событий в ОС, например CreateFile/OpenFile/CloseFile, LoadImage, RegQueryKey/RegCloseKey, ThreadCreate/ThreadExit и т. д. Вы также можете получить все доступные метаданные по каждому событию, включая полнопоточный мониторинг стека со встроенной поддержкой символов для каждой операции. Поскольку в Windows огромное количество подобных событий, Process

Monitor позволяет устанавливать разные виды сложных фильтров, позволяющих охватывать только те события, которые вам нужно увидеть.

URL: <https://docs.microsoft.com/en-us/sysinternals/downloads/procmon>.

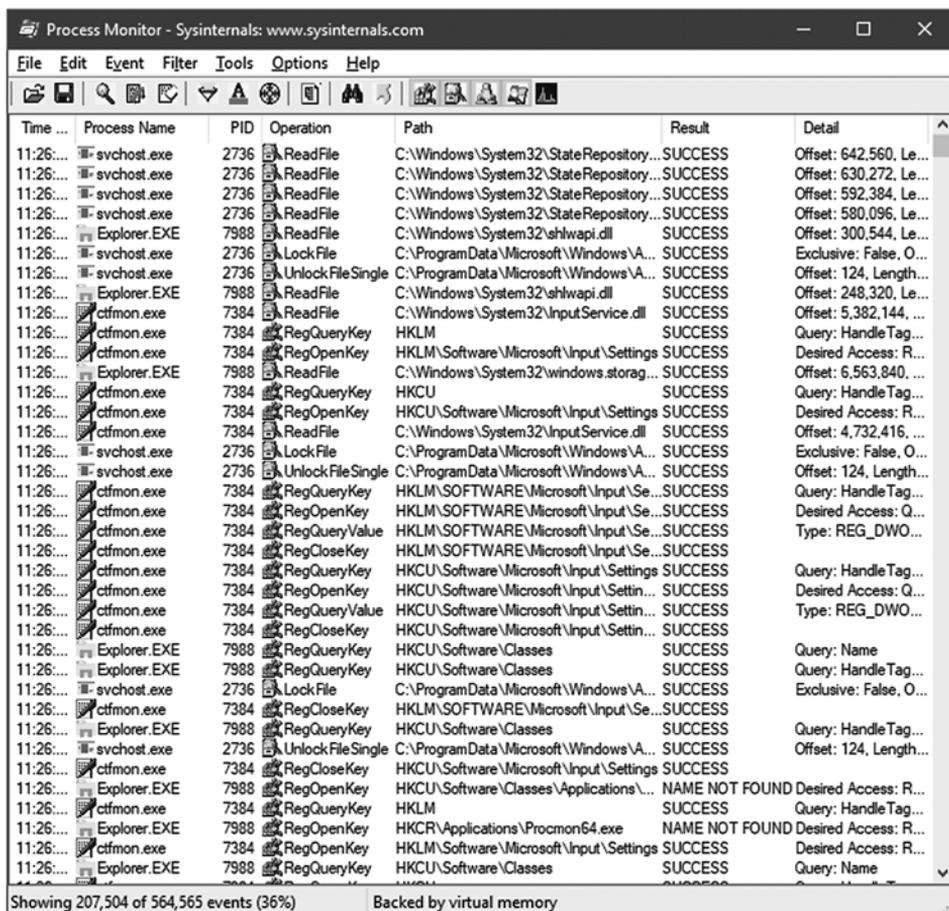


Рис. 6.9. Process Monitor

## Другие полезные инструменты

В этом разделе мы обсудим другие полезные инструменты от разных производителей, которые также могут облегчить процесс исследования производительности.

## ildasm и ilasm

ildasm позволяет получить дизассемблированный код сборки .NET на промежуточном языке и сохранить его в текстовом файле. Этот инструмент сопровождает ilasm, который создает сборку .NET из исходников на промежуточном языке. Таким образом, вы можете декомпилировать сборку в код на промежуточном языке с помощью ildasm, внести в нее изменения и создать измененную сборку с помощью ilasm. Оба инструмента устанавливаются вместе с Visual Studio и доступны из консоли командной строки разработчика. Типичные пути установки этих инструментов выглядят примерно так: `c:\Program Files (x86)\Microsoft SDKs\Windows\v10.0A\bin\NETFX 4.7.1 Tools\ildasm.exe` и `c:\Windows\Microsoft.NET\Framework\v4.0.30319\ilasm.exe`.

Допустим, у нас есть файл `Program.cs` следующего содержания:

```
using System;
namespace ConsoleApp
{
    class Program
    {
        static void Main(string[] args)
        {
            Console.WriteLine("Hello World!");
        }
    }
}
```

Скомпилируем его с помощью Roslyn:

```
csc Program.cs
```

Теперь у нас есть сборка `Program.exe`, которую можно декомпилировать в код на промежуточном языке:

```
ildasm.exe Program.exe /out:Program.il
```

Эта команда создает `Program.il` со всеми метаданными сборки на промежуточном языке. В середине этого файла можно найти следующие строки:

```
.class private auto ansi beforefieldinit ConsoleApp.Program
    extends [mscorlib]System.Object
{
    .method private hidebysig static void Main(string[] args) cil managed
    {
        .entrypoint
        // Code size          13 (0xd)
        .maxstack      8
```

```

IL_0000:  nop
IL_0001:  ldstr      "Hello World!"
IL_0006:  call      void [mscorlib]System.Console::WriteLine(string)
IL_000b:  nop
IL_000c:  ret
} // конец метода Program::Main

.method public hidebysig specialname rtspecialname
  instance void .ctor() cil managed
{
  // Code size          8 (0x8)
  .maxstack    8
  IL_0000:  ldarg.0
  IL_0001:  call      instance void [mscorlib]System.Object::.ctor()
  IL_0006:  nop
  IL_0007:  ret
} // конец метода Program::.ctor

} // конец класса ConsoleApp.Program

```

Откроем этот файл в текстовом редакторе и поменяем `IL_0001: ldstr "Hello World!"` на `IL_0001: ldstr "Modified"`. Затем скомпилируем его обратно в исполняемый файл:

```
ilasm.exe Program.il
```

Теперь если мы воспроизведем `Program.exe`, вместо "Hello World!" получим "Modified".

Этот подход особенно полезен, если вы хотите внести несколько изменений в сборку, не пересобирая весь проект в командной строке.

URL: <https://docs.microsoft.com/en-us/dotnet/framework/tools/ildasm-exe-il-disassembler>.

Закрытый исходный код, бесплатно, только для Windows.

## Monodis

Monodis — это версия `ildasm` для Mono. Он выполняет такое же изменение кода на промежуточном языке, как и в предыдущем примере, но на всех платформах. Monodis выводит код на промежуточном языке в качестве результата, поэтому `ildasm.exe Program.exe /out:Program.il` можно переписать таким образом:

```
monodis Program.exe > Program.il
```

В Mono существует и `ilasm` (с тем же названием).

URL: [www.mono-project.com/docs/tools+libraries/tools/monodis/](http://www.mono-project.com/docs/tools+libraries/tools/monodis/).

Открытый исходный код, бесплатно, кросс-платформенный инструмент.

## ILSpy

ILSpy — это инструмент для просмотра и декомпиляции сборки .NET (рис. 6.10). Это довольно простой декомпилятор без многих функций пользовательского интерфейса. Однако он позволяет использовать свой механизм декомпиляции с помощью пакета NuGet ICSharpCode.Decompiler. Таким образом, вы легко можете встроить этот декомпилятор в свои инструменты.

Изначально ILSpy был приложением только для Windows, но теперь есть и кросс-платформенная версия, основанная на Avalonia (<https://github.com/AvaloniaUI/Avalonia>).

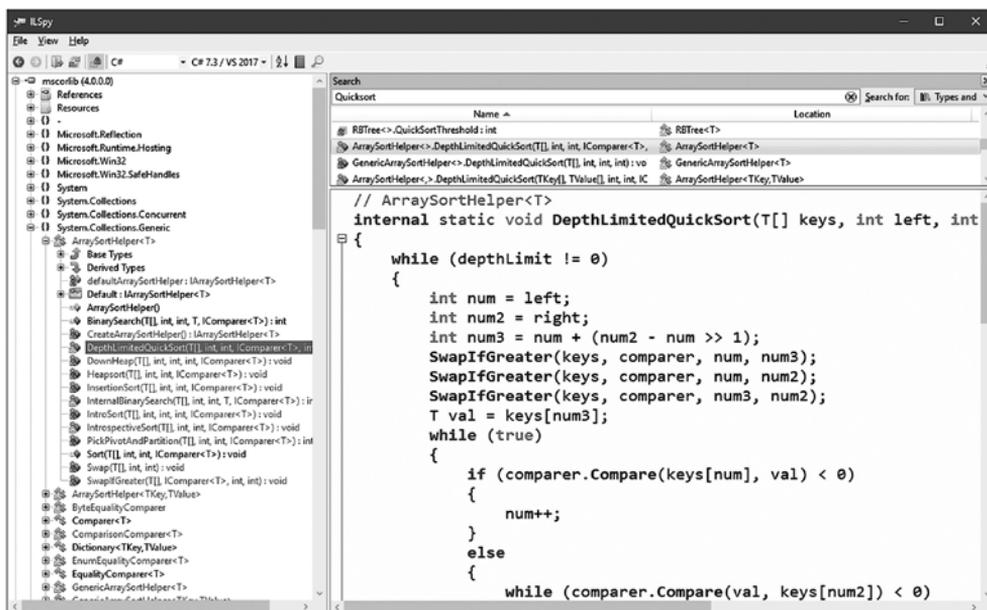


Рис. 6.10. ILSpy

URL: <https://github.com/icsharpcode/ILSpy>, <https://github.com/icsharpcode/AvaloniaILSpy>.

Открытый исходный код (MIT), бесплатно, кросс-платформенный инструмент.

## dnSpy

dnSpy — это отладчик и редактор сборки .NET (рис. 6.11). Его полезные функции:

- декомпиляция на C#, VB и промежуточный язык;
- редактирование сборок на C#/VB/промежуточном языке и метаданных;
- отладка сборок в .NET Framework, .NET Core и Unity без исходного кода;
- мощный редактор шестнадцатеричного кода на промежуточном языке.

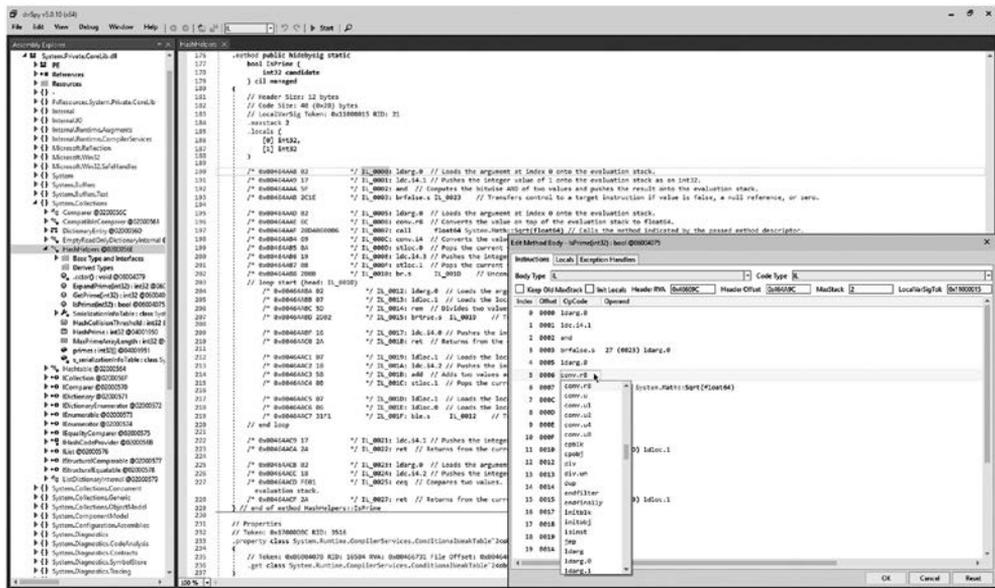


Рис. 6.11. dnSpy

Механизм декомпиляции основан на ILSpy, а механизм компиляции — на Roslyn.

Самая полезная функция dnSpy — редактирование сборки: вы можете легко изменить любую инструкцию на промежуточном языке в сторонней сборке, даже не имея исходного кода. Это значительно упрощает эксперименты, когда вы пытаетесь найти проблему с производительностью в одной из взаимозависимостей своего проекта. Даже если вы работаете над собственной сборкой, dnSpy позволяет вносить небольшие исправления в код, не требуя долгой повторной компиляции всего проекта.

URL: <https://github.com/0xd4d/dnSpy>.

Открытый исходный код (GPLv3), бесплатно, только для Windows.

## WinDbg

WinDbg — самый многофункциональный низкоуровневый отладчик для Windows. Он позволяет профилировать приложения для Windows. Обширный набор команд помогает получить любую информацию, необходимую при отладке.

Команда `.loadby sos clr` загружает специальное расширение WinDbg под названием SOS (Son of Strike), которое предоставляет много дополнительных команд для приложений на .NET. С помощью WinDbg можно исследовать все объекты, потоки, стеки запросов, блокировки и области динамической памяти в среде исполнения, а также управляемую и неуправляемую память, реестры и дизассемблированный код.

У классической версии WinDbg довольно скудный пользовательский интерфейс, и ее сложно использовать. К счастью, существует современная версия WinDbg с переработанным интерфейсом, доступная в Microsoft Store (см. [Luhrs, 2017]).

Снимок экрана современной версии представлен на рис. 6.12.

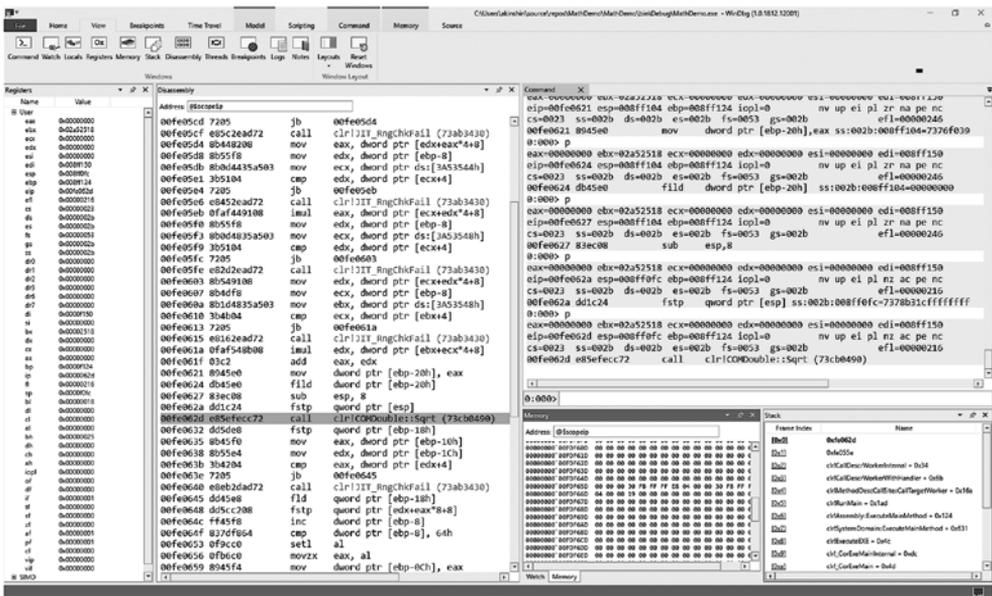


Рис. 6.12. WinDbg

URL: <https://docs.microsoft.com/en-us/windows-hardware/drivers/debugger/debugger-download-tools>.

Закрывать исходный код, бесплатно, только для Windows.

Ресурсы: [Goldshtein, 2016b], <https://docs.microsoft.com/en-us/windows-hardware/drivers/debugger/debugging-using-windbg>, <http://windbg.info/doc/1-common-cmds.html>, <https://theartofdev.com/windbg-cheat-sheet/>.

## Asm-Dude

Asm-Dude — это расширение для Visual Studio 2015+, улучшающее поддержку дизассемблирования. Оно включает в себя следующие полезные функции:

- **улучшенное окно инструментов для дизассемблирования.** Расширение применяет синтаксическое выделение в окне инструментов для дизассемблирования и предоставляет подсказки QuickInfo с подробной информацией о каждой инструкции сборки и характеристиках ее производительности;
- **поддержка языка ASM.** Также в редакторе можно использовать синтаксическое выделение, подсказки QuickInfo, автодополнение кода, сворачивание кода, помощь с подписью и анализ ярлыков. Он значительно упрощает редактирование программ дляборок.

URL: <https://github.com/HJLebbink/asm-dude>.

Открытый исходный код (MIT), бесплатно, только для Windows.

## Консольные инструменты для Mono

В Mono есть несколько встроенных инструментов, которые могут пригодиться при исследованиях. Например, Mono позволяет просматривать сгенерированный собственный код любого метода. Допустим, у нас есть следующая программа:

```
using System;
namespace MyApp
{
    class Program
    {
        static void Main()
        {
            int x = 3, y = 4;
            double z = Math.Sqrt(x * x + y * y);
            Console.WriteLine(z);
        }
    }
}
```

Мы можем попросить Mono скомпилировать этот метод, не исполняя его, с помощью следующей команды в Linux/macOS:

```
$ MONO_VERBOSE_METHOD=MyApp.Program:Main mono
    --compile MyApp.Program:Main Program.exe
```

А так выглядит версия для Windows:

```
> SET MONO_VERBOSE_METHOD=MyApp.Program:Main
> mono --compile MyApp.Program:Main Program.exe
```

В конце результатов выполнения этой команды будет находиться примерно такой машинный код:

```
0000000000000000 subq    0x8,  %rsp
0000000000000004 movl   0x19, %eax
0000000000000009 cvtsi2sd1  eax, %xmm0
000000000000000d movsd  xmm0, -0x8( %rsp)
0000000000000013 fldl   0x8( %rsp)
0000000000000017 fsqrt
0000000000000019 fstpl  -0x8( %rsp)
000000000000001d movsd  -0x8( %rsp), %xmm0
0000000000000023 nop
0000000000000026 movabsq $0x106f05fc8, %r11
0000000000000030 callq  * %r11
0000000000000033 addq   $0x8,  %rsp
0000000000000037 retq
```

Моно также позволяет запускать программу с профайлером Моно для журнала:

```
$ mono --profile=log Program.exe
```

В качестве результата вы получите файл `output.mlpd`, который можно будет открыть с помощью `mprof-report` или Xamarin Profiler (<https://docs.microsoft.com/en-us/xamarin/tools/profiler>). У профайлера Моно много опций, о которых можно узнать из официальной документации.

URL: <https://github.com/mono/mono/>.

Открытый исходный код (MIT/BSD), бесплатно, кросс-платформенный инструмент.

Ресурсы: [www.mono-project.com/docs/](http://www.mono-project.com/docs/), [www.mono-project.com/docs/debug+profile/profile/profiler](http://www.mono-project.com/docs/debug+profile/profile/profiler).

## PerfView

PerfView — это бесплатный инструмент для анализа производительности (рис. 6.13). Он может собирать события ETW и анализировать полученные данные. ETW — это встроенный механизм Windows с поддержкой приложений на .NET с чрезвычайно низкими ограничениями, что делает PerfView очень полезным инструментом для системы мониторинга.

URL: <http://aka.ms/perfview>.

Открытый исходный код (MIT), бесплатно, только для Windows.

Ресурсы: [Goldshtein, 2016a].

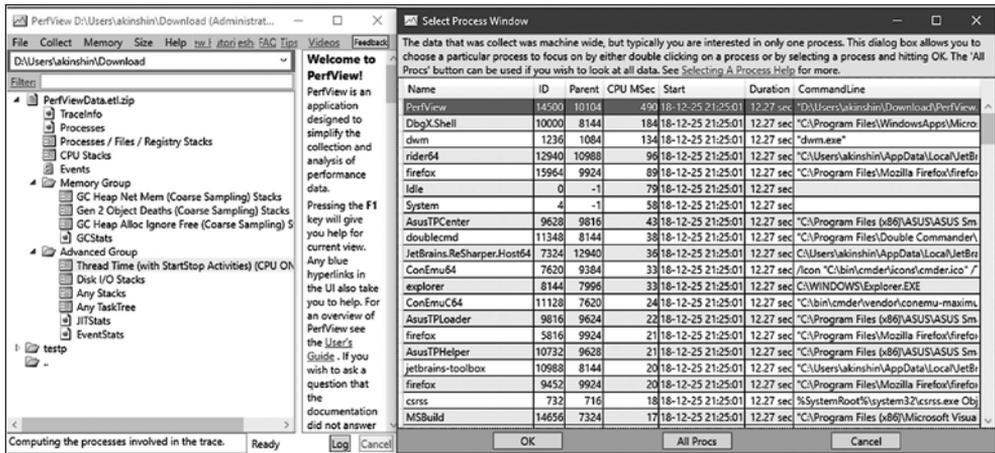


Рис. 6.13. PerfView

## perfcollect

perfcollect — это скрипт для bash, автоматизирующий измерение производительности в приложениях на .NET Core для Linux. Полученную информацию можно просмотреть с помощью PerfView для Windows.

URL: <http://aka.ms/perfcollect>.

Открытый исходный код (MIT), бесплатно, только для Linux.

Ресурсы: [Kokosa, 2017], [Goldshtein, 2017], <https://github.com/dotnet/coreclr/blob/master/Documentation/project-docs/linux-performance-tracing.md>.

## Process Hacker

Process Hacker — бесплатный многофункциональный и многоцелевой инструмент, который поможет вам отслеживать ресурсы системы, отлаживать программное обеспечение и распознавать вредоносные программы. Это продвинутая версия стандартного диспетчера задач Windows. В наборе Sysinternals есть похожий инструмент под названием Process Explorer (<https://docs.microsoft.com/en-us/sysinternals/downloads/process-explorer>).

В Process Hacker вы можете получить подробный обзор каждого процесса с общей статистикой (использование процессора, памяти, ввода-вывода), графиками производительности, десятками метрик производительности для .NET (например, размер динамической памяти системы, очистка диска, количество скомпилированных методов, количество выброшенных исключений и т. д.), загруженными сборками

.NET, информацией о потоках (с мониторингом стеков), переменными окружения, признаками, модулями, дескрипторами и сегментами памяти (рис. 6.14).

URL: <https://github.com/processhacker/processhacker>.

Открытый исходный код (GPLv3), бесплатно, только для Windows.

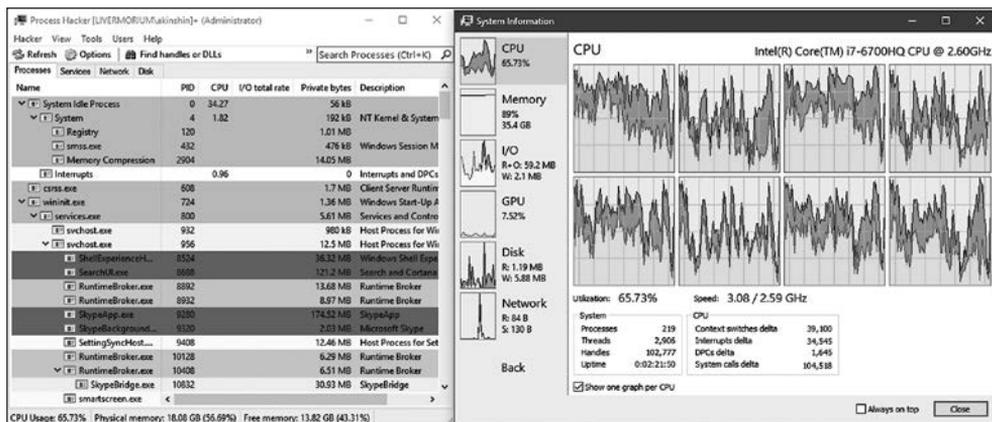


Рис. 6.14. Process Hacker

## Intel VTune Amplifier

Intel VTune Amplifier — это расширенный многоцелевой профайлер (рис. 6.15). Он знаком с сотнями аппаратных счетчиков, поддерживаемых процессором Intel. При особенно сложных исследованиях производительности почти невозможно прийти к каким-либо выводам без данных этих счетчиков.

У VTune много режимов профилирования для разных вариантов использования. Они делятся на четыре группы: «Популярные», «Микроархитектура», «Параллелизм» и «Анализ платформы». Все режимы можно конфигурировать: множество настроек позволяют подстраивать сеанс профилирования под себя и получать результаты только по тем метрикам, которые вам нужны. Один из моих любимых режимов — «Исследование микроархитектуры»: он позволяет получить данные многих аппаратных счетчиков, недоступных в других профайлерах.

Он прекрасно поддерживает разные языки, например C, C++, C#, Fortran, Java, Python, Go и Assembly. У VTune 2019+ есть расширенная поддержка приложений .NET Core.

URL: <https://software.intel.com/en-us/vtune>.

Закрывает исходный код, платно, кросс-платформенный инструмент.

Ресурсы: [Lander, 2018].

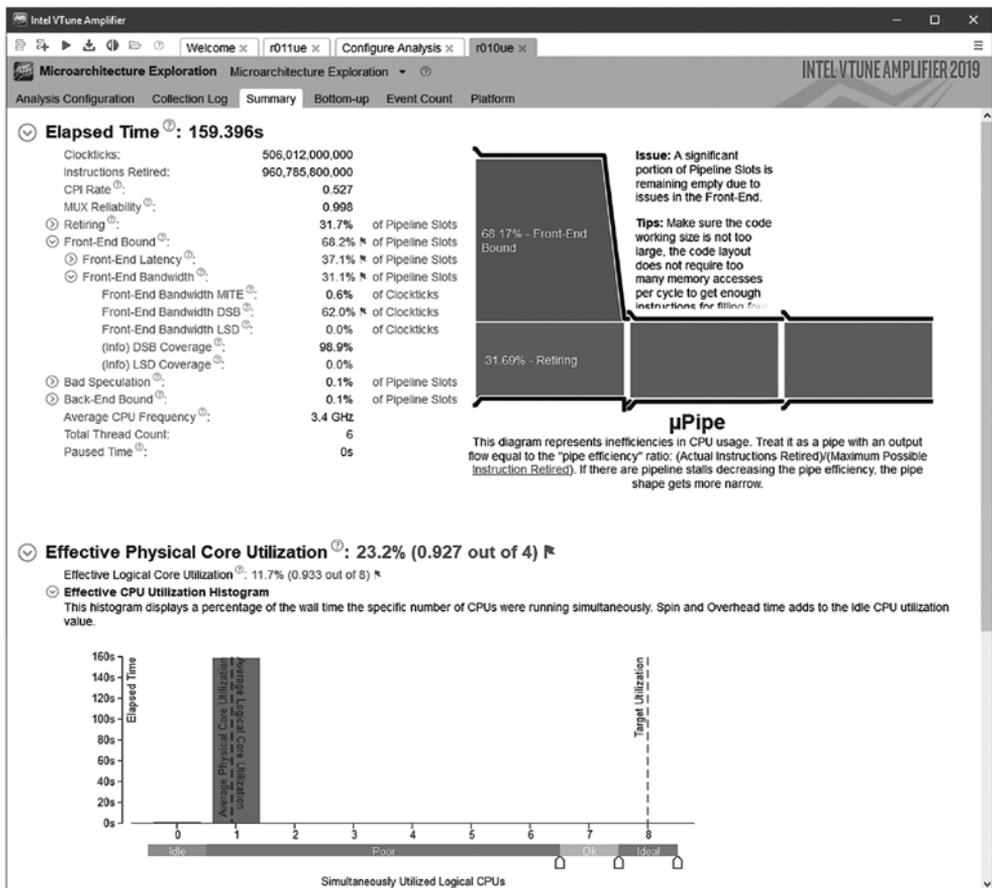


Рис. 6.15. Intel VTune Amplifier

## Выводы

В этой главе мы кратко обсудили инструменты для диагностики, которые могут пригодиться при исследованиях производительности:

- **средство для бенчмаркинга** — BenchmarkDotNet;
- **профайлеры производительности** — встроенный профайлер Visual Studio, встроенный профайлер Rider, dotTrace, Intel VTune Amplifier, Mono Console Tools, perffcollect с PerfView;
- **профайлеры памяти** — встроенный профайлер Visual Studio, dotMemory, Intel VTune Amplifier, VMMap, Mono Console Tools;

- **декомпиляторы на C#/VB** – ILSpy, dnSpy, dotPeek, Rider, ReSharper;
- **декомпиляторы на промежуточном языке** – ildasm, Monodis, ILSpy, dnSpy, dotPeek, ReSharper (с помощью IL Viewer), Intel VTune Amplifier, BenchmarkDotNet (с помощью DisassemblyDiagnoser);
- **декомпиляторы на ASM** – обзор дизассемблирования Visual Studio (лучше использовать с Asm-Dude), WinDbg, BenchmarkDotNet (с помощью DisassemblyDiagnoser), Mono Console Tools;
- **отладчики** – встроенный отладчик Visual Studio, встроенный отладчик Rider, WinDbg;
- **инструменты для наблюдения за системой** – Process Hacker, RAMMap, Process Monitor.

Хороший бенчмарк отвечает на такие вопросы, как «Сколько времени занимает этот метод?», но не отвечает на вопрос «Почему он столько длится?». Для полного исследования производительности зачастую нужны дополнительные инструменты, помогающие диагностировать приложения и приходиться к осмысленным выводам.

Конечно, это не полный список доступных инструментов. Вы с легкостью можете найти остальные в Интернете. Я описал только те, которыми обычно пользуюсь. Вы можете выбрать любые инструменты, которые вам нравятся.

В этой главе были использованы следующие версии инструментов: BenchmarkDotNet v0.11.3 Visual Studio 2017 (15.9), dotPeek/dotTrace/dotMemory/ReSharper/Rider 2018.3, RAMMap 1.51, VMMap 3.25, Process Monitor 3.50, ildasm 4.0.30319.0, ILSpy 4.0 Beta 2, dnSPY 5.0.10, WinDbg Preview 1.0.1812.12001, PerfVew 2.0.26, Asm-Dude 1.9.5.3, Mono 5.16, ProcessHacker 3.0.1563, Intel VTune Amplifier 2019 Update 2. Обновленные версии этих инструментов могут включать изменения в функциях и политике лицензирования.

## Источники

[Balliauw, 2017a] *Balliauw M.* Exploring Intermediate Language (IL) with ReSharper and dotPeek. 2017. January 19. <https://blog.jetbrains.com/dotnet/2017/01/19/exploring-intermediate-language-il-with-resharper-and-dotpeek/>.

[Balliauw, 2017b] *Balliauw M.* Debugging Third-Party Code with Rider. 2017. December 20. <https://blog.jetbrains.com/dotnet/2017/12/20/debugging-third-party-code-rider/>.

[Goldshtein, 2016a] *Goldshtein S.* PerfView: Measure and Improve Your App's Performance for Free // Presented at DotNext Piter 2016, June 3. [www.youtube.com/watch?v=eX644hod65s](http://www.youtube.com/watch?v=eX644hod65s).

[Goldshtein, 2016b] *Goldshtein S.* WinDbg Superpowers for .NET Developers // Presented at DotNext Moscow 2016, December 9. [www.youtube.com/watch?v=8t1aTbnZ2CE](http://www.youtube.com/watch?v=8t1aTbnZ2CE).

[Goldshtein, 2017] *Goldshtein S.* Profiling a .NET Core Application on Linux. 2017. February 27. <http://blogs.microsoft.co.il/sasha/2017/02/27/profiling-a-netcore-application-on-linux/>.

[Kokosa, 2017] *Kokosa K.* Analyzing Runtime CoreCLR Events from Linux — Trace Compass. 2017. August 7. <http://tooslowexception.com/analyzing-runtime-coreclr-events-from-linux-trace-compass/>.

[Lander, 2018] *Lander R.* NET Core Source Code Analysis with Intel® VTune™ Amplifier // Microsoft .NET Blog, 2018. October 23. <https://blogs.msdn.microsoft.com/dotnet/2018/10/23/net-core-source-code-analysis-with-intel-vtuneamplifier/>.

[Luhrs, 2017] *Luhrs A.* New WinDbg Available in Preview! 2017. August 28. <https://blogs.msdn.microsoft.com/windbg/2017/08/28/new-windbg-available-inpreview/>.

[Rusinovich, 2017] *Yosifovich P., Rusinovich M. E., Solomon D. A., Ionescu A.* Windows Internals, Part 1. 7th ed. Microsoft Press, 2017.

[Rusinovich, 2019] *Rusinovich M. E., Solomon D. A., Ionescu A., Allievi A.* Windows Internals, Part 2. 7th ed. Microsoft Press, 2019.

[Sitnik, 2017a] *Sitnik A.* Collecting Hardware Performance Counters with BenchmarkDotNet. 2017. April 4. <https://adamsitnik.com/Hardware-Counters-Diagnoser/>.

[Sitnik, 2017b] *Sitnik A.* Disassembling .NET Code with BenchmarkDotNet. 2017. August 16. <https://adamsitnik.com/Disassembly-Diagnoser/>.

[Sitnik, 2018] *Sitnik A.* Profiling .NET Code with BenchmarkDotNet. 2018. September 28. <https://adamsitnik.com/ETW-Profiler/>.

# 7

## Бенчмарки, ограниченные возможностями процессора

Тук-тук.

Прогнозирование ветвления.

Кто там?

*Классическая шутка программистов*

Одно из самых распространенных мест заторов в бенчмарках — это центральный процессор. Правильная разработка и анализ бенчмарков, ограниченных возможностями процессора, требуют знания различных характеристик среды исполнения и устройств, способных повлиять на производительность. В любой среде исполнения .NET есть множество оптимизаций, которые могут улучшить или ухудшить производительность вашего кода. У каждой микроархитектуры процессора много низкоуровневых механизмов, которые также способны повлиять на результаты измерений. Не зная об этих оптимизациях и механизмах, сложно разрабатывать некоторые из бенчмарков и правильно интерпретировать метрики. В этой главе рассмотрим следующие темы.

- **Регистры и стек.**

Мы обсудим, когда компилятор JIT хранит промежуточные значения в регистрах, а когда в стеке.

- **Инлайнинг.**

Поговорим о том, когда компилятор JIT может заинлайнить ваши методы и почему это имеет большое значение.

- **Параллелизм на уровне команд (ILP).**

Рассмотрим одну из важнейших характеристик аппаратных средств — ILP, позволяющую обрабатывать несколько команд одновременно в одном потоке.

- **Прогнозирование ветвлений.**

Обсудим способность современных процессоров прогнозировать, какие ветви будут включены в программы. Правильные прогнозы помогают улучшать

условия ILP. Это важно для бенчмаркинга, поскольку входные данные могут заметно повлиять на производительность метода, основываясь на количестве правильных прогнозов.

- **Арифметика.**

Мы расскажем, какие проблемы могут возникнуть с бенчмарками, использующими арифметические операции. Обсудим функции аппаратных средств (числа с плавающей запятой и IEEE 754) и среды исполнения (разные окружения и оптимизации JIT).

- **Интринзики.**

Рассмотрим случаи, когда компилятор JIT может сгенерировать разумную собственную реализацию конкретных методов и выражений.

Полные описания каждой из тем довольно объемны, потому что включают в себя множество подробностей о внутренних составляющих аппаратных средств и среды исполнения. Однако при бенчмаркинге вам не обязательно знать все эти внутренние составляющие. В этой главе мы обсудим только высокоуровневые концепции, которые полезно знать. В каждом разделе рассмотрены четыре практических примера, демонстрирующих влияние этих концепций даже на небольшие простые бенчмарки. Во всех примерах по четыре раздела.

- **Исходный код.**

Небольшой набор бенчмарков, показывающий интересное воздействие на производительность. Исходный код всех примеров можно найти в приложении к книге.

- **Результаты.**

Результаты бенчмарка в *конкретном* окружении. Если вы не можете воспроизвести этот результат на своем устройстве, проверьте версии вашей ОС, .NET Core, .NET Core SDK, среды исполнения, компилятора JIT и модель процессора. Производительность всегда зависит от окружения: что угодно может испортить описанный феномен в области производительности или вызвать еще один.

- **Объяснение.**

Краткое описание наблюдаемых результатов. Мы часто будем изучать сгенерированный код на промежуточном языке и собственный код, чтобы понять, что происходит в примере.

- **Обсуждение.**

Общие рекомендации по поводу рассматриваемых эффектов, дополнительная интересная информация, ссылки на вопросы на GitHub и другие источники для дальнейшего изучения. Многие практические примеры основаны на замечательных вопросах и ответах с StackOverflow, соответствующие ссылки приведены в конце раздела.

Вы узнаете о самых распространенных ошибках, совершаемых разработчиками из-за незнания каких-то подводных камней бенчмаркинга. Это поможет вам разработать более качественные бенчмарки, ограниченные возможностями процессора, и правильно интерпретировать их результаты.

## Регистры и стек

Если у нас есть локальная переменная, компилятор JIT может поместить ее в регистры или стек. Операции с регистрами обычно гораздо быстрее операций со значениями из стека. Таким образом, решение компилятора JIT может заметно повлиять на производительность. Невозможно хранить все локальные переменные в регистре, поскольку количество регистров ограничено и компилятор JIT должен применять их разумно. В разных наборах команд процессора различное количество регистров.

### Практический пример 1: продвижение структуры

Во многих случаях при использовании в локальных переменных значения структурного типа компилятор JIT сохраняет его поля в стеке. В некоторых особых случаях они могут быть сохранены в регистре. Этот подход известен как *продвижение структуры* или *скалярная замена*. Он применяется в RyuJIT, но вручную включить или отключить эту функцию для конкретного метода нельзя. Ознакомимся с примером, показывающим ограничения продвижения структуры.

#### Исходный код

Рассмотрим бенчмарк на базе BenchmarkDotNet:

```
public struct Struct3
{
    public byte X0, X1, X2;
}

public struct Struct8
{
    public byte X0, X1, X2, X3, X4, X5, X6, X7;
}

public class Benchmarks
{
    public const int Size = 256;

    private int[] sum = new int[Size];
    private Struct3[] struct3 = new Struct3[Size];
    private Struct8[] struct8 = new Struct8[Size];
```

```

[Benchmark(OperationsPerInvoke = Size, Baseline = true)]
public void Run3()
{
    for (var i = 0; i < sum.Length; i++)
    {
        Struct3 s = struct3[i];
        sum[i] = s.X0 + s.X1;
    }
}

[Benchmark(OperationsPerInvoke = Size)]
public void Run8()
{
    for (var i = 0; i < sum.Length; i++)
    {
        Struct8 s = struct8[i];
        sum[i] = s.X0 + s.X1;
    }
}
}

```

Здесь две структуры: `Struct3` с тремя полями `byte` и `Struct8` с восемью полями `byte`. У нас два бенчмарка, `Run3` и `Run8`. В каждом из них вычисляем сумму первых двух структурных полей в цикле. Единственное различие между `Run3` и `Run8` заключается в используемой структуре.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 2.1.5, RyuJIT-x64):

Method	Mean	StdDev	Ratio
Run3	1.100 ns	0.0091 ns	1.00
Run8	1.579 ns	0.0115 ns	1.44

Как видите, `Run8` работает гораздо медленнее. `Run8` использует `Struct8`, которая похожа на `Struct3`, но содержит на пять полей больше. Эти поля на самом деле не используются в бенчмарке, но мы все равно получаем падение производительности на ~ 30–50 %.

## Объяснение

Посмотрим на собственный код тела цикла `Run3`:

```

; Run3
lea r8,[r8+r10+10h]                ; r8 = &struct3[i]
movzx r10d,byte ptr [r8]           ; r10d = X0
movzx r11d,byte ptr [r8+1]        ; r11d = X1
movzx r8d,byte ptr [r8+2]         ; r8d = X2

```

```

mov r8,rdx ; r8 = &sum
cmp eax,dword ptr [r8+8] ; if (i > sum.Length)
jae 00007ffe`e62a2b74 ; throw
add r10d,r11d ; r10d += r11d
mov dword ptr [r8+r9*4+10h],r10d ; sum[i] = r10d

```

Как видите, мы находим локацию `struct3[i]` и загружаем три поля, `X0`, `X1` и `X2`, в регистры `r10d`, `r11d` и `r8d` соответственно. Так работает продвижение структуры! Нам не нужно поле `X2`, но JIT по умолчанию загружает все поля. Затем мы складываем `r11d` с `r10d` и сохраняем результат в `sum[i]`.

Теперь посмотрим на собственный код тела цикла `Run8`:

```

; Run8
mov rdx,qword ptr [rdx+r8*8+10h] ; rdx = struct8[i]
mov qword ptr [rsp+20h],rdx ; [rsp+20h] = struct8[i]
mov rdx,qword ptr [rcx+8] ; rdx = &sum
mov r9,rdx ; r9 = &sum
cmp eax,dword ptr [r9+8] ; if (i > sum.Length)
jae 00007ffe`e6272b7a ; throw
movzx r10d,byte ptr [rsp+20h] ; r10d = X0
movzx r11d,byte ptr [rsp+21h] ; r11d = X1
add r10d,r11d ; r10d += r11d
mov dword ptr [r9+r8*4+10h],r10d ; sum[i] = r10d

```

Здесь мы сначала загружаем `struct8[i]` в стек. После этого загружаем первые два поля `struct8[i]` из стека в регистры `r10d` и `r11d`. Затем складываем `r11d` с `r10d` и сохраняем результат в `sum[i]`.

Как видите, RyuJIT смог применить продвижение структуры в `Run3` и не смог — в `Run8`. Этот результат можно объяснить ограничением RyuJIT в .NET Core 2.1: он не может продвигать структуры, в которых больше четырех полей.

## Обсуждение

В .NET Core 1.x/2.x у реализации скалярного замещения много ограничений. Например, продвигаемая структура должна соответствовать следующим требованиям (<https://github.com/dotnet/coreclr/issues/6733#issuecomment-240623400>).

- В ней должны быть только непроеизводные поля.
- Она не должна быть аргументом или возвращенным значением, передающимся в регистрах.
- Она не может быть больше 32 байт.
- В ней не может быть больше четырех полей.

В общем-то, не рекомендуется при оптимизации полагаться на эти конкретные эвристические правила, поскольку они могут измениться в будущих версиях RyuJIT. Также они недействительны при использовании других компиляторов JIT,

таких как LegacyJIT-х64 или MonoJIT. Но если вам действительно нужно оптимизировать какие-нибудь горячие методы и версия .NET Core исправлена, можете применить эту информацию, но имеет смысл проверять такие оптимизации после каждого обновления .NET Core (это можно автоматизировать с помощью тестов производительности).

Мы обсудили этот пример, поскольку знание концепции продвижения структур помогает правильно интерпретировать результаты работы бенчмарков. При разработке небольшого бенчмарка, основанного на реальном приложении, не рекомендуется изменять используемые структуры, даже если какие-то из их полей в бенчмарке не задействуются. Любые изменения в составе структур могут повлечь за собой непредсказуемые изменения производительности.

В этом конкретном бенчмарке есть также интересные проблемы с производительностью, связанные с памятью. Обсудим их в главе 8.

См. также:

- `coreclr#6839 Promote (scalar replace) structs with more than fields` (<https://github.com/dotnet/coreclr/issues/6839>);
- `coreclr#6733 Scalar replacement of aggregates` (<https://github.com/dotnet/coreclr/issues/6733>);
- документы по разработке CoreCLR: *First Class Structs* (<https://github.com/dotnet/coreclr/blob/v2.2.0/Documentation/design-docs/firstclass-structs.md>).

Этот практический пример основан на вопросе 38949304 на StackOverflow (<https://stackoverflow.com/q/38949304>).

## Практический пример 2: локальные переменные

Ввод локальной переменной — распространенное перестроение, которое может сделать ваш код более понятным. Эта модификация кода не меняет логику, поэтому разработчики не ожидают того, что перестроение повлияет на производительность приложения. Однако *любые изменения* в исходном коде могут изменить производительность.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public struct Struct
{
    public Struct(uint? someValue)
    {
        SomeValue = someValue;
    }
}
```

```

    public uint? SomeValue { get; }
}

public class Benchmarks
{
    [Benchmark(Baseline = true)]
    public uint? Foo()
    {
        return new Struct(100).SomeValue;
    }

    [Benchmark]
    public uint? Bar()
    {
        Struct s = new Struct(100);
        return s.SomeValue;
    }
}

```

У нас есть два бенчмарка, `Foo` и `Bar`. Оба метода делают одно и то же — создают копию структуры `Struct` (оберточного кода, значимого для типа `uint?`) и возвращают ее единственное поле. При этом `Bar` отличается от `Foo`: он сохраняет копию структуры в локальную переменную вместо того, чтобы использовать ее в возвращаемом выражении. Исполняемая логика в обоих случаях идентична, но есть небольшие изменения на уровне `C#`. Обычно при таком простом перестроении кода мы не ожидаем изменения производительности.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core SDK 2.1.403, .NET Core 2.1.5, RyuJIT-x64):

Method	Mean	StdDev	Ratio
-----	-----:	-----:	-----:
Foo	6.597 ns	0.0433 ns	1.00
Bar	4.975 ns	0.0439 ns	0.75

Как видите, `Bar` работает на ~ 20–30 % быстрее, чем `Foo`. Как такое возможно?

## Объяснение

Посмотрим на сгенерированный код на промежуточном языке (Roslyn 2.9.0.63127):

```

// Foo()
.maxstack 1
.locals init (
    [0] valuetype Struct V_0
)
IL_00: ldc.i4.s    100
IL_02: newobj     System.Void System.Nullable`1::.ctor(!0)
IL_07: newobj     System.Void Struct::.ctor(System.Nullable`1)

```

```

IL_0c: stloc.0    // V_0
IL_0d: ldloc.s  V_0
IL_0f: call     System.Nullable`1 Struct::get_SomeValue()
IL_14: ret

// Bar()
.maxstack 2
.locals /*11000001*/ init (
  [0] valuetype Struct s
)
IL_00: ldloc.s  s
IL_02: ldc.i4.s 100
IL_04: newobj   System.Void System.Nullable`1::ctor(!0)
IL_09: call     System.Void Struct::ctor(System.Nullable`1)
IL_0e: ldloc.s  s
IL_10: call     System.Nullable`1 Struct::get_SomeValue()
IL_15: ret

```

Как видите, между этими методами есть некоторые различия. `Foo` создает `Struct` с помощью `newobj`, загружает результат в локальную переменную и затем загружает адрес этой переменной. `Bar` создает `Struct` с помощью `call`, который сохраняет результат в локальную переменную, и мгновенно загружает адрес этой переменной. Обе реализации эквивалентны друг другу, но используют разные команды на промежуточном языке.

Теперь посмотрим на сгенерированный собственный код `Foo()`:

```

; Foo()
sub  rsp,18h
xor  eax,eax;           ; Initialize Struct
mov  qword ptr [rsp+10h],rax ; Store Struct into stack

mov  eax,64h           ; eax = 100
mov  edx,1             ; edx = 1

xor  ecx,ecx;         ; Initialize SomeValue
mov  qword ptr [rsp+8],rcx ; Store SomeValue into stack
lea  rcx,[rsp+8]      ; rcx = pointer to SomeValue
mov  byte ptr [rcx],d1 ; SomeValue.HasValue = 1
mov  dword ptr [rcx+4],eax ; SomeValue.Value = 100

mov  rax,qword ptr [rsp+8] ; rax = pointer to SomeValue
mov  qword ptr [rsp+10h],rax ; Store SomeValue to a different location on stack
mov  rax,qword ptr [rsp+10h] ; rax = pointer to SomeValue

add  rsp,18h
ret

```

Как видите, пара `stloc.0/ldloc.a.s` заставляет RyuJIT генерировать избыточные команды `mov`. А вот собственный код `Var`:

```
; Var()
push  rax
xor   eax,eax           ; Initialize Struct
mov   qword ptr [rsp],rax ; Store Struct into stack
mov   eax,64h          ; eax = 100
mov   edx,1            ; edx = 1

lea   rcx,[rsp]        ; rcx = pointer to SomeValue
mov   byte ptr [rcx],dl ; SomeValue.HasValue = 1
mov   dword ptr [rcx+4],eax ; SomeValue.Value = 100
mov   rax,qword ptr [rsp] ; rax = pointer to SomeValue

add   rsp,8
ret
```

Он выглядит более эффективным, так как не содержит избыточных команд.

## Обсуждение

Любое перестроение кода, не меняющее логики, может изменить сгенерированный код на промежуточном языке. Любые изменения в коде на промежуточном языке могут непредсказуемо повлиять на эффективность сгенерированного кода. Когда разработчики создают бенчмарки, основанные на сценариях из реальной жизни, они часто делают небольшие перестроения, чтобы бенчмарк проще было понять. К сожалению, такие перестроения могут дополнительно воздействовать на производительность и ухудшить (или улучшить) ее. При перестроении в существующем бенчмарке рекомендуется убедиться, что сделанные вами изменения в коде не влияют на результаты.

В подобных случаях производительность зависит от версии компилятора. Предыдущий пример достоверен для Roslyn 2.9.0.63127 (поставляется в пакете .NET Core SDK 2.1.403), но это может измениться в будущих версиях (см. подробности в [roslyn#30284](https://github.com/dotnet/roslyn/issues/30284) (<https://github.com/dotnet/roslyn/issues/30284>)).

Ситуации, когда небольшие изменения в исходном коде дают интересные эффекты в области производительности, встречаются часто. Например, в вопросе 53452713 на StackOverflow (<https://stackoverflow.com/q/53452713>) представлен простой бенчмарк на Java, ускоряющийся после замены  $2 * i * i$  на  $2 * (i * i)$ .

Этот практический пример основан на вопросе 52565479 на StackOverflow (<https://stackoverflow.com/q/52565479>).

## Практический пример 3: попытка-перехват

Правильно работать с исключениями очень важно, если вы хотите разрабатывать стабильные приложения на .NET. Многие разработчики на всякий случай помещают там и сям блоки «попытка-перехват». Они не ожидают снижения производительности, поскольку исключения считаются редкими. Может показаться, что если исходный код не выдает исключений, ограничения из-за блоков «попытка-перехват» будут незаметными. К сожалению, так происходит не всегда, поскольку компилятор JIT может изменить сгенерированный собственный код при добавлении такого блока.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private const int N = 93;

    [Benchmark(Baseline = true)]
    public long Fibonacci1()
    {
        long a = 0, b = 0, c = 1;
        for (int i = 1; i < N; i++)
        {
            a = b;
            b = c;
            c = a + b;
        }
        return c;
    }

    [Benchmark]
    public long Fibonacci2()
    {
        long a = 0, b = 0, c = 1;
        try
        {
            for (int i = 1; i < N; i++)
            {
                a = b;
                b = c;
                c = a + b;
            }
        }
        catch {}
        return c;
    }
}
```

У нас есть два метода, `Fibonacci1` и `Fibonacci2`, которые вычисляют 93-е число Фибоначчи<sup>1</sup>. Однако `Fibonacci2` заканчивает основной цикл блоком «попытка-перехват». Этот код не выдает исключений, поэтому, наверное, нам не стоит ожидать ограничений производительности?

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 2.1.5, RyuJIT-x64):

Method	Mean	StdDev	Ratio
Fibonacci1	41.07 ns	0.1446 ns	1.00
Fibonacci2	102.93 ns	0.3394 ns	2.50

В этом окружении `Fibonacci2` работает в 2,5 раза медленнее, чем `Fibonacci1`.

## Объяснение

Посмотрим на сгенерированный собственный код `Fibonacci1`:

```

; Fibonacci1
xor  eax, eax          ; a = 0
mov  edx, 1           ; c = 1
mov  ecx, 1           ; i = 1
LOOP:
mov  r8, rdx          ; b = c
lea  rdx, [rax+r8]    ; c = a + b
inc  ecx              ; i++
cmp  ecx, 5Dh         ; if (i < 93)
mov  rax, r8          ; a = b
jlt  LOOP             ; goto LOOP
mov  rax, rdx         ; result = c

ret                    ; return result

```

Эта реализация довольно проста. Переменные `a`, `b` и `c` представлены с помощью регистров `rax`, `r8` и `rdx`.

Теперь посмотрим на сгенерированный собственный код `Fibonacci2`:

```

; Fibonacci2
sub  esp, 10h         ; Reserve space
lea  rbp, [rsp+10h]  ; on stack
mov  qword ptr [rbp-10h], rsp ;

```

<sup>1</sup> 12 200 160 415 121 876 738. Это самое длинное число Фибоначчи, которое можно представить с помощью `long`.

```

xor   eax,eax                ; a = 0
mov   qword ptr [rbp-8],1    ; c = 1
mov   edx,1                  ; i = 1
LOOP:
mov   rcx,qword ptr [rbp-8]  ; b = c
add   rax,rcx                ; a += b
mov   qword ptr [rbp-8],rax  ; c = a
inc   edx                    ; i++
cmp   edx,5Dh                ; if (i < 93)
mov   rax,rcx                ; a = b
j1    LOOP                   ; goto LOOP
mov   rax,qword ptr [rbp-8]  ; result = c

lea   rsp,[rbp]              ; Recover stack pointer
pop   rbp                    ;
ret                                     ; return result

```

Переменные `a` и `b` по-прежнему используют регистры `rax` и `rcx`. При этом переменная `c` размещается не в регистрах, а в стеке (`qword ptr [rbp-8]`). `Fibonacci2` работает намного медленнее `Fibonacci1`, поскольку операции чтения и записи со значениями из стека занимают гораздо больше времени, чем операции с регистрами.

Единственным различием между `Fibonacci1` и `Fibonacci2` является блок «попытка-перехват» в `Fibonacci2`. У нас нет собственных инструкций по работе с исключениями, поскольку `Fibonacci2` не выдает исключений. Однако само существование этого блока заставило RyuJIT поместить переменную `c` в стек, что ухудшило производительность метода.

## Обсуждение

Этот пример основан на вопросе 8928403 на StackOverflow (<https://stackoverflow.com/q/8928403>). Его автор спрашивает, почему метод с блоком «попытка-перехват» работает *быстрее* метода без средства от исключений. Но при использовании RyuJIT мы получаем противоположный результат! Производительность всегда зависит от окружения. Вопрос был задан в 2012 году. Первичные измерения проводились с применением .NET Framework 2.0 с LegacyJIT-х86 и старых версий компилятора на C#. Вот цитата из ответа Джона Скита (<https://stackoverflow.com/a/8928476>): «Возможно, из-за блока “попытка-перехват” больше регистров сохраняется и восстанавливается, поэтому JIT использует их для цикла... что в целом улучшает производительность. Непонятно, является ли разумным решение JIT не использовать столько регистров в нормальном коде».

Изначальная проблема та же (компилятор JIT в одном случае использует регистры, а в другом — стек), но результат противоположен. Поэтому бесполезно применять подобные знания при оптимизациях производительности: разные

компиляторы JIT используют разные алгоритмы, которые в любой момент могут измениться. Однако знать это очень полезно при исследовании производительности, когда вы пытаетесь объяснить какие-нибудь интересные эффекты в данной сфере.

## Практический пример 4: количество вызовов

Количество вызовов в методе — важный фактор для некоторых эвристических правил компилятора JIT. Ограничение их числа может быть небольшим, но оно способно заставить компилятор JIT поменять сгенерированный собственный код для других выражений в том же методе.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class X {}

[LegacyJitX86Job]
public class Benchmarks
{
    private const int N = 100001;

    [Benchmark(Baseline = true)]
    public double Foo()
    {
        double a = 1, b = 1;
        for (int i = 0; i < N; i++)
            a = a + b;
        return a;
    }

    [Benchmark]
    public double Bar()
    {
        double a = 1, b = 1;
        new X(); new X(); new X();
        for (int i = 0; i < N; i++)
            a = a + b;
        return a;
    }
}
```

У нас есть два метода, `Foo` и `Bar`. Оба складывают одну переменную `double` с другой в цикле. Однако у метода `Bar` есть три дополнительных вызова конструктора.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, LegacyJIT-x86 v4.7.3260.0):

Method	Mean	StdDev	Ratio
Foo	103.5 us	0.4686 us	1.00
Bar	309.7 us	1.4324 us	2.99

Метод `Bar` работает в три раза медленнее метода `Foo`. Единственное различие между ними — три дополнительных вызова конструктора в `Bar`. Они должны исполняться почти моментально, не добавляя значительных ограничений. Так почему же у нас такие результаты?

## Объяснение

Взглянем на сгенерированный собственный код `Foo` (показана только основная часть):

```
; Foo()
xor    eax,eax        ; i = 0
LOOP:
fld1                   ; load 1 into st(0)
faddp  st(1),st       ; st(1) += st(0)
inc    eax            ; i++
cmp    eax,186A1h     ; if (i < 100001)
j1     LOOP           ; goto LOOP
```

Мы загружаем 1 в `st(0)` и прибавляем его к `st(1)`. Здесь `st(0)` и `st(1)` являются регистрами данных математического сопроцессора x87 (см. подробности в [FPUx87]). Теперь взглянем на сгенерированный собственный код `Bar`:

```
; Bar()
mov    ecx,569952Ch
call   017130c8        ; new X();
mov    ecx,569952Ch
call   017130c8        ; new X();
mov    ecx,569952Ch
call   017130c8        ; new X();
xor    eax,eax        ; i = 0
LOOP:
fld1                   ; load 1 into st(0)
fadd   qword ptr [esp] ; st(0) += [esp]
fstp   qword ptr [esp] ; [esp] = st(0)
inc    eax            ; i++
cmp    eax,186A1h     ; if (i < 100001)
j1     LOOP           ; goto LOOP
```

Здесь мы сохраняем результат в стек (`qword ptr [esp]`) и выполняем операции чтения/записи в стек при каждой итерации цикла. В начале метода можно увидеть три вызова конструктора `X`. У них нет заметных ограничений. Однако `LegacyJIT-x86` решил применять для вычислений стек, а не регистры, поскольку для этого используется количество вызовов.

## Обсуждение

Описанный в примере феномен действует только при использовании `LegacyJIT-x86`. С другими компиляторами JIT снижения производительности *в этом случае* не наблюдается. Однако количество вызовов в методе все еще может применяться в качестве фактора для различных оптимизаций любым компилятором JIT. В целом лучше не пытаться оптимизировать методы с помощью снижения количества дополнительных вызовов — оно важно лишь в некоторых случаях. В ситуации, когда добавление или удаление дополнительного вызова приводит к неожиданным изменениям производительности, превышающим ожидаемую длительность запроса, нужно проверить, как эти вызовы влияют на сгенерированный собственный код всего метода.

Похожий пример обсуждался в главе 2 (см. подраздел «Условное JIT-компилирование»). Данный практический пример основан на вопросе 32114308 со StackOverflow (<https://stackoverflow.com/q/32114308>).

## Подводя итог

Если у нас есть локальные переменные, компилятор JIT может хранить их в регистрах или в стеке. Если они являются непроезводимыми типами или структурами, это решение может значительно повлиять на производительность. В данном разделе мы осветили некоторые факторы, значимые для этого решения:

- количество полей в определении структуры;
- явный ввод локальной переменной из выражения;
- наличие блока «попытка-перехват», завершающего измерение логики;
- количество вызовов в методе.

Разрабатывая небольшой бенчмарк, основанный на реальном приложении, вы легко можете внести в него условия, важные для эвристических правил JIT. Полезно иметь минимальный бенчмарк, демонстрирующий серьезное влияние на производительность. Однако любые изменения в исходном коде могут привести к дополнительным неожиданным изменениям производительности. Улучшайте бенчмарки осторожно! Если вы хотите сравнить два небольших бенчмарка или

применить результаты бенчмарка к оптимизации реального приложения, стоит проверить, как компилятор JIT работает с локальными переменными.

Конечно, некоторые бенчмарки могут быть объемными и включать в себя сотни дополнительных методов. Почти невозможно проверить собственный код каждого вызываемого метода во всех исследованиях производительности. К счастью, **в большинстве случаев вам не нужно волноваться о проблеме «стек или регистры»** — в реальных бенчмарках она редко влияет на производительность. Однако, если вы сталкиваетесь с ней и получаете результаты, которые не можете объяснить, нужно проверить еще один аспект.

## Инлайнинг

Тема инлайнинга уже неоднократно обсуждалась в этой книге. Когда компилятор JIT выполняет инлайнинг метода, это означает, что вызов данного метода заменяется его телом. Непросто решить, когда стоит использовать инлайнинг, поскольку у этой оптимизации есть как плюсы, так и минусы.

### Плюсы

- **Устранены ограничения вызова.**

Когда мы вызываем метод, у нас всегда есть ограничения. Например, мы производим несколько дополнительных команд (`call`, `ret`). Иногда нужно сохранить некоторые данные регистра перед вызовом и восстановить их после вызова. Инлайнинг устраняет ограничения. Это может быть важно для горячих методов, которые должны быть очень быстрыми.

- **Возможность других оптимизаций.**

После инлайнинга метода становятся возможными другие оптимизации, например свертывание констант или удаление кода.

- **Улучшение распределения регистров.**

В некоторых случаях, когда в метод встраивается код, компилятор JIT может лучше использовать регистры, потому что не должен передавать аргументы вызываемому методу.

### Минусы

- **Увеличение объема кода.**

На уровне процессора есть кэш команд, помогающий быстрее загружать исполняемый код. Удвоение собственного кода метода, к которому применен инлайнинг, может ухудшить производительность кэша команд. Это почти незаметно при работе с небольшими программами, но может повлиять на приложения с большой базой исходного кода.

- **Предотвращение дальнейшего инлайнинга.**

Представьте три метода, А, В и С, где А вызывает В, а В вызывает С. Если компилятор JIT встраивает В в А, последний может оказаться слишком сложным, что станет препятствием для дальнейшего инлайнинга С в А. В то же время инлайнинг С в В может быть более выгодным, чем В в А.

- **Ухудшение распределения регистров.**

Можно представить метод как область действия компилятора JIT, где он пытается использовать регистры наилучшим образом. Поскольку количество регистров ограничено, метод со встроенным кодом может ухудшить условия их применения. В предыдущем разделе мы обсудили случаи ухудшения производительности из-за размещения переменных в стеке вместо регистров.

Таким образом, инлайнинг может оказаться как полезной, так и вредной оптимизацией. Обычно компилятор JIT пытается принять наилучшее для производительности решение. Однако эти решения не всегда очевидны и могут привести к неожиданным феноменам в области производительности. Давайте изучим несколько примеров, которые помогут распознавать ситуации, в которых для исследования производительности важно знать об инлайнинге.

## Практический пример 1: ограничения вызова

Если метод постоянно используется, нужно сделать его максимально быстрым. Обычно вызов простого метода занимает несколько наносекунд. Если сам метод тоже занимает несколько наносекунд, ограничение вызова может увеличить его длительность вдвое. Ограничение можно убрать (к сожалению, не всегда) с помощью инлайнинга. Рассмотрим пример, показывающий, как может ухудшиться производительность при невозможности выполнить инлайнинг горячего метода.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private const int N = 1000;
    private int[] x = new int[N];
    private int[] y = new int[N];
    private int[] z = new int[N];

    [Benchmark(Baseline = true)]
    public void Foo()
    {
        for (int i = 0; i < z.Length; i++)
            z[i] = Sum(x[i], y[i]);
    }
}
```

```
[Benchmark]
public void Bar()
{
    for (int i = 0; i < z.Length; i++)
        z[i] = VirtualSum(x[i], y[i]);
}

public int Sum(int a, int b) => a + b;

public virtual int VirtualSum(int a, int b) => a + b;
}
```

Здесь у нас три массива `int` одинаковой длины: `x`, `y` и `z`. В заявленных бенчмарках `Foo` и `Bar` мы выполняем `z[i] = x[i] + y[i]` для всех элементов массива. Вместо мгновенных вычислений операция сложения выделена в отдельный метод. `Foo` использует `Sum` (невиртуальный метод), а `Bar` — `VirtualSum` (виртуальный метод).

## Результаты

Вот пример результатов (macOS 10.14.2, Intel Core i7-4870HQ CPU 2.50GHz, .NET Core 2.1.3, RyuJIT-x64):

Method	Mean	StdDev	Ratio
Foo	1.121 us	0.0148 us	1.00
Bar	2.311 us	0.0196 us	2.06

Как видите, `Bar` работает вдвое медленнее `Foo`.

## Объяснение

К `VirtualSum` нельзя применить инлайнинг, поскольку он обозначен как виртуальный метод. В соответствии с эвристическими правилами RyuJIT в .NET Core 2.1.3 виртуальные методы встраивать нельзя. `Sum` можно встроить, поскольку факторы, запрещающие это, отсутствуют. `Foo` работает вдвое быстрее `Bar` из-за использования версии операции сложения с инлайнингом. Он не имеет ограничения вызова `Sum`.

## Обсуждение

Инлайнинг обычно запрещен из-за определенных условий, в числе которых следующие.

- **MethodImplOptions.NoInlining.**

Метод может иметь аннотацию `[MethodImpl(MethodImplOptions.NoInlining)]`, которая уведомляет компилятор JIT о том, что его нельзя встраивать. В этом случае инлайнинг применять нельзя, даже если метод пуст.

- **Большие методы.**

Если метод объемный (содержит слишком много команд на промежуточном языке), инлайнинг не будет применяться по умолчанию. Строгих критериев этого объема нет — у разных компиляторов JIT различные правила. В некоторых случаях мы можем попросить компилятор встроить большой метод с помощью `[MethodImpl(MethodImplOptions.AggressiveInlining)]`, но он все равно может решить этого не делать.

- **Работа с исключениями.**

Если метод содержит блок «попытка-перехват», его нельзя встраивать, поскольку эта оптимизация испортит стек вызовов при работе с исключениями.

- **Виртуальные методы (в большинстве случаев).**

Компилятор JIT не может встраивать виртуальные методы (в большинстве случаев), поскольку они могут быть проигнорированы в производном классе. Однако есть особые случаи, когда можно встраивать и виртуальные вызовы, и вызовы интерфейса. Однако этот подход может измениться в будущем (см. подробности в `coreclr#9908` (<https://github.com/dotnet/coreclr/issues/9908>)).

- **Рекурсивные методы.**

Рекурсивные методы встраивать нельзя, поскольку невозможно полностью встроить всю рекурсивную цепочку. Однако потенциально возможно встроить первый рекурсивный этап.

У компиляторов JIT в .NET много различных эвристических правил, явно запрещающих инлайнинг, поэтому рекурсивный метод или метод с атрибутом `[MethodImpl(MethodImplOptions.NoInlining)]` точно не могут заинлайниться. Однако невозможно быть точно уверенными, что конкретный метод всегда будет встраиваться: разные компиляторы (или разные версии одного компилятора) могут иметь разную политику инлайнинга. Чтобы принять окончательное решение, компилятор JIT предпринимает серию наблюдений за каждым методом<sup>1</sup>. Затем он совмещает эти наблюдения с помощью очень запутанных правил. Вот мой любимый метод в реализации RyuJIT<sup>2</sup>:

```
// EstimateCodeSize: произвести различные оценки размера
// кода, основываясь на наблюдениях.
//
// Модель размера кода «исходной точки»,
// эффективно используемая в предыдущих версиях
//
```

<sup>1</sup> Некоторые из этих «наблюдений» RyuJIT можно найти здесь: <https://github.com/dotnet/coreclr/blob/v2.2.0/src/jit/inline.def>.

<sup>2</sup> Версия .NET Core 2.2.0. Полный исходный код вы можете найти по адресу <https://github.com/dotnet/coreclr/blob/v2.2.0/src/jit/inlinepolicy.cpp>.

```

// 0.100 * m_CalleeNativeSizeEstimate +
// -0.100 * m_CallsiteNativeSizeEstimate
//
// При инлайнинге CoreCLR's mscorlib релиз windows x64
// производит множества R=0.42, MSE=228 и MAE=7.25.
//
// Эту оценку можно улучшить с помощью
// перестроения. Получаются результаты:
//
// -1.451 +
// 0.095 * m_CalleeNativeSizeEstimate +
// -0.104 * m_CallsiteNativeSizeEstimate
//
// With R=0.44, MSE=220, and MAE=6.93.

void DiscretionaryPolicy::EstimateCodeSize()
{
// Убедиться, что нам это доступно.
    m_CalleeNativeSizeEstimate = DetermineNativeSizeEstimate();
// Оценка размера основана на модели GLMNET.
// R=0.55, MSE=177, MAE=6.59
//
// Подозревая, что факторы учтены неправильно...
// clang-format off
    double sizeEstimate =
        -13.532 +
        0.359 * (int) m_CallsiteFrequency +
        -0.015 * m_ArgCount +
        -1.553 * m_ArgSize[5] +
        2.326 * m_LocalCount +
        0.287 * m_ReturnSize +
        0.561 * m_IntConstantCount +
        1.932 * m_FloatConstantCount +
        -0.822 * m_SimpleMathCount +
        -7.591 * m_IntArrayLoadCount +
        4.784 * m_RefArrayLoadCount +
        12.778 * m_StructArrayLoadCount +
        1.452 * m_FieldLoadCount +
        8.811 * m_StaticFieldLoadCount +
        2.752 * m_StaticFieldStoreCount +
        -6.566 * m_ThrowCount +
        6.021 * m_CallCount +
        -0.238 * m_IsInstanceCtor +
        -5.357 * m_IsFromPromotableValueClass +
        -7.901 * (m_ConstantArgFeedsConstantTest > 0 ? 1 : 0) +
        0.065 * m_CalleeNativeSizeEstimate;
// clang-format

// Масштабировано и указано в отчете в качестве целого числа
    m_ModelCodeSizeEstimate = (int)(SIZE_SCALE * sizeEstimate);
}

```

Как видите, в этом методе много магических чисел, влияющих на принятие решения. Если вы читали много сгенерированного собственного кода методов на C#, то можете догадаться, какой метод будет встроен в некоторых случаях конкретной версией компилятора JIT. Однако подход к инлайнингу постоянно эволюционирует, поэтому после выхода новых версий компилятора все эти предположения могут оказаться устаревшими.

## Практический пример 2: размещение регистров

В предыдущем разделе мы рассмотрели много примеров ухудшения производительности из-за того, что компилятор JIT решил использовать для некоторых переменных стек вместо регистров. Обсудим еще один случай, включающий в себя инлайнинг.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private const int n = 100;
    private bool flag = false;

    [Benchmark(Baseline = true)]
    public int Foo()
    {
        int sum = 0;
        for (int i = 0; i < n; i++)
            for (int j = 0; j < n; j++)
            {
                if (flag)
                    sum += InlinedLoop();
                sum += i * 3 + i * 4;
            }
        return sum;
    }

    [Benchmark]
    public int Bar()
    {
        int sum = 0;
        for (int i = 0; i < n; i++)
            for (int j = 0; j < n; j++)
            {
                if (flag)
                    sum += NotInlinedLoop();
                sum += i * 3 + i * 4;
            }
    }
}
```

```

    }
    return sum;
}

[MethodImpl(MethodImplOptions.AggressiveInlining)]
public int InlinedLoop()
{
    int sum = 0;
    for (int i = 0; i < 10; i++)
        sum += (i + 1) * (i + 2);
    return sum;
}

[MethodImpl(MethodImplOptions.NoInlining)]
public int NotInlinedLoop()
{
    int sum = 0;
    for (int i = 0; i < 10; i++)
        sum += (i + 1) * (i + 2);
    return sum;
}
}

```

У нас есть два бенчмарка, `Foo` и `Bar`, производящие некие вычисления в цикле. Они не вычисляют ничего полезного, зато помогут продемонстрировать интересный эффект, связанный с производительностью.

И `Foo`, и `Bar` содержат вызов другого метода с дополнительными вычислениями. `Foo` вызывает `InlinedLoop`, обозначенный `AggressiveInlining`, а `Bar` вызывает `NotInlinedLoop`, обозначенный `NoInlining`. Логика `InlinedLoop` идентична логике `NotInlinedLoop`. Единственное различие между ними — подход к инлайнингу.

`InlinedLoop` и `NotInlinedLoop` — условные методы: они будут исполняться, только если `flag == true`. В наших бенчмарках `flag` всегда ложен, то есть на самом деле мы не будем производить эти вызовы. Поскольку мы не вызываем эти методы, можно подумать, что вызовы никак не повлияют на производительность. Это предположение верно для некоторых компиляторов JIT, но не всегда.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, LegacyJIT-x86):

Method	Mean	StdDev	Ratio
Foo	23.403 us	0.2643 us	1.00
Bar	8.495 us	0.0560 us	0.36

Как видите, Foo с вызовом `AggressiveInlining` работает в три раза медленнее, чем Bar с вызовом `NoInlining`.

## Объяснение

Рассмотрим сгенерированный собственный код Foo (представлена только основная часть):

```

; Foo
xor     ebx,ebx ; sum = 0
xor     ecx,ecx ; i = 0

LOOP1:
xor     edx,edx ; edx = 0
mov     dword ptr [ebp-10h],edx ; j = 0
mov     eax,dword ptr [ebp-18h] ; eax = &this
movzx   eax,byte ptr [eax+4] ; eax = flag
mov     dword ptr [ebp-14h],eax ; [ebp-14h] = flag

LOOP2:
cmp     dword ptr [ebp-14h],0 ; if (flag == false)
je      AFTER_CALL ; goto AFTER_CALL

xor     edi,edi ; <InlinedLoop Body>
xor     esi,esi ; <InlinedLoop Body>
lea     eax,[esi+1] ; <InlinedLoop Body>
lea     edx,[esi+2] ; <InlinedLoop Body>
imul   eax,edx ; <InlinedLoop Body>
add     edi,eax ; <InlinedLoop Body>
inc     esi ; <InlinedLoop Body>
cmp     esi,0Ah ; <InlinedLoop Body>
jle    014304A9 ; <InlinedLoop Body>
add     ebx,edi ; sum += InlinedLoop();

AFTER_CALL:
lea     eax,[ecx+ecx*2] ; eax = i * 3
add     eax,ebx ; eax += sum
lea     ebx,[eax+ecx*4] ; sum = eax + i * 4

inc     dword ptr [ebp-10h] ; j++
cmp     dword ptr [ebp-10h],64h ; if (j < 100)
jle    LOOP2 ; goto LOOP2
inc     ecx ; i++
cmp     ecx,64h ; if (i < 100)
jle    LOOP1 ; goto LOOP1

```

Как видите, `InlinedLoop` действительно был встроен (мы попросили об этом компилятор с помощью `AggressiveInlining`). Сгенерированный код `InlinedLoop`

довольно эффективен: он производит все вычисления, используя только регистры. К сожалению, этот встроенный фрагмент повлиял на весь метод: компилятор JIT решил сохранить счетчик цикла `j` в стеке (`dword ptr [ebp-10h]`).

Теперь рассмотрим сгенерированный собственный код `Bar` (представлена только основная часть):

```

; Bar
xor     esi,esi           ; sum = 0
xor     edi,edi           ; i = 0

LOOP1:
xor     ebx,ebx           ; j = 0

LOOP2:
mov     eax,dword ptr [ebp-10h] ; eax = &this
cmp     byte ptr [eax+4],0      ; if (flag == false)
je      0143051A                ; goto AFTER_CALL

mov     ecx,dword ptr [ebp-10h] ; ecx = &this
call   dword ptr ds:[1214D5Ch] ; call NotInlinedLoop
add     esi,eax                ; sum += NotInlinedLoop();

AFTER_CALL:
lea     eax,[edi+edi*2]        ; eax = i * 3
add     eax,esi                ; eax += sum
lea     esi,[eax+edi*4]        ; sum = eax + i * 4

inc     ebx                    ; j++
cmp     ebx,64h                ; if (j < 100)
j1     01430506                ; goto LOOP2
inc     edi                    ; i++
cmp     edi,64h                ; if (i < 100)
j1     014304FE                ; goto LOOP1

```

Выглядит довольно похоже на `Foo`, но есть два важных отличия. Первое — прямой вызов `NotInlinedLoop` вместо встроенного тела этого метода. Второе — оба счетчика цикла, `i` и `j`, используют регистры `edi` и `ebx`. Поэтому он и работает быстрее, чем `Foo`: операции с регистрами обычно более эффективны.

## Обсуждение

Если удалить из метода `InlinedLoop` атрибут `[MethodImpl(MethodImplOptions.AggressiveInlining)]`, он не будет встраиваться и мы получим два метода одинаковой длительности. По умолчанию `LegacyJIT-x86` принимает верное решение.

Данный пример выглядит слишком надуманным, поскольку не вычисляет ничего полезного. Мы обсудили его, так как он показывает минусы инлайнинга при небольшом количестве строк. В реальности такая ситуация может возникнуть

в довольно сложных фрагментах кода, которые тяжело анализировать. В более простых примерах инлайнинг обычно улучшает производительность (или просто не ухудшает ее). Это может создать ложную уверенность в том, что инлайнинг — всегда полезная оптимизация.

Применение `AggressiveInlining` в горячих методах может улучшить производительность, но вы должны быть уверены в том, что это будет правильно (подобное решение требует тщательных измерений). Бездумное использование `AggressiveInlining` во всех методах может привести к серьезным проблемам с производительностью, которые будет очень трудно обнаружить.

## Практический пример 3: кооперативные оптимизации

Инлайнинг может благотворно повлиять на производительность не только из-за удаления ограничений вызовов, но и потому, что способен сделать возможными другие оптимизации.

### Исходный код

Рассмотрим следующие бенчмарки на базе `BenchmarkDotNet`:

```
public class Benchmarks
{
    private double x1, x2;

    [Benchmark(Baseline = true)]
    public double Foo()
    {
        return Calc(true);
    }

    public double Calc(bool dry)
    {
        double res = 0;
        double sqrt1 = Math.Sqrt(x1);
        double sqrt2 = Math.Sqrt(x2);
        if (!dry)
        {
            res += sqrt1;
            res += sqrt2;
        }

        return res;
    }

    [Benchmark]
    public double Bar()
```

```

    {
        return CalcAggressive(true);
    }

    [MethodImpl(MethodImplOptions.AggressiveInlining)]
    public double CalcAggressive(bool dry)
    {
        double res = 0;
        double sqrt1 = Math.Sqrt(x1);
        double sqrt2 = Math.Sqrt(x2);
        if (!dry)
        {
            res += sqrt1;
            res += sqrt2;
        }
        return res;
    }
}

```

У нас есть метод `Calc` с логическим аргументом `dry`. Когда `dry` верен, этот метод выдает результат 0. Когда `dry` является ложным, он выдает сумму квадратных корней из полей `x1` и `x2`. Есть также метод `CalcAggressive` с той же реализацией, но он помечен `[MethodImpl(MethodImplOptions.AggressiveInlining)]`. Представлены два бенчмарка: `Foo`, вызывающий `Calc(true)`, и `Bar`, вызывающий `CalcAggressive(true)`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, LegacyJIT-x86):

Method	Mean	StdDev
Foo	1.5214 ns	0.0972 ns
Bar	0.0000 ns	0.0127 ns

Как видите, `Foo` занимает ~ 1,5 нс, а `Bar` работает почти мгновенно. Как такое возможно?

## Объяснение

Рассмотрим собственный сгенерированный код `Foo`:

```

; Foo
push    ebp
mov     ebp,esp
mov     edx,1
call    dword ptr ds:[0F94D50h] ; call Calc
pop     ebp
ret

```

```

; Calc
fldz                ; Load 0 into stack (res)
fld     qword ptr [ecx+4] ; Load x1 into registers
fsqrt             ; sqrt(x1)
fld     qword ptr [ecx+0Ch] ; Load x2 into registers
fsqrt             ; sqrt(x2)
and     edx,0FFh    ; if (!dry)
je      012C04BA    ; goto SUM
fstp    st(0)       ; discard sqrt2
fstp    st(0)       ; discard sqrt1
jmp     FINISH      ; goto FINISH
SUM:
fxch    st(1)       ; swap FPU registers
faddp   st(2),st    ; res += sqrt1
faddp   st(1),st    ; res += sqrt2
FINISH:
ret                ; return result

```

В методе `Foo` мы вызываем `Calc`, который всегда вычисляет значения `sqrt(x1)` и `sqrt(x2)`. Только после этого он проверяет значение `dry`: если там стоит `true`, вычисленные значения отбрасываются<sup>1</sup>. В нашем бенчмарке значение `dry` всегда `true`, но компилятор JIT об этом не знает. Лучше перенести вычисления квадратных корней внутрь области `if (!dry) { }`, но компилятор `LegacyJIT-x86` не настолько умен — сгенерированный код довольно прямолинеен и точно соответствует изначальной программе на C#.

Теперь рассмотрим собственный сгенерированный код `Bar`:

```

; Bar
push    ebp
mov     ebp,esp
cmp     byte ptr [ecx+4],al
fldz                ; Load 0 into stack (res)
pop     ebp
ret

```

Благодаря атрибуту `[MethodImpl(MethodImplOptions.AggressiveInlining)]` `LegacyJIT-x86` смог построить `CalcAggressive`. После этого `if (!dry)` стало `if (false)` (поскольку значение `dry` правдиво) и компилятор JIT смог полностью удалить область с выражениями `res += sqrt1` и `res += sqrt2`. После этого `sqrt1` и `sqrt2` превратились в неиспользуемые переменные и `LegacyJIT-x86` решил удалить также вычисление квадратных корней. Конечные версии сгенерированного кода (после всех оптимизаций) выдают в качестве результата 0 без дополнительных вычислений.

<sup>1</sup> Если вы до конца не понимаете, как работают регистры данных FPU `st(0)`, `st(1)`, `st(2)`, рекомендую почитать `[FPUx87]`.

В результатах BenchmarkDotNet можно также найти следующее предупреждение, относящееся к `Var`: «Длительность метода неотличима от длительности пустого метода». В BenchmarkDotNet длительность пустого метода с соответствующим идентификатором, например `double Empty() { return 0; }`, считается равной 0. В методе `Var` есть команды, выполнение которых занимает какое-то время, но они считаются ограничениями вызовов, автоматически вычитаемыми из реальных измерений. Поэтому в таблице результатов стоит 0 нс.

## Обсуждение

Кооперативные оптимизации очень полезны и могут значительно улучшить производительность приложений. К сожалению, контролировать их не всегда просто. В данном примере `AggressiveInlining` помогает увеличить производительность благодаря инлайнингу и удалению кода, которые выполняются совместно в LegacyJIT-x86. Но невозможно каждый раз предсказывать, как работающий в данный момент компилятор JIT обработает все случаи использования метода с инлайнингом. *В некоторых конкретных случаях* можно оптимизировать код с помощью `AggressiveInlining`, но в других случаях надо быть уверенными в том, что это не ухудшит производительность (как в предыдущем примере).

В контексте бенчмаркинга следует понимать, что кооперативные оптимизации очень уязвимы: любые изменения в исходном коде могут включить или отключить инлайнинг в ваших методах и повлиять на условия дальнейшей оптимизации.

## Практический пример 4: команда на промежуточном языке starg

Мы уже знаем, что у инлайнинга есть ограничения. Например, он не применяется к виртуальным или рекурсивным методам. Однако некоторые ограничения инлайнинга не так очевидны и, как обычно, могут зависеть от версии компилятора JIT.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    [Benchmark]
    public int Calc()
    {
        return WithoutStarg(0x11) + WithStarg(0x12);
    }
}
```

```

private static int WithoutStarg(int value)
{
    return value;
}

private static int WithStarg(int value)
{
    if (value < 0)
        value = -value;
    return value;
}
}

```

В бенчмарке Calc мы вычисляем сумму двух методов, `WithoutStarg(0x11)` и `WithStarg(0x12)`. Метод `WithoutStarg` просто возвращает свой аргумент; `WithStarg` делает то же самое, но сначала выполняет одну дополнительную проверку: если `value` меньше нуля, он добавляет к этому аргументу `-value`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, LegacyJIT v4.7.3260.0):

Job	Mean	StdDev
LegacyJIT-x64	0.0000 ns	0.0000 ns
LegacyJIT-x86	1.7637 ns	0.0180 ns

Как видите, на LegacyJIT-x64 Calc работает мгновенно, а на LegacyJIT-x86 занимает несколько наносекунд.

## Объяснение

Намек, который поможет разобраться в этих результатах, можно найти в исходном коде конструктора `Decimal` из целого числа (<https://github.com/dotnet/coreclr/blob/v2.1.5/src/mscorlib/src/System/Decimal.cs#L157>):

```

public Decimal(int value) {
    // JIT сейчас не может встраивать методы, содержащие оператор кода starg.
    // Подробности можно найти на DevDiv Bugs 81184: x86 JIT CQ:
    // Удаление стрикции инлайнинга starg.
    int value_copy = value;
    if (value_copy >= 0) {
        flags = 0;
    }
    else {
        flags = SignMask;
        value_copy = -value_copy;
    }
    lo = value_copy;
}

```

```

    mid = 0;
    hi = 0;
}

```

Здесь можно увидеть интересный комментарий: он сообщает о том, что LegacyJIT-x86 не может встраивать методы, содержащие оператор кода `starg`. Он перемещает значение в верхнюю часть стека оценки в ячейке аргумента по конкретному индексу<sup>1</sup>. Конструктор `Decimal` в некоторых программах является небольшим популярным методом, поэтому будет полезно применить инлайнинг там, где это возможно. Избежать ограничений LegacyJIT-x86 по инлайнингу помогает то, что в этом конструкторе нет соотношения `value = -value`. Вместо этого есть соотношение `value_copy = -value_copy` для копии `value`. Этот простой прием позволяет избежать использования оператора кода `starg` на уровне промежуточного языка и разблокировать инлайнинг в LegacyJIT-x86.

Теперь рассмотрим код метода `WithStarg` на промежуточном языке:

```

IL_0000: ldarg.0      // 'value'
IL_0001: ldc.i4.0
IL_0002: bge.s      IL_0008

IL_0004: ldarg.0      // 'value'
IL_0005: neg
IL_0006: starg.s    'value'

IL_0008: ldarg.0      // 'value'
IL_0009: ret

```

Здесь есть оператор кода `starg.s`, который должен препятствовать инлайнингу этого метода в LegacyJIT-x86. Проверим эту гипотезу и посмотрим на собственный код данного метода:

```

; Calc/LegacyJIT-x86
push    ebp
mov     ebp,esp
mov     ecx,12h          ; ecx = 12h
call   dword ptr ds:[11B4D74h] ; call WithStarg
add     eax,11h          ; eax += 11h
pop     ebp
ret     ; return eax

; WithStarg/LegacyJIT-x86
mov     eax,ecx          ; eax = 12h
test    eax,eax          ; if (eax >= 0)
jge    FINISH           ; goto FINISH
neg     eax              ; eax = -eax
FINISH:
ret     ; return eax

```

<sup>1</sup> Больше информации можно найти в официальной документации: <https://docs.microsoft.com/en-us/dotnet/api/system.reflection.emit.opcodes.starg>.

Как видите, мы передаем `12h` в метод `WithStarg`, получаем возвращенное значение, добавляем к нему `11h` и возвращаем сумму. Метод `WithoutStarg` был успешно встроен, поэтому соответствующего вызова нет; `WithStarg` не был встроен, и мы видим его ограничение вызова в таблице результатов (~ 1,8 нс).

Теперь рассмотрим собственный код этого метода в `LegacyJIT-x64`:

```
; Calc/LegacyJIT-x64
mov    eax, 12h
add    eax, 11h
ret
```

Оба метода были встроены. `Calc` работает почти мгновенно, в результате в `BenchmarkDotNet` мы получаем сообщение «Длительность метода неотличима от длительности пустого метода».

## Обсуждение

Иногда у компилятора JIT есть неочевидные условия, препятствующие инлайнингу. У разных компиляторов свои наборы эвристических правил для инлайнинга, которые могут измениться после обновления среды исполнения. Когда компилятор не может встроить метод, мы получаем соответствующее событие ETW с указанием причины. Эту информацию можно получить с помощью атрибута `BenchmarkDotNet [InliningDiagnoser]`: он будет уведомлять обо всех неудавшихся оптимизациях, включающих в себя инлайнинг. В данном примере мы получим следующее сообщение: «Причина неудачи: инлайнинг записывается в аргумент».

Больше информации об обсуждаемом здесь ограничении `LegacyJIT-x86` можно найти в [Akinshin, 2015].

Этот пример основан на вопросе 26369163 со `StackOverflow` (<https://stackoverflow.com/q/26369163>).

## Подводя итог

Инлайнинг — эффективная оптимизация. Вот несколько полезных фактов о нем.

- Инлайнинг критичен для горячих методов, занимающих несколько наносекунд. Когда к подобному методу применяется инлайнинг, удаляется ограничение вызова. Эта оптимизация может заметно увеличить выработку такого метода.
- Инлайнинг в конкретном методе можно отключить с помощью атрибута `[MethodImpl(MethodImplOptions.NoInlining)]`. Существуют и другие явные факторы, автоматически отключающие инлайнинг (работа с исключениями, рекурсия, виртуальный модификатор и др.).

- Нельзя заставить компилятор JIT всегда применять инлайнинг, но можно использовать атрибут `[MethodImpl(MethodImplOptions.AggressiveInlining)]`, чтобы попросить его встроить некоторые методы (если это возможно), не встроенные по умолчанию. Например, компилятор не встраивает объемные методы, содержащие слишком много операторов кода на промежуточном языке (пороговое значение этого «слишком много» зависит от конкретной версии компилятора). В некоторых случаях объемные методы можно встроить при включенном `AggressiveInlining`.
- Не рекомендуется бездумно применять `AggressiveInlining` ко всем методам. В целом компилятору JIT лучше знать, когда выгодно использовать инлайнинг. Иногда с помощью `AggressiveInlining` можно получить улучшение производительности, но в других случаях это может привести к ее спаду.
- Инлайнинг — это не просто удаление ограничений вызовов. Он особенно выгоден при наличии других оптимизаций компилятора JIT, например свертывания констант или удаления неиспользуемого кода. Также он влияет на размещение регистров: после инлайнинга условия эффективного применения регистров могут улучшиться или ухудшиться.

Информация об инлайнинге важна при написании бенчмарков вручную — без использования `BenchmarkDotNet` или других платформ для бенчмаркинга. Рассмотрим следующий код:

```
void Main()
{
    // Запустить timer1
    for (int i = 0; i < n; i++)
        Foo();
    // Остановить timer1

    // Запустить timer2
    for (int i = 0; i < n; i++)
        Bar();
    // Остановить timer2
}
void Foo() { /* Тело бенчмарка */ }
void Bar() { /* Тело бенчмарка */ }
```

Здесь мы хотим сравнить производительность `Foo` и `Bar`. Представим, что `Foo` был встроен в метод `Main`, а `Bar` — нет. Даже если `Foo` на самом деле медленнее `Bar`, благодаря инлайнингу можем получить противоположный результат. Этот конкретный случай можно исправить с помощью атрибута `MethodImplOptions.NoInlining`:

```
[MethodImpl(MethodImplOptions.NoInlining)]
void Foo() { /* Тело бенчмарка */ }
[MethodImpl(MethodImplOptions.NoInlining)]
void Bar() { /* Тело бенчмарка */ }
```

Теперь оба метода *не будут* встраиваться, таким образом, условия соревнования становятся справедливее. Однако постоянно контролировать атрибуты всех методов невозможно, особенно если вы хотите проверять методы из чужих сборок. В этом случае можно измерить делегат, содержащий отсылку к измеряемому методу<sup>1</sup>.

Но это не решает всех проблем. Представьте, что метод встроен в реальном приложении, но не встроен в соответствующем бенчмарке, поскольку вы внесли в код небольшие изменения, затронувшие ограничения инлайнинга для компилятора JIT. В этом случае результаты бенчмарка не соответствуют реальной ситуации. Если вы пользуетесь ими, то можете получить информацию о неудавшемся инлайнинге с помощью атрибута [`InliningDiagnoser`]. Можете также получить эту информацию вручную с помощью соответствующих событий ETW.

## Параллелизм на уровне команд

Параллелизм на уровне команд (ILP) — эффективная техника процессора, помогающая значительно улучшить производительность приложений. В этой главе мы *не будем* обсуждать все детали внутреннего устройства процессора — для бенчмаркинга эта информация не нужна. На практике достаточно просто знать общую концепцию. Это поможет вам разработать качественные бенчмарки и правильно интерпретировать их результаты. Если вы хотите узнать об этом больше, рекомендую почитать [Hennessy, 2011]. А здесь мы просто обсудим несколько примеров очень простых бенчмарков, иллюстрирующих влияние ILP на производительность.

Обсудим основную концепцию ILP. На уровне процессора существуют разные модули исполнения, отвечающие за обработку различных команд. Пока один модуль исполняет текущую команду, остальные обычно простаивают. Этот способ использования процессора неэффективен, поэтому современные устройства позволяют выполнять параллельно несколько команд. Здесь имеется в виду не многопоточность — распараллеливание происходит в одном потоке на одном ядре процессора.

Один из ключевых механизмов ILP — *выполнение команд с изменением последовательности*: процессор может забежать вперед, проверить будущие команды и обработать их заранее (одновременно с текущей).

Еще один важный механизм — *конвейерная обработка команд*. Выполнение команды процессора проходит в несколько стадий, например: поиск команды, ее расшифровка, выполнение, запись результатов и т. д. Когда первые стадии текущей команды завершены, можно начать выполнять их для следующей, не нужно ждать полного завершения текущей команды.

<sup>1</sup> .NET Framework 4.7.2, .NET Core 2.2 и Mono 5.18 не могут встраивать делегаты.

Если открыть [Agner Instructions] (список характеристик производительности команд процессора для разных процессоров), можно увидеть, что обычно указываются две метрики — *длительность* и *взаимная обработка*, выраженные в циклах процессора. Примеры этих значений для Intel Skylake представлены в табл. 7.1.

**Таблица 7.1.** Длительность и взаимная обработка некоторых команд Skylake

Команда	Компоненты операции	Длительность	Взаимная обработка
MOV	r8/r16,r8/r16	1	0,25
MOVQ	x,x	1	0,33
POP	r	2	0,5
PUSH	r	3	1
VMASKMOVPS	m128,x,x	13	1
DPSS	x,x,i	13	1,5
DIV	r8	23	6
FBLD	m80	46	22
FRSTOR	m	175	175

К примеру, длительность MOVQ x, x равна 1, то есть продолжительность одной команды от начала до конца равна одному циклу процессора. Взаимная обработка этой команды занимает 0,33. То есть если есть серия из 3000 таких команд, их можно выполнить за 1000 циклов процессора (в среднем 0,33 цикла процессора на одну команду). Однако это не означает, что мы можем выполнить одну команду за 0,33 цикла: невозможно выполнить команду быстрее, чем за один цикл.

ILP позволяет улучшить производительность, но усложняет измерение отдельной команды, поскольку у любой инструкции есть несколько метрик производительности. Все зависит от того, *как именно мы используем* эти команды в исходном коде. На практике реальная средняя длительность команды — где-то между значениями длительности и взаимной обработки. В некоторых случаях даже невозможно правильно измерить длительность, поскольку нельзя написать программу, которая будет выполнять серию тех же команд без эффектов ILP.

В этом разделе обсудим четыре примера, иллюстрирующих, как ILP может повлиять на результаты бенчмарка.

## Практический пример 1: параллельное выполнение

ILP — распространенная проблема при бенчмаркинге, которая может привести к неверной интерпретации результатов. Обсудим очень простой пример, в котором она появляется.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private const int n = 10001;
    private int x = 3;

    [Benchmark(Baseline = true)]
    public int Div1()
    {
        int a = 1;
        for (int i = 0; i < n; i++)
        {
            a /= x;
        }
        return a;
    }

    [Benchmark]
    public int Div2()
    {
        int a = 1, b = 2;
        for (int i = 0; i < n; i++)
        {
            a /= x;
            b /= x;
        }
        return a + b;
    }

    [Benchmark]
    public int Div3()
    {
        int a = 1, b = 2, c = 3;
        for (int i = 0; i < n; i++)
        {
            a /= x;
            b /= x;
            c /= x;
        }
        return a + b + c;
    }

    [Benchmark]
    public int Div4()
    {
        int a = 1, b = 2, c = 3, d = 4;
        for (int i = 0; i < n; i++)
        {
```

```

        a /= x;
        b /= x;
        c /= x;
        d /= x;
    }
    return a + b + c + d;
}

[Benchmark]
public int Div5()
{
    int a = 1, b = 2, c = 3, d = 4, e = 5;
    for (int i = 0; i < n; i++)
    {
        a /= x;
        b /= x;
        c /= x;
        d /= x;
        e /= x;
    }
    return a + b + c + d + e;
}
}

```

У нас есть пять бенчмарков. В каждом из них мы выполняем операции целочисленного деления в цикле. В `Div1` все деление производится с помощью одной переменной `a`. В `Div2` тело цикла содержит две операции деления с двумя независимыми переменными — `a` и `b`. В `Div3`, `Div4` и `Div5` выполняются соответственно три, четыре и пять операций над разными переменными.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, LegacyJIT-x64 v4.7.3260.0):

Method	Mean	StdDev	Ratio
Div1	75.5 us	0.2012 us	1.00
Div2	75.5 us	0.2196 us	1.00
Div3	80.6 us	0.3359 us	1.07
Div4	100.0 us	0.3588 us	1.33
Div5	126.1 us	0.4532 us	1.67

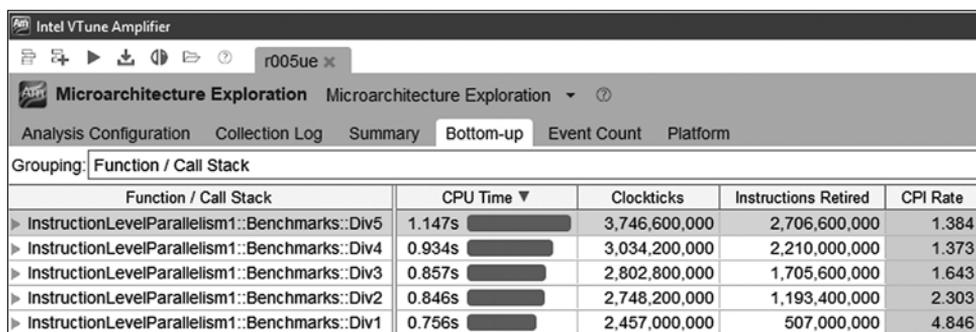
Как видите, у `Div1` и `Div2` очень схожая длительность. Это может выглядеть странно, поскольку в `Div2` две операции деления, а в `Div1` — одна. `Div3` занимает чуть больше времени, чем `Div2` (на 5 мкс). `Div4` на 20 мкс длиннее `Div3`. `Div5` на 26 мкс длиннее `Div4`.

## Объяснение

Воспользуемся Intel VTune Amplifier, чтобы получить больше метрик этих бенчмарков. Записываем метод `Main` этой программы следующим образом:

```
var b = new Benchmarks();
b.Div1();
b.Div2();
b.Div3();
b.Div4();
b.Div5();
```

Кроме того, увеличиваем значение `n` до 100 000 000, что поможет получить значимые результаты. Затем профилируем новую программу в режиме исследования микроархитектуры. Результаты представлены на рис. 7.1.



The screenshot shows the Intel VTune Amplifier interface with the 'Bottom-up' view selected. The report is grouped by 'Function / Call Stack' and displays the following data:

Function / Call Stack	CPU Time	Clockticks	Instructions Retired	CPI Rate
InstructionLevelParallelism1::Benchmarks::Div5	1.147s	3,746,600,000	2,706,600,000	1.384
InstructionLevelParallelism1::Benchmarks::Div4	0.934s	3,034,200,000	2,210,000,000	1.373
InstructionLevelParallelism1::Benchmarks::Div3	0.857s	2,802,800,000	1,705,600,000	1.643
InstructionLevelParallelism1::Benchmarks::Div2	0.846s	2,748,200,000	1,193,400,000	2.303
InstructionLevelParallelism1::Benchmarks::Div1	0.756s	2,457,000,000	507,000,000	4.846

Рис. 7.1. Отчет Vtune для примера «Параллельное выполнение»

Три главные колонки отчета:

- **Clockticks** — сколько произведено тактов системных часов процессора;
- **Instruction Retired** — сколько команд было выполнено;
- **CPI Rate** (количество циклов для одной команды) — сколько тактов системных часов процессора произведено для одной команды в среднем.

Самые интересные методы в таблице результатов — `Div1` и `Div2`, у которых очень схожая длительность. Эта ситуация возникла, поскольку процессор смог исполнить  $a/x$  и  $b/x$  параллельно. Снова посмотрим на отчет Vtune. Количество тактов системных часов у `Div1` и `Div2` тоже очень схоже, но не равно, поскольку профилирование консольного приложения в Vtune не так точно, как набор инструментальных средств для исполнения в BenchmarkDotNet. В то же время **CPI Rate** бенчмарка `Div2` в два раза ниже, чем `Div1`. Это значит, что мы смогли выполнить вдвое больше команд за то же время.

Div3 занимает чуть больше времени, чем Div2, потому что мы приблизились к максимальным возможностям параллелизма. Когда мы продолжаем добавлять новые операции деления в Div4 и Div5, общая длительность значительно возрастает, поскольку достигаем максимальных возможностей ILP: уже нельзя выполнять дополнительное деление параллельно с существующими операциями. CPI Rate для Div4 и Div5 примерно одинаково, что доказывает тот факт, что достигнуты границы параллелизма.

## Обсуждение

ILP помогает быстрее исполнять код, но усложняет написание качественных бенчмарков. Также из-за него мы не можем экстраполировать выводы на другие бенчмарки. Когда мы добавляем новую операцию деления в Div1, она не увеличивает длительность метода. Это не означает, что она выполняется мгновенно. Мы не можем ожидать, что дополнительное деление не увеличит длительность других методов. Реальные затраты производительности на одну команду всегда зависят от контекста ее исполнения: очень важны выражения, которые находились до и после этой команды.

Смотрите также вопрос 54188731 на StackOverflow (<https://stackoverflow.com/q/54188731>).

## Практический пример 2: взаимозависимости данных

Возможности ILP ограничены взаимозависимостями в коде. Рассмотрим следующий метод:

```
int Calc(int a, int b, int c)
{
    int d = a + b;
    int e = d * c;
    return e;
}
```

Здесь мы не можем выполнить арифметические операции  $a + b$  и  $d * c$  параллельно, поскольку вторая операция зависит от результата первой. Это довольно простой пример *взаимозависимости данных*. Рассмотрим пример, показывающий, как подобные зависимости могут повлиять на результаты бенчмарка.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
```

```

private int n = 1000001;
private double x0, x1, x2, x3, x4, x5, x6, x7;

[Benchmark(Baseline = true)]
public void WithoutDependencies()
{
    for (int i = 0; i < n; i++)
    {
        x0++; x1++; x2++; x3++;
        x4++; x5++; x6++; x7++;
    }
}

[Benchmark]
public void WithDependencies()
{
    for (int i = 0; i < n; i++)
    {
        x0++; x0++; x0++; x0++;
        x0++; x0++; x0++; x0++;
    }
}
}

```

У нас есть два метода, `WithoutDependencies` и `WithDependencies`. В обоих случаях мы выполняем восемь увеличений `double` в одном цикле. В первом случае (`WithoutDependencies`) увеличиваем восемь разных переменных, во втором (`WithDependencies`) — одну и ту же переменную восемь раз.

## Результаты

Вот пример результатов (macOS 10.14.2, Intel Core i7-4870HQ CPU 2.50GHz, .NET Core 2.1.3):

Method	Mean	StdDev	Ratio
WithoutDependencies	3.503 ms	0.0327 ms	1.00
WithDependencies	10.560 ms	0.1149 ms	3.02

Как видите, `WithoutDependencies` работает втрое быстрее, чем `WithDependencies`.

## Объяснение

Алгоритм `WithoutDependencies` работает гораздо быстрее, потому что в нем нет никаких взаимозависимостей между выражениями увеличения и производительность цикла может быть улучшена с помощью ILP. В методе `withDependencies` существует взаимозависимость между последовательными увеличениями: нужно сначала закончить предыдущее выражение, а затем уже начинать следующее. Поэтому улучшить производительность с помощью ILP здесь невозможно.

## Обсуждение

Вы можете спросить: «Как же оценить *реальную* длительность увеличения `double`?» Правильный ответ: *реальной* длительности увеличения `double` не существует. Также вы можете спросить: «Какой из этих бенчмарков *правильный*?» Верный ответ: оба *правильные*, но измеряют разные параметры. Производительность приложения зависит от того, как мы используем эти увеличения в исходном коде. Любые взаимозависимости данных могут ограничивать ILP и снижать производительность.

В таблицах команд, например [Agner Instructions], можно найти длительность и тип взаимной обработки некоторых команд, но эти значения не помогут угадать метрики производительности конкретного метода без реальных измерений (однако могут помочь выдвинуть гипотезу, объясняющую их результаты). Эти значения относятся к крайним случаям, бесполезным для исследования производительности без полного исходного кода.

## Практический пример 3: диаграмма взаимозависимостей

В предыдущем примере было очевидно, где появляются взаимозависимости данных между командами. Но их не всегда легко обнаружить. Полная диаграмма взаимозависимостей данных может быть довольно сложной, из-за чего становится труднее догадаться о том, где ILP может оптимизировать код.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private double[] a = new double[100];

    [Benchmark]
    public double Loop()
    {
        double sum = 0;
        for (int i = 0; i < a.Length; i++)
            sum += a[i];
        return sum;
    }

    [Benchmark]
    public double UnrolledLoop()
    {
        double sum = 0;
```

```

    for (int i = 0; i < a.Length; i += 4)
        sum += a[i] + a[i + 1] + a[i + 2] + a[i + 3];
        return sum;
    }
}

```

У нас есть два бенчмарка, `Loop` и `UnrolledLoop`. Оба вычисляют сумму элементов в массиве `double`. Но в методе `UnrolledLoop` выполняется разворачивание вручную: вместо одного сложения за одну итерацию цикла мы каждый раз добавляем в `sum` четыре элемента. Для упрощения в качестве длины массива используется константа, которая делится на четыре.

## Результаты

Вот пример результатов (macOS 10.14.2, .NET Core 2.1.3, Intel Core i7-4870HQ CPU 2.50GHz):

Method	Mean	StdDev
----- -----	-----	-----
Loop	82.04 ns	1.3756 ns
UnrolledLoop	51.69 ns	0.6441 ns

Как видите, `UnrolledLoop` работает на ~ 30–40 % быстрее.

## Объяснение

Сложение значений `double` не является ассоциативной операцией. Это означает, что  $(a + b) + c$  не всегда равно  $a + (b + c)$  (мы подробно обсудим это в разделе «Арифметика»). Таким образом, процессор не может изменять порядок последовательных операций сложения. Это создает неявные взаимозависимости между операциями. Диаграммы взаимозависимостей показаны на рис. 7.2 (диаграмма алгоритма `Loop` — вверху, `UnrolledLop` — внизу).

В методе `Loop` между всеми операциями существуют последовательные взаимозависимости. При первой итерации нужно выполнить `sum += a[0]`. *Только после этого* можно выполнить `sum += a[1]`. Данная операция требует значения `sum` после первой итерации, поэтому операции сложения нельзя выполнять параллельно. *Только после второй операции* мы можем заняться третьей. Здесь нельзя применить ILP — все выражения необходимо выполнять последовательно.

Ситуация в методе `UnrolledLoop` гораздо лучше: выражения `a[0] + a[1] + a[2] + a[3]` и `a[4] + a[5] + a[6] + a[7]` независимы друг от друга — между ними нет взаимозависимостей. Поэтому значения выражения `a[i] + a[i + 1] + a[i + 2] + a[i + 3]` можно вычислить после нескольких параллельных итераций. Конечно, мы не можем выполнить их все параллельно из-за ограничений ILP. Однако это все еще лучше, чем в случае алгоритма `Loop`. Поэтому и появляется рост производительности на ~ 30–40 %.

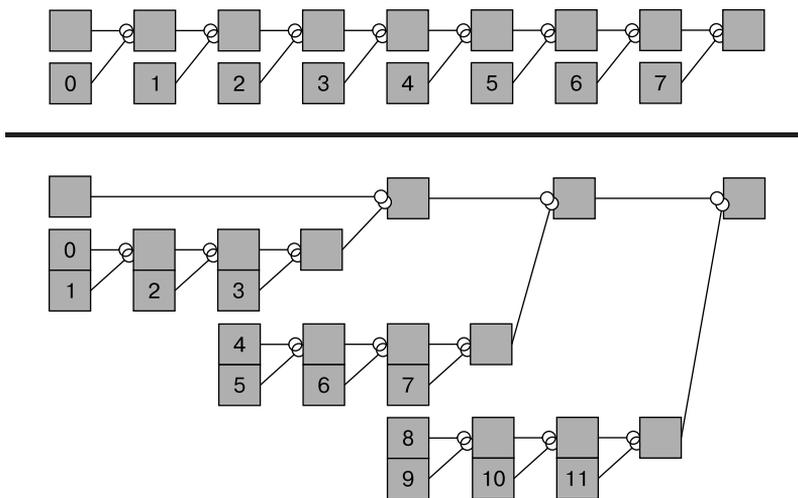


Рис. 7.2. Визуализация примера «Диаграмма взаимозависимостей»

## Обсуждение

В обсуждаемом примере взаимозависимости между выражениями были довольно простыми. В реальных приложениях диаграмма может быть более запутанной, что усложняет анализ. В некоторых случаях взаимозависимостей на уровне C# нет, но они существуют на уровне собственного кода.

Например, в `coreclr#993` (<https://github.com/dotnet/coreclr/issues/993>) была обнаружена проблема с производительностью в `RyuJIT` (ее уже исправили). В примере `RyuJIT` генерировал собственный код, использовавший один и тот же регистр для двух разных операций. В этом случае процессор не мог применить `ILP`, поскольку вторые операции должны были ожидать освобождения регистра для дальнейших вычислений. Подобные ситуации редки, но вы должны быть готовы работать с такими проблемами.

Еще один пример неочевидной взаимозависимости данных можно найти в вопросе `25078285` на `StackOverflow` (<https://stackoverflow.com/q/25078285>). У автора вопроса произошел спад производительности на 50 % после замены 32-битного счетчика цикла 64-битным. Исследование берет пример на C++ и содержит много исходного кода, но его стоит прочитать, если вам нравятся интересные примеры проблем с производительностью.

Анализировать полную диаграмму взаимозависимостей и объяснять результаты измерений производительности не всегда просто<sup>1</sup>, но обычно это возможно сделать, используя только общее знание об `ILP` без деталей конкретного устройства.

<sup>1</sup> Существуют инструменты, которые могут сделать это за вас. Вот хороший пример: <https://godbolt.org/z/baOZWu>.

## Практический пример 4: очень короткие циклы

Современное оборудование содержит множество низкоуровневых характеристик, способных непредсказуемым образом повлиять на ваши бенчмарки. Давайте обсудим еще один интересный пример.

### Исходный код

Рассмотрим следующую программу:

```
public class Program
{
    private static int n = 10000000;
    private static int rep = 100;

    static void Main()
    {
        MeasureAll();
        MeasureAll();
    }

    public static void MeasureAll()
    {
        Measure("Loop 00", () => Loop00());
        Measure("Loop 01", () => Loop01());
        Measure("Loop 02", () => Loop02());
        Measure("Loop 03", () => Loop03());
        Measure("Loop 04", () => Loop04());
        Measure("Loop 05", () => Loop05());
        Measure("Loop 06", () => Loop06());
        Measure("Loop 07", () => Loop07());
    }

    public static void Measure(string title, Action action)
    {
        var stopwatch = Stopwatch.StartNew();
        for (int i = 0; i < rep; i++)
            action();
        stopwatch.Stop();
        Console.WriteLine(title + ": " + stopwatch.ElapsedMilliseconds);
    }

    public static void Loop00()
    {
        for (int i = 0; i < n; i++) { }
    }

    public static void Loop01()
    {
        for (int i = 0; i < n; i++) { }
    }
}
```

```
public static void Loop02()
{
    for (int i = 0; i < n; i++) { }
}

public static void Loop03()
{
    for (int i = 0; i < n; i++) { }
}

public static void Loop04()
{
    for (int i = 0; i < n; i++) { }
}

public static void Loop05()
{
    for (int i = 0; i < n; i++) { }
}

public static void Loop06()
{
    for (int i = 0; i < n; i++) { }
}

public static void Loop07()
{
    for (int i = 0; i < n; i++) { }
}
}
```

У нас есть восемь пустых циклов, измеряемых с помощью `Stopwatch`. Мы намеренно не используем здесь библиотеку `BenchmarkDotNet`, чтобы полностью исключить вероятность столкновения с неизвестными ошибками этой библиотеки. Эффект, который мы обсудим, настолько хорошо заметен, что можно пренебречь полезными приемами бенчмаркинга, такими как прогрев и анализ распределения.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, RyuJIT-x64):

```
Loop 00: 727
Loop 01: 352
Loop 02: 371
Loop 03: 369
Loop 04: 752
Loop 05: 352
Loop 06: 348
Loop 07: 349
```

```

Loop 00: 692
Loop 01: 344
Loop 02: 351
Loop 03: 349
Loop 04: 702
Loop 05: 345
Loop 06: 347
Loop 07: 351

```

Как видите, циклы Loop00 и Loop04 работают вдвое медленнее остальных.

## Объяснение

У меня нет приемлемого объяснения этим результатам. К сожалению, компания Intel держит в секрете многие низкоуровневые характеристики своих устройств и не включает их в официальные руководства. В любом случае этот эффект довольно стабилен (я воспроизвел его более чем на 30 разных компьютерах), поэтому его следует обсудить. Здесь я хочу поделиться с вами некоторыми заметками об этом исследовании.

**Наблюдение 1.** Этот эффект действителен только для RyuJIT-x64, он не воспроизводится на LegacyJIT-x86, LegacyJIT-x64 или MonoJIT. RyuJIT генерирует для пустого цикла следующий код:

```

LOOP:
inc   eax
cmp   eax,edx
jl    LOOP

```

Также у меня есть пример воспроизведения на чистой сборке, доказывающий, что это феномен микроархитектуры процессора (на него не влияет среда исполнения .NET). Он работает одинаково в Windows, Linux и macOS (операционная система тоже не имеет значения).

**Наблюдение 2.** Этот эффект действует только при использовании Intel Haswell и последующих серий процессоров Intel Core, таких как Broadwell, Skylake и Kaby Lake. Он не воспроизводится на более старых процессорах, например, Sandy Bridge или Ivy Bridge.

**Наблюдение 3.** В этом примере есть медленные и быстрые циклы. Точные индексы медленных циклов зависят от расположения сгенерированного собственного кода в памяти. Любые изменения исходного кода меняют это расположение и связанные с ним результаты. Если конкретно, то цикл замедляется, когда пара `cmp/jl` расположена на границе двух 64-байтных сегментов таким образом:

```

00007FFEB1AF377C   inc   eax
00007FFEB1AF377E   cmp   eax,edx
00007FFEB1AF3780   jl    00007FFEB1AF377C

```

Я проверил множество гипотез, включая характеристики кэша команд, MacroFusion<sup>1</sup> и предсказание ветвления (мы обсудим его в следующем разделе), но все они были отброшены.

**Наблюдение 4.** CPI Rate быстрого цикла равен 0,333, то есть процессор выполняет все три команды за один цикл. CPI Rate медленного цикла равен 0,666, поэтому он работает вдвое медленнее, чем быстрый.

Если у вас есть правдоподобное объяснение этого эффекта, пожалуйста, поделитесь им со мной.

## Обсуждение

Несмотря на то что объяснения этому эффекту у меня нет, он существует и может с легкостью испортить ваши нанобенчмарки, если вы о нем не знаете, поскольку реальная производительность зависит не только от исходного кода, но и от расположения в памяти сгенерированного собственного кода. Допустим, мы хотим сравнить производительность двух методов, `Foo` и `Bar`, занимающих несколько наносекунд. Чтобы получить достоверные результаты, сворачиваем их в циклы таким образом:

```
for (int i = 0; i < n; i++)
    Foo();

for (int j = 0; j < n; j++)
    Bar();
```

Если один цикл достигнет границы 64-байтного сегмента, а второй — нет, измерение будет испорчено из-за разных стратегий ИЛР. Но существует способ решения этой проблемы под названием «развертывание циклов». Например, можно переписать цикл метода `Foo` таким образом:

```
for (int i = 0; i < n / 16; i++)
{
    Foo(); Foo(); Foo(); Foo();
    Foo(); Foo(); Foo(); Foo();
    Foo(); Foo(); Foo(); Foo();
    Foo(); Foo(); Foo(); Foo();
}
```

В этом случае мы решаем проблему с ИЛР и уменьшаем ограничения цикла. Данный прием используется в библиотеке `BenchmarkDotNet` по умолчанию, что по-

<sup>1</sup> Эта оптимизация способна объединить команды `cmp` и `j1` в одну макрокоманду, которая может быть выполнена за один цикл ЦП. В [Intel Manual] (раздел 2.3.2.1) есть следующее предложение: «Макросоединения не происходит, если первая команда заканчивается на 63-м байте линии кэша, а вторая является условной ветвью и начинается на 0-м байте следующей линии кэша». Это похоже на нашу ситуацию, но проблема не в этом.

звонит получать достоверные результаты даже от нанобенчмарков. Количество вызовов в теле цикла можно контролировать с помощью функции `UnrollFactor` (подробности — в официальной документации), значение по умолчанию — 16. Если вы задействуете собственные короткие циклы внутри своих бенчмарков, `BenchmarkDotNet` не защитит вас от этой проблемы или других проблем, свойственных коротким циклам, например, как в вопросе 53695961 на `StackOverflow` (<https://stackoverflow.com/q/53695961>). При выполнении высокоскоростной операции внутри цикла, занимающей несколько наносекунд, всегда рекомендуется производить развертывание вручную.

## Подводя итог

ILP часто становится источником ошибок при интерпретации результатов бенчмарка. Возможность выполнять несколько команд одного потока параллельно на одном и том же ядре процессора скрыта от разработчиков на уровне аппаратных средств: ее нельзя контролировать и довольно сложно проанализировать, как именно она влияет на ваш код.

В этом разделе мы обсудили четыре типа возможных проблем.

- После добавления выражения в исходный код производительность способна остаться неизменной, потому что оно может исполняться параллельно с уже имеющимися командами.
- Исходный код может содержать взаимозависимости между выражениями, что препятствует ILP. Поэтому у вас могут быть два бенчмарка, выполняющих одно и то же количество собственных команд, но имеющих разную длительность из-за этих взаимозависимостей.
- Диаграмма взаимозависимостей данных может оказаться довольно запутанной, поскольку некоторые из них бывают неявными.
- Производительность короткого цикла может зависеть от размещения собственного кода в памяти, которое вы не можете контролировать. К счастью, это не влияет на развернутые версии данных циклов<sup>1</sup>.

Следует понимать, что неправильных бенчмарков не бывает<sup>2</sup> — возможна только неправильная интерпретация их результатов. Каждый бенчмарк — это просто про-

---

<sup>1</sup> Вот более корректная версия этого утверждения: «Я никогда не видел, чтобы ILP заметно влиял на большие циклы в простых бенчмарках». Я уверен, что можно найти конкретный случай, когда это имеет значение. Но, скорее всего, вам не стоит об этом волноваться, поскольку вы вряд ли столкнетесь с подобными случаями в реальности. А вот описанная проблема с короткими циклами действительно влияет на многие простые нанобенчмарки.

<sup>2</sup> Обычно мы называем неправильным тот бенчмарк, который не измеряет нужные метрики, которые должен.

грамма, выдающая какие-то числа. Задача специалиста по производительности — совместить эти числа со знанием окружения (устройств, операционных систем, среды исполнения и т. д.) и сделать верные выводы об измеряемом коде.

## Прогнозирование ветвления

Прогнозирование ветвления — это еще одна техника процессора, помогающая открыть новые возможности для ILP. Мы уже знаем, что выполнение команд с изменением последовательности помогает изучить дальнейшие команды и по возможности выполнить их заранее. Это неплохо работает с линейными программами без ветвлений. Но, допустим, у нас есть такая программа:

```
if (flag)
    Foo();
else
    Bar();
```

В этом случае исполнить `Foo` или `Bar` невозможно, не получив значения `flag`. Поскольку обычно в программах очень много условий `if`, тернарных операторов, операторов переключения и циклов, становится довольно сложно воспользоваться преимуществами исполнения в произвольном порядке. Блок предсказания ветвления может значительно улучшить эту ситуацию. Это часть процессора, которая пытается предугадать, какая ветвь будет выбрана, основываясь на предварительной оценке значений условий. С точки зрения внутреннего устройства это очень сложная часть оборудования. Мы не будем рассказывать о нем, потому что в большинстве случаев вам не понадобится детальное знание алгоритмов предсказания ветвления. На практике достаточно просто понимать основную концепцию. В этом разделе мы рассмотрим четыре примера, показывающих, как данные ввода могут повлиять на производительность одной и той же программы. Это поможет вам разрабатывать более качественные бенчмарки, основываясь на имеющихся в коде ветвлениях.

## Практический пример 1: отсортированные и неотсортированные данные

Когда нужно измерить длительность метода, мы обычно фокусируемся на исходном коде и окружении. Однако есть и еще один важный компонент пространства производительности, о котором часто забывают, — данные ввода. Рассмотрим пример, показывающий, как они могут повлиять на метрики производительности.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private const int n = 100000;
    private byte[] sorted = new byte[n];
    private byte[] unsorted = new byte[n];

    [GlobalSetup]
    public void Setup()
    {
        var random = new Random(42);
        for (int i = 0; i < n; i++)
            sorted[i] = unsorted[i] = (byte) random.Next(256);
        Array.Sort(sorted);
    }

    [Benchmark(Baseline = true)]
    public int SortedBranch()
    {
        int counter = 0;
        for (int i = 0; i < sorted.Length; i++)
            if (sorted[i] >= 128)
                counter++;
        return counter;
    }

    [Benchmark]
    public int UnsortedBranch()
    {
        int counter = 0;
        for (int i = 0; i < unsorted.Length; i++)
            if (unsorted[i] >= 128)
                counter++;
        return counter;
    }

    [Benchmark]
    public int SortedBranchless()
    {
        int counter = 0;
        for (int i = 0; i < sorted.Length; i++)
            counter += sorted[i] >> 7;
        return counter;
    }

    [Benchmark]
    public int UnsortedBranchless()
    {
```

```

{
    int counter = 0;
    for (int i = 0; i < unsorted.Length; i++)
        counter += unsorted[i] >> 7;
    return counter;
}
}

```

У нас есть два массива `byte` — `sorted` и `unsorted`. Оба содержат один и тот же набор случайных элементов в разном порядке: массив `sorted` — отсортированные элементы, а `unsorted` — перемешанные в случайном порядке. В бенчмарках `SortedBranch` и `UnsortedBranch` мы нумеруем соответствующие массивы и вычисляем количество элементов, которое больше или равно 128, с помощью простого выражения `if`, например `if (sorted[i] >= 128) counter++`. В бенчмарках `SortedBranchless` и `UnsortedBranchless` происходит то же самое, но вместо выражения `if` мы увеличиваем счетчик с помощью такого выражения, как `sorted[i] >> 7`. Когда элемент массива больше или равен 128, это выражение будет равно 1, что означает: счетчик `counter` будет увеличен на 1. Когда элемент меньше 128, это выражение будет равно 0 и `counter` не изменится. Как видите, эти алгоритмы эквивалентны друг другу, но у последних двух бенчмарков нет ветвлений (тела циклов не содержат ветвей).

## Результаты

Вот пример результатов (macOS 10.14.2, Intel Core i7-4870HQ CPU 2.50GHz, .NET Core 2.1.3):

Method	Mean	StdDev	Ratio
SortedBranch	65.75 us	0.6622 us	1.00
UnsortedBranch	424.04 us	4.9999 us	6.45
SortedBranchless	65.82 us	0.4978 us	1.00
UnsortedBranchless	65.03 us	0.8578 us	1.00

Как видите, алгоритм `SortedBranch` работает в 6–7 раз быстрее, чем `UnsortedBranch`. В то же время длительность `SortedBranchless` и `UnsortedBranchless` примерно одинакова.

## Объяснение

Представим, что блок прогнозирования ветвлений — это маленькое существо, живущее внутри процессора. В нашем примере у этого существа короткая память: оно будет помнить только последнее значение условия, которое пытается спрогнозировать. И всегда станет предполагать, что условие будет иметь то же значение, которое мы наблюдали в последний раз. Допустим, ему надо спрогнозировать значения выражения `a[i] >= 128` для следующего небольшого массива: `a = {0, 32, 64, 96, 128, 160, 192, 224}`. В этом случае наше существо создаст следующую цепочку аргументов.

- $a[0] >= 128$  (**неверно**, поскольку  $a[0] == 0$ ).  
 «У меня нет предыдущего значения этого условия. Наверное, оно **неверно**».  
 Прогноз **правильный**.
- $a[1] >= 128$  (**неверно**, поскольку  $a[1] == 32$ ).  
 «В прошлый раз это выражение было **неверным**. Наверное, сейчас так же».  
 Прогноз **правильный**.
- $a[2] >= 128$  (**неверно**, поскольку  $a[2] == 64$ ).  
 «В прошлый раз это выражение было **неверным**. Наверное, сейчас так же».  
 Прогноз **правильный**.
- $a[3] >= 128$  (**неверно**, поскольку  $a[3] == 96$ ).  
 «В прошлый раз это выражение было **неверным**. Наверное, сейчас так же».  
 Прогноз **правильный**.
- $a[4] >= 128$  (**верно**, поскольку  $a[4] == 128$ ).  
 «В прошлый раз это выражение было **неверным**. Наверное, сейчас так же».  
 Прогноз **неправильный**.
- $a[5] >= 128$  (**верно**, поскольку  $a[5] == 160$ ).  
 «В прошлый раз это выражение было **верным**. Наверное, сейчас так же».  
 Прогноз **правильный**.
- $a[6] >= 128$  (**верно**, поскольку  $a[6] == 192$ ).  
 «В прошлый раз это выражение было **верным**. Наверное, сейчас так же».  
 Прогноз **правильный**.
- $a[7] >= 128$  (**верно**, поскольку  $a[7] == 224$ ).  
 «В прошлый раз это выражение было **верным**. Наверное, сейчас так же».  
 Прогноз **правильный**.

Мы получили семь правильных прогнозов из восьми. Неплохой результат! Теперь сделаем то же самое с другим массивом, содержащим те же элементы в другом порядке:  $a = \{224, 0, 192, 32, 160, 64, 128, 96\}$ .

- $a[0] >= 128$  (**верно**, поскольку  $a[0] == 224$ ).  
 «У меня нет предыдущего значения этого условия. Наверное, оно **неверно**».  
 Прогноз **неправильный**.

- $a[1] \geq 128$  (**неверно**, поскольку  $a[1] == 0$ ).  
«В прошлый раз это выражение было **верным**. Наверное, сейчас так же».  
Прогноз **неправильный**.
- $a[2] \geq 128$  (**верно**, поскольку  $a[2] == 192$ ).  
«В прошлый раз это выражение было **неверным**. Наверное, сейчас так же».  
Прогноз **неправильный**.
- $a[3] \geq 128$  (**неверно**, поскольку  $a[3] == 32$ ).  
«В прошлый раз это выражение было **верным**. Наверное, сейчас так же».  
Прогноз **неправильный**.
- $a[4] \geq 128$  (**верно**, поскольку  $a[4] == 160$ ).  
«В прошлый раз это выражение было **неверным**. Наверное, сейчас так же».  
Прогноз **неправильный**.
- $a[5] \geq 128$  (**неверно**, поскольку  $a[5] == 64$ ).  
«В прошлый раз это выражение было **верным**. Наверное, сейчас так же».  
Прогноз **неправильный**.
- $a[6] \geq 128$  (**верно**, поскольку  $a[6] == 128$ ).  
«В прошлый раз это выражение было **неверным**. Наверное, сейчас так же».  
Прогноз **неправильный**.
- $a[7] \geq 128$  (**неверно**, поскольку  $a[7] == 96$ ).  
«В прошлый раз это выражение было **верным**. Наверное, сейчас так же».  
Прогноз **неправильный**.

В этом случае все восемь прогнозов неверны.

Конечно, реальные блоки прогнозирования ветвлений гораздо умнее нашего воображаемого существа и у них гораздо больше памяти под архив значений условий. Но общая идея остается той же: они пытаются предсказать будущие значения, основываясь на существующих наблюдениях. Когда эти значения соответствуют определенной схеме, например, все равны, гораздо проще предсказывать будущие значения, чем когда они абсолютно случайны.

Когда прогноз верен, мы можем оценить *верную* ветвь вне очереди и получить заметное улучшение производительности.

Когда прогноз неверен, оцениваем *неверную* ветвь вне очереди. Получив реальное значение условия, мы должны отменить результаты оценки и оценить другую

ветвь. Эта ситуация известна как *неверный прогноз ветвления*, она сильно ухудшает производительность, поскольку нужно потратить время на отмену существующих результатов и оценку другой ветви, не получив преимуществ выполнения вне последовательности.

Поэтому `UnsortedBranch` работает настолько медленнее `SortedBranch`: при работе с несортированным массивом мы получаем огромное количество неверных прогнозов. Разницы между бенчмарками `SortedBranchless` и `UnsortedBranchless` практически нет, поскольку в них нет условий, включающих в себя элементы массива. Они работают так же быстро, как `SortedBranch`, поскольку не влекут за собой ухудшения производительности из-за неверных прогнозов.

## Обсуждение

Прогнозирование ветвлений — еще одна полезная для производительности, но вредная для бенчмаркинга техника. Если в вашем исходном коде есть ветвление, невозможно определить его реальную длительность в конкретном окружении в целом, поскольку она зависит от данных ввода. Для разработки качественного бенчмарка в этом случае требуется проверка разных схем данных ввода, которые могут дать разные результаты измерения.

Этот пример основан на вопросе 11227809 со `StackOverflow` (<https://stackoverflow.com/q/11227809>). В самом популярном ответе на него можно найти еще одну интересную интерпретацию прогнозирования ветвлений, основанную на поездах и железнодорожных узлах.

## Практический пример 2: количество условий

Допустим, у нас есть простой блок `if/else`:

```
if (/* Выражение */)
{
    /* Выражение1 */
}
else
{
    /* Выражение2 */
}
```

Работая с исходным кодом на `C#`, мы часто рассматриваем такое выражение как неделимую единицу. На уровне `C#` есть только два варианта: выражение верно (должно выполняться `Statement1`) или выражение неверно (должно выполняться `Statement2`). Это хорошая ментальная модель, когда мы думаем о логике программы. Но если думаем о производительности и прогнозировании ветвлений, появляется больше вариантов в случае составного выражения.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private const int n = 100000;
    private int[] a = new int[n];
    private int[] b = new int[n];
    private int[] c = new int[n];

    [Params(false, true)]
    public bool RandomData;

    [GlobalSetup]
    public void Setup()
    {
        if (RandomData)
        {
            var random = new Random(42);
            for (int i = 0; i < n; i++)
            {
                a[i] = random.Next(2);
                b[i] = random.Next(2);
                c[i] = random.Next(2);
            }
        }
    }

    [Benchmark(Baseline = true)]
    public int OneCondition()
    {
        int counter = 0;
        for (int i = 0; i < a.Length; i++)
            if (a[i] * b[i] * c[i] != 0)
                counter++;
        return counter;
    }

    [Benchmark]
    public int TwoConditions()
    {
        int counter = 0;
        for (int i = 0; i < a.Length; i++)
            if (a[i] * b[i] != 0 && c[i] != 0)
                counter++;
        return counter;
    }

    [Benchmark]
    public int ThreeConditions()
```

```

{
    int counter = 0;
    for (int i = 0; i < a.Length; i++)
        if (a[i] != 0 && b[i] != 0 && c[i] != 0)
            counter++;
    return counter;
}
}

```

У нас есть три массива `int` — `a`, `b` и `c` и три бенчмарка — `OneCondition`, `TwoConditions` и `ThreeConditions`. Все они вычисляют количество случаев, когда `a[i] != 0 && b[i] != 0 && c[i] != 0`. В методе `ThreeConditions` мы используем это выражение без изменений. В методе `TwoConditions` заменили `a[i] != 0 && b[i] != 0` на `a[i] * b[i] != 0` (мы полагаем, что значения элементов довольно малы и умножение можно оценить без выхода за верхнюю границу). В методе `OneCondition` заменили все выражение на `a[i] * b[i] * c[i] != 0`.

У нас также есть параметр `RandomData`. Когда он верен, мы заполняем все массивы случайными числами от 0 до 1. Когда неверен, мы не заполняем массивы, то есть все элементы равны нулю.

## Результаты

Вот пример результатов (macOS 10.14.2, Intel Core i7-4870HQ CPU 2.50GHz, .NET Core 2.1.3, RyuJIT-x64):

Method	RandomData	Mean	StdDev	Ratio
OneCondition	False	130.15 us	1.9242 us	1.00
TwoConditions	False	89.68 us	1.5718 us	0.69
ThreeConditions	False	58.51 us	0.4505 us	0.45
OneCondition	True	227.79 us	1.7919 us	1.00
TwoConditions	True	419.46 us	2.9244 us	1.84
ThreeConditions	True	717.50 us	6.7728 us	3.15

Как видите, когда параметр `RandomData` ложен, самым медленным бенчмарком является `OneCondition`, а самым быстрым — `ThreeConditions`. Когда он верен, ситуация противоположная: `OneCondition` — самый быстрый, а `ThreeConditions` — самый медленный.

## Объяснение

Когда параметр `RandomData` ложен, `OneCondition` оказывается самым медленным бенчмарком, поскольку проводит больше операций, чем остальные. Умножение целых чисел — «тяжелая» операция, она занимает гораздо больше времени, чем сравнение целого числа с нулем или операция `&&`. В `OneCondition` две операции умножения и одно сравнение, в `TwoConditions` одна операция умножения, два

сравнения и одна операция `&&`, а в `ThreeConditions` три сравнения и две операции `&&`. Чем больше операций умножения, тем больше времени занимают методы.

Когда параметр `RandomData` верен, на производительность начинает влиять прогнозирование ветвлений, поскольку у нас большое количество неверных прогнозов. Вместо того чтобы работать со всем выражением, прогнозирование ветвлений пытается предсказать индивидуальные сравнения по отдельности.

Теперь рассмотрим собственный код `ThreeConditions`:

```

; ThreeConditions/RyuJIT-x64
sub    rsp,28h                ; Move stack pointer
xor    eax,eax                ; counter = 0
xor    edx,edx                ; i = 0
mov    r8,qword ptr [rcx+8]   ; r8 = &a
cmp    dword ptr [r8+8],0     ; if (a.Length <= 0)
jle    FINISH                 ; goto FINISH
START:
mov    r9,r8                  ; r9 = &a
cmp    edx,dword ptr [r9+8]   ; if (i >= a.Length)
jae    OUT_OF_RANGE          ; goto OUT_OF_RANGE
movsxd r10,edx                ; r10 = i
cmp    dword ptr [r9+r10*4+10h],0 ; if (a[i] == 0)
je     CONTINUE              ; goto CONTINUE
mov    r9,qword ptr [rcx+10h] ; r9 = &b
cmp    edx,dword ptr [r9+8]   ; if (i >= b.Length)
jae    OUT_OF_RANGE          ; goto OUT_OF_RANGE
cmp    dword ptr [r9+r10*4+10h],0 ; if (b[i] == 0)
je     CONTINUE              ; goto CONTINUE
mov    r9,qword ptr [rcx+18h] ; r9 = &c
cmp    edx,dword ptr [r9+8]   ; if (i >= c.Length)
jae    OUT_OF_RANGE          ; goto OUT_OF_RANGE
cmp    dword ptr [r9+r10*4+10h],0 ; if (c[i] == 0)
je     CONTINUE              ; goto CONTINUE
inc    eax                    ; counter++
CONTINUE:
inc    edx                    ; i++
cmp    dword ptr [r8+8],edx   ; if (i < a.Length)
jg     START                  ; goto START
FINISH:
add    rsp,28h                ; Restore stack pointer
ret                                ; return counter
OUT_OF_RANGE:
call   IndexOutOfRangeException ; throw IndexOutOfRangeException
int    3                       ;

```

Как видите, внутри выражения `a[i] != 0 && b[i] != 0 && c[i] != 0` шесть команд условного перехода! Три из них являются проверками по диапазону значений, в данном примере они всегда ложные. Другие три команды соответствуют проверкам `a[i] != 0`, `b[i] != 0` и `c[i] != 0`. Прежде всего блок прогнозирования ветвлений

должен предугадать значение  $a[i] \neq 0$ . Если этот прогноз будет неправильным, все выражение окажется ложным. Если правильным, то блок прогнозирования должен предугадать значение  $b[i] \neq 0$ . Если этот прогноз будет неправильным, все выражение окажется ложным. Если правильным, то блок прогнозирования должен предугадать значение  $c[i] \neq 0$ . Поскольку во всех массивах случайные данные, мы можем трижды пострадать от неверного прогноза ветвления.

Ущерб от неверного прогноза в этом случае намного больше, чем длительность операции умножения. Поэтому `ThreeConditions` и становится самым медленным методом. `TwoConditions` работает быстрее, так как страдает от неверного прогноза только дважды. А в методе `OneCondition` может случиться максимум один неверный прогноз за один запуск.

## Обсуждение

Одна из самых популярных целей бенчмаркинга — определить, какой из методов быстрее. Даже если мы точно знаем окружение, все равно производительность может зависеть от данных ввода. Как видите, метод `OneCondition` может быть и быстрее, и медленнее всех в зависимости от содержимого массивов.

Этот пример основан на вопросе 35531369 со StackOverflow (<https://stackoverflow.com/q/35531369>).

## Практический пример 3: минимум

В этом примере попытаемся измерить производительность двух простых методов, вычисляющих минимум из двух чисел. Мы проверим следующие две реализации:

```
int MinTernary(int x, int y)
{
    return x < y ? x : y;
}
```

```
int MinBitHacks(int x, int y)
{
    return x & ((x - y) >> 31) | y & (~ (x - y) >> 31);
}
```

Первая реализация кажется очевидной, но в ней есть одна важная проблема: она может пострадать от неверных прогнозов из-за условия в выражении. К счастью, ее можно переписать, убрав ветвления, с помощью битовых операций.

Здесь мы вычисляем  $(x-y)$ , знак этого выражения зависит от того, какое из чисел меньше. Затем  $(x-y) \gg 31$  создает битовую маску, содержащую только нули и единицы. Далее мы вычисляем обратную маску:  $\sim(x-y) \gg 31$ . Потом соединяем

компоненты операции и соответствующие битовые маски с помощью `and` (минимальное число получает маску `11...11`). Вот и все: оператор `or` выдаст правильный результат. Далее приведен пример для  $x=8$  и  $y=3$  (предполагаются восьмибитные числа):

Expression	Binary	Decimal
<code>x</code>	<code>00001000</code>	<code>8</code>
<code>y</code>	<code>00000011</code>	<code>3</code>
<code>x-y</code>	<code>00000101</code>	<code>5</code>
<code>(x-y)&gt;&gt;31</code>	<code>00000000</code>	<code>0</code>
<code>~(x-y)&gt;&gt;31</code>	<code>11111111</code>	<code>-1</code>
<code>x&amp;( (x-y)&gt;&gt;31)</code>	<code>00000000</code>	<code>0</code>
<code>y&amp;(~(x-y)&gt;&gt;31)</code>	<code>00000011</code>	<code>3</code>
<code>Result</code>	<code>00000011</code>	<code>3</code>

Как видите, здесь нет ветвления — мы вычисляем минимум, используя только битовые операции.

## Исходный код

Рассмотрим следующие бенчмарки на базе `BenchmarkDotNet`:

```
public class Benchmarks
{
    const int N = 100001;

    private int[] a = new int[N];
    private int[] b = new int[N];
    private int[] c = new int[N];

    [Params(false, true)]
    public bool RandomData;

    [GlobalSetup]
    public void Setup()
    {
        if (RandomData)
        {
            var random = new Random(42);
            for (int i = 0; i < N; i++)
            {
                a[i] = random.Next();
                b[i] = random.Next();
            }
        }
    }

    [Benchmark]
    public void Ternary()
    {
```

```

    for (int i = 0; i < N; i++)
    {
        int x = a[i], y = b[i];
        c[i] = x < y ? x : y;
    }
}

[Benchmark]
public void BitHacks()
{
    for (int i = 0; i < N; i++)
    {
        int x = a[i], y = b[i];
        c[i] = x & ((x - y) >> 31) | y & (~(x - y) >> 31);
    }
}
}

```

У нас есть два бенчмарка, `Ternary` и `BitHacks`, которые вносят минимальные значения `a[i]` и `b[i]` в `c[i]` в виде цикла. У каждого бенчмарка свой способ вычисления минимума: `Ternary` использует тернарные операции (с ветвлением), а `BitHacks` — битовые (без ветвления).

Имеется также параметр `RandomData`. Когда он верен, мы заполняем массивы `a` и `b` случайными числами. Когда он неверен, массивы не заполняем, то есть все элементы равны нулю.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2 (JIT 4.7.3260.0); Mono x64 5.180.225):

Method	Job	RandomData	Mean	StdDev
Ternary	LegacyJitX64	False	136.0 us	1.9197 us
BitHacks	LegacyJitX64	False	170.3 us	1.1214 us
Ternary	LegacyJitX86	False	142.3 us	1.2358 us
BitHacks	LegacyJitX86	False	177.6 us	1.6017 us
Ternary	Mono	False	157.8 us	1.3883 us
BitHacks	Mono	False	231.0 us	4.5545 us
Ternary	RyuJitX64	False	126.0 us	1.4962 us
BitHacks	RyuJitX64	False	172.8 us	1.9703 us
Ternary	LegacyJitX64	True	498.2 us	4.3987 us
BitHacks	LegacyJitX64	True	171.4 us	0.9027 us
Ternary	LegacyJitX86	True	577.1 us	5.5484 us
BitHacks	LegacyJitX86	True	179.5 us	1.4957 us
Ternary	Mono	True	159.3 us	1.2456 us
BitHacks	Mono	True	229.0 us	2.0781 us
Ternary	RyuJitX64	True	504.3 us	5.2434 us
BitHacks	RyuJitX64	True	173.1 us	1.0211 us

Вот значения среднего арифметического, сгруппированные в более удобную таблицу (без информации по стандартному отклонению):

	RandomData=False		RandomData=True	
	Ternary	BitHacks	Ternary	BitHacks
-----	-----	-----	-----	-----
LegacyJIT-x86	142.3 us	177.6 us	577.1 us	179.5 us
LegacyJIT-x64	136.0 us	170.3 us	498.2 us	171.4 us
RyuJIT-x64	126.0 us	172.8 us	504.3 us	173.1 us
Mono	157.8 us	231.0 us	159.3 us	229.0 us

Когда параметр `RandomData` ложен, метод `BitHacks` всегда работает медленнее, чем `Ternary`. Когда он верен, `BitHacks` работает быстрее на `LegacyJIT-x86`, `LegacyJIT-x64`, `RyuJIT-x64`, но не на `Mono`.

## Объяснение

Прежде всего обсудим ситуацию в .NET Framework (`LegacyJIT-x86`, `LegacyJIT-x64`, `RyuJIT-x64`). Когда параметр `RandomData` ложен, `BitHacks` работает медленнее, чем `Ternary`, поскольку содержит больше команд. Когда он верен, у `Ternary` наблюдается снижение производительности из-за неверных прогнозов ветвления. Значение `RandomData` не влияет на длительность алгоритма `BitHacks`, потому что в нем нет условной логики в теле цикла.

Ситуация на `Mono` гораздо интересней. Можно сделать несколько интересных наблюдений.

- На `Mono` `Ternary` всегда работает быстрее, чем `BitHacks` (даже когда параметр `RandomData` верен).
- Версия метода `Ternary` для `Mono` работает гораздо быстрее, чем тот же код на .NET Framework, если параметр `RandomData` верен.
- Мы получаем примерно одинаковую длительность для `RandomData=False` и `RandomData=True` на `Mono` для обоих бенчмарков.

Рассмотрим код. Для упрощения представим сгенерированный код методов `MinTernary` и `MinBitHacks`. Вот код для `RyuJIT-x64`:

```
; MinTernary/RyuJIT-x64
cmp  edx,r8d    ; if (x < y)
j1   LESS      ; goto LESS
mov  eax,r8d    ; result = y
ret                                ; return y
LESS:
mov  eax,edx    ; result = x
ret                                ; return x
```

Выглядит очень просто: мы сравниваем *x* и *y* и получаем минимальное значение. Теперь рассмотрим тот же метод на Mono:

```
; MinTernary/Mono5.180.225-x64
sub    $0x18,%rsp      ; move stack pointer
mov    %rsi,(%rsp)     ; save rsi on stack
mov    %rdi,0x8(%rsp)  ; save rdi on stack

mov    %rdx,%rdi      ; rdi = x
mov    %r8,%rsi       ; rsi = y
cmp    %esi,%edi      ; compare x and y
mov    %rsi,%rax      ; rax = rsi (y)
cmovl %rdi,%rax      ; rax = rdi (x) if (x < y)

mov    (%rsp),%rsi    ; restore rsi from stack
mov    0x8(%rsp),%rdi ; restore rdi from stack
add    $0x18,%rsp     ; restore stack pointer
retq                               ; return rax
```

Здесь Mono использует условное перемещение (команда `cmovl`). `cmovl %rdi,%rax` перемещает значение из `%rdi` в `%rax`, только если предыдущая команда `cmp` решила, что  $x < y$ . На выполнение команды `cmovl` не влияет блок прогнозирования ветвлений. В реализации `Ternary` на Mono нет спада производительности из-за неверных прогнозов, поскольку на уровне собственного кода ветвления нет, несмотря на то что такое условие есть в исходном коде на C#.

Теперь мы можем объяснить сделанное наблюдение. Значение `RandomData` не влияет на производительность методов `Ternary` и `BitHacks` на Mono, поскольку ни в одном из них нет ветвлений. Метод `BitHack` занимает больше времени, чем `Ternary`, поскольку в нем больше тяжелых команд. Метод `Ternary` работает быстрее на Mono, чем на .NET Framework, когда параметр `RandomData` верен, поскольку в реализации на Mono на самом деле нет ветвлений (в реализации на .NET Framework есть команда `jmp`) и поэтому нет снижения производительности из-за неверных прогнозов.

## Обсуждение

Все главные компоненты пространства производительности (исходный код, окружение, данные ввода) важны для нас. Мы не можем сказать, какой метод, `Ternary` или `BitHacks`, в данном примере быстрее: производительность зависит от окружения и данных ввода одновременно. Даже если вы видите выражение с `if` в программе на C#, это не означает, что на уровне собственного кода появится настоящее ветвление, — все зависит от компиляторов C# и JIT.

Версии различных алгоритмов без ветвлений могут выглядеть интересно, поскольку на них не влияют неверные прогнозы. Это облегчает анализ производительности таких методов (не нужно нумеровать разные наборы данных ввода).

Существует любопытный проект `movfuscator` (<https://github.com/xoreaxeaxeax/movfuscator>), способный превратить программу в серию команд `mov`. Обе программы — изначальная и версия `movfuscator` — эквивалентны друг другу. С научной точки зрения это очень интересный проект, поскольку позволяет создавать версии любой программы без ветвлений. К сожалению, такие версии очень медленные, что делает их непригодными для использования<sup>1</sup>.

Смотрите также: `coreclr#21615`: «`TextInfo.ToLowerAsciiInvariant` без ветвлений/`ToUpperAsciiInvariant`» (<https://github.com/dotnet/coreclr/pull/21615>).

Этот пример основан на [Akinshin, 2016a].

## Практический пример 4: схемы

В первом примере на тему прогнозирования ветвлений («Отсортированные и неотсортированные данные») мы представляли блок прогнозирования в виде существа, запоминающего только последнее оцененное значение каждого условия. Реальные блоки гораздо умнее — они могут делать правильные прогнозы, даже если данные соответствуют определенной схеме.

### Исходный код

Рассмотрим следующие бенчмарки на базе `BenchmarkDotNet`:

```
public class Benchmarks
{
    private int[] a = new int[100001];

    [Params(
        "000000000000",
        "000000000001",
        "000001000001",
        "001001001001",
        "010101010101",
        "random"
    )]
    public string Pattern;

    [GlobalSetup]
    public void Setup()
    {
```

<sup>1</sup> Можете попытаться поиграть в DOOM без ветвлений. Исходный код находится здесь: <https://github.com/xoreaxeaxeax/movfuscator/tree/master/validation/doom>. На рендеринг одного кадра уходит примерно 7 ч.

```

var rnd = new Random(42);
for (int i = 0; i < a.Length; i++)
    a[i] = Pattern == "random"
        ? rnd.Next(2)
        : Pattern[i % Pattern.Length] - '0';
}

[Benchmark(Baseline = true)]
public int Run()
{
    int counter = 0;
    for (int i = 0; i < a.Length; i++)
        if (a[i] == 0)
            counter++;
        else
            counter--;
    return counter;
}
}

```

У нас есть массив `int`, заполненный нулями и единицами по определенной схеме. В единственном бенчмарке мы сравниваем каждый элемент массива с нулем: если он равен нулю, увеличиваем счетчик `counter`, если наоборот — уменьшаем. Таким образом, количество команд одинаково для всех схем.

## Результаты

Вот пример результатов (macOS 10.14.2, Intel Core i7-4870HQ CPU 2.50GHz, .NET Core 2.1.3):

Pattern	Mean	StdDev	Ratio
000000000000	86.30 us	0.5490 us	1.00
000000000001	90.75 us	0.5556 us	1.05
000001000001	95.63 us	0.4887 us	1.11
001001001001	109.50 us	0.5972 us	1.27
010101010101	141.40 us	0.4198 us	1.64
random	434.80 us	3.5712 us	5.04

Как видите, бенчмарк со схемой `000000000000` — самый быстрый, а со случайной схемой — самый медленный.

## Объяснение

Блок прогнозирования ветвлений выдает максимальную производительность, когда все значения условий одинаковы. В этом случае неверных прогнозов нет вообще. Когда схема случайна, получается больше всего неверных прогнозов (и худшая

производительность), поскольку предсказать случайные значения довольно сложно. У нас есть и промежуточные результаты между этими двумя случаями: блок прогнозирования может распознать некоторые схемы. В данном примере худшая схема — `010101010101`, поскольку прогнозируемое значение каждый раз меняется. Но бенчмарк с этой схемой все равно работает втрое быстрее, чем со случайной.

## Обсуждение

Если вы хотите больше узнать о внутреннем устройстве прогнозирования ветвления, мы рекомендуем прочесть [Intel Manual], [Rohou, 2015], [Edelkamp, 2016], [Luu, 2017] и [Mittal, 2018]. Блок прогнозирования — очень сложная часть процессора. У разных моделей процессора различные алгоритмы прогнозирования. Они могут включать в себя неочевидные факторы. Некоторые части этих алгоритмов могут держаться в тайне. Цитируем [Agner Microarch]:

«3.8. Прогнозирование ветвлений в процессорах Intel Haswell, Broadwell и Skylake

Блок прогнозирования ветвлений был перепроектирован в Haswell, но о его конструкции известно очень мало.

Измеренная выработка для условных переходов и ветвлений варьируется между одной ветвью за один временной цикл до одной ветви за два временных цикла для условных переходов и выбранных спрогнозированных ветвей. У невыбранных спрогнозированных ветвей выработка даже больше — до двух ветвей за временной цикл.

Высокая выработка для выбранных ветвей — одна за цикл — наблюдалась при количестве до 128 ветвей, где не более одной ветви на 16 байт кода. Если на 16 байт кода приходится больше одной ветви, то выработка снижается до одного условного перехода за два временных цикла. Если в критической части кода более 128 ветвей и они размещаются как минимум на 16 байтах, то, видимо, выработка у первых 128 выше, а у оставшихся снижается.

Эти наблюдения могут означать существование двух методов предсказания ветвлений: быстрого, связанного с кэшем `μop` и кэшем команд, и медленного, использующего целевой буфер ветвлений».

Как видите, узнать все подробности внутреннего устройства блока прогнозирования на всех существующих процессорах нелегко. Однако обычно это знание не требуется на практике: можно разрабатывать прекрасные бенчмарки и корректно анализировать результаты, опираясь только на основную концепцию прогнозирования ветвлений.

## Подводя итог

Прогнозирование ветвлений усиливает функции ИЛР, связанные с ветвями. Из примеров, которые мы обсудили, можно сделать несколько выводов.

- Производительность зависит от данных ввода. Даже если каждый раз выполняется одно и то же количество команд, длительность метода может различаться в зависимости от условий ветви.
- При наличии составного выражения, например `a && b && c`, в качестве условия ветви можно считать его неделимой единицей в коде на C#. На этом уровне есть только два варианта: выражение истинно (мы выбираем эту ветвь) или ложно (не выбираем ее). Однако на уровне собственного кода оно переводится в три команды условного перехода. Таким образом, блок прогнозирования должен выполнить три независимых прогноза. В худшем случае можно получить три неверных прогноза для этого выражения.
- Даже если на уровне C# имеется явное ветвление (например, выражение с `if` или тернарным оператором), некоторые компиляторы JIT могут быть настолько разумными, что заменят его собственной реализацией без ветвления. И тогда случайные данные не повлияют на исполнение кода, поскольку блоку прогнозирования нечего прогнозировать.
- Обычно наилучшая ситуация для блока прогнозирования — когда условие ветви всегда имеет одно и то же значение. Худшая — когда значения условия ветви случайны. Однако существует множество промежуточных случаев, а современные блоки прогнозирования способны распознать регулярные схемы и обеспечить хорошую производительность. Это все равно будет хуже, чем в наилучшей ситуации, но гораздо лучше, чем в худшей, со случайными данными.

Разрабатывая бенчмарк с ветвлениями, следует внимательно проверить разные схемы ввода данных. Конечно, не нужно переписывать все схемы для каждого условия в каждом бенчмарке. Обычно достаточно проверить наилучший случай (все значения условия одинаковы), худший (все значения случайны) и несколько реалистичных (с данными из реальной жизни). Обычно эти случаи обеспечивают достаточно данных для того, чтобы сделать выводы.

## Арифметика

Арифметические операции, например сложение и умножение, широко распространены во многих программах. Их легко использовать, но сложнее измерять, особенно если вычисления включают в себя числа с плавающей запятой.

Обычно мы пропускаем подробные объяснения различных эффектов, потому что они не пригодятся вам при бенчмаркинге. В этом разделе нужно будет кратко обсудить такие операции с типами с плавающей запятой, как `float`, `double` и `decimal`, — это поможет вам разобраться в некоторых результатах бенчмарков, включающих в себя арифметические операции.

Типы `float` и `double` соответствуют стандарту IEEE 754, в котором указано, что число с плавающей запятой представляется с помощью *знака*  $S$ , *экспоненты*  $E$  и *мантиссы*  $M$ , что можно перевести в реальное значение по следующему правилу:

$$V = (-1)^S \cdot 1.M \cdot 2^{E - E_{\text{bias}}}$$

После этой формулы многие разработчики прекращают читать текст о числах с плавающей запятой, поскольку все становится слишком сложно и запутанно. Вместо классической теории мы используем подход, предложенный Фабьеном Санглардом в [Sanglard, 2017]. Согласно *интерпретации Сангларда* число с плавающей запятой представляется с помощью *знака*, *окна* между двумя последовательными степенями двойки и *ответвления* в этом окне. Все числа можно разбить на непересекающиеся интервалы (окна):  $[0,25; 0,25)$ ,  $[0,25; 0,5)$ ,  $[0,5; 1)$ ,  $[1; 2)$ ,  $[2; 4)$  и т. д. Каждое окно также можно разбить на непересекающиеся подинтервалы (корзины). Если мы хотим перевести число в вид по стандарту IEEE 754, нужно найти окно, содержащее это число. Индекс окна и является значением экспоненты. Далее внутри этого окна нужно найти корзину. Индекс корзины (ответвление) является значением мантиссы. Если число отрицательное, мы должны сделать то же самое для абсолютного значения этого числа и поставить 1 в знаковый разряд.

К сожалению, нельзя внести все реальные числа в память компьютера: диапазон и точность зависят от имеющегося количества битов. В табл. 7.2 можно увидеть главные характеристики 32-, 64- и 80-битных чисел с плавающей запятой.

**Таблица 7.2.** Характеристики чисел с плавающей запятой

Число	Знак	Экспонента	Мантисса	Разряды	Нижняя граница	Верхняя граница	$E_{\text{bias}}$
32-битное	1	8	23	$\approx 7,2$	$1,2 \cdot 10^{-38}$	$3,4 \cdot 10^{+38}$	127
64-битное	1	11	52	$\approx 15,9$	$2,3 \cdot 10^{-308}$	$1,7 \cdot 10^{+308}$	1023
80-битное	1	15	64	$\approx 19,2$	$3,4 \cdot 10^{-4932}$	$1,1 \cdot 10^{+4932}$	16 383

Например, 32-битное число включает в себя 1 бит на знак, 8 бит на экспоненту и 23 бита на мантиссу. Этого достаточно, чтобы демонстрировать числа от  $1,2 \cdot 10^{-38}$  до  $3,4 \cdot 10^{+38}$ , но мы можем сохранить примерно 7,2 разряда для каждого числа.

Выполним простое упражнение и вычислим реальное значение следующего 32-битного числа, записанного по стандарту  $3,4 \cdot 10^{+38}$  (подробнее об этом числе можно узнать на <https://float.exposed/0x4e6e6b29>):

Sign	Exponent	Mantissa
0	10011100	11011100110101100101001

- Знак  $S$  равен нулю, то есть число является положительным (1 обозначает отрицательные числа).
- Экспонента  $E$  равна  $10011100_2$ , или  $156_{10}$ . Чтобы найти нужное окно, следует вычесть из него  $E_{\text{bias}}$ . Этот прием помогает расшифровать крайне малые и крайне большие числа с использованием неотрицательного числа в качестве экспоненты. Для 32-битных чисел  $E_{\text{bias}} = 127$  (см. табл. 7.2),  $E - E_{\text{bias}} = 156 - 127 = 29$ . То есть наше окно —  $[2^{29}, 2^{30}]$  или  $[536\ 870\ 912; 1\ 073\ 741\ 824]$ .
- Мантисса  $M$  равна  $11011100110101100101001_2$ , или  $7\ 236\ 393_{10}$ . Поскольку в ней 23 бита, окно нужно разделить на  $2^{23}$  (8 388 608) корзин. Индекс нашей корзины (ответвления внутри окна) — 7 236 393.

Окном оказалось  $[536\ 870\ 912; 1\ 073\ 741\ 824]$ . Если разделить его на  $2^{23}$  подинтервала, получим размер корзины, равный 64. Поскольку мы знаем индекс корзины (ответвления), то с легкостью можем вычислить значение:

$$V = 536\ 870\ 912 + 64 \cdot 7\ 236\ 393 = 1\ 000\ 000\ 064.$$

То же значение можно получить и по классической формуле. В ней мы используем  $1.M$ , поскольку мантисса по умолчанию начинается с 1. Это помогает сохранить один бит памяти. Значение  $1.M$  равно  $1.11011100110101100101001_2$ , или  $15\ 625\ 001_{10} \cdot 2^{-23}$ . Таким образом, получаем:

$$V = (-1)^0 \cdot (15\ 625\ 001 \cdot 2^{-23}) \cdot 2^{156 - 127} = 15\ 625\ 001 \cdot 2^6 = 1\ 000\ 000\ 064.$$

На платформе .NET существует только два собственных типа, соответствующих стандарту IEEE 754: `float` (32-битный) и `double` (64-битный). На .NET отсутствует тип для 80-битных чисел с плавающей запятой, но среда исполнения все равно может выполнять промежуточные вычисления с помощью таких значений. Есть и еще один дополнительный стандартный тип, который может применяться для реальных значений: `decimal` (128-битный). Но это не собственный тип, это тип `struct`. У него есть пользовательская реализация, основанная на четырех полях `int`<sup>1</sup>, не соответствующая стандарту IEEE 754. Она была разработана для финансовых и банковских вычислений. На C# можно указать тип, который вы хотите использовать, с помощью специального постфикса: `1.0f` для `float`, `1.0d` для `double`, `1.0m` для `decimal`.

<sup>1</sup> Ее исходный код можно найти здесь: <https://referencesource.microsoft.com/#mscorlib/system/decimal.cs>.

У каждого типа для чисел с плавающей запятой есть свой набор функций. Например, если мы переведем `1 000 000 064` во `float` и напечатаем его в 10-разрядном виде (`((float)1000000064). ToString("G10")`), то получим `1000000060` вместо `1000000064`. Несмотря на то что `1000000064` прекрасно представлено в стандарте IEEE 754, среда исполнения округляет его, поскольку точность типа `float` недостаточно велика, чтобы справляться с 10-разрядными числами. Это число может быть точно представлено в типе `decimal`. Еще один интересный факт: `1000000064.00m.ToString()` выдаст `1000000064,00`, поскольку тип `decimal` сохраняет информацию о двух нулях после запятой. Другие интересные факты о десятичных разрядах можно найти в [Skeet, 2008]<sup>1</sup>.

На аппаратном уровне существует несколько наборов команд, которые могут работать с числами по стандарту IEEE 754. Первый набор команд, совместимый с `x86` и поддерживающий этот стандарт, называется `x87`: он появился в первом математическом сопроцессоре от Intel — Intel 8087. Позже компания Intel разработала и другие наборы команд, например `SSE` и `AVX`, также поддерживающие операции по стандарту IEEE 754.

Разные компиляторы JIT используют разные наборы команд для операций с `float` и `double`. Например, `LegacyJIT-x86` может работать только с `x87`. `LegacyJIT-x64` в этом смысле лучше — он может работать и с `SSE` (если он доступен). А `RyuJIT` еще лучше — он и с `AVX` умеет работать (если тот доступен).

Большинство классических правил арифметики не работают с числами с плавающей запятой. Вот одно из самых известных уравнений<sup>2</sup> в стандарте IEEE 754:

$$0,1d + 0,2d \neq 0,3d.$$

Такие ситуации возникают, поскольку `0,1d`, `0,2d` и `0,3d` не могут быть полностью выражены в форме записи IEEE 754:

```
0.1d ~ 0.100000000000000005551115123125783
+0.2d ~ 0.200000000000000011102230246251565
-----
0.300000000000000044408920985006262
0.3d ~ 0.299999999999999988897769753748435
```

Многие арифметические правила в принципе не работают с типами `float` и `double`:  $(a + b) + c \neq a + (b + c)$ ,  $(ab)c \neq a(bc)$ ,  $(a + b)c \neq ac + bc$ ,  $a^{x+y} \neq a^x a^y$  и т. д. Это неудивительно для тех, кто знает стандарт IEEE 754. Однако есть один важный факт о числах с плавающей запятой на платформе .NET, который обычно неизвестен разработчикам: операции с типами `float` и `double` недетерминированы, то есть

<sup>1</sup> А также здесь: <http://csharpindepth.com/Articles/General/Decimal.aspx>.

<sup>2</sup> См. также <https://0.30000000000000004.com/>.

одна и та же программа может выдавать разные результаты с плавающей запятой при разных условиях.

Вот мой любимый пример из [Skeet, 2008]<sup>1</sup>:

```
static float Sum(float a, float b) => a + b;
static float x;
static void Main()
{
    x = Sum(0.1f, 0.2f);
    float y = Sum(0.1f, 0.2f);
    Console.WriteLine(x == y);
    // y = y + 1;
    // Console.WriteLine(y);
    // GC.KeepAlive(y);
}
```

Кажется, эта программа всегда выдает `True`. Но `LegacyJIT-x86` будет выдавать `True` только в режиме отладки. В режиме релиза мы получим `False`. Как такое возможно? Подсказку можно найти в спецификации:

«ЕСМА-335, I.12.1.3 “Работа с типами данных с плавающей запятой”

Номинальным типом переменной или выражения является *float32* или *float64*, но его значение **может быть выражено с использованием внутренних средств с помощью дополнительного диапазона и/или модуля точности**».

В режиме релиза `LegacyJIT-x86` использует 80-битное число с плавающей запятой для `y`. В `.NET` нет типа для таких чисел, но они могут применяться для промежуточных вычислений. Конвертирование комментария одной из комментированных строк в текст кода источника может заставить `LegacyJIT-x86` использовать тип `float` для `y`, что изменит результат программы.

Если вы хотите понять все нюансы применения типов с плавающей запятой, рекомендую вам прочесть [Goldberg, 1991].

## Практический пример 1: денормализованные числа

Продолжим обсуждать IEEE 754. В табл. 7.3 можно увидеть нижнюю и верхнюю границы окна, а также размер корзины для разных значений экспоненты в контексте 32-битных чисел.

<sup>1</sup> Его также можно найти здесь: <http://csharpindepth.com/Articles/General/Floating-Point.aspx>.

Все экспоненты следуют одному и тому же правилу, кроме последней ( $E = 0$ ). Когда экспонента равна нулю, мы получаем дополнительное окно, охватывающее числа от 0 до  $2^{-126}$ . Размер корзины равен  $2^{-149}$  (то же значение получаем и при  $E = 1$ ). Эти числа (кроме нуля) известны как *денормализованные числа*. Обычно операции с такими числами вызывают серьезные проблемы с производительностью. Узнаем, насколько серьезными они могут быть, на примере.

**Таблица 7.3.** Окна для 32-битных чисел с плавающей запятой

<b><math>E</math></b>	<b>Нижняя граница</b>	<b>Верхняя граница</b>	<b>Размер корзины</b>
254	$2^{127} = 1,7 \cdot 10^{38}$	$2^{128} = 3,4 \cdot 10^{38}$	$2^{104} = 2,0 \cdot 10^{31}$
253	$2^{126} = 8,5 \cdot 10^{37}$	$2^{127} = 1,7 \cdot 10^{38}$	$2^{103} = 1,0 \cdot 10^{31}$
128	$2^1 = 2$	$2^2 = 4$	$2^{-22} = 2,4 \cdot 10^{-7}$
127	$2^0 = 1$	$2^1 = 2$	$2^{-23} = 1,2 \cdot 10^{-7}$
3	$2^{-124} = 4,7 \cdot 10^{-38}$	$2^{-123} = 9,4 \cdot 10^{-38}$	$2^{-147} = 5,6 \cdot 10^{-45}$
2	$2^{-125} = 2,4 \cdot 10^{-38}$	$2^{-124} = 4,7 \cdot 10^{-38}$	$2^{-148} = 2,8 \cdot 10^{-45}$
1	$2^{-126} = 1,2 \cdot 10^{-38}$	$2^{-125} = 2,4 \cdot 10^{-38}$	$2^{-149} = 1,4 \cdot 10^{-45}$
0	0	$2^{-126} = 1,2 \cdot 10^{-38}$	$2^{-149} = 1,4 \cdot 10^{-45}$

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    [Params(100000, 1000000)]
    public int N;

    [Benchmark]
    public double PowerA()
    {
        double res = 1.0;
        for (int i = 0; i < N; i++)
            res = res * 0.96;
        return res;
    }
    private double resB;

    [Benchmark]
    public double PowerB()
    {
        resB = 1.0;
        for (int i = 0; i < N; i++)
            resB = resB * 0.96;
    }
}
```

```

    return resB;
}

[Benchmark]
public double PowerC()
{
    double res = 1.0;
    for (int i = 0; i < N; i++)
        res = res * 0.96 + 0.1 - 0.1;
    return res;
}
}

```

Здесь мы вычисляем  $0,96^N$  тремя разными способами. В `PowerA` просто умножаем локальную переменную на  $0,96$   $N$  раз. В `PowerB` вместо локальной переменной используем поле для результатов умножения. В `PowerC` задействуем локальную переменную, но производим над ней действие  $+ 0,1 - 0,1$  после каждой итерации.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, JIT 4.7.3260.0):

Method	Jit	Platform	N	Mean	StdDev
PowerA	LegacyJit	X86	100000	151.5 us	1.298 us
PowerB	LegacyJit	X86	100000	17,480.7 us	99.446 us
PowerC	LegacyJit	X86	100000	330.7 us	1.129 us
PowerA	RyuJit	X64	100000	3,547.9 us	11.868 us
PowerB	RyuJit	X64	100000	3,783.8 us	12.350 us
PowerC	RyuJit	X64	100000	366.6 us	1.383 us
PowerA	LegacyJit	X86	1000000	150,718.6 us	3,663.819 us
PowerB	LegacyJit	X86	1000000	219,923.4 us	6,075.390 us
PowerC	LegacyJit	X86	1000000	3,521.8 us	82.629 us
PowerA	RyuJit	X64	1000000	43,119.9 us	693.725 us
PowerB	RyuJit	X64	1000000	45,739.5 us	771.414 us
PowerC	RyuJit	X64	1000000	3,755.5 us	54.615 us

Вот значения среднего арифметического, сгруппированные в более удобную таблицу (без информации о стандартном отклонении):

JIT	N	PowerA	PowerB	PowerC
LegacyJIT-x86	100000	151.5 us	17,480.7 us	330.7 us
RyuJIT-x64	100000	3,547.9 us	3,783.8 us	366.6 us
LegacyJIT-x86	1000000	150,718.6 us	219,923.4 us	3,521.8 us
RyuJIT-x64	1000000	43,119.9 us	45,739.5 us	3,755.5 us

Некоторые из этих цифр могут вас удивить. Мы можем задать следующие вопросы по поводу таблицы результатов.

- Почему PowerC работает так быстро?
- Почему PowerA и PowerB работают так медленно на LegacyJIT-x86 при  $N = 10^8$ ?
- Почему PowerA гораздо быстрее, чем PowerB и PowerC, на LegacyJIT-x86 при  $N = 10^5$ ?

## Объяснение

Попробуем ответить на эти вопросы. Прежде всего сравним PowerA и PowerC на RyuJIT. Чтобы понять, почему PowerC быстрее, нужно рассмотреть табл. 7.4, где промежуточные значения `res` представлены в реальной десятичной форме с внутренней шестнадцатеричной репрезентацией.

**Таблица 7.4.** Промежуточные результаты RyuJIT-x64 для бенчмарка с денормализованными числами

i	PowerA	PowerC
0	1,0 3FF0000000000000	1,0 3FF0000000000000
1	0,96 3FEEB851EB851EB8	0,9600000000000008 3FEEB851EB851EB9
885	2,0419318345555615E-16 3CAD6D6617566397	1,8041124150158794E-16 <b>3CAA000000000000</b>
886	1,9602545611733389E-16 3CAC4010166769D8	1,6653345369377348E-16 <b>3CA8000000000000</b>
887	1,8818443787264053E-16 3CAB1EC7C3967A17	1,6653345369377348E-16 <b>3CA8000000000000</b>
18171	6,42285339593621E-323 0000000000000000 <b>D</b>	1,6653345369377348E-16 3CA8000000000000
18172	5,92878775009496E-323 0000000000000000 <b>C</b>	1,6653345369377348E-16 3CA8000000000000
18173	5,92878775009496E-323 0000000000000000 <b>C</b>	1,6653345369377348E-16 3CA8000000000000

Давайте пошагово разберем, что здесь происходит.

- Изначальное значение `res` равно 1,0, что составляет 3FF0000000000000 в формате IEEE 754.

- После первой итерации ( $i=1$ ) значение `res` становится  $0.96$  (3FEЕВ851ЕВ851ЕВ8) в `PowerA`. В `PowerC` выражение  $res * 0.96 + 0.1 - 0.1$  дает  $0.960000000000000008$  (3FEЕВ851ЕВ851ЕВ9). Разница между `PowerA` и `PowerC` составляет 1 бит.
- При  $i=886$  мы получаем  $1.6653345369377348E-16$  (3СА8000000000000) в `PowerC`. Это магическое число является инвариантом  $res * 0.96 + 0.1 - 0.1$ : данная операция не меняет это число. Мы можем продолжить выполнение, но `res` не изменится.
- При  $i=18172$  получаем  $5.92878775009496E-323$  (0000000000000000С) в `PowerA`. Это число является инвариантом для  $res * 0.96$ : значение `res` больше не изменится ни в одном методе.

Теперь мы видим, что `PowerA` выполняет бóльшую часть операций с числом  $5.92878775009496E-323$ , являющимся денормализованным: поэтому производительность так сильно снижается. В `PowerC` прием  $+ 0.1 - 0.1$  помогает сохранять промежуточные результаты нормализованными. Поскольку в `PowerC` нет операций с денормализованными числами, этот метод работает довольно быстро.

Теперь взглянем на то, что происходит в `LegacyJIT-x86`. Этот компилятор JIT использует команду `x87`. Так выглядит дизассемблированный код `PowerA` и `PowerB`:

```
; PowerA (N=10^5: ~167us           N=10^6: ~152770us)
fld     qword ptr ds:[14D2E28h]    ; 0.96
fmulp  st(1),st                   ; In a register
; PowerB (N=10^5: ~19079us        N=10^6: ~226219us)
fld     qword ptr ds:[892E20h]    ; 0.96
fmul   qword ptr [ecx+4]
fstp   qword ptr [ecx+4]          ; In memory
```

Как видите, `PowerA` выполняет умножение с использованием регистра, а `PowerB` хранит промежуточный результат в памяти, поскольку он должен передать это значение в поле. Следующую подсказку можно найти в [Intel Manual]:

«§ 8.2 Типы данных математического процессора для X87

**За исключением 80-битного формата `double` с усиленной точностью** все типы данных существуют **только в памяти**. Когда они загружаются в регистры данных математического процессора для X87, они **конвертируются в формат `double` с усиленной точностью** и обрабатываются именно в этом формате.

Когда в качестве исходного операнда берется денормализованное число, математический процессор для X87 **автоматически нормализует** число, если оно конвертировано в формат `double` с усиленной точностью».

Таким образом, `PowerA` действительно использует для вычислений 80-битные числа с плавающей запятой. Он не затрагивает денормализованную зону для  $N = 10^5$ ,

в отличие от PowerB, применяющего 64-битные числа. Поэтому PowerA работает так быстро, если  $N = 10^5$ : он производит все вычисления на нормализованных числах с помощью регистра. Для  $N = 10^6$  существует много денормализованных операций даже с 80-битными числами (попробуйте вычислить точный момент получения первого денормализованного числа и момент, когда мы получим значение инварианта).

## Обсуждение

Как видите, денормализованное число может вызвать серьезные проблемы с производительностью. Подобные числа можно использовать также для формирования временных интервалов атаки по сторонним каналам (например, см. [Andryscio, 2015]). Влияние денормализованных чисел на производительность сильно зависит от окружения.

## Практический пример 2: Math.Abs

`Math.Abs` — это широко распространенный статический метод, выдающий абсолютное значение определенного числа. Проверим его производительность на разных версиях .NET Core.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private int positive = 1, negative = -1;

    [Benchmark]
    public int Positive()
    {
        return Math.Abs(positive);
    }

    [Benchmark]
    public int Negative()
    {
        return Math.Abs(negative);
    }
}
```

У нас есть два бенчмарка: `Positive` (он измеряет `Math.Abs` для `+1`) и `Negative` (измеряет `Math.Abs` для `-1`).

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 2.0.9 и .NET Core 2.1.5):

Method	Job	Mean	StdDev
Positive	.NETCore20	0.2797 ns	0.0182 ns
Negative	.NETCore20	0.9145 ns	0.0239 ns
Positive	.NETCore21	0.2744 ns	0.0077 ns
Negative	.NETCore21	0.2762 ns	0.0126 ns

Как видите, бенчмарк `Negative` на .NETCore 2.0 работает в три раза медленнее.

## Объяснение

Рассмотрим его реализацию на .NET Core 2.0.0 (<https://github.com/dotnet/coreclr/blob/v2.0.0/src/mscorlib/src/System/Math.cs#L268>):

```
public static int Abs(int value)
{
    if (value >= 0)
        return value;
    else
        return AbsHelper(value);
}

private static int AbsHelper(int value)
{
    Contract.Requires(value < 0,
        "AbsHelper нужно вызывать только для отрицательных значений!" +
        "(обходное решение для инлайнинга JIT)");
    if (value == Int32.MinValue)
        throw new OverflowException(SR.Overflow_NegateTwosCompNum);
    Contract.EndContractBlock();
    return -value;
}
```

Можно увидеть, что `Math.Abs` мгновенно выдает `value` для положительных данных ввода и вызывает дополнительный метод `AbsHelper` для отрицательных. Поэтому для отрицательных значений мы всегда получаем дополнительный вызов. Он не встроен, поэтому в таких случаях происходит спад производительности. В .NET Core 2.1 производительность была улучшена, и теперь реализация выглядит таким образом:

```
[MethodImpl(MethodImplOptions.AggressiveInlining)]
public static int Abs(int value)
```

```
{
    if (value < 0)
    {
        value = -value;
        if (value < 0)
        {
            ThrowAbsOverflow();
        }
    }
    return value;
}

[StackTraceHidden]
private static void ThrowAbsOverflow()
{
    throw new OverflowException(SR.Overflow_NegateTwosCompNum);
}
```

В обновленной реализации нет дополнительного вызова для отрицательных чисел. Поэтому на .NET Core 2.1 бенчмарки `Positive` и `Negative` одинаковой длительности.

## Обсуждение

В обсуждении на GitHub можно найти прекрасное объяснение этому подходу, которое дал Энди Эйерс (<https://github.com/dotnet/corefx/issues/26253#issuecomment-356736809>):

«Общее указание заключается в том, чтобы выделить исключения во вспомогательные методы, которые создают объект исключения и все связанные с ним данные (например, отформатированные сообщения об исключении), и затем выдавать исключения без условий. Затем эвристические правила компилятора по поводу производительности инлайнинга заблокируют инлайнинг вспомогательного алгоритма. Мы получаем некоторое количество преимуществ для производительности:

- экономия общего размера кода при наличии нескольких вызывающих функций или функций с несколькими точками вызова;
- точки вызова вспомогательного алгоритма считаются редкими и поэтому переносятся в раздел неиспользуемого кода функции;
- вспомогательный алгоритм на промежуточном языке компилируется, только если вот-вот появится исключение, поэтому функция вызова компилируется быстрее;
- пролог/эпилог функции вызова может быть упрощен благодаря меньшему количеству сохранений в регистр и восстановлений.

Генератор собственного кода для исключений, применяющих ресурсно-ориентированные строки, удивительно велик.

Не существует “правильной” причины, препятствующей инлайнингу методов с исключениями, и методы, которые выдают исключения с условиями (такие как оригинальный `AbsHelper` в данном примере), могут быть в итоге встроены, поскольку могут содержать смесь используемого и неиспользуемого кода. Методы, выдающие исключения без условий, вряд ли будут содержать используемый код».

Многие разработчики думают, что операции с числами настолько фундаментальны, что их наверняка идеально написали много лет назад и с тех пор ни разу не меняли. Это не так — в большинстве базовых операций постоянно происходит улучшение производительности. Например, в [Icaza, 2018] можно прочитать историю об улучшении производительности в два раза для вычислений с 32-битными числами с плавающей запятой.

См. также:

- `corefx#26253 Math.Abs is slow` (<https://github.com/dotnet/corefx/issues/26253>);
- `coreclr#15823 Improve performance for Math.Abs` (<https://github.com/dotnet/coreclr/pull/15823>).

## Практический пример 3: `double.ToString`

Конверсия из `double` в `string` — еще одна операция, часто используемая в большинстве приложений .NET. Эта конверсия занимает немало времени. Измерим ее производительность на .NET Core 2.0 и .NET Core 2.1.

### Исходный код

Рассмотрим следующий бенчмарк на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private double value = -8.98846567431158E+307;

    [Benchmark]
    public string ConvertToString()
    {
        return value.ToString(CultureInfo.InvariantCulture);
    }
}
```

У нас есть один бенчмарк, который измеряет конверсию ToString для числа `-8.98846567431158E+307`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 2.0.9 и .NET Core 2.1.5):

```

      Job |           Mean |           StdDev |
-----:|-----:|-----:|
.NETCore20 | 4,649.4 ns | 125.019 ns |
.NETCore21 | 222.1 ns | 1.425 ns |

```

Как видите, `double.ToString()` для `-8.98846567431158E+307` работает гораздо быстрее на .NET Core 2.1.

## Объяснение

В `coreclr#14646` (<https://github.com/dotnet/coreclr/pull/14646>) к реализации `double.ToString()` был добавлен алгоритм `Grisu3` (подробнее о нем можно прочитать в [Steele, 1990] и [Andryscio, 2016]). Это улучшение было включено в .NET Core 2.1. В комментариях к запросу на включение изменений можно найти результаты бенчмарка для разных данных ввода (фрагмент этих результатов представлен в табл. 7.5).

**Таблица 7.5.** Улучшение производительности `Grisu3` для `double.ToString`

Число	Аргументы	До	После
<code>-1,79769313486232E+308</code>	—	237,492	28,660
<code>-8,98846567431158E+307</code>	—	227,782	29,921
<code>-1,79769313486232E+308</code>	<code>culture: "zh"</code>	252,797	26,215
<code>4,94065645841247E-324</code>	<code>format: "E"</code>	222,350	40,334
<code>-1,79769313486232E+308</code>	<code>format: "F50"</code>	324,054	132,538
<code>4,94065645841247E-324</code>	<code>format: "G"</code>	213,085	39,974
<code>-1,79769313486232E+308</code>	<code>format: "R"</code>	443,718	45,578
<code>4,94065645841247E-324</code>	<code>format: "R"</code>	231,865	49,403

## Обсуждение

Резкий подъем производительности был замечен в некоторых внутренних бенчмарках .NET Core — см. `coreclr#16624` (<https://github.com/dotnet/coreclr/issues/16624>) и `coreclr#16625` (<https://github.com/dotnet/coreclr/issues/16625>).

Отметьте, что старая и новая реализации могут в особых случаях выдавать разные значения. Например, рассмотрим следующие строки:

```
var value = BitConverter.Int64BitsToDouble(-4585072949362425856);  
Console.WriteLine(value);
```

В .NET Core 2.0 мы получим -122.194458007813, а в .NETCore 2.1 — -122.194458007812. Обсуждение имеется в coreclr#17805 (<https://github.com/dotnet/coreclr/issues/17805>).

## Практический пример 4: деление целых чисел

Операция по делению целых чисел может быть объемной, если делитель не является степенью двойки. Существует известная битовая операция, которая заменяет деление на умножение с небольшим сдвигом<sup>1</sup>. Два следующих метода приходят к одному результату:

```
uint Div3Simple(uint n) => n / 3;  
uint Div3BitHacks(uint n) => (uint)((n * (ulong)0xA0000000) >> 33);
```

В теории `Div3BitHacks` должен работать намного быстрее, поскольку он не выполняет объемную операцию деления. Проверим, как это работает на практике.

## Исходный код

Рассмотрим следующий бенчмарк на базе `BenchmarkDotNet`:

```
public class Benchmarks  
{  
    private uint x = 1, initialValue = uint.MaxValue;  
  
    [Benchmark(OperationsPerInvoke = 16)]  
    public void Simple()  
    {  
        x = initialValue;  
        x = x / 3;  
        x = x / 3;  
    }  
}
```

<sup>1</sup> Более подробно узнать о ней можно в [Lemire, 2019] и [Tillaart, 2007]. Также множество интересных битовых операций можно найти на <https://graphics.stanford.edu/~seander/bithacks.html>.

```

    x = x / 3;
    x = x / 3;
}

```

```

[Benchmark(OperationsPerInvoke = 16)]
public void BitHacks()
{
    x = initialValue;
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
    x = (uint) ((x * (ulong) 0xAAAAAAAB) >> 33);
}
}

```

У нас есть два бенчмарка, `Simple` и `BitHacks`. Оба делят `x` на 3 (16 раз). Чтобы избежать ILP, все операции деления используют одно и то же поле `x`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2 с JIT 4.7.3260.0; Mono 5.18.0.225):

Method	JIT	Mean	StdDev
Simple	LegacyJIT-x86	5.6259 ns	0.0217 ns
BitHacks	LegacyJIT-x86	1.3119 ns	0.0123 ns
Simple	LegacyJIT-x64	1.2916 ns	0.0065 ns
BitHacks	LegacyJIT-x64	0.8484 ns	0.0039 ns

Simple	RyuJIT-x64	0.8491 ns	0.0099 ns
BitHacks	RyuJIT-x64	0.7035 ns	0.0081 ns
Simple	Mono-x86	3.5624 ns	0.0111 ns
BitHacks	Mono-x86	13.4624 ns	0.1121 ns
Simple	Mono-x64	1.1475 ns	0.0117 ns
BitHacks	Mono-x64	1.4359 ns	0.0074 ns

Вот значения среднего арифметического, сгруппированные в более удобную таблицу (без информации о стандартном отклонении):

JIT	Simple	BitHacks
LegacyJIT-x86	5.6259 ns	1.3119 ns
LegacyJIT-x64	1.2916 ns	0.8484 ns
RyuJIT-x64	0.8491 ns	0.7035 ns
Mono-x86	3.5624 ns	13.4624 ns
Mono-x64	1.1475 ns	1.4359 ns

Мы можем сделать следующие наблюдения о результатах.

- Бенчмарк Simple работает быстрее на LegacyJIT-x64, RyuJIT-x64 и Mono-x64, чем на LegacyJIT-x86 и Mono-x86.
- Бенчмарк BitHacks работает крайне медленно на Mono-x86.

## Объяснение

Чтобы понять, что здесь происходит, нужно рассмотреть сгенерированный собственный код для всех компиляторов JIT. Начнем с LegacyJIT-x86, поскольку он создает самый простой собственный код:

```
; Simple/LegacyJIT-x86
mov  eax,dword ptr [esi+4] ; eax = x
xor  edx,edx              ; edx = 0
div  eax,ecx              ; eax /= 3
mov  dword ptr [esi+4],eax ; x = eax

; BitHacks/LegacyJIT-x86
mov  eax,dword ptr [ecx+4] ; eax = x
mov  edx,0AAAAAAABh      ; edx = 0AAAAAAABh
mul  eax,edx              ; eax * edx (result in edx)
mov  eax,edx              ; eax = edx
shr  eax,1                ; eax >>= 1
xor  edx,edx              ; edx = 0
mov  dword ptr [ecx+4],eax ; x = eax
```

Здесь нет никакого волшебства: LegacyJIT-x86 переводит код на C# в сборку самым простым способом. В начале каждой операции деления мы загружаем значение *x*

из стека в регистр, выполняем деление и сохраняем значение *x* из реестра в стек. Бенчмарк *BitHacks* работает быстрее, чем *Simple*, поскольку в нем используется умножение вместо деления.

Теперь рассмотрим собственный код *LegacyJIT-x64*:

```
; Simple/LegacyJIT-x64
mov ecx,dword ptr [r8+8] ; ecx = x
mov eax,0AAAAAAABh ; eax = 0AAAAAAABh
mul eax,ecx ; aex * ecx (result in edx)
shr edx,1 ; edx >>= 1
mov dword ptr [r8+8],edx ; x = edx

; BitHacks/LegacyJIT-x64
mov eax,dword ptr [rcx+8] ; eax = x
mov edx,0AAAAAAABh ; edx = 0AAAAAAABh
imul rax,rdx ; rax * rdx (result in rax)
shr rax,21h ; rax >>= 31
mov dword ptr [rcx+8],eax ; x = eax
```

*LegacyJIT-x64* достаточно разумен для того, чтобы заменить деление на умножение в бенчмарке *Simple*! Поэтому его версия работает быстрее, чем версия *LegacyJIT-x86*.

Теперь посмотрим на собственный код *RyuJIT-x64*:

```
; Simple/RyuJIT-x64
mov edx,0AAAAAAABh ; edx = 0AAAAAAABh
mul eax,edx ; eax * edx (result in edx)
mov eax,edx ; eax = edx
shr eax,1 ; eax >>= 1
mov dword ptr [rcx+8],eax ; x = eax

; BitHacks/RyuJIT-x64
moveax,eax; eax = eax
imul rax,rdx ; rax * rdx (result in rax)
shr rax,21h ; rax >>= 31
mov dword ptr [rcx+8],eax ; x = eax
```

*RyuJIT-x64* тоже оказался достаточно умным, чтобы заменить деление умножением. Он работает чуть быстрее, чем *LegacyJIT-x64*, поскольку не загружает значение *x* из стека в регистр в начале операции (актуальное значение *x* уже находится в регистре после предыдущей операции).

А теперь рассмотрим собственный код *Mono-x86*:

```
; Simple/Mono-x86
movl $0x0,-0xc(%rbp) ; -0xc(%rbp) = 0
mov -0x10(%rbp),%eax ; eax = x
mov %eax,0x8(%rdi) ; 0x8(%rdi) = eax
```

```

mov    0x8(%rdi),%eax      ; eax = 0x8(%rdi)
mov    $0xaaaaaaaaab,%ecx  ; ecx = 0xaaaaaaaaab
mul    %ecx                ; eax * ecx (result in edx)
mov    %edx,-0xc(%rbp)     ; -0xc(%rbp) = edx
mov    %eax,-0x10(%rbp)    ; -0x10(%rbp) = eax
mov    -0xc(%rbp),%eax     ; eax = -0xc(%rbp) (mul result)
shr    %eax                ; eax >>= 1
mov    %eax,-0x10(%rbp)    ; x = eax

; BitHacks/Mono-x86
mov    0x8(%rdi),%eax      ; %eax = x
movl   $0x0,0xc(%rsp)      ; 0xc(%rsp) = 0
movl   $0xaaaaaaaaab,0x8(%rsp) ; 0x8(%rsp) = 0xaaaaaaaaab
movl   $0x0,0x4(%rsp)      ; 0x4(%rsp) = 0
mov    %eax,(%rsp)         ; (%rsp) = %eax
lea    0x0(%rbp),%ebp      ; %ebp = 0x0(%rbp)
callq  ffffffff4          ; Call external method
mov    %edx,-0xc(%rbp)     ; -0xc(%rbp) = %edx
mov    %eax,-0x10(%rbp)    ; -0x10(%rbp) = %eax
mov    -0xc(%rbp),%eax     ; %eax = -0xc(%rbp)
shr    %eax                ; %eax >>= 1
mov    %eax,0x8(%rdi)      ; x = eax

```

Монро-х86 не умеет работать с битовыми операциями с простыми командами — он генерирует запутанный код с внешним вызовом. Поэтому бенчмарк BitHacks так медленно работает на Монро-х86.

Посмотрим на собственный код Монро-х64:

```

; Simple/Mono-x64
mov    0x10(%rsi),%eax     ; eax = x
mov    $0xaaaaaaaaab,%ecx  ; ecx = 0xaaaaaaaaab
mov    %eax,%eax          ; eax = eax
imul  %rcx,%rax           ; rax * rcx (result in rax)
shr    $0x21,%rax         ; rax >>= 31
mov    %eax,0x10(%rsi)    ; x = eax

; BitHacks/Mono-x64
mov    0x10(%rsi),%eax     ; eax = x
mov    %eax,%eax          ; eax = eax
mov    $0xaaaaaaaaab,%ecx  ; ecx = 0xaaaaaaaaab
imul  %rcx,%rax           ; rax * rcx (result in rax)
shr    $0x21,%rax         ; rax >>= 31
shr    $0x0,%eax          ; eax >>= 0
mov    %eax,0x10(%rsi)    ; x = eax

```

Монро-х64 тоже догадался заменить деление умножением. Более того, оптимизированная версия Simple эффективнее, чем BitHacks, где мы применили оптимизацию вручную. Также он может генерировать собственный код для BitHacks, используя только простые команды (без внешних вызовов).

## Обсуждение

Как видите, производительность деления сильно зависит от окружения. Некоторые компиляторы JIT могут автоматически использовать обсуждаемую нами оптимизацию. Такая автоматическая оптимизация может сделать собственный код для бенчмарка `Simple` более эффективным, чем для `BitHacks`, где мы применили ее вручную.

Данные результаты действительны только для указанных версий среды исполнения. Невозможно узнать, какие оптимизации будут в следующих версиях .NET.

Смотрите также:

- `coreclr#8106 Move magic division optimization from morph to lowering` (<https://github.com/dotnet/coreclr/pull/8106>);
- [Akinshin, 2016b];
- [Chen, 2019].

## Подводя итог

В стандарте IEEE 754 каждое число с плавающей запятой представлено с помощью знака, экспоненты и мантиссы. Вместо классических терминов можно использовать интерпретацию Сангларда, заменяющую экспоненту окном между двумя последовательными степенями двойки, например [1; 2] или [8; 16], а мантиссу — ответвлением внутри этого окна (каждое окно разбито на фиксированное количество корзин). В .NET типы `float` (32-битный) и `double` (64-битный) соответствуют стандарту IEEE 754, а `decimal` (128-битный) является пользовательской структурой для чисел с плавающей запятой для финансовых и банковских вычислений (у нее высокая точность, но низкая производительность).

Одно и то же выражение с числами с плавающей запятой может выдавать разные результаты в различных случаях. Например, `LegacyJIT-x86` может использовать 80-битные числа для промежуточных вычислений, даже если вы применяете в коде типы `float` (32-битный) и `double` (64-битный).

В контексте бенчмаркинга важно знать о денормализованных числах. Это числа, соответствующие стандарту IEEE 754, с нулевой экспонентой. Обычно в реальном коде их нет, поскольку они крайне малы (меньше  $1.2 \cdot 10^{-38}$  для `float`), но если встречаются, происходит значительное ухудшение производительности, например в 100 раз. Такой эффект можно использовать для формирования временных интервалов атаки по сторонним каналам.

Почти все приложения для .NET применяют разные операции с числами. Производительность таких операций зависит от значений чисел, версии компилятора и среды исполнения. Измерять даже простое арифметическое выражение мо-

жет быть сложно из-за большого количества разных комбинаций данных ввода и окружений. Поэтому нельзя экстраполировать результаты, полученные в одном окружении, на общие случаи.

## Интринзики

Интринзик (intrinsic) — это разумная реализация конкретного метода или выражения, которые может в отдельных случаях использовать компилятор JIT. В этом подразделе мы обсудим некоторые виды интринзиков, доступные в разных компиляторах JIT для .NET.

### Практический пример 1: Math.Round

Обсудим метод `Math.Round(double x)`, который округляет значение до ближайшего целого числа<sup>1</sup>.

В .NET Core 2.1 он реализуется так<sup>2</sup>:

```
[Intrinsic]
public static double Round(double a)
{
    // Если в числе нет дробной части, ничего не делать.
    // Этот быстрый ввод необходим для обхода потери
    // точности в пограничных случаях на некоторых платформах.
    if (a == (double)((long)a))
    {
        return a;
    }

    // У нас было число, одинаково близкое к двум целым числам.
    // Нужно выдать четное.
    double flrTempVal = Floor(a + 0.5);
    if ((a == (Floor(a) + 0.5)) && (FMod(flrTempVal, 2.0) != 0))
    {
        flrTempVal -= 1.0;
    }

    return copysign(flrTempVal, a);
}
```

<sup>1</sup> Больше информации о разных перегрузках можно найти в следующей документации: <https://docs.microsoft.com/en-us/dotnet/api/system.math.round>.

<sup>2</sup> См. <https://github.com/dotnet/coreclr/blob/v2.1.7/src/mscorlib/shared/System/Math.cs#L647>.

Атрибут [Intrinsic] означает, что компилятор может выбросить эту реализацию и заменить вызов алгоритма более эффективными собственными командами.

## Исходный код

Рассмотрим следующий бенчмарк на базе BenchmarkDotNet:

```
public static class MyMath
{
    public static double Round(double a)
    {
        if (a == (double)((long)a))
        {
            return a;
        }
        double flrTempVal = Math.Floor(a + 0.5);
        if ((a == (Math.Floor(a) + 0.5)) && (flrTempVal % 2.0 != 0))
        {
            flrTempVal -= 1.0;
        }

        return copysign(flrTempVal, a);
    }

    private static double copysign(double x, double y)
    {
        var xbits = BitConverter.DoubleToInt64Bits(x);
        var ybits = BitConverter.DoubleToInt64Bits(y);

        if (((xbits ^ ybits) >> 63) != 0)
        {
            return BitConverter.Int64BitsToDouble(xbits ^ long.MinValue);
        }

        return x;
    }
}

public class Benchmarks
{
    private double doubleValue = 1.3;

    [Benchmark]
    public double SystemRound()
    {
        return Math.Round(doubleValue);
    }
}
```

```
[Benchmark]
public double MyRound()
{
    return MyMath.Round(doubleValue);
}
}
```

У нас есть метод `MyMath.Round`, являющийся скопированной реализацией системного метода `Math.Round`. Есть также два бенчмарка, `SystemRound` и `MyRound`, вызывающие соответствующие реализации `Round`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2 с LegacyJIT 4.7.3260.0, .NET Core 2.1.5 с RyuJIT-x64):

Method	Job	Mean	StdDev
SystemRound	LegacyJitX64	7.2785 ns	0.2532 ns
MyRound	LegacyJitX64	7.1982 ns	0.0876 ns
SystemRound	RyuJitX64	0.4929 ns	0.0184 ns
MyRound	RyuJitX64	3.4426 ns	0.0338 ns

Как видите, на RyuJIT-x64 `SystemRound` работает гораздо быстрее, чем `MyRound`. А на LegacyJIT-x64 у обоих методов одинаковая длительность.

## Объяснение

[`Intrinsic`] означает, что у компилятора JIT есть особая информация об этом методе и он может заменить данную реализацию более эффективным собственным кодом. RyuJIT-x64 может сгенерировать очень эффективный собственный код с помощью команды `AVX vroundsd`:

```
; SystemRound/RyuJIT-x64
vzeroupper
vroundsd    mm0, xmm0, mmword ptr [rcx+8], 4
ret
```

Поэтому `SystemRound` так быстро работает на RyuJIT-x64 (занимает меньше 1 нс). У компилятора нет особой информации о методе `MyMath.Round`, поэтому он генерирует простой собственный код для данной реализации, который работает медленнее.

На LegacyJIT-x64 у обоих бенчмарков одинаковая длительность, поскольку у этого компилятора нет особого интринзика для метода `Math.Round`. Поэтому в обоих случаях он работает с тем же кодом на промежуточном языке.

## Обсуждение

При сравнении производительности одного и того же метода на разных компиляторах мы должны помнить, что у них могут быть разные наборы интринзиков, которые применимы к любому системному методу.

Смотрите также:

- вопрос 40460850 *Significant drop in performance of Math.Round on x64 platform* на StackOverflow (<https://github.com/dotnet/coreclr/issues/8053>);
- coreclr#8053 *A question about Math.Round intrinsic on x64* (<https://github.com/dotnet/coreclr/issues/8053>).

## Практический пример 2: ротация битов

Компилятор JIT может генерировать интринзики не только для известных методов, но и для выражений в конкретной форме. Рассмотрим метод, реализующий классическую ротацию битов для значения `ulong`:

```
public static ulong RotateRight64(ulong value, int count)
{
    return (value >> count) | (value << (64 - count));
}
```

Подобные выражения часто используются в разных криптографических алгоритмах. Этот метод может выполняться миллионы раз в одном алгоритме, поэтому было бы хорошо иметь здесь приличный уровень производительности. Проверим его производительность на разных компиляторах JIT.

## Исходный код

Рассмотрим следующий бенчмарк на базе BenchmarkDotNet:

```
public class Benchmarks
{
    public static ulong RotateRight64(ulong value, int count)
    {
        return (value >> count) | (value << (64 - count));
    }

    private ulong a = 100;
    private int b = 2;

    [Benchmark]
    public ulong Foo()
```

```

{
    return RotateRight64(a, b);
}
}

```

Здесь мы просто применяем операцию «ротация битов» для приватного поля `ulong`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2 с LegacyJIT-x86 4.7.3260.0, .NET Core 2.1.5 с RyuJIT-x64):

Job	Mean	StdDev
LegacyJitX86	4.676 ns	0.1208 ns
RyuJitX64	1.217 ns	0.0299 ns

Как видите, этот бенчмарк работает гораздо быстрее на .NET Core 2.1.5 с RyuJIT-x64, чем на .NET Framework 4.7.2 с LegacyJIT-x86 4.7.3260.0.

## Объяснение

RyuJIT может распознать схему `(value >> count) | (value << (64 - count))` и сгенерировать для нее быструю реализацию:

```
ror    rax,cl
```

LegacyJIT-x86 не поддерживает эти эвристические правила и генерирует простой собственный код для изначального выражения. Конечно, он работает гораздо медленнее, чем одна инструкция `ror`.

## Обсуждение

Мы обсудили похожий интринзик в примере «Деление целых чисел», где некоторые компиляторы JIT могли заменить деление умножением. У каждого компилятора есть свой набор схем кода, которые можно оптимизировать. Контролировать такие интринзики довольно сложно: любые изменения в исходном коде могут запретить оптимизацию, потому что компилятор способен распознать лишь отдельные формы этих схем.

Смотрите также:

- [coreclr#1619 RyuJIT: Understand the idiomatic rotate bits](https://github.com/dotnet/coreclr/issues/1619) (<https://github.com/dotnet/coreclr/issues/1619>);
- [oreclr#1830 Generate efficient code for rotation patterns](https://github.com/dotnet/coreclr/pull/1830) (<https://github.com/dotnet/coreclr/pull/1830>).

## Практический пример 3: векторизация

В пространстве имен `System.Numerics`<sup>1</sup> существует много полезных структур, в том числе типы со включенным SIMD: `Vector2`, `Vector3`, `Vector4`, `Matrix3x2`, `Matrix4x4`, `Plane` и `Quaternion`. У RyuJIT есть поддержка ускорения устройства для этих типов с помощью интринзиков SIMD. Операции SIMD — это еще один вид распараллеливания на уровне устройства: с помощью специальных наборов команд, например SSE или AVX, мы можем проводить операцию на нескольких наборах данных одновременно. Другие компиляторы, такие как LegacyJIT-x86 и LegacyJIT-x64, не обладают продвинутой поддержкой этих типов — они используют опцию возврата в исходный режим и выполняют соответствующие операции без интринзиков.

### Исходный код

Рассмотрим следующий бенчмарк на базе BenchmarkDotNet:

```
public struct MyVector4
{
    public float X, Y, Z, W;

    public MyVector4(float x, float y, float z, float w)
    {
        X = x;
        Y = y;
        Z = z;
        W = w;
    }

    [MethodImpl(MethodImplOptions.AggressiveInlining)]
    public static MyVector4 operator *(MyVector4 left, MyVector4 right)
        => new MyVector4(
            left.X * right.X,
            left.Y * right.Y,
            left.Z * right.Z,
            left.W * right.W);
}

public class Benchmarks
{
    private Vector4 vectorA, vectorB, vectorC;
    private MyVector4 myVectorA, myVectorB, myVectorC;

    [Benchmark]
    public void MyMul() => myVectorC = myVectorA * myVectorB;

    [Benchmark]
    public void SystemMul() => vectorC = vectorA * vectorB;
}
```

<sup>1</sup> Доступна начиная с .NET Framework 4.6 и .NET Core 1.0. См. также <https://docs.microsoft.com/en-us/dotnet/api/system.numerics>.

У нас есть два бенчмарка, `SystemMul` и `MyMul`. `SystemMul` перемножает две копии `Vector4`. `MyMul` также перемножает два вектора, но использует копии `MyVector`. Тип `MyVector` является частичной копией системного класса `Vector4`<sup>1</sup>. Метод `operator *` в оригинальном методе отмечен атрибутом `[Intrinsic]`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, LegacyJIT-x64/RyuJIT-x64 v4.7.3260.0):

Method	Job	Mean	StdDev
MyMul	LegacyJitX64	12.33 ns	0.058 ns
SystemMul	LegacyJitX64	12.37 ns	0.109 ns
MyMul	RyuJitX64	1.71 ns	0.021 ns
SystemMul	RyuJitX64	0.00 ns	0.009 ns

Как видите, бенчмарк `SystemMul` работает почти мгновенно. Бенчмарк `MyMul` на `RyuJIT-x64` работает довольно быстро, но медленнее `SystemMul`. На `LegacyJIT-x64` оба бенчмарка одинаковой длительности, и это время гораздо больше, чем их результат на `RyuJIT-x64`.

## Объяснение

Рассмотрим собственный код обоих методов на `LegacyJIT-x64`:

```
; SystemMul/MyMul, LegacyJIT-x64
mov     eax,dword ptr [rcx+38h]
mov     dword ptr [rsp+20h],eax
mov     eax,dword ptr [rcx+3Ch]
mov     dword ptr [rsp+24h],eax
mov     eax,dword ptr [rcx+40h]
mov     dword ptr [rsp+28h],eax
mov     eax,dword ptr [rcx+44h]
mov     dword ptr [rsp+2Ch],eax
mov     eax,dword ptr [rcx+48h]
mov     dword ptr [rsp+10h],eax
mov     eax,dword ptr [rcx+4Ch]
mov     dword ptr [rsp+14h],eax
mov     eax,dword ptr [rcx+50h]
mov     word ptr [rsp+18h],eax
mov     eax,dword ptr [rcx+54h]
mov     dword ptr [rsp+1Ch],eax
lea     rdx,[rsp+20h]
mov     rax,qword ptr [rdx]
mov     qword ptr [rsp+40h],rax
mov     rax,qword ptr [rdx+8]
```

<sup>1</sup> Версию этого класса для .NET Core 2.2.1 можно найти здесь: [https://github.com/dotnet/corefx/blob/v2.2.1/src/System.Numerics.Vectors/src/System/Numerics/Vector4\\_Intrinsics.cs#L252](https://github.com/dotnet/corefx/blob/v2.2.1/src/System.Numerics.Vectors/src/System/Numerics/Vector4_Intrinsics.cs#L252).

```

mov    qword ptr [rsp+48h],rax
lea    rdx,[rsp+10h]
mov    rax,qword ptr [rdx]
mov    qword ptr [rsp+30h],rax
mov    rax,qword ptr [rdx+8]
mov    qword ptr [rsp+38h],rax
movss  xmm3,dword ptr [rsp+40h]
mulss  xmm3,dword ptr [rsp+30h]
movss  xmm2,dword ptr [rsp+44h]
mulss  xmm2,dword ptr [rsp+34h]
movss  xmm1,dword ptr [rsp+48h]
mulss  xmm1,dword ptr [rsp+38h]
movss  xmm0,dword ptr [rsp+4Ch]
mulss  xmm0,dword ptr [rsp+3Ch]
xor    eax,eax
mov    qword ptr [rsp],rax
mov    qword ptr [rsp+8],rax
lea    rax,[rsp]
movss  dword ptr [rax],xmm3
movss  dword ptr [rax+4],xmm2
movss  dword ptr [rax+8],xmm1
movss  dword ptr [rax+0Ch],xmm0
lea    rdx,[rsp]
mov    eax,dword ptr [rdx]
mov    dword ptr [rcx+58h],eax
mov    eax,dword ptr [rdx+4]
mov    dword ptr [rcx+5Ch],eax
mov    eax,dword ptr [rdx+8]
mov    dword ptr [rcx+60h],eax
mov    eax,dword ptr [rdx+0Ch]
mov    dword ptr [rcx+64h],eax

```

У обоих методов одинаковая реализация, поскольку у них одинаковая репрезентация на промежуточном языке. Собственный код использует для умножения команду SSE.

Теперь посмотрим на собственный код `MyMul` на `RyuJIT-x64`:

```

; MyMul/RyuJIT-x64
lea    rax,[rcx+38h]
vmovss xmm0,dword ptr [rax]
vmovss xmm1,dword ptr [rax+4]
vmovss xmm2,dword ptr [rax+8]
vmovss xmm3,dword ptr [rax+0Ch]
lea    rax,[rcx+48h]
vmovss xmm4,dword ptr [rax]
vmovss xmm5,dword ptr [rax+4]
vmovss xmm6,dword ptr [rax+8]
vmovss xmm7,dword ptr [rax+0Ch]

```

```

vmulss    xmm0,xmm0,xmm4
vmulss    xmm1,xmm1,xmm5
vmulss    xmm2,xmm2,xmm6
vmulss    xmm3,xmm3,xmm7
lea       rax,[rcx+58h]
vmovss    dword ptr [rax],xmm0
vmovss    dword ptr [rax+4],xmm1
vmovss    dword ptr [rax+8],xmm2
vmovss    dword ptr [rax+0Ch],xmm3
vmovaps   xmm6,xmmword ptr [rsp+10h]

```

Эта версия гораздо короче и разумнее: она использует команды AVX, недоступные на LegacyJIT-x64.

Теперь посмотрим на собственный код SystemMul на RyuJIT-x64:

```

; SystemMul/RyuJIT-x64
vmovupd   xmm0,xmmword ptr [rcx+8]
vmovupd   xmm1,xmmword ptr [rcx+18h]
vmulps    xmm0,xmm0,xmm1
vmovupd   xmmword ptr [rcx+28h],xmm0

```

Метод `operator *` отмечен атрибутом `[Intrinsic]`. У RyuJIT-x64 есть о нем особая информация: он может выполнять умножение с помощью одной команды AVX `vmulps`. BenchmarkDotNet приводит результат 0 из-за эффектов ILP.

## Обсуждение

Этот пример похож на пример `Math.Round`. Однако он заслуживает отдельного обсуждения, поскольку API `System.Numerics` были разработаны для использования подобных интринзиков.

Иногда бенчмаркинг команд SSE/AVX требует дополнительного прогрева. Вот цитата из [Agnor Microarch]:

«11.9 Модуль выполнения

Период прогрева для векторных команд YMM и ZMM.

Процессор отключает верхние части модулей выполнения векторов, когда они не применяются, с целью сохранения энергии. У инструкций с 256-битными векторами выработка примерно в 4,5 раза ниже нормальной в период изначального прогрева примерно в 56 000 временных циклов, или 14 мкс. Фрагмент кода, содержащий операции с 256-битными векторами, будет запущен на полной скорости после периода прогрева. Процессор возвращается в режим медленного 256-битного выполнения 2,7 миллиона временных циклов, или 675 мкс, после последней 256-битной команды (это время было измерено на процессоре с частотой 4 ГГц). Похожее время применимо и к 512-битным векторам».

## Практический пример 4: System.Runtime.Intrinsics

В предыдущих примерах мы обсуждали *неявные* интринзики. Это означает, что некоторые компиляторы JIT *могут* использовать продвинутые собственные команды для генерирования более эффективного кода. Но их невозможно контролировать: в некоторых случаях нужно быть готовыми к получению медленных собственных реализаций.

С момента выхода .NET Core 3.0 существуют пространства имен `System.Runtime.Intrinsics` с различными API, предоставляющие прямой доступ к собственным командам. Здесь мы говорим о *явных* интринзиках — заставляем компилятор использовать конкретную команду без каких-либо других опций.

Допустим, мы хотим вычислить количество установленных битов в значении `uint`. В SSE4 для этого есть собственная команда `popcnt` (<https://www.felixcloutier.com/x86/popcnt>). Однако она может быть недоступна на старых устройствах, не поддерживающих SSE4. Чтобы правильно разобраться в этом случае, мы можем написать такой код:

```
public uint MyPopCount(uint x)
{
    if (Popcnt.IsSupported)
        return Popcnt.PopCount(x);
    else
    {
        // Реализация вручную
    }
}
```

Запрос `Popcnt.PopCount(x)` всегда использует команду `popcnt`. У компилятора нет других вариантов.

### Исходный код

Рассмотрим следующий бенчмарк на базе BenchmarkDotNet:

```
public static unsafe class CompareHelper
{
    // Принимаем x.Length == y.Length
    public static bool NotEqualManual(int[] x, int[] y)
    {
        for (int i = 0; i < x.Length; i++)
            if (x[i] == y[i])
                return false;
        return true;
    }
}
```

```

// Принимаем x.Length == y.Length; x.Length % 4 == 0
public static bool NotEqualSse41(int[] x, int[] y)
{
    fixed (int* xp = &x[0])
    fixed (int* yp = &y[0])
    {
        for (int i = 0; i < x.Length; i += 4)
        {
            Vector128<int> xVector = Sse2.LoadVector128(xp + i);
            Vector128<int> yVector = Sse2.LoadVector128(yp + i);
            Vector128<int> mask = Sse2.CompareEqual(xVector, yVector);
            if (!Sse41.TestAllZeros(mask, mask))
                return false;
        }
    }
    return true;
}

// Принимаем x.Length == y.Length; x.Length % 8 == 0
public static bool NotEqualAvx2(int[] x, int[] y)
{
    fixed (int* xp = &x[0])
    fixed (int* yp = &y[0])
    {
        for (int i = 0; i < x.Length; i += 8)
        {
            Vector256<int> xVector = Avx.LoadVector256(xp + i);
            Vector256<int> yVector = Avx.LoadVector256(yp + i);
            Vector256<int> mask = Avx2.CompareEqual(xVector, yVector);
            if (!Avx.TestZ(mask, mask))
                return false;
        }
    }
    return true;
}

public class Benchmarks
{
    private const int n = 100000;
    private int[] x = new int[n];
    private int[] y = new int[n];

    [GlobalSetup]
    public void Setup()
    {
        Array.Fill(x, 1);
        Array.Fill(y, 2);
    }
}

```

```

[Benchmark(Baseline = true)]
public bool Manual() => CompareHelper.NotEqualManual(x, y);

[Benchmark]
public bool Sse41() => CompareHelper.NotEqualSse41(x, y);

[Benchmark]
public bool Avx2() => CompareHelper.NotEqualAvx2(x, y);
}

```

У нас есть три бенчмарка, `Manual`, `Sse41` и `Avx2`. Все они проверяют, нет ли в массивах `x` и `y` пары `x[i]/y[i]`, где `x[i] == y[i]`. В бенчмарке `Manual` есть простой цикл, проверяющий каждую пару элементов на соответствие этому условию. В бенчмарках `Sse41` и `Avx2` мы делаем то же самое с помощью команд `SSE4.1` и `AVX2`, вызываемых напрямую с помощью `System.Runtime.Intrinsics`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 3.0.0-preview-27122-01):

Method	Mean	StdDev	Ratio
Manual	53.34 us	0.5719 us	1.00
Sse41	40.45 us	0.5451 us	0.76
Avx2	23.56 us	0.1158 us	0.44

Как видите, бенчмарк `Avx2` — самый быстрый, `Sse41` работает медленно, а `Manual` — медленнее всех.

## Объяснение

С помощью API `System.Runtime.Intrinsics` мы можем вызвать команды `SSE/AVX`, которые могут обрабатывать несколько элементов массива одновременно. Поэтому он позволяет улучшать производительность на устройствах с поддержкой этих команд.

## Обсуждение

Явные интринзики позволяют реализовывать разные алгоритмы внутри одного и того же метода, основываясь на доступности команды. Например, если `Avx.IsSupported` истинно, мы можем выполнить быстрый алгоритм на базе `AVX`. Если `Avx.IsSupported` ложно, можем вернуться к медленному алгоритму без использования интринзиков.

Это хорошо для производительности, но плохо для бенчмаркинга: так становится сложнее сделать общие выводы о производительности метода, основываясь на

одной серии запусков. Конечно же, эта проблема существует и без `System.Runtime.Intrinsics` — компилятор может генерировать разные собственные реализации на разных устройствах. Но теперь нужно проверять не только эффекты компилятора, но и пользовательский код, специфичный для устройства, в путях выполнения бенчмарка.

Смотрите также:

- [Mijailovic 2018a], [Mijailovic 2018b], [Mijailovic 2018c], [Mijailovic 2018d];
- [Damageboy 2018a], [Damageboy 2018b], [Damageboy 2018c];
- [Lui 2018];
- <https://github.com/EgorBo/IntrinsicsPlayground>;
- `dotnet/designs`: «Внутренние средства, зависящие от платформы .NET» (<https://github.com/dotnet/designs/blob/e55c517a1e7f8dc35b092397058029531209d610/accepted/platform-intrinsics.md>);
- `dotnet/machinelearning#1292`: *.NET Platform Dependent Intrinsics59* (<https://github.com/dotnet/machinelearning/pull/1292>).

## Подводя итог

В этом разделе мы обсудили несколько видов интринзиков.

- У некоторых компиляторов JIT есть особые интринзики для стандартных методов. Например, в RyuJIT-x64 есть интринзик для `Math.Round`. В то же время у этого метода есть и простая реализация на C#, применяемая другими компиляторами.
- Некоторые компиляторы JIT могут распознать определенные схемы в исходном коде и сгенерировать разумный собственный код с использованием специальных команд. Например, RyuJIT-x64 может трансформировать идиоматическую ротацию битов (`(value >> count) | (value << (64 - count))`) в одну команду `ror`.
- В пространстве имен `System.Numerics` существуют типы с включенным SIMD, например `Vector4` или `Matrix4x4`. Эти типы были разработаны, чтобы ускоряться на уровне устройства с помощью команд SIMD. Компиляторы, незнанные с этими типами, возвращаются в исходный момент с медленной реализацией.
- С момента выхода .NET Core 3.0, у нас есть доступ к явным интринзикам, позволяющим вызывать конкретные собственные команды из разных наборов команд. В исходном коде мы также можем проверить, какие из этих наборов поддерживаются в данном процессоре.

Различные интринзики в разных компиляторах JIT делают бенчмарки более зависимыми от конкретного устройства. Становится сложно делать общие выводы по

поводу производительности метода, основываясь на одном окружении. Изменение среды исполнения, версии компилятора или устройства может сильно изменить результаты. К счастью, теперь вам известно еще одно, что может помочь понять разницу в производительности в разных окружениях.

## Выводы

Бенчмарки, ограниченные возможностями процессора, довольно популярны, но их не так уж просто разрабатывать и анализировать, поскольку многие характеристики устройств и среды исполнения могут испортить эксперименты. В этой главе мы обсудили следующие темы.

- **Регистры и стек.**

Когда компилятор JIT генерирует собственный код метода, он может поместить локальную переменную в стек или регистры. Обычно операции с регистрами выполняются гораздо быстрее, чем со стеком. К сожалению, контролировать компилятор невозможно: даже небольшие и безвредные изменения могут повлиять на его решения.

- **Инлайнинг.**

Когда компилятор JIT выполняет инлайнинг метода, он заменяет вызов метода его телом. Обычно это полезная оптимизация, поскольку она удаляет ограничения вызова и позволяет выполнить другие оптимизации компилятора. Однако она также может испортить производительность, ухудшив размещение регистров или предотвратив дальнейший более полезный инлайнинг. Его можно отключить в конкретном методе с помощью атрибута `[MethodImpl(MethodImplOptions.NoInlining)]`. Существует много других факторов, предотвращающих инлайнинг, например размер метода, работа с исключениями, виртуальный модификатор и рекурсия. Некоторые из них неочевидны и могут действовать только для конкретных компиляторов (например, команды `starf` предотвращают инлайнинг на LegacyJIT-x86). Мы можем сообщить компилятору, что очень хотим заинлайнить конкретный метод с помощью атрибута `[MethodImpl(MethodImplOptions.AggressiveInlining)]`. Но заставить его не можем, поскольку инлайнинг возможен не всегда. `AggressiveInlining` способен помочь оптимизировать некоторые небольшие и популярные методы, но может и увеличить длительность некоторых из них.

- **ILP.**

ILP позволяет выполнять несколько команд одновременно в одном потоке. Как обычно, это полезно для производительности, но вредно для бенчмаркинга. Например, вы можете добавить несколько выражений в тело бенчмарка, но каких-либо изменений в производительности не произойдет, поскольку они

будут выполняться параллельно с уже существующим кодом. Функции ILP зависят от диаграммы взаимозависимостей, имеющихся в вашем коде на C# или на уровне собственного кода. Когда цикл очень короткий, его производительность может заметно измениться из-за расположения собственного кода. Чтобы предотвратить подобные ситуации, рекомендуется разворачивать такие циклы вручную.

- **Прогнозирование ветвлений.**

То, что процессор может правильно прогнозировать выбранные ветви, значительно улучшает условия для ILP. Блок прогнозирования ветвлений использует архив выбранных ветвей. Это означает, что на производительность могут повлиять изменения в данных ввода, даже если вы выполняете то же самое количество собственных команд.

- **Арифметика.**

Производительность даже самых простых арифметических операций зависит от окружения. Вычисления на числах с плавающей запятой недетерминированы, поэтому результат программы также может различаться в разных средах исполнения и на различных устройствах. В стандарте IEEE существуют денормализованные числа, способные сильно замедлить вычисления. Поэтому производительность вычислений типов `float` и `double` зависит также от значений операндов.

- **Интринзики.**

В C# существует множество неявных и явных интринзиков, позволяющих получить эффективный собственный код для конкретного устройства. Неявные интринзики компилятор JIT задействует для оптимизации конкретных выражений или системных методов с применением лучших из доступных команд устройства. Явные интринзики вы используете вручную, чтобы оптимизировать методы с помощью любых команд устройства (если они доступны).

Все эти темы важны для разработки и анализа бенчмарков. Правильная разработка бенчмарка требует тщательной работы со всеми компонентами пространства производительности. Изменения в исходном коде могут повлиять на генерирование собственного кода для локальных переменных (их можно поместить в стек или реестры), методы инлайнинга компилятора JIT и условия ILP. Изменения в окружении (например, в версии среды исполнения или устройства) могут повлиять на сгенерированные собственные команды и доступность интринзиков. Изменения в данных ввода могут повлиять на количество неверных прогнозов. При анализе распределений производительности для конкретного сочетания исходного кода/окружения/данных ввода нужно помнить, что при других условиях производительность может сильно измениться. А теперь вы знаете, что нужно проверить при исследованиях производительности в случае подобных изменений в бенчмарках, ограниченных возможностями процессора.

## ИСТОЧНИКИ

[Agner Instructions] *Fog A.* Instruction Tables. Lists of Instruction Latencies, Throughputs and Micro-Operation Breakdowns for Intel, AMD and VIA CPUs. [www.agner.org/optimize/instruction\\_tables.pdf](http://www.agner.org/optimize/instruction_tables.pdf).

[Agner Microarch] *Fog A.* The Microarchitecture of Intel, AMD and VIA CPUs. An Optimization Guide for Assembly Programmers and Compiler Makers. [www.agner.org/optimize/microarchitecture.pdf](http://www.agner.org/optimize/microarchitecture.pdf).

[Akinshin, 2015] *Akinshin A.* A Story About JIT-X86 Inlining and Starg. 2015. February 26. <https://aakinshin.net/posts/inlining-and-starg/>.

[Akinshin, 2016a] *Akinshin A.* Performance Exercise: Minimum. 2016. December 20. <https://aakinshin.net/posts/perfex-min/>.

[Akinshin, 2016b] *Akinshin A.* Performance Exercise: Division. 2016. December 26. <https://aakinshin.net/posts/perfex-div/>.

[Amit, 2018] *Amit N.* How New-Lines Affect the Linux Kernel Performance. 2018. <https://sites.google.com/site/nadavamit/blog/linux-inline>.

[Andryscio, 2015] *Andryscio M., Kohlbrenner D., Mowery D., Jhala R., Lerner S., Shacham H.* On Subnormal Floating Point and Abnormal Timing // Security and Privacy (Sp), 2015. IEEE Symposium. IEEE: 623–639.

[Andryscio, 2016] *Andryscio M., Jhala R., Lerner S.* Printing Floating-Point Numbers: A Faster, Always Correct Method // ACM Sigplan Notices, 2016. ACM: 51: 555–567.

[Ayers, 2016] *Ayers A.* Some Notes on Using Machine Learning to Develop Inlining Heuristics. 2016. August. <https://github.com/AndyAyersMS/PerformanceExplorer/blob/master/notes/notes-aug-2016.md>.

[Chen, 2019] *Chen R.* The Intel 80386, Part 4: Arithmetic. 2019. January 24. <https://blogs.msdn.microsoft.com/oldnewthing/20190124-00/?p=100775>.

[Damageboy, 2018a] *Damageboy.* NET Core 3.0 Intrinsic in Real Life – 1/3. 2018. August 18. <https://bits.houmus.org/2018-08-18/netcoreapp3.0-intrinsic-in-real-life-pt1>.

[Damageboy, 2018b] *Damageboy.* NET Core 3.0 Intrinsic in Real Life – 2/3. 2018. August 19. <https://bits.houmus.org/2018-08-19/netcoreapp3.0-intrinsic-in-real-life-pt2>.

[Damageboy, 2018c] *Damageboy.* NET Core 3.0 Intrinsic in Real Life – 3/3. 2018. August 20. <https://bits.houmus.org/2018-08-20/netcoreapp3.0-intrinsic-in-real-life-pt3>.

[Edelkamp, 2016] *Edelkamp S., Weiß A.* BlockQuicksort: How Branch Mispredictions Don't Affect QuickSort. 2016. arXiv Preprint arXiv:1604.06697, June. <https://arxiv.org/abs/1604.06697v2>.

[FPUx87] Programming with the X87 Floating-Point Unit. <http://home.agh.edu.pl/~am-rozek/x87.pdf>.

[Goldberg, 1991] *Goldberg D.* What Every Computer Scientist Should Know About Floating-Point Arithmetic // ACM Computing Surveys (CSUR), 1991. 23 (1). ACM: 5–48.

[Hennessy, 2011] *Hennessy J. L., Patterson D. A.* Computer Architecture: A Quantitative Approach. 5th ed. Morgan Kaufmann, 2011.

[Icaza, 2018] *Icaza M. de.* How We Doubled Mono's Float Speed. 2018. April 11. <https://tirania.org/blog/archive/2018/Apr-11.html>.

[Intel Manual] Intel: Intel® 64 and IA-32 Architectures Software Developer's Manual (325462-061US). 2016. [www.intel.com/content/dam/www/public/us/en/documents/manuals/64-ia-32-architectures-software-developer-manual-325462.pdf](http://www.intel.com/content/dam/www/public/us/en/documents/manuals/64-ia-32-architectures-software-developer-manual-325462.pdf).

[Lemire, 2019] *Lemire D., Kaser O., Kurz N.* Faster Remainder by Direct Computation: Applications to Compilers and Software Libraries. 2019. arXiv Preprint arXiv:1902.01961. <https://arxiv.org/abs/1902.01961>.

[Lui, 2018] *Lui B.* Using .NET Hardware Intrinsic API to Accelerate Machine Learning Scenarios. 2018. October 10. <https://blogs.msdn.microsoft.com/dotnet/2018/10/10/using-net-hardware-intrinsic-api-to-accelerate-machine-learning-scenarios/>.

[Luu, 2017] *Luu D.* Branch Prediction. 2017. August. <https://danluu.com/branch-prediction/>.

[Mijailovic, 2018a] *Mijailovic N.* Exploring .NET Core Platform Intrinsic: Part 1 — Accelerating SHA-256 on ARMv8. 2018. June 6. <https://mijailovic.net/2018/06/06/sha256-armv8/>.

[Mijailovic, 2018b] *Mijailovic N.* Exploring .NET Core Platform Intrinsic: Part 2 — Accelerating AES Encryption on ARMv8. 2018. June 18. <https://mijailovic.net/2018/06/18/aes-armv8/>.

[Mijailovic, 2018c] *Mijailovic N.* Exploring .NET Core Platform Intrinsic: Part 3 — Viewing the Code Generated by the JIT. 2018. July 5. <https://mijailovic.net/2018/07/05/generated-code/>.

[Mijailovic, 2018d] *Mijailovic N.* Exploring .NET Core Platform Intrinsic: Part 4 — Alignment and Pipelining. 2018. July 20. <https://mijailovic.net/2018/07/20/alignment-and-pipelining/>.

[Mittal, 2018] *Mittal S.* A Survey of Techniques for Dynamic Branch Prediction. 2018. arXiv Preprint arXiv:1804.00261, April. <https://arxiv.org/pdf/1804.00261.pdf>.

[Morrison, 2008] *Morrison V.* To Inline or Not to Inline: That Is the Question. 2008. August 19. <https://blogs.msdn.microsoft.com/vancem/2008/08/19/to-inline-or-not-to-inline-that-is-the-question/>.

[Notario, 2004] *Notario D.* Jit Optimizations: Inlining (II). 2004. November 1. <https://blogs.msdn.microsoft.com/davidnotario/2004/11/01/jit-optimizations-inlining-ii/>.

[Rohou, 2015] *Rohou E., Swamy B. N., Seznec A.* Branch Prediction and the Performance of Interpreters – Don’t Trust Folklore. 2015. <https://hal.inria.fr/hal-01100647>.

[Sanglard, 2017] *Sanglard F.* Game Engine Black Book: Wolfenstein 3D. CreateSpace Independent Publishing Platform, 2017.

[Skeet, 2008] *Skeet J.* C# in Depth. Manning. 2008.

[Steele, 1990] *Steele Jr., L. Guy, White J. L.* How to Print Floating-Point Numbers Accurately // ACM Sigplan Notices, 1990. ACM: 25:112–126.

[Tillaart, 2007] *Tillaart R.* Optimizing Integer Divisions with Multiply Shift in C# // CodeProject, 2007. January 27. [www.codeproject.com/Articles/17480/Optimizing-integer-divisions-with-Multiply-Shift-i](http://www.codeproject.com/Articles/17480/Optimizing-integer-divisions-with-Multiply-Shift-i).

# 8

## Бенчмарки, ограниченные возможностями памяти

Обвинять сборщик мусора в появлении проблем с производительностью — все равно что обвинять печень в появлении похмелья...

Он спасает вас от вашего же кода.

*Бен Адамс*

Довольно часто память вызывает узкие места в коде. В этом случае важно понимать, как она работает на разных уровнях, от процессора до среды исполнения .NET. Это позволит вам разрабатывать хорошие бенчмарки. В то же время если вы не знаете каких-то свойств памяти<sup>1</sup>, то запросто можете разработать неправильный бенчмарк, пропустив важную часть пространства производительности или измерив производительность чего-то специфичного для памяти, а не своего кода.

Управление памятью в .NET — это объемная тема, она заслуживает того, чтобы ей посвятили отдельную книгу. И эта книга существует — «Об управлении памятью в .NET» ([Kokosa, 2018a]). В ней более 1000 страниц подробного обзора важнейших аспектов управления памятью.

Если вам интересны подробности устройства памяти на аппаратном уровне, я рекомендую прочесть [Drepper, 2007]. Это довольно старая работа, но в ней объясняются довольно фундаментальные понятия, все еще актуальные для современных устройств.

При обсуждении памяти программы разработчики обычно имеют в виду разные типы памяти на уровне ОС, например виртуальную память, память управления, закрытый набор, общую память, резидентную память, рабочий набор и т. д. В данном разделе мы об этом говорить не будем<sup>2</sup>.

---

<sup>1</sup> Некоторые из этих свойств неочевидны, если вы о них не знаете. Вот довольно интересный пример — [Majkowski, 2018].

<sup>2</sup> Интересная информация о разных типах памяти имеется в [Goldshstein, 2016] и [Gregg, 2018]. В [Dawson, 2018a] и [Dawson, 2018b] можно найти актуальные практические примеры, связанные с производительностью.

В этой книге не станем рассматривать теоретические аспекты управления памятью, а продолжим изучать практические примеры, иллюстрирующие, как разные подводные камни могут повлиять на бенчмарки, ограниченные возможностями памяти. Будет использована такая же структура, как и в главе 7. В каждом примере — по четыре раздела: «Исходный код», «Результаты», «Объяснение» и «Обсуждение».

Эта глава поможет вам разрабатывать более качественные бенчмарки, ограниченные возможностями памяти, и избегать распространенных ошибок. Разбираться в деталях устройства памяти полезно в любом случае, но для самых простых бенчмарков это не обязательно. Как обычно, вам будет достаточно просто понимать основные концепции и разбираться в том, как их применять при разработке и анализе бенчмарков.

## Кэш процессора

Операции чтения и записи очень популярны в любых программах. Обсуждая алгоритмическую сложность разных алгоритмов, мы часто используем  $\theta(1)$  в качестве сложности простой операции ввода-вывода. Это правильно, но не означает, что все подобные операции одинаковой длительности: реальная производительность зависит от области памяти, с которой мы работаем.

Например, мы можем работать с физическими дисками, HDD или SSD. Они прекрасно подходят для надежного хранения данных. С точки зрения производительности такое хранение — неоптимальное решение для алгоритмов, обрабатывающих данные, поскольку доступ к дискам довольно медленный.

Основная память (RAM) работает гораздо быстрее дисков. В бенчмарках мы часто работаем с массивами и разными структурами данных, существующими в RAM. Доступ к RAM работает быстрее, чем к диску, но во многих случаях все равно недостаточно быстро.

Поэтому существует кэш процессора — довольно эффективное хранилище часто используемых данных, расположенное в процессоре. При выполнении операций ввода-вывода на одних и тех же данных несколько раз процессор размещает соответствующие блоки памяти в кэше. Это позволяет сильно улучшить производительность.

Существуют и регистры процессора, которые работают еще быстрее, чем его кэш, но их немного. Достаточно, чтобы предоставить быстрый доступ к нескольким переменным, но недостаточно для работы с большим массивом.

Мы можем работать напрямую с регистрами процессора или с основной памятью на уровне собственного кода, но к кэшу процессора прямого доступа у нас нет. Поэтому тема кэша процессора так важна для бенчмаркинга: он может значительно изменить производительность кода без нашего прямого вмешательства. Давайте же обсудим несколько примеров, демонстрирующих соответствующие эффекты.

## Практический пример 1: схемы доступа к памяти

При выборе схемы доступа к памяти в ваших бенчмарках важно понимать эффекты кэша процессора. Изучим пример, показывающий, почему это так.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private int n = 512;
    private long[,] a;

    [GlobalSetup]
    public void Setup()
    {
        a = new long[n, n];
    }

    [Benchmark(Baseline = true)]
    public long SumIj()
    {
        long sum = 0;
        for (int i = 0; i < n; i++)
            for (int j = 0; j < n; j++)
                sum += a[i, j];
        return sum;
    }

    [Benchmark]
    public long SumJi()
    {
        long sum = 0;
        for (int i = 0; i < n; i++)
            for (int j = 0; j < n; j++)
                sum += a[j, i];
        return sum;
    }
}
```

У нас есть квадратичный массив `a`. В бенчмарке `SumIj` представлен классический способ вычисления суммы элементов в этом массиве. В бенчмарке `SumJi` происходит то же самое, но с использованием элементов `a[j, i]` вместо `a[i, j]` при каждой итерации.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 2.1.5, RyuJIT-x64):

Method	Mean	StdDev	Ratio
SumIj	334.8 us	6.466 us	1.00
SumJi	692.0 us	30.509 us	2.13

Как видите, бенчмарк `SumJi` работает гораздо медленнее, чем `SumIj`.

## Объяснение

В бенчмарке `SumIj` мы нумеруем все элементы построчно. Если в кэше нет `a[0, 0]`, наблюдается ситуация под названием «неудачное обращение к кэш-памяти». Это означает, что нам нужно загрузить данное значение в кэш, на что требуется некоторое время.

Неделимым элементом кэша процессора является кэш-строка. Типичный размер кэш-строки — 64 байта, таким образом, она может содержать восемь значений `long`. Загружая в кэш `a[0, 0]`, на самом деле мы загружаем всю кэш-строку, содержащую также `a[0, 1]`, `a[0, 2]`, `a[0, 3]`, `a[0, 4]`, `a[0, 5]`, `a[0, 6]` и `a[0, 7]` (предполагаем при этом, что массив размещен в памяти). После того как мы загрузили данную кэш-строку, становится возможно получать быстрый доступ к этим семи элементам, поскольку они уже находятся в кэше. Поэтому следующие семь операций чтения будут быстрыми.

В бенчмарке `SumJi` нумеруем все элементы по столбцам. При чтении значения `a[0, 0]` также появляется неудачное обращение к кэш-памяти, влекущее за собой ухудшение производительности. Но нам сейчас не нужны элементы `a[0, 1]`..`a[0, 7]`, загруженные в кэш вместе с `a[0, 0]`. После элемента `a[0, 0]` мы читаем значение `a[1, 0]`. И снова происходит неудачное обращение! Элементы, загруженные в кэш вместе с `a[1, 0]` (`a[1, 1]`..`a[1, 7]`), сейчас бесполезны, поскольку следующим используемым элементом будет `a[2, 0]`.

`SumIj` и `SumJi` выполняют одинаковое количество команд. Но `SumJi` работает гораздо медленнее, поскольку в нем больше неудачных обращений к кэш-памяти. Схема

размещения элементов в памяти для этого примера представлена на рис. 8.1 (каждая кэш-строка выделена своим цветом).

0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	0,10	0,11	0,12	0,13	0,14	0,15
1,0	1,1	1,2	1,3	1,4	1,5	1,6	1,7	1,8	1,9	1,10	1,11	1,12	1,13	1,14	1,15
2,0	2,1	2,2	2,3	2,4	2,5	2,6	2,7	2,8	2,9	2,10	2,11	2,12	2,13	2,14	2,15

64 байта
64 байта

**Рис. 8.1.** Квадратичный массив и кэш-строки процессора

## Обсуждение

В реальности невозможно всегда контролировать схему доступа к памяти, но в бенчмарках это возможно. Если вы хотите получить качественный обзор пространства производительности, я рекомендую проверить различные схемы доступа (при возможности): последовательную схему (которая должна быть самой быстрой), схему, где одна и та же кэш-строка никогда не затрагивается дважды (которая должна быть самой медленной), случайную схему (которая должна быть близка к самой медленной) и несколько схем, совпадающих с реальными сценариями.

При сравнении разных алгоритмов можно получить противоположные результаты, если использовать разные схемы доступа. Во многих случаях невозможно сказать, какая структура данных будет более эффективной для вашей программы, поскольку одна и та же структура может оказаться быстрее в одном типе бенчмарка и медленнее — в другом. Например, операция ввода работает гораздо быстрее со списком указателей следующего элемента, чем с простым массивом, но нумерация такого списка может протекать гораздо медленнее из-за большого количества неудачных обращений.

Если вы хотите использовать информацию о кэше процессора при оптимизации, вас может заинтересовать тема совместимых с кэшем алгоритмов и структур данных (примеры найдете в [Hiroshi, 2015] и [Kulukundis, 2017], а также в разделе «Разработка, ориентированная на данные» в [Kokosa, 2018a]). Новые интересные примеры по кэшу процессора можно также найти в [Douillet, 2018].

## Практический пример 2: уровни кэша

Ключевые принципы работы кэша процессора схожи на разных устройствах, но его физическое размещение зависит от модели процессора. Рассмотрим процессор

Intel Core i7-6700HQ CPU 2.60GHz (<https://ark.intel.com/products/88967/Intel-Core-i7-6700HQ-Processor-6M-Cache-up-to-3-50-GHz->). В нем три уровня кэша: L1, L2 и L3. Размер L1 — 32 Кбайт, это самый быстрый уровень. Размер L2 — 256 Кбайт, он тоже быстрый, но медленнее L1. Размер L3 — 6 Мбайт, это самый медленный уровень кэша, тем не менее он работает гораздо быстрее, чем основная физическая память. Рассмотрим пример, показывающий производительность разных уровней кэша.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
[HardwareCounters(HardwareCounter.CacheMisses)]
public class Benchmarks
{
    private const int N = 16 * 1024 * 1024;
    private byte[] data;

    [Params(1, 2, 4, 8, 16, 32, 64, 128, 256,
            512, 1024, 2048, 4096, 8192, 16384, 32768)]
    public int SizeKb;

    [GlobalSetup]
    public void Setup()
    {
        data = new byte[SizeKb * 1024];
    }

    [Benchmark]
    public void Calc()
    {
        int mask = data.Length - 1;
        for (int i = 0; i < N; i++)
            data[(i * 64) & mask]++;
    }
}
```

У нас есть массив `byte data`, а также параметр `SizeKb`, определяющий размер этого массива в килобайтах. В единственном бенчмарке `Calc` мы увеличиваем элементы данного массива с дельтой 64 байта. Это не случайное число, а размер одной кэш-строки процессора — размер минимального блока, обрабатываемого кэшем. Кэш процессора не может добыть одну переменную из основной памяти, потому что всегда работает с *кэш-строками*. Количество увеличений в бенчмарке одинаково для всех значений `SizeKb`. Атрибут `[HardwareCounters(HardwareCounter.CacheMisses)]`

просит BenchmarkDotNet измерить неудачные обращения к кэшу процессора с помощью аппаратных счетчиков.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 2.1.5, RyuJIT-x64):

SizeKb	Mean	StdDev	CacheMisses/Op
1	18.75 ms	0.1259 ms	1,044
2	18.63 ms	0.1602 ms	1,058
4	18.62 ms	0.1656 ms	1,348
8	18.74 ms	0.1555 ms	1,065
16	18.75 ms	0.1675 ms	1,292
32	18.82 ms	0.1431 ms	1,841
64	21.76 ms	0.2145 ms	2,743
128	21.55 ms	0.1594 ms	3,702
256	21.55 ms	0.1367 ms	3,076
512	36.71 ms	0.4937 ms	2,791
1024	36.31 ms	0.2990 ms	3,051
2048	36.57 ms	0.3610 ms	49,448
4096	40.92 ms	0.4023 ms	434,477
8192	67.61 ms	0.7010 ms	3,162,028
16384	85.49 ms	0.7213 ms	5,493,341
32768	92.18 ms	0.8848 ms	6,240,472

Как видите, у нас есть несколько групп результатов бенчмарка. Значения `SizeKb` от 1 до 32 дают примерно одинаковые результаты. Значения от 64 до 256 формируют другую группу результатов, в два раза медленнее первой. Еще есть группа значений `SizeKb` от 512 до 4096 с большей длительностью. После `SizeKb`, равного 8192, длительность возрастает еще значительно.

## Объяснение

При размере рабочей памяти менее 32 Кбайт процессор может хранить весь массив на уровне кэша L1. Это довольно эффективно и обеспечивает хорошую производительность. Начиная с 64 Кбайт, массив нельзя сохранить в L1, поскольку он слишком большой: процессор вынужден использовать L2, работающий медленнее. С 512 Кбайт процессор вынужден использовать L3, потому что L2 не хватает: производительность ухудшается. Начиная с 8192 Кбайт, массив слишком велик для всех

уровней кэша процессора: операции чтения/записи начинают работать напрямую с основной памятью, которая еще медленнее, чем L3.

Алгоритмическая сложность и количество выполненных собственных команд одинаковы для всех значений `SizeKb`. Однако бенчмарк с рабочей памятью 32 768 Кбайт работает в несколько раз медленнее, чем бенчмарк с рабочей памятью 1 Кбайт.

## Обсуждение

Информация о кэше процессора очень важна, если вы начинаете разрабатывать небольшие бенчмарки, основанные на реальных приложениях. В таких приложениях рабочая память (реально используемая в жизненном цикле приложения) может быть довольно большой — десятки мегабайт или даже гигабайт. Кэш процессора обычно не разогрет: когда мы работаем с сегментом памяти впервые, данные в кэш еще не загружены. Поэтому доступ к памяти будет открываться медленно. В небольших искусственных бенчмарках кэш процессора обычно разогрет, поскольку мы выполняем несколько итераций для прогрева, чтобы получить повторяемые результаты, а рабочая память не очень большая, так как нет гигабайтов памяти — для данного конкретного бенчмарка это не нужно. Другой распространенной ошибкой при бенчмаркинге является применение результатов подобных бенчмарков для оптимизации реальных приложений. Иногда это возможно, но не всегда: в реальном приложении производительность может быть гораздо хуже из-за отсутствия преимуществ кэша процессора, которые были в небольшом бенчмарке. Общая рекомендация проста: если вы работаете с массивами или другими структурами данных, нужно запускать бенчмарки на рабочей памяти разных объемов.

Производительность кэша процессора зависит также от микроархитектуры процессора. Для примера можно привести цитату из [Intel OptManual], 2.1.3 «Кэш и подсистема памяти» об изменениях в Intel Skylake: «Производительность операции записи в L3, по сравнению с предыдущим поколением, увеличена с 4 до 2 циклов на строку».

Разрабатывать небольшие бенчмарки, демонстрирующие подобные эффекты, не просто, но это может заметно повлиять на производительность приложения. Может быть непросто обнаружить изменения производительности на разных процессорах из-за эффективности кэша процессора, но это дополнительный фактор, способный повлиять на результаты измерений.

## Практический пример 3: ассоциативность кэша

Еще одним важным свойством кэша процессора является ассоциативность. Это особое число, используемое для совмещения основной памяти и кэш-строк. Например, в процессоре Intel Core i7-6700HQ CPU 2.60GHz ассоциативность уровня

кэша L1 — 8-поточная, L2 — 4-поточная, а L3 — 12-поточная. Рассмотрим еще один пример, который поможет понять, как нужно интерпретировать эти значения при измерениях производительности.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private int[, ] a;

    [Params(1023, 1024, 1025)]
    public int N;

    [GlobalSetup]
    public void Setup()
    {
        a = new int[N, N];
    }

    [Benchmark]
    public int Max()
    {
        int max = int.MinValue;
        for (int i = 0; i < N; i++)
            max = Math.Max(max, a[i, 0]);
        return max;
    }
}
```

У нас есть квадратичный массив **a**. В единственной бенчмарке **Max** вычисляем максимальный элемент в первом столбце этого массива. Размер массива является параметром бенчмарка: мы проверяем массивы размером  $1023 \times 1023$ ,  $1024 \times 1024$  и  $1025 \times 1025$ .

## Результаты

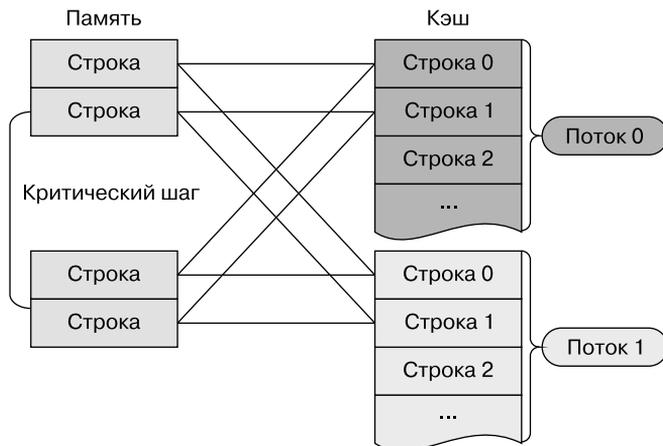
Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 2.1.5, RyuJIT-x64):

N	Mean	StdDev
1023	2.026 us	0.0694 us
1024	4.452 us	0.2049 us
1025	2.012 us	0.0117 us

Как видите, у случаев с **N=1023** и **N=1025** примерно одинаковая длительность. Но случай с **N=1024** работает гораздо медленнее.

## Объяснение

Пора обсудить значение ассоциативности кэша. На рис. 8.2 приведено схематичное изображение кэша с двухпоточной ассоциативностью.



**Рис. 8.2.** Схема кэша с двухпоточной ассоциативностью

Как упоминалось ранее, неделимой единицей кэша процессора является кэш-строка (обычно равная 64 байтам). Двухпоточная ассоциативность означает, что каждому 64-байтному сегменту основной памяти соответствуют две кэш-строки, которые могут содержать его. Общий размер кэша гораздо меньше объема основной памяти, поэтому он должен заново использовать одну и ту же пару кэш-строк для разных 64-байтных сегментов. Разница между сегментами основной памяти, соответствующих одному и тому же набору кэш-строк, известна как критический шаг. Его значение можно легко вычислить, разделив объем кэша на значение ассоциативности. В табл. 8.1 приведены значения критического шага для разных уровней кэша, основанные на его ассоциативности.

**Таблица 8.1.** Значения критического шага для разных кэшей процессора

Уровень	Объем	Ассоциативность	Критический шаг
L1	32 Кб	8-поточная	4 Кб
L2	256 Кб	4-поточная	64 Кб
L2	256 Кб	8-поточная	32 Кб
L3	6 Мб	12-поточная	512 Кб

В данном бенчмарке уровень L1 достаточно велик для того, чтобы обработать все элементы, с которыми мы работаем. У него 8-поточная ассоциативность, таким образом, критический шаг равен 4 Кбайт, или 4096 байтам. Разница между после-

довательными элементами в первом столбце равна  $4 * N$  байтам (поскольку размер `int` равен 4 байтам). При  $N = 1024$  эта разница составляет ровно 4096 байт и равна значению критического шага. Это означает, что все элементы из первого столбца соответствуют одним и тем же 8 кэш-строкам в L1. Мы не получаем улучшения производительности, связанного с кэшем, потому что не можем эффективно его использовать: у нас только 512 байт (8 кэш-строк, умноженные на размер кэш-строки 64 байта) вместо изначальных 32 Кбайт. Когда мы запускаем первый столбец в форме цикла, соответствующие элементы выталкивают друг друга из кэша. При  $N = 1023$  и  $N = 1025$  проблемы с критическим шагом исчезают — все элементы могут храниться в кэше, что гораздо эффективнее.

## Обсуждение

Разработчики часто применяют в бенчмарках степени двойки, поскольку это упрощает вычисление объема рабочей памяти (и выглядит более научно). К сожалению, это увеличивает вероятность возникновения проблем с критическим шагом. Из-за него легко получить плохие метрики производительности. Общая рекомендация остается все той же: при экспериментах с производительностью необходимо проверять разные объемы рабочей памяти, включая те, которые не являются степенями двойки.

Влияние критического шага зависит также от устройства. Приведу еще одну цитату из [Intel OptManual], 2.1.3 «Кэш и подсистема памяти» об изменениях в Intel Skylake: «В Intel Skylake ассоциативность уровня L2 изменена с 8-поточной на 4-поточную».

При сравнении метрик производительности в бенчмарке, ограниченном возможностями памяти, на двух разных процессорах может появиться разница из-за разных значений ассоциативности кэша и критического шага.

## Практический пример 4: ошибочное разделение

Ошибочное разделение — это эффект, способный испортить многопоточные бенчмарки. Рассмотрим пример, демонстрирующий его.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private static int[] x = new int[1024];

    private void Inc(int p)
    {
        for (int i = 0; i < 1000001; i++)
        {
```

```

        x[p]++; x[p]++; x[p]++; x[p]++;
        x[p]++; x[p]++; x[p]++; x[p]++;
        x[p]++; x[p]++; x[p]++; x[p]++;
        x[p]++; x[p]++; x[p]++; x[p]++;
    }
}

[Params(1, 256)]
public int Step;

[Benchmark]
public void Run()
{
    Task.WaitAll(
        Task.Factory.StartNew(() => Inc(0 * Step)),
        Task.Factory.StartNew(() => Inc(1 * Step)),
        Task.Factory.StartNew(() => Inc(2 * Step)),
        Task.Factory.StartNew(() => Inc(3 * Step)));
}
}

```

У нас есть метод `Inc`, многократно увеличивающий один и тот же элемент массива. Он использует развертывание циклов вручную, чтобы избежать эффектов ILP, которые обсуждались в главе 7. В единственном бенчмарке `Run` мы запускаем четыре задания, увеличивающие разные элементы массива (в каждом задании свой индекс элемента). В бенчмарке есть параметр `Step`, определяющий разницу между индексами увеличиваемых элементов. При `Step=1` мы увеличиваем `x[0]`, `x[1]`, `x[2]` и `x[3]`. При `Step=256` увеличиваем `x[0]`, `x[256]`, `x[512]` и `x[768]`.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Core 2.1.5, RyuJIT-x64):

Step	Mean	StdDev
1	215.66 ms	8.953 ms
256	61.54 ms	4.002 ms

Как видите, в случае со `Step=256` бенчмарк работает гораздо быстрее, чем со `Step=1`.

## Объяснение

Представьте себе ситуацию с двумя потоками на двух разных ядрах процессора, которые производят операции чтения/записи с одной и той же переменной. На Intel Core i7-6700HQ у каждого ядра собственные кэши уровней `L1` и `L2`. Поэтому процессору нужно синхронизировать значение переменной между ними. Очевидно, что из-за синхронизации ухудшается производительность. Эта ситуация известна как *истинное разделение* (рис. 8.3, слева).

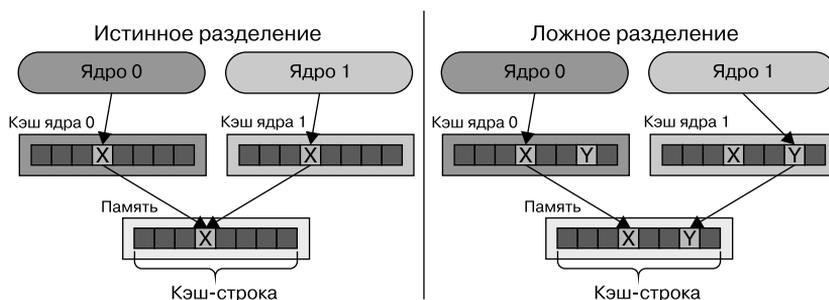


Рис. 8.3. Истинное и ложное разделение

Теперь представьте себе другую ситуацию: у нас опять есть два потока на двух разных ядрах процессора, но они выполняют операции чтения/записи на *разных* переменных. Можно предположить, что ухудшения производительности из-за синхронизации не будет, поскольку потоки не делят между собой одну переменную. Однако неделимой единицей кэша процессора для синхронизации является не одна переменная, а кэш-строка! Если эти переменные относятся к одной и той же кэш-строке, кэшу процессора все равно нужно синхронизировать ее! И неважно, что мы работаем с разными переменными. Если мы выполняем операции чтения/записи на одной и той же кэш-строке на разных ядрах, процессор все равно будет ее синхронизировать, даже если на самом деле мы не делим память между потоками. Эта ситуация известна как *ложное разделение* (см. рис. 8.3, справа). Из-за синхронизации производительность все равно ухудшается.

## Обсуждение

Обсуждаемая проблема важна только для многопоточных бенчмарков. Более того, она непостоянна: эффект ложного разделения можно наблюдать, только если нужные нам переменные относятся к одной кэш-строке. Любые изменения в исходном коде или окружении могут разнести переменные по двум разным кэш-строкам: первая будет в конце одной строки, а вторая — в начале другой. В этом случае эффект ложного разделения не повлияет на результаты по этим двум переменным.

Общая рекомендация: если вы пишете многопоточный бенчмарк, убедитесь, что разница между используемыми переменными из разных потоков — более 64 байт. В предыдущем примере мы сделали это с помощью `Step=256`: разные задания задействуют элементы массива, расположенные довольно далеко друг от друга. Если говорить об отдельных полях, между ними можно добавить восемь неиспользуемых переменных `long`.

Дополнительные примеры бенчмарков с ложным разделением можно найти в [Mendola, 2008], [Jainam M., 2017] и [Wakart, 2013].

## Подводя итог

В данном разделе мы обсудили четыре темы, которые могут оказаться важными при бенчмаркинге из-за свойств современных процессоров.

- **Схемы доступа к памяти.**

Последовательный доступ к памяти всегда быстрее, чем случайный, поскольку кэш процессора работает с кэш-строками (их типичный размер — 64 байта), а не с переменными. Загрузив переменную в кэш, вы загружаете и соседние переменные из той же кэш-строки. После этого вы получаете доступ к ним без ухудшения производительности из-за неудачного обращения к кэш-памяти.

- **Уровни кэша.**

Обычно у кэша процессора три уровня: L1, L2 и L3 (но можно найти и другие конфигурации кэша с двумя или четырьмя уровнями). Первый уровень — самый быстрый, но меньше всех по объему. Последний — самый объемный, но работает гораздо медленнее остальных. Операции с любым уровнем кэша процессора работают быстрее операций с данными из основной памяти, не представленными в кэше.

- **Ассоциативность кэша.**

У каждого байта основной памяти есть ограниченное число позиций в кэше процессора, способных обработать его значение. Обычно ассоциативность кэша сейчас от 4 до 24. Минимальная положительная разница между сегментами данных, соответствующих одному и тому же набору кэш-строк, известна как критический шаг.

- **Ложное разделение.**

В многопоточных бенчмарках может возникнуть ситуация, когда два разных потока выполняют операции чтения/записи с двумя разными переменными на двух разных ядрах процессора. Если эти переменные относятся к одной и той же кэш-строке, мы получим ситуацию, известную как ложное разделение: процессор должен синхронизировать эту строку между ядрами. В итоге из-за подобной ситуации ухудшается производительность.

Если вы хотите разработать хороший бенчмарк, ограниченный возможностями процессора, проверьте разные объемы рабочей памяти. Чтобы уменьшить количество объемов, можно взять объемы L1, L2, L3 и объем, значительно превышающий L3. Чтобы избежать проблем с критическим шагом, имеет смысл также проверить объемы, не равные степени двойки. Также стоит проверять разные схемы доступа (если возможно), например последовательный или случайный доступ. Такие крайние случаи позволяют получить общее представление о пространстве производительности, поскольку обычно дают как лучшие, так и худшие показатели. Однако все равно полезно проверять случаи, близкие к реальным сценариям использования.

## Схема размещения памяти

В этом разделе мы обсудим, как производительность зависит от реальных адресов переменных, с которыми мы работаем. В .NET не всегда возможно контролировать размещение объектов и структур, но существует множество интересных эффектов на уровне устройства, вызываемых производительностью, которые способны повлиять на результаты бенчмарка.

В предыдущем разделе мы обсудили типичные проблемы с кэшем процессора, часто влияющие на простые бенчмарки. Мы продолжим говорить о них, поскольку эта тема прочно связана со схемой размещения памяти.

### Практический пример 1: размещение структур

В .NET можно контролировать размещение структур вручную с помощью атрибутов `[StructLayout]` и `[FieldOffset]` (подробнее о них рассказывается в [Kalapos, 2018]). Однако большинство разработчиков их не используют, а полагаются на алгоритмы размещения по умолчанию. В то же время в разных средах исполнения .NET применяются различные методы размещения, которые могут серьезно повлиять на производительность приложения.

#### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public struct Struct7
{
    public byte X0, X1, X2, X3, X4, X5, X6;
}

public struct Struct8
{
    public byte X0, X1, X2, X3, X4, X5, X6, X7;
}

[LegacyJitX86Job, MonoJob]
public class Benchmarks
{
    public const int Size = 256;
    private int[] sum = new int[Size];
    private Struct7[] struct7 = new Struct7[Size];
    private Struct8[] struct8 = new Struct8[Size];

    [Benchmark(OperationsPerInvoke = Size, Baseline = true)]
    public void Run7()
    {
```

```

    for (var i = 0; i < sum.Length; i++)
    {
        Struct7 s = struct7[i];
        sum[i] = s.X0 + s.X1;
    }
}

[Benchmark(OperationsPerInvoke = Size)]
public void Run8()
{
    for (var i = 0; i < sum.Length; i++)
    {
        Struct8 s = struct8[i];
        sum[i] = s.X0 + s.X1;
    }
}
}

```

Мы уже обсуждали похожий бенчмарк в примере «Продвижение структуры» главы 7. У нас есть две структуры: `Struct7` с семью полями `byte` и `Struct8` с восемью полями `byte`. Также есть два бенчмарка, `Run7` и `Run8`. В каждом из них мы вычисляем сумму первых двух полей структуры в цикле. Единственная разница между ними — используемая структура.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, LegacyJIT-x86 v4.7.3260.0; Mono-x64 v5.18.0):

Method	Job	Mean	StdDev	Ratio
Run7	LegacyJitX86	7.331 ns	0.0216 ns	1.00
Run8	LegacyJitX86	2.409 ns	0.0088 ns	0.33
Run7	Mono	3.643 ns	0.0177 ns	1.00
Run8	Mono	3.716 ns	0.0164 ns	1.02

Как видите, `Run8` работает втрое быстрее `Run7` в LegacyJIT-x86. В Mono-x64 `Run8` работает немного медленнее, чем `Run7`.

## Объяснение

Когда у нас есть массив структур, LegacyJIT-x86 пытается разместить его память максимально компактно. Расположение первых восьми элементов `Struct7[]` показано на рис. 8.4, *слева* (каждая копия структуры выделена своим цветом). Элементы размещены в памяти один за другим без пробелов. Как видите, большинство из них не выровнены. Доступ к невыровненным данным обычно медленнее, чем к выровненным. Поэтому `Run8` работает гораздо быстрее: все его элементы выровнены естественным образом, поскольку каждый из них содержит ровно 8 байт.

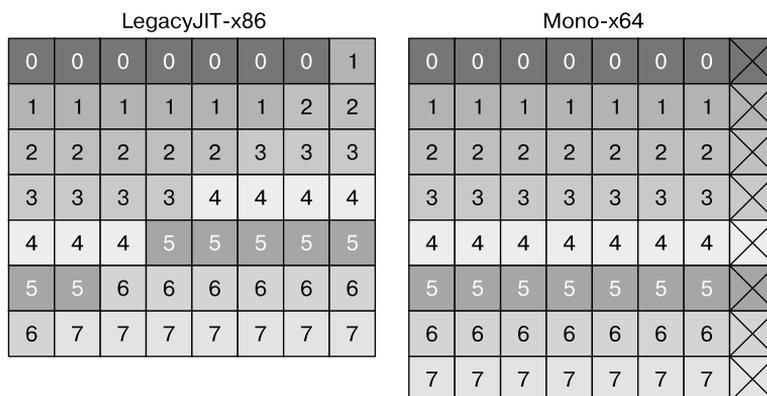


Рис. 8.4. Размещение Struct7 в LegacyJIT-x86 и Mono-x64

На рис. 8.4, *справа*, показано размещение Struct7[] в Mono: там используется пробел в 1 байт после каждого элемента, чтобы разместить все копии Struct7. С одной стороны, это плохо, поскольку такой метод размещения увеличивает общий объем памяти для хранения этого массива. С другой — это хорошо, потому что все элементы выровнены правильно и операция доступа может выполняться гораздо быстрее, чем когда они не выровнены.

### Обсуждение

Если вы хотите получить лучшую производительность из возможных для операции с массивами структур, будет разумно вручную контролировать размещение копий этих структур. Однако правильное размещение увеличивает объем требуемой памяти из-за пробелов. Также следует отметить, что изменения в производительности из-за доступа к невыровненным данным в значительной степени зависят от используемой модели процессора.

Дополнительную интересную информацию о проблемах с размещением памяти можно найти в [Sumedh, 2013], [Sandler, 2008] и [Lemirer, 2012].

Этот пример основан на вопросе 38949304 со StackOverflow (<https://stackoverflow.com/q/38949304>).

## Практический пример 2: конфликты кэш-банка

В контексте кэша процессора кэш-банк — это небольшой сегмент внутри кэш-строки процессора. При совмещении байта из основной памяти с кэш-строкой процессора можно также уникально определить номер кэш-банка, содержащего данный байт. В этом примере мы измерим последовательные операции с памятью, работающие с одним и тем же кэш-банком из разных кэш-строк.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public unsafe class Benchmarks
{
    private readonly int[] data = new int[2 * 1024 * 1024];

    [Params(15, 16, 17)]
    public int Delta;

    [Benchmark]
    public bool Calc()
    {
        fixed (int* dataPtr = data)
        {
            int* ptr = dataPtr;
            int d = Delta;
            bool res = false;
            for (int i = 0; i < 1024 * 1024; i++)
            {
                res |= (ptr[0] < ptr[d]);
                ptr++;
            }
            return res;
        }
    }
}
```

У нас есть массив `data` и параметр под названием `Delta`. В бенчмарке мы нумеруем первые  $1024 \cdot 1024$  элементов этого массива. Каждый элемент `data[i]` мы сравниваем с `data[i + Delta]`. Алгоритм написан с помощью небезопасного кода, чтобы избежать проверки границ при доступе к элементам массива. Код не вычисляет ничего полезного — это просто очередной маленький пример, показывающий довольно интересный эффект процессора.

## Результаты

Вот пример результатов на Skylake (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, RyuJIT-x64 v4.7.3260):

Delta	Mean	StdDev
15	0.957 ms	0.0030 ms
16	0.955 ms	0.0045 ms
17	0.956 ms	0.0051 ms

А это — пример результатов на Ivy Bridge (Windows 10.0.15063.1387, Intel Core i7-3615QM CPU 2.30GHz, .NET Framework 4.7.2, RyuJIT-x64 v4.7.3190):

Delta	Mean	StdDev
15	1.040 ms	0.0036 ms
16	1.243 ms	0.0063 ms
17	1.039 ms	0.0062 ms

Как видите, у всех запусков на Skylake примерно одинаковая длительность. А на Ivy Bridge запуск с `Delta=16` работает на 20 % медленнее.

## Объяснение

Объяснение этим результатам можно найти в [Intel OptManual], 3.6.1.3 «Как разобраться с конфликтом кэш-банка L1D»:

«В микроархитектуре Intel под кодовым названием Sandy Bridge внутренняя организация кэша L1D может заявить о ситуации, когда появляются две микрооперации загрузки с адресами, имеющими конфликт банков. При наличии конфликта банков между двумя операциями загрузки более поздняя из них будет отложена до момента разрешения конфликта. Конфликт банков происходит, когда у двух операций загрузки совпадают 2–5 бит их линейного адреса, но они не относятся к одному набору в кэше (6–12 бит).

Конфликты банков необходимо разрешать, только если код ограничен пропускной способностью загрузки. Некоторые конфликты банков не вызывают ухудшения производительности, поскольку скрываются за другими ограничениями. Разрешение этих конфликтов не улучшает производительность.

Конфликт банков L1 DCache не применяется к микроархитектуре Haswell».

Таким образом, каждую кэш-строку можно разбить на 16 кэш-банков (это число также зависит от модели процессора). На Ivy Bridge две операции загрузки могут вступить в конфликт, если они направлены на значения, относящиеся к кэш-банкам с совпадающими номерами в разных кэш-строках.

## Обсуждение

Эта проблема существует только на старых процессорах Intel (например, Ivy Bridge). Описанного эффекта не наблюдается на моделях процессоров новее, чем Haswell. И даже на процессорах Sandy/Ivy Bridge эту проблему нечасто можно встретить в реальных бенчмарках. Но в любом случае о таких эффектах знать полезно, поскольку они могут непредсказуемым образом изменить показатели производительности. Не зная об этом, легко прийти к неверным выводам.

## Практический пример 3: расщепление кэш-строки

Вот еще один пример, относящийся к кэшу процессора. На этот раз обсудим его в контексте размещения данных.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
[StructLayout(LayoutKind.Explicit, Pack = 8)]
public struct MyStruct
{
    [FieldOffset(0x04)] public ulong X0;
    [FieldOffset(0x0C)] public ulong X1;
    [FieldOffset(0x14)] public ulong X2;
    [FieldOffset(0x1C)] public ulong X3;
    [FieldOffset(0x24)] public ulong X4;
    [FieldOffset(0x2C)] public ulong X5;
    [FieldOffset(0x34)] public ulong X6;
    [FieldOffset(0x3C)] public ulong X7;
}

public unsafe class Benchmarks
{
    private int N = 1000;

    public void Run(int offset)
    {
        var myStruct = new MyStruct();
        if ((long) &myStruct.X0 % 64 == offset)
        {
            for (int i = 0; i < N; i++)
                myStruct.X0++;
        }
        else if ((long) &myStruct.X1 % 64 == offset)
        {
            for (int i = 0; i < N; i++)
                myStruct.X1++;
        }
        else if ((long) &myStruct.X2 % 64 == offset)
        {
            for (int i = 0; i < N; i++)
                myStruct.X2++;
        }
        else if ((long) &myStruct.X3 % 64 == offset)
        {

```

```

    for (int i = 0; i < N; i++)
        myStruct.X3++;
}
else if ((long) &myStruct.X4 % 64 == offset)
{
    for (int i = 0; i < N; i++)
        myStruct.X4++;
}
else if ((long) &myStruct.X5 % 64 == offset)
{
    for (int i = 0; i < N; i++)
        myStruct.X5++;
}
else if ((long) &myStruct.X6 % 64 == offset)
{
    for (int i = 0; i < N; i++)
        myStruct.X6++;
}
else if ((long) &myStruct.X7 % 64 == offset)
{
    for (int i = 0; i < N; i++)
        myStruct.X7++;
}
}

[Benchmark(Baseline = true)]
public void InsideCacheLine() => Run(4);

[Benchmark]
public void CacheSplit() => Run(60);
}

```

У нас есть тип значений `MyStruct` с явным отображением. Он содержит восемь полей `ulong` со следующими относительными адресами: `0x04`, `0x0C`, `0x14`, `0x1C`, `0x24`, `0x2C`, `0x34` и `0x3C`. В этом случае .NET Framework разместит данную структуру по 8 байт, то есть одно поле точно будет располагаться на границе двух кэш-строк. Метод `Run` использует переменную `offset` и находит поле с адресом, соответствующим условию «остаток после деления адреса на 64 должен быть равен `offset`». Далее он увеличивает это поле `N` раз.

Также у нас есть два бенчмарка, `InsideCacheLine` и `CacheSplit`. Бенчмарк `InsideCacheLine` вызывает `Run(4)`, что означает увеличение поля, находящегося внутри кэш-строки. Бенчмарк `CacheSplit` вызывает `Run(60)`, что означает увеличение поля на границе двух кэш-строк: первые четыре байта этого поля размещены в конце одной строки, а последние два — в начале другой.

## Результаты

Вот пример результатов на Skylake (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, RyuJIT-x64 v4.7.3260):

Method	Mean	StdDev	Ratio
InsideCacheLine	1.630 us	0.0063 us	1.00
CacheSplit	3.041 us	0.0089 us	1.87

Как видите, бенчмарк `CacheSplit` работает значительно медленнее, чем `InsideCacheLine`.

## Объяснение

Объяснение можно найти в [Intel OptManual], 3.6.4 «Размещение»:

«Доступ к неверно размещенным данным может вызвать значительное ухудшение производительности, особенно в случае расщепления кэш-строк. Объем кэш-строки в Pentium 4 и других недавно выпущенных процессорах Intel, включая основанные на микроархитектуре Intel Core, составляет 64 байта.

Доступ к данным, не выровненным в 64-байтных границах, ведет к двум операциям доступа к памяти и требует выполнения нескольких микроопераций (вместо одной). Доступ, выходящий за 64-байтные границы, скорее всего, приведет к сильному ухудшению производительности, особенно на устройствах с более длительной конвейерной обработкой».

## Обсуждение

Расщепление кэш-строк — еще один эффект, способный повлиять на производительность приложения непредсказуемым образом. В большинстве бенчмарков этих проблем не будет, поскольку данные обычно правильно размещаются с помощью .NET Runtime. Однако нужно быть внимательными при изменении отображения структур вручную или написании небезопасного кода.

Много дополнительной информации по этой теме есть в [Intel OptManual].

## Практический пример 4: альтернативное именование 4К

Альтернативное именование 4К — весьма интересный феномен, способный повлиять на измерения. Так происходит, если мы сохраняем значение в одну локацию памяти и загружаем другое значение из другой локации памяти с разницей между этими локациями 4096 байт. Приведу пример подобной ситуации.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
    private readonly byte[] data = new byte[32 * 1024 * 1024];
    private readonly int baseOffset;

    public Benchmarks()
    {
        GCHandle handle = GCHandle.Alloc(data, GCHandleType.Pinned);
        IntPtr addrOfPinnedObject = handle.AddrOfPinnedObject();
        long address = addrOfPinnedObject.ToInt64();
        const int align = 4 * 1024; // 4 KB
        baseOffset = (int) (align - address % align);
    }

    [Params(0, 1)]
    public int SrcOffset;

    [Params(
        -65, -64, -63, -34, -33, -32, -31, -3, -2, -1,
        0, 1, 2, 30, 31, 32, 33, 34, 63, 64, 65, 66)]
    public int StrideOffset;

    [Benchmark]
    public void ArrayCopy() => Array.Copy(
        sourceArray: data,
        sourceIndex: baseOffset + SrcOffset,
        destinationArray: data,
        destinationIndex: baseOffset + SrcOffset +
            24 * 1024 + // 24 KB
            StrideOffset,
        length: 16 * 1024 // 16 KB
    );
}
```

У нас есть бенчмарк `ArrayCopy`, копирующий 16 Кбайт из одной локации массива в другую. В конструкторе объекта мы закрепляем копию массива и запрещаем системе очистки диска перемещать его. Также вычисляем адрес массива и находим индекс `baseOffset`, размещенный в соответствии с 4-килобайтной границей. Параметр `SrcOffset` контролирует размещение исходных данных (`sourceIndex` равен `baseOffset + SrcOffset`). Параметр `StrideOffset` контролирует размещение адреса пункта назначения (`destinationIndex` равен `baseOffset + SrcOffset + 24 * 1024 + StrideOffset`, то есть разница между `destinationIndex` и `sourceIndex` составляет `24 * 1024 + StrideOffset`).

## Результаты

Вот пример результатов на Haswell (Windows 10.0.17134.523, Intel Core i7-4702MQ CPU 2.20GHz, .NET Framework 4.7.2, RyuJIT-x64 v4.7.3260):

SrcOffset	StrideOffset	Mean	StdDev
0	-65	401.8 ns	4.727 ns
0	-64	335.2 ns	32.741 ns
0	-63	447.8 ns	29.978 ns
0	-34	502.1 ns	35.900 ns
0	-33	482.4 ns	30.916 ns
0	-32	369.1 ns	18.939 ns
0	-31	481.8 ns	27.200 ns
0	-3	487.4 ns	21.360 ns
0	-2	476.2 ns	25.476 ns
0	-1	496.1 ns	21.471 ns
0	0	364.3 ns	28.113 ns
0	1	1,184.3 ns	2.415 ns
0	2	1,224.3 ns	2.339 ns
0	30	2,079.1 ns	5.735 ns
0	31	1,197.0 ns	2.367 ns
0	32	315.5 ns	3.046 ns
0	33	1,117.5 ns	2.957 ns
0	34	1,150.7 ns	2.149 ns
0	63	1,106.0 ns	2.494 ns
0	64	317.4 ns	3.952 ns
0	65	881.8 ns	6.027 ns
0	66	856.9 ns	2.421 ns
1	-65	333.1 ns	3.071 ns
1	-64	434.8 ns	5.049 ns
1	-63	445.0 ns	3.903 ns
1	-34	436.0 ns	3.135 ns
1	-33	318.3 ns	2.898 ns
1	-32	444.9 ns	2.463 ns
1	-31	443.4 ns	6.471 ns
1	-3	417.3 ns	2.362 ns
1	-2	422.7 ns	2.393 ns
1	-1	357.7 ns	9.241 ns
1	0	430.4 ns	4.918 ns
1	1	1,020.1 ns	2.329 ns
1	2	1,015.7 ns	2.179 ns
1	30	1,021.5 ns	2.753 ns
1	31	412.8 ns	6.160 ns
1	32	834.7 ns	3.752 ns
1	33	709.2 ns	11.557 ns
1	34	708.8 ns	1.318 ns
1	63	608.8 ns	8.753 ns
1	64	663.9 ns	1.496 ns
1	65	625.9 ns	5.878 ns
1	66	648.8 ns	7.477 ns

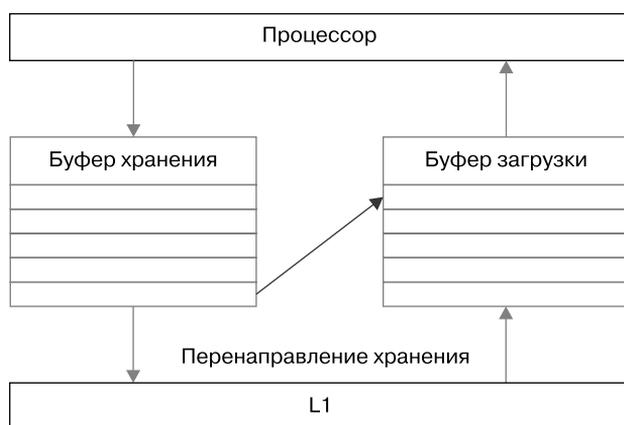
Таблица приведена для всех значений параметров, поскольку содержит много интересных эффектов, связанных с размещением: мы получили десятки разных показателей производительности одних и тех же операций, просто перемещающих 16 Кбайт памяти. Вы можете взять эту таблицу или построить такую же на собственном устройстве и попытаться объяснить результаты. В данном разделе мы сфокусируемся на небольшом фрагменте:

SrcOffset	StrideOffset	Mean	StdDev
0	-1	496.1 ns	21.471 ns
0	0	364.3 ns	28.113 ns
0	1	1,184.3 ns	2.415 ns
0	2	1,224.3 ns	2.339 ns
0	30	2,079.1 ns	5.735 ns
0	31	1,197.0 ns	2.367 ns
0	32	315.5 ns	3.046 ns

Как видите, мы получили чрезвычайно высокие показатели для значений `StrideOffset` от 1 до 31. В других фрагментах изначальной таблицы (например, для значений `StrideOffset` от -31 до 1) показатели не так высоки, то есть это связано не просто с доступом к невыровненным данным в памяти — мы наблюдаем более значительный эффект.

## Объяснение

При выполнении операций чтения/записи с памятью кэш процессора используется в качестве промежуточного хранилища данных. Однако между регистрами и процессором есть еще один уровень, показанный на рис. 8.5.



**Рис. 8.5.** Буфер хранения, буфер загрузки и перенаправление хранения

Представьте команду, перемещающую данные из регистров в кэш процессора. Она выполняет действие, занимающее какое-то время, — процессор не может переместить данные мгновенно. Однако бессмысленно ждать окончания перемещения, чтобы процессор мог начать выполнять следующую команду. Вместо этого значение регистра размещается в специальном *буфере хранения*. Затем можно начать выполнение следующей команды, пока процессор перемещает значения из буфера хранения в кэш процессора.

Тот же подход применяется и для получения данных из кэша процессора: вместо того чтобы ждать, пока данные переместятся из кэша в регистры процессора, мы загружаем данные заранее с помощью *буфера загрузки*.

Теперь представьте ситуацию, когда мы записываем значение в память и сразу же его читаем. В этом случае буферы хранения и загрузки могут вызывать значительную задержку, поскольку нужно ждать, пока значение переместится из регистра в кэш процессора с помощью буфера хранения, а потом обратно. Только после этого его можно использовать. К счастью, эта проблема уже решена с помощью *перенаправления хранения*. Этот механизм позволяет перемещать значения из буфера хранения в буфер загрузки в обход кэша процессора!

Чтобы перенаправление хранения стало эффективным, процессор должен очень быстро понимать, что нужное значение находится в буфере хранения. Поскольку нумерация этого буфера каждый раз будет занимать какое-то время, процессор использует небольшую хешированную таблицу для значений из буфера, где хешем являются последние значимые 12 бит адреса этого значения (в процессоре от Intel). Как вы думаете, что случится в случае пересечения хешей?

Теперь мы готовы прочитать об альтернативном именовании 4К в [Intel OptManual], 11.8 «Альтернативное именование 4К»:

«Альтернативное именование 4-килобайтной памяти происходит, когда код хранится в одной локации памяти и сразу же загружается из другой локации памяти с разницей между ними 4 Кбайт. Например, загрузка на линейный адрес 0x400020 происходит сразу после сохранения на линейный адрес 0x401020.

Пятый — одиннадцатый биты адресов загрузки и хранения одинаковы, и доступные относительные адреса частично или полностью пересекаются.

Альтернативное именование 4К может замедлить загрузку на пять циклов. Это ухудшение может быть значительным, если оно возникает повторно, а загрузка происходит на постоянно используемом участке. Если загрузка охватывает две кэш-строки, она может быть задержана до того момента, пока значения с конфликтом из хранения не будут загружены в кэш. Таким образом, альтернативное именование 4К, происходящее с повторными невыровненными загрузками на Intel AVX, вызывает сильное ухудшение производительности.

Для определения альтернативного именованния 4К используйте событие `LD_BLOCKS_PARTIAL.ADDRESS_ALIAS`, подсчитывающее количество случаев, когда загрузки Intel AVX были заблокированы из-за него.

Для решения проблемы альтернативного именованния 4К попробуйте следующие приемы в таком порядке.

- Размещать данные на 32 байтах.
- Изменить разницу между буфером входящих и буфером исходящих (если возможно).
- Использовать 16-байтный доступ для памяти, не размещенной на 32 байтах».

Альтернативное именованние 4К объясняет выделенный фрагмент из таблицы результатов. Разница между исходным и конечным адресами равна  $24 * 1024 + \text{StrideOffset}$ . Когда значение `StrideOffset` относится к интервалу 1...31, мы получаем ситуацию, которую точно описывает цитата из руководства Intel.

## Обсуждение

Альтернативное именованние 4К не влияет на большинство бенчмарков, но этот эффект может быть очень важен при копировании фрагментов из одной локации в другую.

Интересные примеры перенаправления хранения и альтернативного именованния 4К можно найти в [Lemire, 2018], [Wong, 2014], [Bakhvalov, 2018] и JDK-8150730 (<https://bugs.openjdk.java.net/browse/JDK-8150730>).

## Подводя итог

В этом разделе мы обсудили несколько проблем в области производительности, связанных с размещением данных.

- **Размещение структур.**

При обработке массива структур производительность зависит *от размещения и объема каждой копии структуры*. Стратегия отображения зависит от атрибутов `[StructLayout]` и `[FieldOffset]` и версии среды исполнения.

- **Конфликты кэш-банков.**

Конфликт банков происходит, если у *двух одновременных* операций загрузки *совпадают* 2–5-й биты их линейного адреса, но они *из разных наборов в кэше* (6–12-й биты). Эта проблема актуальна для *Sandy Bridge* и *Ivy Bridge*, но при использовании *Haswell* и последующих микроархитектур процессора от Intel о ней волноваться не стоит.

- **Расщепление кэш-строк.**

Расщепление кэш-строк возникает при выполнении операций чтения/записи с данными, не выровненными в 64-байтных границах.

- **Альтернативное именование 4К.**

Альтернативное именование 4К происходит, когда код сохраняется в одну локацию памяти и сразу после этого загружается из другой *с разницей между ними 4 Кбайт*.

Об этих эффектах нужно помнить в ходе работы со структурами, написания небезопасного кода или копирования объемных фрагментов.

## Сборщик мусора

Сборка мусора — обширная и весьма интересная тема. Если вы хотите изучить ее подробно, я рекомендую прочесть [Jones, 2016] и [Kokosa, 2018a]. В этом разделе обсудим лишь *некоторые аспекты*, полезные с точки зрения бенчмаркинга, и рассмотрим соответствующие эффекты с помощью небольших примеров. Вы также найдете много полезных ссылок, которые помогут больше узнать о сборке мусора в разных средах исполнения.

## Практический пример 1: режимы сборки мусора

В .NET Framework и .NET Core есть несколько вариантов конфигурации поведения сборщика мусора. Одна из важнейших опций — переключение между режимами Сервер и Рабочая станция. Проверим, как эта настройка может повлиять на измерения.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
[Config(typeof(Config))]
[MemoryDiagnoser]
public class Benchmarks
{
    private class Config : ManualConfig
    {
        public Config()
        {
            Add(Job.Default.WithGcServer(true).WithId("Server"));
        }
    }
}
```

```

        Add(Job.Default.WithGcServer(false).WithId("Workstation"));
    }
}

[Benchmark]
public byte[] Heap()
{
    return new byte[10 * 1024];
}

[Benchmark]
public unsafe void Stackalloc()
{
    var array = stackalloc byte[10 * 1024];
    Consume(array);
}

[MethodImpl(MethodImplOptions.NoInlining)]
private static unsafe void Consume(byte* input)
{
}
}

```

У нас есть два бенчмарка: `Heap`, размещающий 10 Кбайт в управляемой области динамической памяти, и `Stackalloc`, размещающий 10 Кбайт в стеке. Бенчмарк `Stackalloc` использует пустой метод `Consume`, помеченный атрибутом `[MethodImpl(MethodImplOptions.NoInlining)]` для предотвращения DCE.

У нас также есть механизмы `Server` и `Workstation`, ответственные за выполнение этих бенчмарков в соответствующих режимах сборки мусора.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, RyuJIT-x64 v4.7.3260):

Method	Job	Mean	StdDev	Gen 0
Heap	Server	745.193 ns	22.7130 ns	0.1917
Stackalloc	Server	4.531 ns	0.0920 ns	-
Heap	Workstation	480.974 ns	7.3521 ns	3.2673
Stackalloc	Workstation	4.425 ns	0.0537 ns	-

Графа `Gen 0` показывает количество циклов очистки программы поколения 0 на 1000 операций.

Как видите, бенчмарк `Heap` работает гораздо медленнее в режиме `Server`, чем в режиме `Workstation`. При этом эти настройки никак не влияют на бенчмарк `Stackalloc`.

## Объяснение

Режим сборки мусора *Workstation* разработан для интерактивных приложений пользовательского интерфейса, которые должны быстро реагировать. В этом режиме производится много коротких операций сборки мусора: среда исполнения пытается избежать долгих пауз на сборку, которые могут привести к зависанию интерфейса.

Режим сборки мусора *Server* разработан для серверных приложений, от которых требуется максимальная выработка. В этом режиме выполняется немного длинных операций сборки: среда исполнения не беспокоится о долгих паузах.

В бенчмарке *Heap* гораздо больше операций сборки мусора поколения 0 в режиме *Workstation*. Паузы на сборку довольно короткие, и они не так сильно ухудшают среднюю производительность, как в режиме *Server*.

Стоит отметить, что правильно измерить производительность методов, размещающих много объектов, не всегда просто. Эти размещения могут показаться «кредитом производительности»: само размещение обрабатывается довольно быстро, но в будущем, при сборке мусора, за него придется платить. Эти «выплаты» сильно зависят от выбранных настроек среды исполнения и сборщика мусора.

Распространенной проблемой при написании бенчмарков вручную является исключение времени сборки мусора из измерений. Вы легко можете попасть в такую ситуацию, если остановите измерения до того, как сборщик мусора начнет собирать объекты, размещенные бенчмарком. Не стоит недооценивать длительность пауз на сборку мусора. Некоторые из них могут занимать 1 мин (см. [Lemarchand, 2018]) и даже 15 мин (см. [Kokosa, 2018b])! Общий совет прост: если в вашем бенчмарке слишком много размещений, нужно делать больше итераций! В этом случае в метрики производительности будет включено среднее влияние сборки мусора. В то же время в действительности вы можете улучшить производительность, поскольку сборка мусора может происходить за пределами метода. Это не означает, что о ней не стоит беспокоиться, — она по-прежнему влияет на производительность. Вам все равно придется «выплачивать кредит производительности», но это можно будет сделать после завершения измерений метода.

В бенчмарке *Heap* реальная длительность размещения объектов приблизительно одинакова для обоих режимов сборки мусора. Разница в показателях видна из-за операций сборки, происходящих в ходе бенчмаркинга. В то же время бенчмарк *Stackalloc* не размещает ничего в управляемой области динамической памяти (в графе *Gen 0* стоит «-»), поэтому на него и не влияют режимы сборки мусора.

## Обсуждение

Представляем список самых популярных настроек, которые можно изменить.

- **gcServer** — определяет, нужно ли CLR запускать серверную или клиентскую сборку мусора. Значение по умолчанию `false` для приложений для Рабочего стола и `true` для приложений ASP.NET.
- **GcConcurrent** — определяет, нужно ли CLR запускать сборку мусора отдельным потоком (или потоками) параллельно с потоками приложения. Значение по умолчанию — `true`.
- **GCcpuGroup** — определяет, поддерживает ли сборка мусора несколько групп процессоров. Если у компьютера несколько групп процессоров и включена серверная сборка мусора, включение этого элемента распространяет ее на все группы процессоров и принимает во внимание все ядра при создании и стабилизации областей динамической памяти. Значение по умолчанию — `false`.
- **GcAllowVeryLargeObjects** — на 64-битных платформах разрешает использование массивов общим объемом более 2 Гбайт. Значение по умолчанию — `false`.
- **GCHeapCount** — желаемое количество куч для сборки мусора на сервере. Значение по умолчанию — `0`, то есть не указано.

В приложениях на .NET Framework все эти настройки можно контролировать с помощью `app.config`. Вот пример конфигурации:

```
<configuration>
  <runtime>
    <gcServer enabled="true"/>
    <gcConcurrent enabled="true"/>
    <GCcpuGroup enabled="true"/>
    <gcAllowVeryLargeObjects enabled="true"/>
    <GCHeapCount enabled="6"/>
  </runtime>
</configuration>
```

В .NET Core можно указать эти значения с помощью файла `runtimeconfig.json`<sup>1</sup> или переменных окружения `COMPLUS_*`. Можно также указать много дополнительных опций, например наименьший размер объектов поколения 0 (`GCgen0size`) или размер сегмента области динамической памяти (`GCsegmentSize`) (<https://github.com/dotnet/coreclr/blob/v2.2.2/src/gc/gcconfig.h>).

Много полезной информации о сборке мусора в .NET Framework и .NET Core можно найти в [Kokosa, 2018a] (глава 11) и [MSDOCS GC Fundamentals].

<sup>1</sup> См.: <https://github.com/dotnet/cli/blob/v2.2.104/Documentation/specs/runtimeconfiguration-file.md>.

## Практический пример 2: объем «инкубатора» в Mono

У Mono есть собственная реализация сборщика мусора. Первые версии Mono использовали программу *Boehm* (Boehm — Demers — Weiser). Это классический консервативный сборщик мусора на C/C++. Он был неэффективен для приложений .NET, поэтому, начиная с Mono 2.8, его решили заменить на SGen — программу, учитывающую поколения объектов. SGen является сборщиком мусора по умолчанию, начиная с версии Mono 3.2. Его подробное описание приведено в [MONODOCS Sgen].

Главное, что вы должны понять: механизмы сборки мусора в .NET Framework/.NET Core и Mono абсолютно различные. Поэтому нельзя применять наблюдения за одним из них ко всей платформе .NET. Например, SGen использует два основных поколения сборщиков мусора (в отличие от .NET Framework/.NET Core, имеющих три): *младшее* («инкубатор») и *старшее*. В нем также много настроек, которые можно конфигурировать. Например, можно настроить объем поколения «инкубатора». Проверим, как это может повлиять на измерения.

### Исходный код

Рассмотрим следующий бенчмарк на базе BenchmarkDotNet:

```
[Config(typeof(Config))]
[MemoryDiagnoser]
public class Benchmarks
{
    private class Config : ManualConfig
    {
        public Config()
        {
            Add(Job.Mono
                .With(new[] {new EnvironmentVariable(
                    "MONO_GC_PARAMS", "nursery-size=1m")})
                .WithId("Nursery=1MB"));
            Add(Job.Mono
                .With(new[] {new EnvironmentVariable(
                    "MONO_GC_PARAMS", "nursery-size=4m")})
                .WithId("Nursery=4MB"));
        }
    }

    [Benchmark]
    public byte[] Heap()
    {
        return new byte[10 * 1024];
    }
}
```

У нас есть всего один бенчмарк, размещающий 10 Кбайт в управляемой области динамической памяти. Также есть два алгоритма, выполняющие этот бенчмарк с разными объемами «инкубатора»: 1 и 4 Мбайт.

## Результаты

Посмотрите на следующие результаты (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, Mono 5.18):

Job	Mean	StdDev	Gen 0
Nursery=1MB	6.058 us	0.0321 us	2.3193
Nursery=4MB	7.669 us	0.0473 us	0.5951

Графа Gen 0 показывает количество циклов сборки мусора поколения 0 на 1000 операций.

Как видите, Nursery=1MB работает быстрее, чем Nursery=4MB.

## Объяснение

Любое изменение настроек сборки мусора с большой вероятностью каким-то образом повлияет на показатели бенчмарка, *размещающего* объект. Но сделать какие-либо общие выводы о наилучших значениях настроек для всех приложений невозможно.

Объем поколения-«инкубатора» в Mono 5.18 равняется 4 Мбайт. Как видите, для нашего бенчмарка, размещающего всего 10 Кбайт памяти, лучшим значением кажется 1 Мбайт. Но это не означает, что 1 Мбайт — наилучшее значение для других приложений. Например, в [Akinshin, 2018] можно найти рассказ о том, как я изменил объем с 4 на 64 Мбайт и *увеличил* время загрузки Rider вдвое на Linux и macOS.

## Обсуждение

Вы можете указать разные параметры SGen с помощью переменной окружения MONO\_GC\_PARAMS (все параметры объединены в одну строку с помощью запятых). Представляем вам список некоторых параметров SGen в Mono 5.18 (актуальный список для вашей версии Mono можно найти с помощью `man mono`).

- `max-heap-size=size` — устанавливает максимальный размер области динамической памяти.
- `nursery-size=size` — устанавливает объем поколения-«инкубатора».
- `major=collector` — указывает, какой основной сборщик мусора использовать. Доступные варианты — `marksweep` (программа Mark&Sweep), `marksweep-conc`

(многопоточный Mark&Sweep) и `marksweep-conc-par` (параллельный и многопоточный Mark&Sweep).

- `mode=balanced|throughput|pause[:max-pause]` — указывает, что должно быть целью сборщика мусора.
- `soft-heap-limit=size` — когда размер области динамической памяти становится больше этого значения, игнорирует требования триггерных метрик сборки мусора и разрешает использование только четырех «инкубаторных» размеров роста основной области динамической памяти между базовыми операциями сборки.
- `evacuation-threshold=threshold` — устанавливает порог эвакуации в процентах.
- `(no-)lazy-sweep` — включает и выключает ленивую сборку мусора в программе Mark&Sweep.
- `(no-)concurrent-sweep` — включает и выключает многопоточную сборку мусора в программе Mark&Sweep.
- `stack-mark=mark-mode` — указывает, как нужно сканировать потоки приложения. Режимы — `precise` и `conservative`.
- `save-target-ratio=ratio` — указывает нужную пропорцию сохранения для основного сборщика мусора.
- `default-allowance-ratio=ratio` — указывает допустимое отклонение при размещении по умолчанию, если вычисленный размер слишком мал.
- `minor=minor-collector` — указывает, какую младшую версию программы применять.
- `alloc-ratio=ratio` — указывает, какая часть памяти из «инкубатора» будет использоваться в пространстве размещения.
- `promotion-age=age` — указывает возраст, которого должен достичь объект в «инкубаторе», чтобы считаться старым поколением.
- `allow-synchronous-major` — запрещает основному сборщику мусора выполнять синхронные операции сборки.

В реализации SGen много весьма интересных функций. Например, поколение «инкубатор» состоит из слотов фиксированного размера. Так выглядит определенное заранее указанного размера в Mono 5.18<sup>1</sup>:

```
#if SIZEOF_VOID_P == 4
static const int allocator_sizes [] = {
    8,   16,   24,   32,   40,   48,   64,   80,
    96,  124,  160,  192,  224,  252,  292,  340,
    408,  452,  508,  584,  680,  816,  1020,
    1364, 2044, 2728, 4092, 5460, 8188 };
```

<sup>1</sup> Полный исходный код можно найти здесь: <https://github.com/mono/mono/blob/mono-5.18.0.245/mono/sgen/sgen-internal.c#L38>.

```
#else
static const int allocator_sizes [] = {
    8,    16,    24,    32,    40,    48,    64,    80,
    96,   128,   160,   192,   224,   248,   288,   336,
    368,  448,  504,  584,  680,  816,  1016,
    1360, 2040, 2728, 4088, 5456, 8184 };
#endif
```

Таким образом, если создать в x64 объект, которому нужно 2729 байт, будет использоваться 4088-байтный слот, потому что это минимальный возможный слот, вмещающий подобный объект. Если вы хотите отслеживать и мониторить трафик памяти, то должны знать такие подробности, иначе не сможете сразу интерпретировать показатели.

Если вы хотите получить метрики производительности для разных режимов сборки мусора, можно запустить `mono` с аргументом `-stats`: он выдаст много полезной статистики по программе сборки.

## Практический пример 3: области динамической памяти для крупных объектов

В .NET Framework и .NET Core существует два вида областей динамической памяти:

- для небольших объектов (SOH) — меньше 85 000 байт;
- для крупных объектов (LOH)<sup>1</sup> — больше или равных 85 000 байтам.

Говоря о поколениях сборщиков мусора, мы обычно имеем в виду SOH. Но нельзя забывать и о LOH, имеющих собственные правила управления памятью. Приведу еще один пример, иллюстрирующий влияние работы с объектами LOH на производительность.

### Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
[MemoryDiagnoser]
public class Benchmarks
{
    [Benchmark]
    public byte[] Allocate84900()
    {
```

<sup>1</sup> См.: <https://docs.microsoft.com/en-us/dotnet/standard/garbage-collection/large-object-heap>.

```

    return new byte[84900];
}

[Benchmark]
public byte[] Allocate85000()
{
    return new byte[85000];
}
}

```

У нас есть два бенчмарка: `Allocate84900`, размещающий 84 900 байт, и `Allocate85000`, размещающий 85 000 байт.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, RyuJIT-x64 v4.7.3260):

Method	Mean	StdDev	Gen 0	Gen 1	Gen 2
Allocate84900	3.017 us	0.0216 us	26.313	-	-
Allocate85000	4.511 us	0.0362 us	27.023	27.023	27.023

Графы `Gen 0`, `Gen 1` и `Gen 2` показывают количество циклов сборки мусора поколений 0, 1 и 2 соответственно на 1000 операций. Как видите, `Allocate85000` работает в 1,5 раза медленнее, чем `Allocate84900`. Также у `Allocate85000` есть операции сборки мусора поколений 1 и 2, в отличие от `Allocate84900`.

## Объяснение

Концепция ЛОН появилась из-за того, что перемещение объектов во время сборки мусора — это объемная операция. По умолчанию сборка мусора не касается объектов ЛОН, то есть не перемещает их<sup>1</sup>. Это разумное решение в случае приложений, работающих с большим количеством объемных массивов: оно снижает ограничения сборки мусора в случае сложного размещения. Однако оно может ухудшить производительность в простых случаях вроде данного бенчмарка, поскольку запускает сложные техники сборки мусора. `Allocate84900` работает быстро, так как в процессе сборки мусора могут быть собраны все размещенные объекты в поколении 0. `Allocate85000` работает медленнее, потому что сборщику нужно собрать следующие поколения (все размещенные объекты находятся в ЛОН, а не в поколении 0).

<sup>1</sup> Начиная с версий .NET Framework 4.5.1 и .NET Core 1.0, стало возможно заставить сборщик мусора включать в себя ЛОН с помощью `GCSettings.LargeObjectHeapCompactionMode`. Дополнительную информацию по этой теме можно найти в официальной документации: <https://docs.microsoft.com/en-us/dotnet/api/system.runtime.gcsettings.largeobjectheapcompactionmode>.

## Обсуждение

В целом я не рекомендую использовать на практике знание таких эвристических правил. Однако константа 85 000 становится настолько фундаментальной, что ее начали применять для разных правил оптимизации во многих приложениях. Например, эту магическую константу можно найти даже в реализации стандартных классов<sup>1</sup>.

У LON есть одно интересное исключение — массивы `double` в 32-битной среде исполнения. Приведу высказывание Абхишека Мондала из [Gray, 2011]: «В 32-битной архитектуре механизм исполнения CLR пытается разместить эти массивы с более чем 1000 переменных `double` в LON из-за того, что доступ к ним обеспечит улучшение производительности. Но применение тех же эвристических правил в 64-битной архитектуре преимуществ не даст, поскольку переменные уже размещены в границах 8 байт. Поэтому в .NET 4.5 мы убрали эти правила для 64-битной архитектуры».

В Mono также есть концепция LON, известная как *пространство крупных объектов*. Его порог по умолчанию в Mono 5.18 составляет 8000 байт<sup>2</sup>.

Подробную информацию о LON можно найти в [Kokosa, 2018a] (глава 5, раздел «Структурирование размеров»), [Morter, 2013] и [Goldshtein, 2013].

## Практический пример 4: финализация

Последнее понятие, связанное со сборкой мусора, которое мы обсудим, — это финализация. В .NET у каждого объекта может быть *финализатор* (*finalizer*), исполняемый специальным потоком для финализации после стадии сборки мусора. Эта техника может пригодиться, если у вас есть ресурсы, которыми вы не управляете и которые хотите удалить с помощью сборщика мусора. Однако алгоритмы завершения серьезно воздействуют на производительность этих программ. Проверим, как они могут повлиять на наши показатели.

## Исходный код

Рассмотрим следующие бенчмарки на базе BenchmarkDotNet:

```
public class Benchmarks
{
```

<sup>1</sup> Примеры можно увидеть здесь: <https://github.com/dotnet/corefx/blob/v2.2.1/src/Common/src/CoreLib/System/Text/StringBuilder.cs#L73>.

<sup>2</sup> См.: <https://github.com/mono/mono/blob/mono-5.18.0.245/mono/sgen/sgen-conf.h#L161>.

```

public class ClassWithoutFinalizer
{
}

public class ClassWithFinalizer
{
    ~ClassWithFinalizer()
    {
    }
}

[Benchmark(Baseline = true)]
public object WithoutFinalizer()
{
    return new ClassWithoutFinalizer();
}

[Benchmark]
public object WithFinalizer()
{
    return new ClassWithFinalizer();
}
}

```

У нас есть два класса, `ClassWithoutFinalizer` (пустой) и `ClassWithFinalizer` (пустой класс с пустым финализатором). В двух заявленных бенчмарках (`WithoutFinalizer` и `WithFinalizer`) мы просто размещаем копии соответствующих классов.

## Результаты

Вот пример результатов (Windows 10.0.17763.195, Intel Core i7-6700HQ CPU 2.60GHz, .NET Framework 4.7.2, RyuJIT-x64 v4.7.3260):

Method	Mean	StdDev	Ratio
WithoutFinalizer	2.235 ns	0.0422 ns	1.00
WithFinalizer	153.198 ns	1.7301 ns	68.57

Как видите, `WithFinalizer` работает примерно в 70 раз медленнее, чем `WithoutFinalizer`!

## Объяснение

Это еще один пример того, как сборка мусора может повлиять на показатели производительности. В бенчмарке `withFinalizer` у сборщика мусора гораздо больше работы: он должен отследить все алгоритмы завершения и выполнить их. В данном примере этот алгоритм ничего не делает, но при этом сборщик мусора не может его пропустить.

## Обсуждение

Довольно сложно производить точные измерения, когда сборщик мусора собирает недостижимые объекты и исполняет алгоритмы завершения. Сборка мусора в .NET не детерминирована. Это означает, что проконтролировать точный момент исполнения этих алгоритмов невозможно. Но можно подождать, пока они все будут завершены. Вот самая распространенная схема последней сборки мусора:

```
GC.Collect();  
GC.WaitForPendingFinalizers();  
GC.Collect();
```

Мы очищаем память, ждем выполнения всех финализаторов и еще раз очищаем память (убираем все, что осталось после ликвидации). Эта схема может пригодиться, если вы хотите, чтобы сборка мусора в ранее размещенных объектах не влияла на новые измерения.

Этот пример основан на примере «Ограничение из-за финализации» из [Kokosa, 2018a] (см. рис. 12.11).

## Подводя итог

В этом разделе мы обсудили четыре практических примера, иллюстрирующих влияние сборки мусора на производительность приложения. Мы поговорили о разных режимах сборщиков мусора, размере поколения-«инкубатора» в Mono, LOH в .NET Framework и влиянии финализации на производительность.

При бенчмаркинге нужно помнить о следующем.

- Если вы размещаете объекты, сборка мусора повлияет на измерения.
- В общем случае нельзя контролировать сборку мусора и невозможно исключить ее ограничения из измерений. Это нормально: вам не нужно исключать их, поскольку это один из важнейших факторов производительности, влияющий на все управляемые приложения.
- Если у вас большое стандартное отклонение из-за недетерминированной сборки мусора, лучше всего будет увеличить количество итераций. Это поможет получить более стабильное влияние сборки мусора на измерения.
- Бенчмарки с большим трафиком памяти очень чувствительны к настройкам сборщика мусора. Переключение между разными режимами или изменение настроек может полностью изменить результаты бенчмарка.

Писать бенчмарки с большим количеством объектов, требующих размещения, не всегда просто, поскольку вы не можете контролировать тот момент, когда сборщик мусора решит, что вам пора «выплачивать кредит производительности».

Только знание внутреннего устройства программы поможет правильно интерпретировать результаты бенчмарка. В большинстве случаев достаточно знать общие понятия (влияние сборки мусора на измерения, поколения сборщиков мусора, LON, алгоритмы завершения, настройки). В некоторых случаях могут потребоваться глубинное знание внутреннего устройства (здесь я хочу снова порекомендовать [Kokosa, 2018a]) и качественные инструменты, которые помогут исследовать разные проблемы с памятью (например, PerfView или dotMemory).

## Выводы

В этой главе были освещены три темы, связанные с бенчмарками, ограниченными возможностями памяти.

- **Кэш процессора.**

При выполнении операций чтения/записи с основной памятью процессора можно их ускорить с помощью кэша процессора. Это может значительно повлиять на показатели производительности из-за разных схем доступа к памяти, размера и ассоциативности разных уровней кэша процессора и других эффектов, специфичных для кэша, например ложного разделения.

- **Схема размещения памяти.**

Размещение данных, которое не всегда возможно контролировать, также значительно влияет на производительность. Невыровненный доступ к памяти, конфликт кэш-банков, расщепление кэш-строк и альтернативное именование 4К могут испортить вам показатели в самый неожиданный момент.

- **Сборка мусора.**

Сборка мусора также может непредсказуемым образом повлиять на показатели производительности, поскольку она не детерминирована и в любой момент может добавить ограничения. Они зависят от настроек сборщика мусора (например, режима сервера/рабочей станции или размера «инкубатора» Mono) и функционала сборки (например, LON или финализации).

Знание этих свойств аппаратных средств и среды исполнения поможет вам лучше разрабатывать бенчмарки и анализировать их результаты. Главный совет по поводу таких бенчмарков: расширяйте исследование пространства производительности — нужно проверить разные размеры рабочей памяти, схемы доступа и размещения памяти, а также разные настройки сборщика мусора. Основываясь на этих конфигурациях, вы сможете сделать выводы, подходящие не только для конкретного бенчмарка, но и для других ситуаций. Правильное описание пространства производительности поможет экстраполировать эти результаты и предсказать метрики производительности реальных приложений, основываясь на отдельных бенчмарках.

## ИСТОЧНИКИ

[Akinshin, 2018] *Akinshin A.* Analyzing Distribution of Mono GC Collections. 2018. February 20. <https://aakinshin.net/posts/mono-gc-collects>.

[Bakhvalov, 2018] *Bakhvalov D.* Store Forwarding by Example. 2018. March 9. <https://dendibakh.github.io/blog/2018/03/09/Store-forwarding>.

[Bray, 2011] *Bray B.* Large Object Heap Improvements in .NET 4.5. 2011. October 3. <https://blogs.msdn.microsoft.com/dotnet/2011/10/03/large-objectheap-improvements-in-net-4-5/>.

[Dawson, 2018a] *Dawson B.* Zombie Processes Are Eating Your Memory // Random ASCII, 2018. <https://randomascii.wordpress.com/2018/02/11/zombieprocesses-are-eating-your-memory/>.

[Dawson, 2018b] *Dawson B.* 24-Core CPU and I Can't Type an Email (Part One) // Random ASCII, 2018. <https://randomascii.wordpress.com/2018/08/16/24-corecpu-and-i-cant-type-an-email-part-one/>.

[Douillet, 2018] *Douillet N.* Effects of CPU Caches. 2018. April 6. <https://medium.com/@minimarcel/effect-of-cpu-caches-57db81490a7f>.

[Drepper, 2007] *Drepper U.* What Every Programmer Should Know About Memory. Red Hat, Inc 11 (July): 2007. <https://people.freebsd.org/~lstewart/articles/cpumemory.pdf>.

[Goldshtein, 2013] *Goldshtein S.* On 'Stackalloc' Performance and the Large Object Heap. 2013. October 17. <http://blogs.microsoft.co.il/sasha/2013/10/17/onstackalloc-performance-and-the-large-object-heap/>.

[Goldshtein, 2016] *Goldshtein S.* Windows Process Memory Usage Demystified. 2016. January 5. <http://blogs.microsoft.co.il/sasha/2016/01/05/windowsprocess-memory-usage-demystified/>.

[Gregg, 2018] *Gregg B.* How to Measure the Working Set Size on Linux. 2018. January 17. [www.brendangregg.com/blog/2018-01-17/measure-working-set-size.html](http://www.brendangregg.com/blog/2018-01-17/measure-working-set-size.html).

[Hiroshi, 2015] *Inoue H., Taura K.* SIMD-and Cache-Friendly Algorithm for Sorting an Array of Structures // Proceedings of the VLDB Endowment 8 (11), 2015. VLDB Endowment: 1274–1285.

[Intel OptManual] Intel® 64 and IA-32 Architectures Optimization Reference Manual (248966-033). 2016. [www.intel.com/content/dam/www/public/us/en/documents/manuals/64-ia-32-architectures-optimization-manual.pdf](http://www.intel.com/content/dam/www/public/us/en/documents/manuals/64-ia-32-architectures-optimization-manual.pdf).

[Jainam M., 2017] *Jainam M.* Understanding False Sharing. 2017. March 17. <https://parallelcomputing2017.wordpress.com/2017/03/17/understanding-falshesharing/>.

[Jones, 2016] *Jones R., Hosking A., Moss E.* The Garbage Collection Handbook: The Art of Automatic Memory Management. Chapman; Hall/CRC, 2016.

[Kalapos, 2018] *Kalapos G.* Struct Layout in C# – .NET Concept of the Week – Episode 13. 2018. May 11. [https://kalapos.net/Blog/ShowPost/DotNetConceptOfTheWeek13\\_DotNetMemoryLayout](https://kalapos.net/Blog/ShowPost/DotNetConceptOfTheWeek13_DotNetMemoryLayout).

[Kokosa, 2018a] *Kokosa K.* Pro .NET Memory Management: For Better Code, Performance and Scalability. 1st ed. Apress, 2018. <https://prodotnetmemory.com/>.

[Kokosa, 2018b] *Kokosa K.* War Story – the Mystery of the Very Long GC Pauses in .NET Windows Service. 2018. December 13. <http://tooslowexception.com/scenario-mystery-of-the-very-long-gc-pauses-in-net-windows-service/>.

[Kulukundis, 2017] *Kulukundis M.* Designing a Fast, Efficient, Cache-Friendly Hash Table, Step by Step // Presented at the CppCon 2017. September 27. [www.youtube.com/watch?v=ncHmEUmJZf4](http://www.youtube.com/watch?v=ncHmEUmJZf4).

[Lemarchand, 2018] *Lemarchand R.* The Mysterious Case of the 1 Minute Pauses // Remi's World, 2018. <https://theonlinedebugger.blogspot.com/2018/11/themysterious-case-of-1-minute-pauses.html>.

[Lemirer, 2012] *Lemire D.* Data Alignment for Speed: Myth or Reality? 2012. May 31. <https://lemire.me/blog/2012/05/31/data-alignment-for-speed-myth-orreality/>.

[Lemirer, 2018] *Lemire D.* Don't Make It Appear Like You Are Reading Your Own Recent Writes. 2018. January 4. <https://lemire.me/blog/2018/01/04/dont-make-itappear-like-you-are-reading-your-own-recent-writes/>.

[Majkowski, 2018] *Majkowski M.* Every 7.8us Your Computer's Memory Has a Hiccup. 2018. November 23. <https://blog.cloudflare.com/every-7-8us-your-computersmemory-has-a-hiccup/>.

[Mendola, 2008] *Mendola G.* 2008. May 31. <http://cpp-today.blogspot.com/2008/05/false-sharing-hits-again.html>.

[MONODOCS SGen] Generational GC // Mono Docs. [www.mono-project.com/docs/advanced/garbage-collector/sgen/](http://www.mono-project.com/docs/advanced/garbage-collector/sgen/).

[Morter, 2013] *Morter C.* Large Object Heap Compaction: Should You Use It? 2013. October 2. [www.red-gate.com/simple-talk/dotnet/net-framework/large-objectheap-compaction-should-you-use-it/](http://www.red-gate.com/simple-talk/dotnet/net-framework/large-objectheap-compaction-should-you-use-it/).

[MSDOCS GC Fundamentals] Fundamentals of Garbage Collection // Microsoft Docs. <https://docs.microsoft.com/en-us/dotnet/standard/garbage-collection/fundamentals>.

---

[Sandler, 2008] *Sandler A.* Aligned Vs. Unaligned Memory Access. 2008. June 3. [www.alexonlinux.com/aligned-vs-unaligned-memory-access](http://www.alexonlinux.com/aligned-vs-unaligned-memory-access).

[Sumedh, 2013] *Sumedh.* Coding for Performance: Data Alignment and Structures. 2013. September 26. <https://software.intel.com/en-us/articles/codingfor-performance-data-alignment-and-structures>.

[Wakart, 2013] *Wakart N.* Using JMH to Benchmark Multi-Threaded Code. 2013. May 15. <http://psy-lob-saw.blogspot.com/2013/05/using-jmh-to-benchmarkmulti-threaded.html>.

[Wong, 2014] *Wong H.* Store-to-Load Forwarding and Memory Disambiguation in X86 Processors. 2014. January 9. <http://blog.stuffedcow.net/2014/01/x86-memory-disambiguation/>.

# 9

## Аппаратные и программные таймеры

Человек, у которого одни часы, знает, который час. Человек, у которого двое часов, никогда в этом не уверен.

*Закон Сигала*

Существует множество полезных инструментов для бенчмаркинга, которые могут упростить вам жизнь, но обычно их использование опционально. Применять их или нет — зависит от ваших предпочтений. Но один инструмент для бенчмаркинга необходим — *API для отметок времени* (методы, помогающие узнать текущее время). Нельзя написать бенчмарк без отметки времени. Очень важно понимать, какие API есть в вашей системе, каковы принципы их работы и основные свойства. Конечно же, можно создать бенчмарк и без этой информации. Однако глубинное понимание аппаратных и программных таймеров позволит вам разрабатывать более качественные бенчмарки, контролировать степень точности и избегать ошибок при проставлении отметок времени. В этой главе мы рассмотрим следующие темы.

- **Терминология.**

Вы узнаете основные термины, часто применяемые при обсуждении таймеров: единицы времени, единицы частоты, генератор тиков, погрешности дискретизации, разрешение, детализация, длительность, точность, корректность и т. д.

- **Аппаратные таймеры.**

Мы обсудим самые широко используемые аппаратные компоненты, способные проставлять отметки времени: TSC, ACPI PM и HPET. Речь пойдет об истории и внутреннем устройстве этих таймеров, о соответствующих низкоуровневых API для получения отметок времени и переключения между разными временными ресурсами.

- **API для проставления отметок времени в ОС.**

В операционных системах есть собственные API для проставления отметок времени, которые можно использовать на разных платформах для программирования, включая .NET. Вы узнаете, какие API существуют в Windows, Linux и macOS.

- **API для проставления отметок времени в .NET.**

Мы обсудим три основных API, которые можно применять в .NET Framework, .NET Core и Mono: `DateTime.UtcNow`, `Environment.TickCount`, `Stopwatch.GetTimestamp`. Узнаем, как их использовать, какова их внутренняя реализация и как измерить их разрешение и длительность.

- **Подводные камни при проставлении отметок времени.**

Мы обсудим самые распространенные ошибки, которые допускают разработчики при проставлении отметок времени в каждом из типов API для проставления отметок времени в .NET.

Я хочу быть уверенным в том, что мы говорим на одном языке, поэтому сначала обсудим некоторые термины.

## Терминология

В этой книге мы используем множество специфических терминов и обозначений. Иногда читатели в них путаются. В данном разделе кратко обсудим основные понятия:

- **единицы времени** — день, ч, мин, с, мс, мкс, нс, пс;
- **единицы частоты** — ТГц, ГГц, МГц, кГц, Гц, мГц, мкГц, нГц;
- **основные компоненты аппаратного таймера** — генератор тиков, счетчик тиков и API счетчика тиков;
- **погрешности тиков и дискретизации** — как компьютеры работают с дискретным временем;
- **основные характеристики таймера** — номинальная частота, реальная частота, номинальная обратная частота, номинальное разрешение, номинальная детализация, реальная обратная частота, реальное разрешение, реальная детализация, максимальное смещение частоты, длительность отметки времени, время доступа, ограничения таймера, точность, случайные искажения, корректность, систематическая погрешность.

Понимать все термины и обозначения очень важно.

## Единицы времени

Нельзя говорить о времени, не зная основных единиц, помогающих измерять временные интервалы. Надеюсь, вы понимаете, что такое *секунда* — это базовая единица времени Международной системы единиц (СИ). Точное определение секунды, данное Национальным институтом стандартов и технологий, звучит

так: «Секунда — время, равное 9 192 631 770 периодам излучения, соответствующего переходу между двумя сверхтонкими уровнями основного состояния атома цезия-133».

Разумеется, для бенчмаркинга помнить это определение не нужно. Достаточно обычного бытового понимания того, как подсчитывается время в повседневной жизни. Но если вам интересно, откуда взялось это определение (почему именно 9 192 631 770 и при чем тут атом цезия), и хочется узнать историю подсчета времени и связанные с ней технические понятия, стоит почитать [Jones, 2000].

В СИ существуют дополнительные временные единицы, часто используемые разработчиками программного обеспечения. Самые полезные из них (с соответствующими символами и эквивалентами в секундах) представлены в табл. 9.1.

**Таблица 9.1.** Единицы времени

Единица	Обозначение		Длительность, с
	Русское	Международное	
Сутки (день)	день	d (day)	86 400
Час	ч	h (hour)	3600
Минута	мин	m (min)	60
Секунда	с	s (sec)	1
Миллисекунда	мс	ms	$10^{-3}$
Микросекунда	мкс	us ( $\mu$ s)	$10^{-6}$
Наносекунда	нс	ns	$10^{-9}$
Пикосекунда	пс	ps	$10^{-12}$

Кто-то может подумать, что микросекунда, наносекунда и пикосекунда — очень маленькие единицы времени и в реальности они нам не нужны. Они действительно очень малы. Отношение пикосекунды к секунде такое же, как секунды к 31 710 годам! Но иногда в реальном ПО стоит беспокоиться и о маленьких единицах времени, например микросекундах (пример можно увидеть в [Cook, 2017]). При написании бенчмарков часто нужны наносекунды — это типичная единица времени для коротких фрагментов кода. Многие отдельные команды процессора занимают даже меньше 1 нс, поэтому пикосекунды также могут пригодиться.

Для обозначения времени и временных интервалов часто используются буквы  $t$  и  $T$ . То есть  $T = 5$  с может обозначать «временной интервал равен 5 секундам».

Есть пара моментов, в которых люди часто путаются.

- В научных работах, статьях, записях в блогах и других текстах на общие темы обычно используют термины *day*, *hour*, *min/minutes*, *sec/second*, которые широко распространены и всем понятны. В текстах, посвященных измерениям времени и производительности, мы для краткости часто применяем символы *d*, *h*, *m* и *s*.
- Стандартное международное обозначение СИ для микросекунд —  $\mu\text{s}$ . К сожалению, на обычной клавиатуре нет символа  $\mu^1$ . К тому же он может вызвать проблемы с кодировкой в некоторых текстовых редакторах. Поэтому разработчики часто используют обозначение *us*.

Существуют и неофициальные единицы времени, которые можно встретить в блогах:

- *мгновение (jiffy)* — короткий период времени неуточненной длины;
- *щелчок (flick)* (<https://github.com/OculusVR/Flicks>) — единица времени, введенная Oculus, 1 щелчок = 1/705 600 000 с.

Теперь поговорим о единицах частоты, которые легко выразить через единицы времени.

## Единицы частоты

Говоря о свойствах таймера, мы используем удобный термин «*частота*». Единицей частоты является *1 Гц* (Hz). Если частота какого-то события равна *n* герц, это значит, что оно происходит *n* раз в секунду. Таким образом,  $1 \text{ Гц} = 1/1 \text{ с} = 1 \text{ с}^{-1}$ . Каждой единице частоты соответствует временной период. Например, 20 Гц соответствуют 50 мс, поскольку

$$20 \text{ Гц} = \frac{20}{1 \text{ с}} = \frac{20}{1000 \text{ мс}} = \frac{1}{50 \text{ мс}}.$$

Некоторые дополнительные полезные единицы частоты и соответствующие им временные периоды представлены в табл. 9.2.

<sup>1</sup> Символ Unicode GREEK SMALL LETTER MU (U + 03BC), код ASCII 230. Его можно напечатать с помощью Alt + 230 в Windows, Option + m — в macOS, Ctrl + Shift + u00b5 — в Linux.

Таблица 9.2. Единицы частоты

Единица	Обозначение		Значение, Гц	Временной период
	Российское	Международное		
Терагерц	ТГц	THz	$10^{12}$	1 пс
Гигагерц	ГГц	GHz	$10^9$	1 нс
Мегагерц	МГц	MHz	$10^6$	1 мкс
Килогерц	кГц	kHz	$10^3$	1 мс
Герц	Гц	Hz	1	1 с
Миллигерц	мГц	mHz	$10^{-3}$	$10^3$ с
Микрогерц	мкГц	Uhz ( $\mu$ Hz)	$10^{-6}$	$10^6$ с
Наногерц	нГц	nHz	$10^{-9}$	$10^9$ с

Общепринятым обозначением частоты является буква  $f$ . Если нужно вычислить частоту какого-либо события, мы должны разделить количество событий на временной интервал, в который они происходили. Например, если что-то случается 42 раза в сутки, то его частота вычисляется так:

$$f = \frac{42}{1 \text{ день}} = \frac{42}{86400 \text{ с}} \approx 0,000486 \text{ с}^{-1} = 486 \text{ мкГц.}$$

Термин «частота» широко используется во многих физических и инженерных дисциплинах. Вот несколько известных примеров:

- человек может слышать звуки частотой между 20 Гц и 20 кГц;
- видимый спектр (та часть электромагнитного спектра, которая видима человеческому глазу) равен примерно 430... 779 ТГц. Диапазон частоты желтого цвета составляет примерно 508... 526 ТГц;
- 440 Гц — частота музыкальной ноты ля первой октавы (ля 440 (A440) — международный стандарт настройки музыкальных инструментов);
- При связи с подводными лодками используют крайне низкую частоту — 3... 30 Гц;
- коротковолновые радиостанции работают на частотах, относящихся к в диапазону 1,6... 30 МГц;
- частота микроволновки обычно около 2,45 ГГц;
- самые распространенные частоты Wi-Fi — около 2,4 ГГц (802.11b/g/n/ax) и 5 ГГц (802.11a/h/j/n/ac/ax).

Если мы говорим о волнах и хотим изобразить их на графике, частоту можно запросто сравнить визуально. Посмотрите на рис. 9.1. Там изображены три волны разных частот:

- а) допустим, первая волна является референтной волной с частотой  $1x$ ;
- б) частота второй волны вдвое больше, чем референтной, —  $2x$ ;
- в) частота третьей волны  $8x$  — в восемь раз больше первой, референтной, и в четыре раза больше второй частоты.

а) частота =  $1x$



б) частота =  $2x$



в) частота =  $8x$



**Рис. 9.1.** Три волны разной частоты

Как видите, частоты разных волн можно сравнить с помощью изображения, даже не зная точного значения референтной частоты  $x$ .

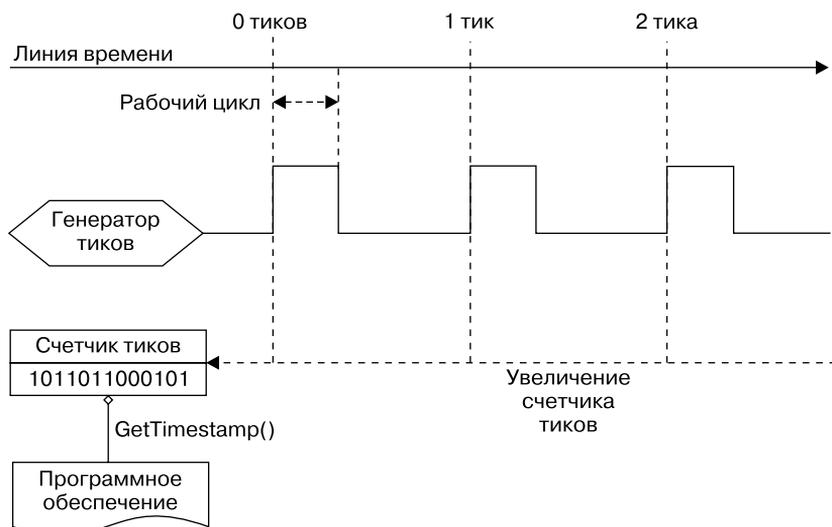
Термин «частота» очень полезен также для описания одного из основных свойств таймера. Давайте узнаем, как его можно использовать для описания характеристик аппаратных таймеров.

## Основные компоненты аппаратного таймера

Реальное время непрерывно. К сожалению, работать с непрерывным временем и измерять неточные временные интервалы невозможно. Все измерения времени основаны на аппаратных таймерах. В целом, аппаратный таймер состоит из следующих трех частей (рис. 9.2).

- **Генератор тиков.** Эта часть устройства генерирует особые события (тики, или импульсы) с постоянной частотой. На практике частота генератора может меняться, но в большинстве случаев проще считать ее постоянной. Обычно генератор реализуется с помощью кварцевого осциллятора — небольшого кусочка кварца или другого керамического материала.

- **Счетчик тиков.** В современных компьютерах нет типа данных, выражающего реальное время. Мы можем только имитировать его с помощью основных типов данных, таких как `int` или `long`. Аппаратные таймеры используют счетчик тиков, в целом являющийся целочисленной величиной, подсчитывающей, сколько тиков сгенерировано генератором. Каждый тик соответствует временному интервалу (опять-таки проще представить, что одному и тому же постоянному интервалу). Таким образом, количество тиков можно перевести во временной интервал.
- **API счетчика тиков.** Это интерфейс для программирования, позволяющий получить текущее значение счетчика тиков из вашего ПО.



**Рис. 9.2.** Компоненты аппаратного таймера

Эта конструкция позволяет измерить любой временной интервал (с ограничениями, которые мы вскоре обсудим). Обычно длительность тика фиксирована и довольно мала, она описана в документации таймера или ее можно получить с помощью другого API. Иногда для длительности 1 тика разработчики используют термин «мгновение».

**Пример.** Допустим, мы можем получить значение счетчика тиков с помощью метода `GetCurrentTicks()` и частота нашего генератора тиков равна 64 Гц. Это означает, что 1 тик равен  $(1/64) \text{ с} = 0,015625 \text{ с} = 15,625 \text{ мс}$ . Вот пример измерений:

```
int startTicks = GetCurrentTicks();           // 100 тиков
SomeLogic();                                 // Реальное время: 0.5 с
int endTicks = GetCurrentTicks();            // 132 тика
int elapsedTicks = endTicks - startTicks;    // 32 тика
```

```
double ticksInSec = 1.0 / 64.0;           // 1 тик = 0,015625 с
double elapsedTimeInSec =                 // Измерить прошедшее время
    elapsedTicks * ticksInSec;           // 32 · 0,015625 с = 0.5 с
```

Метод `SomeLogic()` занимает 0,5 с, но заранее мы этого не знаем и хотим получить это значение в программе. Вызвав `GetCurrentTicks()`, мы получаем две отметки времени — до и после вызова метода. Допустим, первое значение — 100 тиков, а второе — 132 тика. Разница между этими отметками равна 32 тикам. Мы легко можем перевести тики в секунды, поскольку знаем частоту (64 Гц):

$$\text{ПрошедшееВремя} = \text{Тики} \cdot \frac{1}{f} = 32 \cdot \frac{1}{64 \text{ Гц}} = 32 \cdot 15,625 \text{ мс} = 0,5 \text{ с.}$$

### Упражнение

Допустим,  $f = 500$  Гц, `startTicks = 1280`, `endTicks = 1301`. Сколько прошло времени в миллисекундах?

Надеюсь, вы решили задачу без проблем. Выглядит довольно легко, да? Но не всегда все так просто, как в этих примерах. У подхода, основанного на тиках, есть несколько проблем, и одна из основных — погрешности дискретизации.

## Тики и погрешности дискретизации

Таким образом, на аппаратном уровне используется дискретное время (выражаемое в тиках) вместо непрерывного. Такое преобразование времени (реальное время → количество тиков) называется *дискретизацией*. Процесс дискретизации добавляет в измерения *погрешности дискретизации*. Выясним на примерах, что это означает.

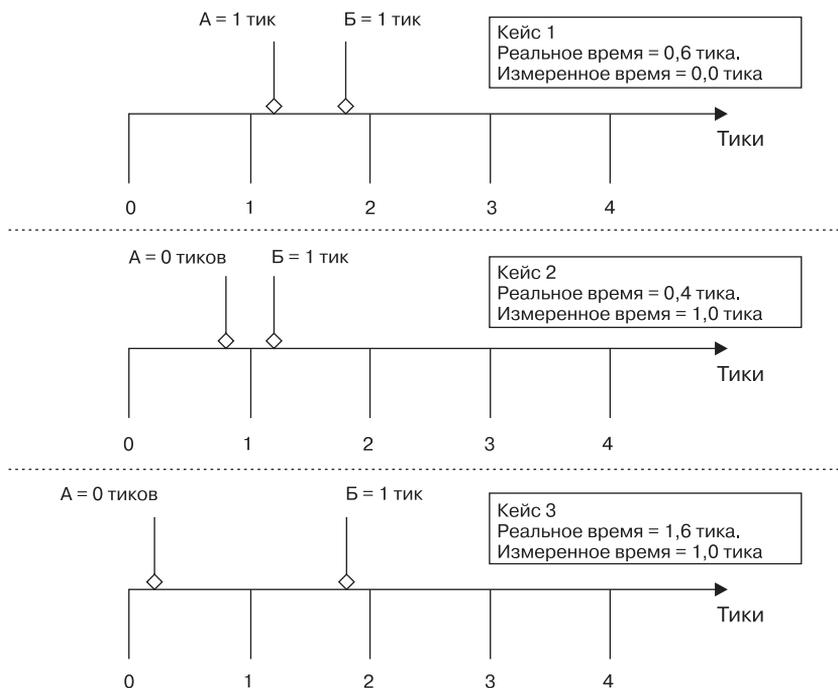
### Примеры

Рассмотрим три измерения, показанные на рис. 9.3. Во всех этих случаях есть две отметки времени, А и В, и мы пытаемся измерить временной промежуток между ними. Все отметки выражены в тиках, и в качестве единицы времени используем 1 тик. Здесь измеряемое значение всегда является целым числом, поскольку счетчик тиков считает его целочисленным. Реальное время выражено дробным числом (это теоретическое значение, относящееся только к конкретному моменту на данной линии времени).

- **Кейс 1.** Реальное А = 1,2 тика, реальное В = 1,8 тика. Из-за дискретизации в обоих случаях получается одно и то же значение счетчика тиков: измеренное А = измеренное В = 1 тик. Если попытаться вычислить прошедшее время по

этим показателям, получим: измеренное  $B$  – измеренное  $A = 0$  тиков. Реальное измеряемое время равно  $0,6$  тика, но мы просто не можем его измерить, поскольку это значение слишком мало.

- **Кейс 2.** Реальное  $A = 0,8$  тика, реальное  $B = 1,2$  тика, измеренное  $A = 0$  тиков, измеренное  $B = 1$  тик. Реальное прошедшее время равно  $0,4$  тика (меньше, чем в кейсе 1), но измеренное прошедшее время равно  $1$  тика (больше, чем в кейсе 1). Поэтому мы не можем сравнивать измеренные временные интервалы, не зная погрешности дискретизации. Если один измеренный интервал больше другого, это еще не значит, что так же было и в реальности!



**Рис. 9.3.** Погрешности дискретизации

- **Кейс 3.** Реальное  $A = 0,2$  тика, реальное  $B = 1,8$  тика, измеренное  $A = 0$  тиков, измеренное  $B = 1$  тик. Реальное прошедшее время равно  $1,6$  тика (намного больше, чем в кейсе 2), но измеренное прошедшее время равно  $1$  тика (так же, как и в кейсе 1). Если два измеренных интервала равны, реальные интервалы могут иметь разницу до 2 тиков.

Таким образом, аппаратная погрешность дискретизации времени составляет  $\pm 1$  тик. Теперь нам нужно узнать еще несколько терминов, чтобы описывать погрешности.

## Основные характеристики таймеров

Существует много терминов, описывающих основные характеристики таймеров. В этом подразделе мы рассмотрим:

- номинальные и реальные частоту, разрешение, детализацию;
- диапазон частоты;
- длительность отметки времени, время доступа, ограничения таймера;
- точность и корректность.

### Номинальные и реальные частота, разрешение, детализация

Вы могли подумать, что минимальной достижимой положительной разницей между двумя отметками времени является 1 тик. Но это не всегда верно. Правильнее будет сказать, что разница составляет не менее 1 тика. Тик — это единица измерения таймера, но это не значит, что у вас всегда есть возможность измерить интервал в 1 тик. Например, 1 тик для `DateTime` равен 100 нс, но измерить такой малый интервал с помощью `DateTime` невозможно (об этом подробнее — в следующем разделе).

Здесь могут появиться терминологические разногласия по поводу термина «*частота*». Иногда частота означает количество тиков в одной секунде. Это *номинальная частота*. Иногда — сколько увеличений числа на счетчике происходит за одну секунду. Это *реальная частота*.

Если у нас есть значение частоты, можно вычислить *обратную частоту*. Ее формула проста: <Обратная частота> = 1 / <Частота>. Таким образом, если мы говорим о номинальной частоте, то *номинальная обратная частота* — это длительность 1 тика. Если мы говорим о реальной частоте, то *реальная обратная частота* — это временной интервал между двумя последовательными увеличениями счетчика.

**Пример.** Значение `Stopwatch.Frequency` является номинальной частотой секундомера, поскольку ее можно использовать только для вычисления длительности 1 тика. О ней ничего не сказано в спецификации и документации, поэтому она может выдать любое значение. И по нему мы не можем сделать никаких выводов о реальной частоте секундомера `Stopwatch`. Например, в `Mono Stopwatch.Frequency` всегда равна 10 000 000.

«Обратная частота» звучит довольно коряво, поэтому существует еще один удобный термин — «*разрешение*». К сожалению, с ним тоже могут возникнуть проблемы. Иногда под разрешением подразумевают длительность 1 тика. Это номинальное разрешение. Иногда имеется в виду минимальный положительный интервал между двумя разными измерениями. Это *реальное разрешение*.

Для разрешения есть и другой термин — «детализация». Обычно оба они используются как синонимы (поэтому можно говорить также о *номинальной* и *реальной детализации*), но чаще детализация описывает реальную обратную частоту (реальное разрешение), а не длительность 1 тика.

Если мы действительно можем измерить интервал 1 тика, то все в порядке: между номинальной и реальной величиной нет разницы, они равны. Поэтому часто говорят просто «частота» или «разрешение» без дополнительной информации. Однако, если реальное разрешение больше 1 тика, могут появиться проблемы с терминологией. Будьте внимательны и всегда обращайтесь внимание на контекст.

**Пример.** Стандартное значение `DateTime.Ticks` — 100 нс. В современных версиях Windows частота таймера, ответственного за `DateTime.Now`, по умолчанию равна 64 Гц. Поэтому реальное разрешение выглядит следующим образом:

$$\begin{aligned} \text{реальное разрешение} &= \frac{1}{\text{реальная частота}} = \frac{1}{64 \text{ Гц}} = 15,625 \text{ мс} = \\ &= 15625000 \text{ нс} = 156250 \text{ импульсов.} \end{aligned}$$

Давайте еще раз посмотрим на все эти значения:

- номинальное разрешение — 100 нс;
- реальное разрешение — 15,625 мс;
- номинальная частота — 10 МГц;
- реальная частота — 64 Гц.

Как видите, важно различать номинальные и реальные значения.

## Отклонение частоты

Как мы уже говорили, проще всего считать, что частота неизменна. Обычно это допущение не влияет на вычисления. Однако полезно знать о том, что частота может отличаться от заявленного значения. В этом случае реальная частота может отличаться от заявленного значения на так называемое *максимальное отклонение частоты*, выражаемое в долях на миллион (ppm,  $10^{-6}$ ).

**Пример.** Заявленная частота таймера равна 2 Гц с максимальным отклонением частоты на 70 ppm. Это означает, что реальная частота должна относиться к диапазону 1 999 930 000... 2 000 070 000 Гц. Допустим, мы измерили временной интервал и получили значение 1 с (или 2 000 000 000 тиков). Если реальная частота равна 1 999 930 000 Гц, то реальный временной интервал составляет:

$$\text{измеренное время} = \frac{2000000000 \text{ импульсов}}{1999930000 \text{ импульсов/с}} \approx 1,000035001225 \text{ с.}$$

Если реальная частота равна 2 000 070 000 Гц, реальный временной интервал составляет:

$$\text{измеренное время} = \frac{2000000000 \text{ импульсов}}{2000070000 \text{ импульсов/с}} \approx 0,999965001225 \text{ с.}$$

Таким образом, реальное значение измеренного интервала (предположим, что других погрешностей нет) находится в диапазоне 0,999 965 001 225... 1,000 035 001 225 с.

Еще раз повторю: обычно нас это не волнует, поскольку другие погрешности влияют на конечную погрешность сильнее.

### Длительность отметки времени, время доступа, ограничения таймера

Когда мы обсуждали рис. 9.3, отметки времени были показаны, как мгновенные события. На самом деле вызов API метода для проставления отметок также занимает какое-то время. Иногда он взаимодействует с устройством, и подобный вызов может быть довольно затратным. Вы можете столкнуться с разными терминами для этого значения: *длительность отметки времени*, *время доступа* или *ограничения таймера*. Все они обычно означают одно и то же: интервал таймера между двумя моментами — вызовом API для проставления отметок и получением значения.

### Точность и корректность

Существует два более важных термина — «точность» и «корректность».

*Точность* (она же *случайная погрешность*) — это максимальная разница между двумя измерениями одного и того же временного отрезка. Точность описывает степень повторяемости результатов измерения. Другими словами, точность определяется случайными погрешностями измеренных значений, близких к реальному значению.

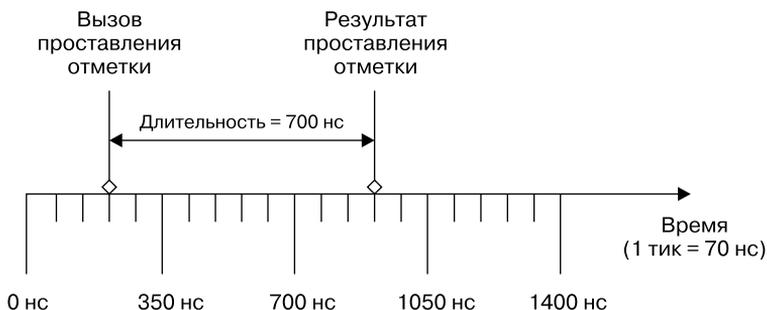
*Корректность* (она же *системная погрешность*) — это максимальная разница между измеренным и реальным значениями.

В большинстве случаев длительность отметки времени настолько мала в сравнении с реальным разрешением, что ею можно пренебречь. Но иногда она велика и может повлиять на общую корректность. Можно сказать, что корректность в этом случае является суммой длительности и разрешения.

**Пример.** В Windows 10 с включенным НРЕТ (об этом подробнее — в следующих разделах) частота `Stopwatch` равна 14,31818 МГц, а длительность `Stopwatch.GetTimestamp()` составляет примерно 700 нс. Вычислить разрешение `Stopwatch` легко:  $1/14\,318\,180 \text{ с} \approx 70 \text{ нс}$ . К сожалению, длительность гораздо больше, поэтому невозможно реально измерить интервалы 70 нс:

$$\text{корректность} \approx \text{длительность} + \text{разрешение} \approx 700 \text{ нс} + 70 \text{ нс} \approx 770 \text{ нс.}$$

Типичное измерение для подобной ситуации представлено на рис. 9.4.



**Рис. 9.4.** Небольшое разрешение и большая длительность

Таким образом, если вам нужно вычислить уровень корректности, нужно знать оба значения — реальное разрешение и длительность отметки времени.

Разрешение, точность и корректность часто путают. Рассмотрим различия между ними с помощью простого примера.

**Пример.** У нас есть таймер с частотой 100 Гц (то есть 1 с = 100 тиков). Мы измеряли интервал ровно 1 с пять раз. Вот результаты: 119 тиков, 121 тик, 122 тика, 120 тиков, 118 тиков. В этом случае:

- *разрешение* — это наименьшая разница между двумя измеренными значениями. Мы не можем получить разницы меньше чем 1 тик, потому что работаем с целочисленным количеством тиков, но можем получить ровно 1 тик (реальное и номинальное разрешения равны). Таким образом, разрешение составляет ровно 1 тик, или 10 мс;
- *корректность* — это разница между реальным и измеренным значениями. Реальное значение равно 100 тикам, а среднее между всеми измерениями — 120 тиков. Таким образом, корректность — примерно 20 тиков, или 200 мс;
- *точность* — это максимальная разница между измерениями, соответствующими одному и тому же реальному значению. Мы измеряем ровно 1 с каждый раз, но получаем разные значения (например, из-за отклонения частоты): от 118 до 122 тиков. Таким образом, точность составляет примерно 4 тика, или 40 мс.

Таким образом, получаем:

- разрешение — 10 мс;
- корректность — 200 мс;
- точность — 40 мс.

Как видите, все три термина определяют разные значения. Но люди их путают, потому что часто во всех трех случаях наблюдаются одни и те же значения. Точность ограничена номинальным разрешением (нельзя получить точность ниже 1 тика). Корректность ограничена точностью и реальным разрешением (если разница между измерениями одного и того же значения равна  $x$ , корректность не может быть ниже  $x$ ). Обычно при работе с таймером высокой точности и малом времени доступа у точности, разрешения и корректности один порядок, а иногда они могут быть равны. Поэтому, если все знают контекст (точные значения всех характеристик таймера), эти термины могут замещать друг друга (например, можно сказать «уровень точности» вместо «уровень корректности», поскольку они равны). Формально это неправильно, но так все равно делают. Читая описание измерений, всегда смотрите на контекст и будьте готовы к неточным утверждениям.

## Подводя итог

В этом разделе мы узнали следующие термины.

- *Единица времени* — единица измерения времени. Основной единицей времени является 1 с, но бенчмарки часто работают с очень маленькими единицами, например 1 мкс ( $10^{-6}$  с, международное обозначение —  $\mu\text{s}$  или  $\text{us}$ ) или 1 нс ( $10^{-9}$  с, обозначение —  $\text{ns}$ ). Часто используемые единицы времени: день (d), ч (h), мин (m), с (s), мс (ms), мкс ( $\mu\text{s}$ ), нс (ns), пс (ps). Общепринятые обозначения времени и временных интервалов —  $t$  и  $T$ . Существуют неформальные единицы времени, например мгновение, означающее краткий период времени неуточненной длины, разработчики часто применяют его для обозначения длительности 1 тика.
- *Единица частоты* — единица измерения частоты, обратная единице времени:  $1 \text{ Гц} = 1 \text{ с}^{-1}$ . Часто используемые единицы частоты: нГц, мкГц, мГц, Гц, кГц, МГц, ГГц, ТГц. Общепринятое обозначение частоты —  $f$ .
- *Генератор тиков* — элемент устройства, генерирующий особый тип событий (тики) с постоянной частотой.
- *Счетчик тиков* — целочисленный счетчик, обрабатывающий количество прошедших тиков.
- *API счетчика тиков* — программируемый интерфейс, позволяющий получить текущее значение счетчика тиков на вашем ПО.
- *Аппаратный таймер* — сочетание генератора тиков, счетчика тиков и API счетчика тиков.
- *Дискретизация* — переход от реального непрерывного времени к дискретному времени (количеству тиков).
- *Погрешности дискретизации* — погрешности, появившиеся из-за дискретизации (мы не можем выразить реальное время с помощью целочисленного значения).

- *Номинальная частота* — количество тиков в 1 с.
- *Реальная частота* — количество увеличений числа на счетчике за 1 с.
- *Номинальная обратная частота, номинальное разрешение, номинальная детализация* — длительность 1 тика.
- *Реальная обратная частота, реальное разрешение, реальная детализация* — минимальный положительный интервал между двумя разными результатами измерения.
- *Максимальное отклонение частоты* — разница между реальной и заявленной частотами.
- *Длительности отметки времени, время доступа, ограничения таймера* — длительность запроса API счетчика тиков, выдающего текущее значение счетчика.
- *Точность, случайная погрешность* — максимальная разница между разными измерениями одного и того же отрезка времени.
- *Корректность, систематическая погрешность* — максимальная разница между измеренным и реальным значениями.

Теперь нам известна основная терминология. В следующем разделе будем использовать эти термины для того, чтобы обсудить происхождение генераторов тиков — аппаратных таймеров.

## Аппаратные таймеры

Все методы для проставления отметок времени так или иначе задействуют аппаратные средства. Поэтому прежде всего нам нужно узнать, какие существуют аппаратные таймеры и как их можно применять. В этом разделе я расскажу о следующих таймерах:

- TSC (счетчик отметок времени);
- HPET (таймер событий высокой точности);
- ACPI PM (таймер управления энергией).

Мы также поговорим:

- о краткой истории разных видов этих таймеров;
- об основных свойствах таймеров, например о реальной частоте и длительности отметки времени, на разных устройствах;
- о том, как правильно работать с TSC с помощью C#;
- как переключаться между TSC, HPET и ACPI PM в Windows и Linux;
- о проблемах, которые могут возникнуть с каждым из таймеров.

## TSC

**TSC** — общепринятое обозначение **счетчика отметок времени** (Time Stamp Counter). Это внутренний 64-битный регистр, имеющийся во всех процессорах x86, начиная с Pentium. TSC является независимым счетчиком, на который не влияют изменения в текущем времени системы. Он продолжает монотонно увеличивать значения тиков. Длительность тика зависит от модели процессора. Частота TSC обычно близка к номинальной частоте процессора.

Значение TSC может быть прочитано регистрами EDX:EAX с помощью команды RDTSC. Код операции этой команды — 0F 31 ([Intel Manual], том 2B 4-545). С# и другие языки .NET достаточно высокого уровня, поэтому мы обычно не работаем напрямую с кодами операции сборок, так как у нас есть мощный BCL, содержащий управляемые оболочки всех полезных функций. Но если вы действительно этого хотите, существуют специальные приемы. Чтобы лучше понять внутреннее устройство, мы научимся получать значения TSC без стандартных классов .NET. В Windows его можно прочесть напрямую из кода на С# с помощью следующих внедрений в сборку:

```
const uint PAGE_EXECUTE_READWRITE = 0x40;
const uint MEM_COMMIT = 0x1000;

[DllImport("kernel32.dll", SetLastError = true)]
static extern IntPtr VirtualAlloc(IntPtr lpAddress,
                                uint dwSize,
                                uint flAllocationType,
                                uint flProtect);

static IntPtr Alloc(byte[] asm)
{
    var ptr = VirtualAlloc(IntPtr.Zero,
                          (uint)asm.Length,
                          MEM_COMMIT,
                          PAGE_EXECUTE_READWRITE);
    Marshal.Copy(asm, 0, ptr, asm.Length);
    return ptr;
}

delegate long RdtscDelegate();
static readonly byte[] rdtscAsm =
{
    0x0F, 0x31, // RDTSC
    0xC3      // RET
};

static void Main()
{
    var rdtsc = Marshal
        .GetDelegateForFunctionPointer<RdtscDelegate>(Alloc(rdtscAsm));
    Console.WriteLine(rdtsc());
}
```

Давайте подробно обсудим этот код.

- Для внедрения в сборку нужна функция `VirtualAlloc` из `kernel32.dll`. Она может вручную разместить память в виртуальном адресном пространстве текущего процесса.
- Функция `Alloc` берет массив `byte` с кодами операций команд сборки, размещает память с помощью `VirtualAlloc`, копирует туда коды и выдает указатель на адрес размещенного и заполненного фрагмента памяти. Предпоследний аргумент `VirtualAlloc (flAllocationType)` отвечает за то, что мы будем делать с этой памятью: `MEM_COMMIT` означает, что мы собираемся подтверждать изменения в памяти. Последний аргумент `VirtualAlloc (flProtect)` отвечает за режим защиты памяти: `PAGE_EXECUTE_READWRITE` означает, что можно исполнять код напрямую с размещенных страниц.
- Мы определяем подпись для новой управляемой функции `rdtsc` с помощью `RdtscDelegate` (у нее нет никаких аргументов, и она возвращает значение `long`).
- Массив `rdtscAsm` содержит все коды операций нужной сборки: `0F 31` для `RDTSC` и `C3` для `RET`.
- Метод `Main` использует `Marshal.GetDelegateForFunctionPointer` для конвертации неуправляемого указателя функции в делегат. Обобщенные перегруженные алгоритмы поддерживаются только в `.NET Framework 4.5.1` и более поздних версиях. Аргументом этого метода является `Alloc(rdtscAsm)`: мы берем массив `byte` с кодами операций сборки и превращаем его в `IntPtr`, указывающий на фрагмент памяти с данными кодами.

Этот подход позволяет вызывать `RDTSC` из управляемого кода. Обычно так делать не рекомендуется, поскольку с `TSC` много проблем, которые могут испортить ваши показатели (многие мы вскоре обсудим). У операционных систем есть специальные API, позволяющие получать отметки времени высокой точности без внедрения в сборку и получения напрямую информации о `TSC`. Эти API защищают вас от проблем, которые можно получить из-за прямого вызова `RDTSC`. Однако иногда описанное внедрение в сборку может оказаться полезным для исследований и диагностики.

Если вы хотите прочесть значение `TSC` напрямую с помощью команды `RSTSC`, стоит знать о том, что процессор может изменить порядок команд и испортить вам измерения. См. [Intel Manual], том 3B 17-41, раздел 17.15: «Команда `RSTSC` не поддается сериализации или упорядочению вместе с другими командами. Она не всегда дожидается исполнения всех предыдущих команд, прежде чем прочесть счетчик. Так же и последующие команды могут начать исполнение до окончания операции команды `RDTSC`».

Классический способ решения этой проблемы можно найти в [Agner Optimizing Assembly] (раздел 18.1): «При всех процессорах с внеочередным исполнением нуж-

но ввести XOR EAX, EAX/CPUID до и после каждого прочтения счетчика, чтобы оно не выполнялось параллельно ни с чем другим. CPUID — команда сериализации, то есть она создает очередь и ждет, пока все операции из очереди завершатся, прежде чем продолжить. Это очень полезно для тестирования».

В [Agner Optimizing Cpp] (раздел 16 «Скорость тестирования») можно найти пример прямого вызова RDTSC на C++ с барьером памяти с помощью CPUID.

Существует еще одна собственная команда для проставления отметок времени, предотвращающая изменение порядка команд, — RDTSCP. Она также читает значение TSC, но ожидает исполнения всех предыдущих инструкций, прежде чем прочесть счетчик. См. [Intel Manual], том 2B 4-545: «Если программному обеспечению требуется исполнение RSTSC только после локального завершения всех предыдущих команд, оно может либо использовать RDTSCP (если процессор поддерживает данную команду), либо исполнить выражение LFENCE;RDTSC».

Вы можете применить RDTSCP вместо RDTSC и не бояться внеочередного исполнения. Кроме прочтения TSC RDTSCP также читает ID процессора, но для измерения времени он вам не нужен.

Обсудим время доступа RDTSCP. В табл. 9.3 можно увидеть список значений обратной выработки RDTSC (временных циклов процессора) для разных процессоров (данные взяты из [Agner Instructions]).

**Таблица 9.3.** Обратная выработка RDTSC на разных процессорах

Процессор	Обратная выработка
AMD K7	11
AMD K8	7
AMD K10	67
AMD Bulldozer	42
AMD Piledriver	42
AMD Steamroller	78
AMD Bobcat	87
AMD Jaguar	41
Intel Pentium M, Core Solo, Core Duo	42
Intel Pentium 4	80
Intel Pentium 4 w. EM64T (Prescott)	100
Intel Core 2 (Merom)	64

Продолжение ⇨

Таблица 9.3 (продолжение)

Процессор	Обратная выработка
Intel Core 2 (Wolfdale)	32
Intel Nehalem	24
Intel Sandy Bridge	28
Intel Ivy Bridge	27
Intel Haswell	24
Intel Broadwell	24
Intel Skylake	25
Intel SkylakeX	25

Как можно интерпретировать эти числа? Допустим, у нас есть процессор Intel Haswell (обратная выработка 24) с постоянной частотой процессора 2,2 ГГц. Один временной цикл процессора равен примерно 0,45 нс (это наше разрешение). Можно сказать, что вызов RDTSC занимает примерно  $24 \cdot 0,45 \text{ нс} \approx 10,8 \text{ нс}$  (для RDTSC можно предположить, что длительность примерно равна обратной выработке).

Можно также оценить выработку RDTSC на вашем устройстве. Загрузите `testp.zip` (<http://www.agner.org/optimize/testp.zip>) с сайта Агнера Фога, соберите его и запустите `misc_int.sh1`. Вот типичные результаты для Intel Haswell:

Выработка rdtsc

```
Processor 0
Clock Core cys Instruct Uops uop p0 uop p1 uop p2
1686 2384 100 1500 255 399 0
1686 2384 100 1500 255 399 0
1686 2384 100 1500 255 399 0
1686 2384 100 1500 254 399 0
1686 2384 100 1500 255 399 0
1686 2384 100 1500 255 399 0
1686 2384 100 1500 255 399 0
1686 2384 100 1500 254 399 0
1686 2384 100 1500 255 399 0
1686 2384 100 1500 255 399 0
```

У нас 2384 цикла процессора на 100 команд RDTSC, то есть примерно 24 CPI.

На современных устройствах и операционных системах TSC работает очень хорошо, но у него долгая история (<https://stackoverflow.com/a/19942784>) и его часто считают ненадежным источником отметок времени. Давайте обсудим разные поколения TSC и проблемы, которые могут с ним возникнуть (больше информации вы найдете в [Intel Manual], том 3В 17-40, раздел 17.16).

## Поколение 1: вариативный TSC

Первая версия TSC (см. список семейств процессоров в [Intel Manual], том 3B 17-40, раздел 17.16) была очень проста, она просто подсчитывала внутренние временные циклы процессора. Это не самый разумный способ измерять время на современных устройствах, поскольку процессор может динамически менять собственную частоту (это позволяют, например, технологии SpeedStep и Turbo Boost от Intel).

Существует и другая проблема: у каждого ядра процессора есть свой TSC и они не синхронизированы. Если поток начинает измерения на одном ядре и заканчивает на другом, полученный результат не может считаться надежным. Например, на [support.microsoft.com](http://support.microsoft.com) (см. [MSSupport 895980]) есть интересный отчет об ошибке, его автор получил следующий результат команды ping:

```
C:\>ping x.x.x.x
```

```
Pinging x.x.x.x with 32 bytes of data:
```

```
Reply from x.x.x.x: bytes=32 time=-59ms TTL=128
```

Эта проблема возникает на компьютере, когда в BIOS включена технология AMD Cool'n'Quiet (двойные ядра AMD), или на некоторых многоядерных процессорах Intel. Многоядерная или многопроцессорная система может столкнуться со сдвигом TSC, если не синхронизировано время на разных ядрах. Эта проблема может возникнуть в операционных системах, использующих TSC в качестве ресурса слежения за временем.

Если вы хотите применить TSC на старом устройстве/ПО, разумно будет установить привязку вашего потока или процесса к процессору. Если вы работаете с собственным кодом, это можно сделать с помощью `SetThreadAffinityMask` в Windows или `sched_setaffinity` в Linux. В управляемом коде на C# можно использовать свойство процесса `ProcessorAffinity` таким образом:

```
IntPtr affinityMask = (IntPtr) 0x0002; // Только второе ядро
Process.GetCurrentProcess().ProcessorAffinity = affinityMask;
```

К счастью, на современных устройствах этих проблем нет, поскольку внутреннее устройство TSC было значительно улучшено.

## Поколение 2: постоянный TSC

*Постоянный* TSC — это следующее поколение TSC. Он решает проблему динамической частоты, увеличивая показатели с постоянным интервалом. Это значительный шаг вперед, но у постоянного TSC все равно есть проблемы, например, он может

остановиться, когда процессор уходит в глубокий сон (подробнее — в [Kidd 2014]). Эти проблемы были решены в следующем воплощении TSC.

## Поколение 3: инвариантный TSC

*Инвариантный TSC*, последняя версия счетчика, работает прекрасно. Приведу цитату из [Intel Manual]: «Инвариантный TSC будет работать в постоянном ритме в любом режиме ACPI: энергопотребления, простоя или экономии энергии. Архитектура продолжает развиваться. На процессорах с поддержкой инвариантного TSC ОС может использовать его в качестве таймера системных часов (вместо таймеров ACPI или HPET)».

Проверить, какой у вас тип TSC, можно с помощью кода операции `CPUID`. К счастью, для этого не нужно писать еще одно внедрение в сборку, поскольку существуют инструменты для определения типа TSC. В Windows его можно проверить с помощью утилиты `Coreinfo` (<https://docs.microsoft.com/en-us/sysinternals/downloads/coreinfo>) — части набора `Sysinternals`.

Вот частичный пример результата со строками, определяющими TSC:

```
Coreinfo v3.31 – Сохраненная информация о процессоре системы и топологии
памяти
Copyright (C) 2008-2014 Mark Russinovich
Sysinternals – www.sysinternals.com
Intel(R) Core(TM) i7-6700HQ CPU @ 2.60GHz
Intel64 Family 6 Model 94 Stepping 3, GenuineIntel
RDTSCP * Поддерживает команду RDTSCP
TSC * Поддерживает команду RDTSC
TSC-INVARIANT * TSC работает в постоянном ритме
```

Мы видим, что поддерживаются команды `RDTSC` и `RDTSCP`, доступен инвариантный TSC. То же самое можно сделать в Linux с помощью следующей команды:

```
$ cat /proc/cpuinfo | tr ' ' '\n' | sort -u | grep -i "tsc"
```

Если доступны `RDTSC`, `RDTSCP` и инвариантный TSC, результатом должны стать следующие строки:

```
constant_tsc
nonstop_tsc
rdtscp
tsc
```

Инвариантный TSC помечается комбинацией отметок `constant_tsc` (синхронизация ядер) и `nonstop_tsc` (независимость от режима энергопотребления).

В большинстве случаев можно доверять инвариантному TSC и использовать его как таймер системных часов для измерений высокой точности. В редких случаях

могут появиться проблемы, например, с синхронизацией в больших *многопроцессорных* системах, но в целом об этом не стоит волноваться. Сейчас инвариантный TSC является очень популярным типом TSC, его можно найти в большинстве современных процессоров Intel.

Теперь мы знаем основное о разных поколениях TSC, знаем инструкции по сборке для получения значений счетчиков и то, как вызвать его из управляемого кода на C# и какие проблемы могут встретиться. Но существуют и другие аппаратные таймеры.

## HPET и ACPI PM

Кроме TSC, у многих процессоров есть два дополнительных таймера — *HPET* и *ACPI PM*. Они также являются независимыми счетчиками, на которые не влияют изменения текущего времени системы.

**HPET** — это *таймер событий высокой точности* (High-Precision Event Timer). Он был разработан Microsoft и AMD на замену таким старым таймерам, как TSC, и в качестве основного таймера для измерений высокой точности. Однако HPET не стал основным таймером — большей частью из-за длительного времени доступа. На современных устройствах и в операционных системах он обычно отключен (в качестве основного источника отметок времени используется инвариантный TSC), но его можно включить, если он вам зачем-то нужен.

Если верить [HPET Specifications] (раздел 2.2), минимальная частота часов HPET равна 10 МГц, но реальная частота HPET всегда составляет 14,31818 МГц (происхождение этого числа объясняется в подразделе «История магических чисел»).

**ACPI PM** — это таймер системы управления энергопотреблением. Самые распространенные аббревиатуры — *ACPI PM* и *ACPI PMT*. ACPI означает *обновленный интерфейс конфигурации и энергопотребления* (Advanced Configuration and Power Interface), а PMT — *таймер управления энергопотреблением* (Power Management Timer). Его часто называют также ACPI PM, PMS или просто таймером управления энергопотреблением.

Как указано в [ACPI Specifications] (раздел 4.8.2.1), частота этого таймера всегда равна 3,579545 МГц. HPET и ACPI PM задействуют один и тот же кристалл задающего осциллятора (14,31818 МГц равно 4...3,579545 МГц). Следовательно, у ACPI PM тоже длительное время доступа.

В операционных системах есть основной аппаратный таймер, используемый для проставления отметок времени по умолчанию. Обычно им является TSC, но вы можете поменять его вручную.

В Windows можно включить или выключить HPET с помощью утилиты `bcdedit`<sup>1</sup>. Для включения нужно запустить ее с аргументами `/set useplatformclock true` и перезагрузить компьютер:

```
:: Включить HPET (требуется перезагрузка):  
bcdedit /set useplatformclock true
```

Так вы устанавливаете в менеджере загрузки значение `useplatformclock`, требующее HPET вместо TSC. Если больше не хотите его использовать, нужно удалить это значение с помощью `/deletevalue` и перезагрузить:

```
:: Отключить HPET (требуется перезагрузка):  
bcdedit /deletevalue useplatformclock
```

Если вы хотите проверить, включен HPET или нет, нужно посмотреть, есть ли `useplatformclock` в результатах следующей команды:

```
bcdedit /enum
```

В Linux все файлы, связанные с временными ресурсами, обычно размещаются по адресу `/sys/devices/system/clocksource/clocksource0/`. Полный список доступных временных ресурсов можно посмотреть в `available_clocksource`. Например, на моем компьютере с Linux есть TSC, HPET и ACPI PM:

```
# Получить доступные временные ресурсы:  
$ cat /sys/devices/system/clocksource/clocksource0/available_clocksource  
tsc hpet acpi_pm
```

Текущий временной ресурс можно найти в `current_clocksource`:

```
# Получить текущий временной ресурс:  
$ cat /sys/devices/system/clocksource/clocksource0/current_clocksource  
tsc
```

Это значение легко изменить. Например, для включения HPET нужно запустить следующее:

```
# Установить текущий временной ресурс:  
$ sudo /bin/sh -c \  
    'echo hpet > /sys/devices/system/clocksource/clocksource0/  
    current_clocksource'
```

---

<sup>1</sup> Инструмент командной строки для управления данными конфигурации загрузки (BCD). Больше информации о нем можно найти здесь: <https://docs.microsoft.com/en-us/windows-hardware/manufacture/desktop/bcdedit-command-line-options> и <https://msdn.microsoft.com/en-us/library/windows/hardware/ff542202.aspx>.

Обычно HPET отключен, но не нужно предполагать, что таймером по умолчанию всегда является TSC. Например, включенный HPET можно встретить на унаследованных серверах, на которых несколько лет не переустанавливали ОС. Его также могли включить вручную для каких-то конкретных сценариев или из-за ошибок<sup>1</sup>.

## История магических чисел

Мы уже знаем, что частота HPET равна 14,31818 МГц, а частота ACPI PM — 3,579545 МГц. Почему именно эти числа используются для аппаратных таймеров? Для того чтобы это понять, нужно посетить интригующий урок истории (можете пропустить его, если не любите историю).

В 1950 году Национальный комитет по телевизионным системам (NTSC) начал создавать новый стандарт для цветного телевидения. Стандарт был одобрен в 1953 году. Это было сложное техническое задание, потому что новый стандарт должен был быть совместим со старым черно-белым телевидением (B&W TV). Новый стандарт задействует систему расшифровки цветности и яркости: цветное изображение представлено как сумма сигналов цветности и яркости. Сигнал яркости соответствовал монохромному сигналу в B&W TV, чтобы оно могло принимать новый стандарт. Сигнал цветности содержал только информацию о цвете (два дополнительных сигнала с разными фазами). Теперь решим простую задачу: нам нужно выбрать частоту сигнала цветности  $f_c$  (также известную как частота цветовой поднесущей), которая не повлияет на B&W TV. Рассмотрим несколько основных условий, которым она должна соответствовать.

### Условие 1. Ширина диапазона для сигнала цветности

Частота сигнала цветности  $f_c$  должна быть максимально высокой — это позволит получить меньшую шумовую структуру. По американскому стандарту максимальная частота видео  $f_{\max} = 4,18$  МГц. После серии экспериментов оказалось, что разница  $f_{\max} - f_c$  не может быть меньше 0,6 МГц, иначе искажается изображение. Поэтому есть следующее требование:

$$f_{\max} - f_c \geq 0,6 \text{ МГц.}$$

Теперь у нас есть верхняя граница  $f_c$ :

$$f_c \leq 3,58 \text{ МГц.}$$

<sup>1</sup> Например, в CentOS 7 была ошибка программно-аппаратных средств: в `available_clocksource` содержалось только значение `hpet acpi_pm` без `tsc`. Обсуждение можно найти здесь: <https://stackoverflow.com/q/45803565>.

## Условие 2. Линейная частота

Чтобы минимизировать видимость цветовой поднесущей на черно-белых экранах, в качестве ее частоты должно использоваться нечетное полуцелое, кратное уровню горизонтальной линии ( $h$ )  $f_h$ :

$$f_c = (2n + 1) \frac{f_h}{2}.$$

Благодаря этому пики сигнала цветности попадут точно между пиками сигнала яркости, что минимизирует интерференцию. В случае четного, кратного  $2n$ , получим схему сильного шума (набор вертикальных линий).

## Условие 3. Аудиосигнал

Нам также нужно минимизировать интерференцию между аудиосигналом (несущей звукового сопровождения) и сигналом цветности (поднесущей цветности). Поэтому следует ввести дополнительное требование (по аналогии с условием 2) к расстоянию между размещением несущей звукового сопровождения  $f_{\Delta s}$  и частотой поднесущей цветности  $f_c$ :

$$f_{\Delta s} - f_c = (2m + 1) \frac{f_h}{2}.$$

Подставив  $(2n + 1)(f_h / 2)$  вместо  $f_c$ , получаем:

$$f_{\Delta s} = (2m + 1) \frac{f_h}{2} + (2n + 1) \frac{f_h}{2}.$$

Следовательно:

$$\frac{f_{\Delta s}}{f_h} = m + n + 1 = k,$$

где  $k$  — целое число.

В изначальном стандарте частота кадров составляла 30 Гц при 525 линиях на кадр (15 750 линий в секунду). Это число было выбрано из-за технологических ограничений того времени, связанных с электронно-лучевыми трубками. Таким образом, частота горизонтальных линий  $f_h = 15\,750$  Гц. По американскому стандарту для V&W TV размещение несущей звукового сопровождения  $f_{\Delta s}$  между частотой аудио и видео было ровно на частоте 4,5 МГц. Поэтому получаем:

$$\frac{f_{\Delta s}}{f_h} = \frac{4,5 \text{ МГц}}{15\,750 \text{ Гц}} \approx 285,714285714.$$

Чтобы минимизировать интерференцию между аудиосигналом и цветным видеосигналом,  $f_{\Delta s}/f_h$  должно быть целым числом. Было решено сделать  $f_{\Delta s}$  286-й гармоникой  $f_h$  (286 — ближайшее целое число к 285,714285714). Мы не можем изменить

частоту несущей звукового сопровождения — устаревшие телеприемники ее не расшифруют, но можем изменить частоту горизонтальной линии! Вычислить новую частоту горизонтальной линии просто:

$$f_h = \frac{f_s}{286} = 15\,734,26573 \text{ Гц.}$$

Коэффициент снижения частоты составляет  $15\,750 \text{ Гц} / 15\,734,26573 \text{ Гц} \approx 1,001$ . Интересным последствием является то, что теперь частота кадра равна  $29,97 \text{ Гц}$  вместо  $30 \text{ Гц}$ , а частота полукадров —  $59,94 \text{ Гц}$  вместо  $60 \text{ Гц}$ <sup>1</sup>.

#### Условие 4. Простая конструкция

Нам нужен простой в использовании осциллятор. Создать цепочку делителей частоты проще, когда  $(2n + 1)$  выводится из небольших простых чисел. Мы знаем, что:

$$f_c = (2n + 1) \frac{f_h}{2}.$$

Если  $f_c \leq 3,58 \text{ МГц}$ , а  $f_h = 15\,734,26573 \text{ Гц}$ , то

$$2n + 1 = \frac{2f_h}{f_c} \leq \frac{2,3580000 \text{ Гц}}{15\,734,26573 \text{ Гц}} \approx 455,0578.$$

Мы знаем, что частота сигнала цветности  $f_c$  должна быть максимально высокой. Максимальное из возможных значений  $(2n + 1)$  (которое должно быть нечетным целым числом) —  $455$ . Это прекрасное число, поскольку у него есть небольшие делители частоты, а именно  $5$ ,  $7$  и  $13$ :

$$(2n + 1) = 5 \cdot 7 \cdot 13 = 455.$$

#### Решение

Ура, теперь мы можем вычислить  $f_c$  ставшую частотой по умолчанию для сигнала цветовой синхронизации NTSC:

$$f_c = (2n + 1) \frac{f_h}{2} = 455 \cdot \frac{15\,734,26573 \text{ Гц}}{2} \approx 3,579545 \text{ МГц.}$$

Если вам интересна история телевидения, много других занимательных технических деталей вы найдете в [Schlyter] и [Stephens 1999]. Значение  $3,579545 \text{ МГц}$

<sup>1</sup> Конвертировать фильмы, в которых  $24$  кадра в секунду, в видеостандарт NTSC с частотой  $59,94 \text{ Гц}$  — это особое удовольствие. Если вкратце: для этого нужно замедлить фильм на  $1/1000$  — до  $23,976$  кадра в секунду, что удлиняет полуторачасовой фильм на  $5,4 \text{ с}$ . Искать по запросу «Преобразование 3:2».

сильно повлияло на современные аппаратные таймеры. Но как? Пора узнать больше об одном из первых тактовых осцилляторов — **тактовом осцилляторе Intel 8284**.

Вспомним некоторые старые модели процессоров и тактовых осцилляторов. Intel 8284 — это тактовый осциллятор для микропроцессоров Intel 8086/8088. По спецификации максимальная частота для 8088 составляет 5 МГц. Сигнал должен получать 33,3 % рабочего временного цикла ( $1/3$  — время высокого уровня,  $2/3$  — время низкого уровня), поэтому изначальный сигнал должен быть около 15 МГц (можно получить 5 МГц, разделив изначальную частоту на 3).

В то время телевизоры часто применяли в качестве мониторов. Поэтому адаптеру цветной графики (CGA) требовался сигнал 3,579545 МГц для создания цветовой поднесущей NTSC.

Кроме того, размещать несколько кристаллических осцилляторов на одном чипе было дорого. В итоге было решено использовать один и тот же кристалл для CGA и процессора. Поэтому частота задающего осциллятора равна 14,31818 МГц ( $4 \cdot \text{NTSC}$ ). Она позволяет получить 3,579545 МГц для видеоконтроллера CGA (частота задающего осциллятора делится на 4) и 4,77272666 МГц для процессора (делится на 3). Да, это было меньше лимита 5 МГц (спад производительности на 4,6 %), но это был хороший компромисс, позволявший выпускать дешевые чипы для процессора. Эту историю можно найти в блоге Тима Патерсона — создателя MS-DOS (см. [Paterson, 2009]). Также стоит прочесть ту же историю в изложении Келвина Хсия (см. [Hsia, 2004]). Дополнительная техническая информация об Intel 8284 есть в [Karna, 2017] и [Govindarajalu, 2002].

Теперь мы понимаем, откуда произошли частоты ACPI PM и HPET. ACPI PM использует частоту NTSC 3,579545 МГц, поскольку она уже поддерживается аппаратными средствами. Минимальные требования к частоте у HPET — 10 МГц. Поскольку вводить дополнительный осциллятор для HPET было дорого, решили использовать частоту 14,31818 МГц, которая также уже реализована на аппаратном уровне. Другой аппаратный таймер, на который повлияли эти магические числа, — PIT (программируемый таймер интервалов), также известный как чип Intel 8253/8254. Частота этого таймера — 1,193182 МГц. Он использует частоту задающего осциллятора 14,31818 МГц, разделенную на 12, поэтому совместим с CGA (частота CGA =  $3 \cdot$  частота PIT) и процессором (частота процессора =  $4 \cdot$  частота PIT).

## Подводя итог

В настоящее время самым распространенным и надежным аппаратным таймером является TSC. Значение TSC можно прочитать с помощью команды `RDTSC`, имеющей высокое разрешение и низкую длительность. Но в целом мы не советуем использовать его напрямую, поскольку с TSC много проблем, например:

- на некоторых старых процессорах нет регистров TSC;
- процессор может изменить частоту и этим повлиять на старую версию TSC;
- в многоядерных системах появляются проблемы с синхронизацией;
- даже при инвариантном TSC в больших многопроцессорных системах все равно возникают проблемы с синхронизацией;
- некоторые процессоры могут исполнять RDTSC вне очереди.

Поэтому прямой вызов RDTSC не является правильным выбором для измерения времени в целом, потому что заранее нельзя быть уверенными в том, что он выдает надежные показатели. К счастью, современные операционные системы предоставляют полезные API, позволяющие получать самые надежные отметки времени для действующего устройства.

TSC — не единственный генератор тиков, существуют также ACPI PM и HPET. ACPI PM (частота 3,579545 МГц) и HPET (частота 14,31818 МГц) можно встретить даже в современных версиях Windows и Linux, но они непопулярны из-за большой длительности.

Теперь мы знаем, каковы основные аппаратные источники тиков. В следующем разделе поговорим о разных способах получения значения тиков из ПО.

## API для проставления отметок времени в ОС

Мы уже знаем об аппаратных таймерах и о том, как их использовать. Но взаимодействовать с ними напрямую не всегда разумно: требуется знание этих таймеров на разных устройствах и глубинное понимание того, что может пойти не так во всех нужных окружениях. К счастью, операционные системы вводят более высокий уровень абстракции, предоставляя специальные API.

Существует три основные группы API для проставления отметок времени в Windows.

- **Системный таймер:**
  - `GetSystemTime` — выводит текущие *системные* дату и время в формате скоординированного универсального времени (UTC) как `SYSTEMTIME`;
  - `GetLocalTime` — показывает текущие *локальные* дату и время как `SYSTEMTIME`;
  - `GetSystemTimeAsFileTime` — выдает текущие системные дату и время в формате UTC как `FILETIME`.

- **Системные тики:**

- `GetTickCount` — выводит количество миллисекунд, прошедших с момента запуска системы. Первая версия выдает 32-битное число до 49,7 суток;
- `GetTickCount64` — 64-битная версия `GetTickCount`.

- **Таймер высокого разрешения:**

- `QueryPerformanceCounter` и `QueryPerformanceFrequency` — выдают текущее значение и частоту счетчика производительности, являющуюся отметкой времени высокого разрешения, которую можно использовать для измерений временного интервала;
- `KeQueryPerformanceCounter` — аналог `QueryPerformanceCounter`, который можно применять в драйверах устройства (API в режиме ядра);
- `GetSystemTimePreciseAsFileTime` — выдает текущие время и дату системы с максимально возможным уровнем точности.

Вторая группа (системные тики) не очень интересна<sup>1</sup>, поэтому мы сосредоточимся на первой и третьей (системный таймер и таймер высокого разрешения), которые и рассмотрим в следующих двух подразделах.

Также обсудим некоторые API для проставления отметок времени для Unix, например `clock_gettime`, `clock_settime`, `clock_getres`, `mach_absolute_time`, `mach_timebase_info`, `gethrtime`, `read_real_time`, `gettimeofday` и `settimeofday`.

## API для проставления отметок времени в Windows: системный таймер

В Windows существует несколько типов демонстрации времени. Вот два самых популярных варианта:

- `SYSTEMTIME` — указывает дату и время с использованием отдельных полей для месяца, дня, года, дня недели, часа, минут, секунд и миллисекунд. В зависимости от вызванной функции время дается либо в формате UTC, либо локальное;
- `FILETIME` — содержит 64-битное значение, представляющее количество 100-наносекундных интервалов, прошедшее с 1 января 1601 года (UTC).

Windows предоставляет еще один полезный механизм — *системный таймер*, который позволяет узнать, который час (если нам не нужны измерения с высоким

---

<sup>1</sup> Она полезна лишь в некоторых конкретных ситуациях, и о ней нет интересной информации. Мы обсудим ее в следующем разделе, поскольку это API, лежащий в основе `Environment.TickCount` в Windows.

разрешением). Основной API — функция `GetSystemTimeAsFileTime`. Она выдает `FILETIME`, представляющий текущие системные дату и время в формате UTC. Если мы хотим получить это значение в виде `SYSTEMTIME`, то можем использовать также `GetSystemTime`: работает медленно, но выдает текущие дату и время в более подходящем формате. Конвертировать `FILETIME` в `SYSTEMTIME` можно вручную с помощью `FileTimeToSystemTime`. Если хочется получить локальные дату и время, а не UTC, можно применить функцию `GetLocalTime`.

Все предыдущие API используют системный таймер Windows с точки зрения внутреннего устройства. Важно понимать, каково разрешение этого таймера, как его можно изменить и как это может повлиять на ваше приложение.

## Системный таймер и его разрешение

Реальное разрешение системного таймера может иметь разные значения. Узнать конфигурацию вашей ОС легко с помощью утилиты `ClockRes` (<https://docs.microsoft.com/en-us/sysinternals/downloads/clockres>) (часть набора `Sysinternals`). Вот типичный результат в современных версиях Windows:

```
> Clockres.exe
Clockres v2.1 - Clock resolution display utility
Copyright (C) 2016 Mark Russinovich
Sysinternals
```

```
Maximum timer interval: 15.625 ms
Minimum timer interval: 0.500 ms
Current timer interval: 1.000 ms
```

Прежде всего изучим максимальный интервал таймера, который равен 15,625 мс, что соответствует частоте 64 Гц. Это разрешение `DateTime` по умолчанию, когда нет запущенных несистемных приложений. Данное значение может быть изменено *любым приложением* на программном уровне. В примере текущий интервал таймера равен 1 мс (частота 1000 Гц). Но у этого значения есть ограничения: минимальный интервал таймера — 0,5 мс (частота 2000 Гц), а максимальный — 15,625 мс. Текущий интервал таймера может относиться только к указанному диапазону.

Это типичная конфигурация для современной версии Windows. Но в более старых версиях можно увидеть другие значения разрешения. Вот два примера:

- Windows 95/98/Me — 55 мс (мы обсудили это значение в разделе «Аппаратные таймеры», оно получено благодаря NTSC);
- Windows NT/2000/XP — 10 или 15 мс.

Много полезной информации о разных конфигурациях можно найти в [The Windows Timestamp Project].

## API для разрешения системного таймера

Как же изменить разрешение таймера? Для этого существуют API для Windows:

- `timeBeginPeriod`, `timeEndPeriod` из `winmm.dll`;
- `NtQueryTimerResolution`, `NtSetTimerResolution` из `ntdll.dll`.

Их можно использовать напрямую из C#. Представляем вспомогательный класс:

```
public struct ResolutionInfo
{
    public uint Min;
    public uint Max;
    public uint Current;
}

public static class WinApi
{
    [DllImport("winmm.dll",
        EntryPoint = "timeBeginPeriod",
        SetLastError = true)]
    public static extern uint TimeBeginPeriod(uint uMilliseconds);

    [DllImport("winmm.dll",
        EntryPoint = "timeEndPeriod",
        SetLastError = true)]
    public static extern uint TimeEndPeriod(uint uMilliseconds);

    [DllImport("ntdll.dll", SetLastError = true)]
    private static extern uint NtQueryTimerResolution
        (out uint min,
         out uint max,
         out uint current);

    [DllImport("ntdll.dll", SetLastError = true)]
    private static extern uint NtSetTimerResolution
        (uint desiredResolution,
         bool setResolution,
         ref uint currentResolution);

    public static ResolutionInfo QueryTimerResolution()
    {
        var info = new ResolutionInfo();
        NtQueryTimerResolution(out info.Min,
                               out info.Max,
                               out info.Current);

        return info;
    }

    public static ulong SetTimerResolution(uint ticks)
    {

```

```

    uint currentRes = 0;
    NtSetTimerResolution(ticks, true, ref currentRes);
    return currentRes;
}
}

```

Структура данных `ResolutionInfo` представляет минимальное, максимальное и текущее разрешения системного таймера. В статическом классе `WinApi` мы импортируем четыре нужные функции из `winmm.dll` и `ntdll.dll`. Пользовательские методы `QueryTimerResolution` и `SetTimerResolution` являются оберткой для импортированных `NtQueryTimerResolution` и `NtSetTimerResolution`.

Теперь немного разберемся с этим классом. Прежде всего мы можем создать собственный `ClockRes`, основываясь на описанном API:

```

var resolutionInfo = WinApi.QueryTimerResolution();
Console.WriteLine($"Min    = {resolutionInfo.Min}");
Console.WriteLine($"Max    = {resolutionInfo.Max}");
Console.WriteLine($"Current = {resolutionInfo.Current}");

```

Результат (без запущенных приложений):

```

Min      = 156250
Max      = 5000
Current  = 156250

```

Единственное различие между `ClockRes` и нашей программой в том, что `ClockRes` выдает результат в миллисекундах, а мы — в промежутках по 100 нс. `Max = 5000` означает `MaxResolution = 5000 · 100 нс = 0,5 мс`.

Теперь вручную проверим, действительно ли `resolutionInfo.Current` является реальным разрешением `DateTime`. Вот очень простой код, показывающий наблюдаемое поведение `DateTime`:

```

// DateTimeResolutionObserver
for (int i = 0; i < 5; i++)
{
    DateTime current = DateTime.UtcNow;
    DateTime last = current;
    while (last == current)
        current = DateTime.UtcNow;
    TimeSpan diff = current - last;
    Console.WriteLine(diff.Ticks);
}

```

Мы сохраняем текущее значение `DateTime.UtcNow` в файл `current` и ждем следующего значения `DateTime.UtcNow` в цикле `while` (после обновления переменной `last`). Это не самый красивый и правильный способ получить разрешение `DateTime`, но это простая программа, на которую должно влиять реальное разрешение `DateTime`.

Типичный результат (без запущенных приложений):

```
155934
156101
156237
156256
156237
```

А это результат для случая `resolutionInfo.Current = 5000`:

```
5574
4634
5353
5014
4271
```

Как видите, полученные числа не совсем равны 156 250 или 5000. Поэтому разница между двумя последовательными разными значениями `DateTime` примерно равна текущему интервалу таймера.

### Разбираемся с классом WinApi

Запустите в своей системе `ClockRes`. Затем получите минимальное, максимальное и типичное разрешения таймера системы, используя код на C#.

- Попробуйте увеличить или уменьшить текущее разрешение с помощью `SetTimerResolution`. Проверьте новое значение разрешения с помощью `API` и `DateTimeResolutionObserver`.
- Попробуйте изменить текущее разрешение, применив функции `TimeBeginPeriod/TimeEndPeriod`.
- Попробуйте установить для текущего разрешения неработающее значение (меньше минимума или больше максимума).

Изменить это значение, скорее всего, окажется сложно, поскольку другие приложения уже затребовали высокую частоту таймера. Поэтому разумным будет завершить их перед этими экспериментами. Но как узнать, какие приложения меняли разрешение? Нам поможет утилита `powercfg`!

## Анализ системного таймера: `powercfg`

Допустим, текущий интервал вашего таймера не является максимальным. Как вы узнаете, чья в этом вина? Какая программа увеличила частоту системного таймера? Можете проверить это с помощью `powercfg`. Это утилита командной строки, которая помогает контролировать настройки системы энергопотребления. Обычно ее можно найти по адресу `C:\Windows\System32\powercfg.exe`.

Давайте проверим, как это работает. Запустите из профиля администратора следующую команду:

```
> powercfg -energy duration 10
```

Она будет следить за вашей системой в течение 10 с и сгенерирует отчет в HTML (`energy-report.html` в текущей директории) с множеством полезных сведений, включая информацию о разрешении таймера платформы. Вот пример результата:

```
Platform Timer Resolution:Platform Timer Resolution
The default platform timer resolution is 15.6ms (15625000ns)
and should be used whenever the system is idle. If the timer
resolution is increased, processor power management technologies
may not be effective. The timer resolution may be increased due
to multimedia playback or graphical animations.
Current Timer Resolution (100ns units) 5003
Maximum Timer Period (100ns units) 156250
```

```
Platform Timer Resolution: Outstanding Timer Request
A program or service has requested a timer resolution smaller
than the platform maximum timer resolution.
Requested Period 5000
Requesting Process ID 6676
Requesting Process Path
\Device\HarddiskVolume4\Users\akinshin\ConsoleApplication1.exe
```

```
Platform Timer Resolution: Outstanding Timer Request
A program or service has requested a timer resolution smaller
than the platform maximum timer resolution.
Requested Period 10000
Requesting Process ID 10860
Requesting Process Path
\Device\HarddiskVolume4\Program Files (x86)\Mozilla Firefox\firefox.exe
```

Как видите, интервал по умолчанию равен 15,6 мс, Firefox требует интервал 1,0 мс, а `ConsoleApplication1.exe` в домашнем каталоге (которое просто вызывает `WinApi.SetTimerResolution(5000)`) — 0,5 мс. `ConsoleApplication1.exe` победило, и теперь у нас есть максимально возможная частота таймера платформы.

У нас осталась еще одна тема, связанная с системным таймером, — `Thread.Sleep`.

### Упражнение

Запустите все свои любимые приложения и следите за системой в течение 10 с помощью `powercfg`. Изучите отчет и найдите все приложения, запросившие меньшее разрешение таймера.

## Системный таймер и Thread.Sleep

Все сказанное ранее звучит очень интересно, но в чем его практическая ценность? Почему нам должно быть важно разрешение системного таймера? Здесь я хочу задать вам вопрос: что делает следующий вызов?

```
Thread.Sleep(1);
```

Кто-то, вероятно, ответит: вводит текущий поток в состояние ожидания на 1 мс. К сожалению, это неверный ответ. В документации утверждается следующее: «Реальный тайм-аут может быть не равен в точности указанному тайм-ауту, поскольку указанный тайм-аут будет изменен, чтобы совпадать с временными тиками».

На самом деле прошедшее время зависит от разрешения системного таймера. Напишем еще один примитивный бенчмарк (здесь не требуется корректность, мы просто хотим продемонстрировать поведение `Sleep`, поэтому не нужны обычные составляющие бенчмаркинга, такие как прогрев, статистика и т. д.):

```
for (int i = 0; i < 5; i++)
{
    var stopwatch = Stopwatch.StartNew();
    Thread.Sleep(1);
    stopwatch.Stop();
    var time = stopwatch.ElapsedTicks * 1000.0 / Stopwatch.Frequency;
    Console.WriteLine(time + " ms");
}
```

Этот код просто пытается измерить длительность `Thread.Sleep(1)` с помощью `Stopwatch` пять раз. Типичный результат для текущего временного интервала — 15,625 мс:

```
14.8772437280584 ms
15.5369201880125 ms
18.6300283418281 ms
15.5728431635545 ms
15.6129649284456 ms
```

Как видите, протекшие интервалы гораздо длиннее 1 мс. Теперь запустим Firefox, устанавливающий интервал на 1 мс, и повторим этот дурацкий бенчмарк:

```
1.72057056881932 ms
1.48123957592228 ms
1.47983997947259 ms
1.47237546507424 ms
1.49756820116866 ms
```

Firefox повлиял на вызов `Sleep` и уменьшил прошедший интервал примерно в 10 раз. Хорошее объяснение такому поведению `Sleep` можно найти в [The Windows Timestamp Project]:

«Допустим, значение `ActualResolution` установлено на 156 250, прерванное сердцебиение системы запускается периодами в 15,625 мс или на частоте 64 Гц, а вызов `Sleep` сделан с требуемой задержкой 1 мс. Нужно рассмотреть два сценария.

- Вызов был сделан  $< 1$  мс ( $\Delta T$ ) до следующего перерыва. Следующий перерыв не подтвердит, что требуемый период времени истек. Только перерыв после него заставит вызов вернуться. Итоговая задержка состояния ожидания будет равна  $\Delta T + 15,625$  мс.
- Вызов был сделан  $\geq 1$  мс ( $\Delta T$ ) до следующего перерыва. Следующий перерыв заставит вызов вернуться. Итоговая задержка состояния ожидания будет равна  $\Delta T$ ».

Существует много других свойств `Sleep`, но они не относятся к темам, освещаемым в данной книге. Конечно, существуют и другие API для Windows, зависящие от разрешения системного таймера, например `waitableTimer`. Мы не будем обсуждать этот класс подробно. Я просто хочу еще раз порекомендовать вам прочитать о нем в [The Windows Timestamp Project].

## API для проставления отметок времени в Windows: QPC

Основными API для проставления отметок времени с высоким разрешением в Windows являются `QueryPerformanceCounter` (QPC) и `QueryPerformanceFrequency` (QPF). QPC совершенно независим от системного времени и UTC — на него не влияют зимнее время, корректировочные секунды и часовые пояса. Если вам нужны измерения истинного времени с высоким разрешением, используйте `GetSystemTimePreciseAsFileTime` (доступен начиная с Windows 8/Windows Server 2012). Таким образом, это лучший вариант для измерения длительности операции.

Вот несколько важных фактов о QPC в разных версиях Windows.

- QPC доступен в *Windows XP* и *Windows 2000* и хорошо работает в большинстве систем. Однако BIOS некоторых аппаратных систем неправильно указывает характеристики процессора этого устройства (неинвариантный TSC), и некоторые многоядерные или многопроцессорные системы применяли процессоры с TSC, которые нельзя синхронизировать между разными ядрами. Системы с бракованными аппаратно-программными средствами, на которых запускаются эти версии Windows, могут не обеспечивать одинаковое прочтение QPC на разных ядрах, если в качестве основы для QPC использовался TSC.

- Все компьютеры, поставляемые с *Windows Vista* и *Windows Server 2008*, применяли HPET или ACPI PM в качестве основы для QPC.
- Большинство компьютеров с *Windows 7* и *Windows Server 2008 R2* имеют процессоры с TSC постоянного ритма и используют эти счетчики в качестве основы для QPC.
- *Windows 8*, *Windows 8.1*, *Windows Server 2012* и *Windows Server 2012 R2* задействуют TSC в качестве основы для счетчика производительности.

Есть две основные функции для отметок времени с высоким разрешением в `kernel32.dll`, которые можно импортировать в программу на C# со следующими строками:

```
[DllImport("kernel32.dll")]
static extern bool QueryPerformanceCounter(out long value);
```

```
[DllImport("kernel32.dll")]
static extern bool QueryPerformanceFrequency(out long value);
```

Как можно догадаться по названиям, `QueryPerformanceCounter` позволяет получить значение счетчика (с помощью `out long value`), а `QueryPerformanceFrequency` — частоту генератора тиков. Но как это работает? Давайте узнаем!

Рассмотрим простую программу:

```
static void Main()
{
    long ticks;
    QueryPerformanceCounter(out ticks);
}
```

```
[DllImport("kernel32.dll")]
static extern bool QueryPerformanceCounter(out long value);
```

Соберите ее в Release-x64 и откройте исполняемый файл в WinDbg. Между кодом x86 и x64 asm есть разница, но для понимания происходящего хватит и кода x64 asm. Установим точку останова на `KERNEL32!QueryPerformanceCounter` (команда `bp`) и перейдем к ней (команда `g`). Для упрощения из кода убраны префиксы адресов, например `00007ff:`

```
> bp KERNEL32!QueryPerformanceCounter
> g
KERNEL32!QueryPerformanceCounter:
e6ccb720 jmp qword ptr [KERNEL32!QuirkIsEnabled2Worker+0x9ec8 (e6cd16378)]
          ds:00007ffe6cd16378={ntdll!RtlQueryPerformanceCounter (e6d83a7b0)}
```

Если не можете установить точку останова на `KERNEL32!QueryPerformanceCounter`, попробуйте использовать `KERNEL32!QueryPerformanceCounterStub` (в разных версиях Windows разные стили именования):

```
> bp KERNEL32!QueryPerformanceCounterStub
> g
```

```
KERNEL32!QueryPerformanceCounterStub:/
f431f5750 jmp qword ptr [KERNEL32!_imp_QueryPerformanceCounter (f43255290)]
          ds:00007fff43255290={ntdll!RtlQueryPerformanceCounter (f45300ff0)}
```

KERNEL32!QueryPerformanceCounter (или KERNEL32!QueryPerformanceCounterStub) просто переадресовывает нас на ntdll!RtlQueryPerformanceCounter. Рассмотрим дизассемблированный вид этого метода (команда uf):

```
> uf ntdll!RtlQueryPerformanceCounter
ntdll!RtlQueryPerformanceCounter:
e6d83a7b0 push    rbx
e6d83a7b2 sub     rsp,20h

; Проверка специальной отметки
e6d83a7b6 mov     al,byte ptr [SharedUserData+0x3c6 (e03c6)]
e6d83a7bd mov     rbx,rcx
e6d83a7c0 cmp     al,1
e6d83a7c2 jne    ntdll!RtlQueryPerformanceCounter+0x44 (e6d83a7f4)

; Быстрая версия rdtsc
ntdll!RtlQueryPerformanceCounter+0x14:
e6d83a7c4 mov    rcx,qword ptr [SharedUserData+0x3b8 (e03b8)]
e6d83a7cc rdtsc
e6d83a7ce shl    rdx,20h
e6d83a7d2 or     rax,rdx
e6d83a7d5 mov    qword ptr [rbx],rax
e6d83a7d8 lea   rdx,[rax+rcx]
e6d83a7dc mov    c1,byte ptr [SharedUserData+0x3c7 (e03c7)]
e6d83a7e3 shr    rdx,c1
e6d83a7e6 mov    qword ptr [rbx],rdx

ntdll!RtlQueryPerformanceCounter+0x39:
e6d83a7e9 mov    eax,1
e6d83a7ee add    rsp,20h
e6d83a7f2 pop    rbx
e6d83a7f3 ret

; Медленная версия syscall
ntdll!RtlQueryPerformanceCounter+0x44:
e6d83a7f4 lea   rdx,[rsp+40h]
e6d83a7f9 lea   rcx,[rsp+38h]
e6d83a7fe call  ntdll!NtQueryPerformanceCounter (e6d8956f0)
e6d83a803 mov    rax,qword ptr [rsp+38h]
e6d83a808 mov    qword ptr [rbx],rax
e6d83a80b jmp   ntdll!RtlQueryPerformanceCounter+0x39 (e6d83a7e9)
```

В [SharedUserData+0x3c6 (e03c6)] есть специальная отметка, определяющая, какой алгоритм QPC будет применяться. Если все в порядке — мы работаем на современном устройстве с инвариантным TSC и можем использовать его напрямую, — переходим

к быстрому алгоритму (`ntdll!RtlQueryPerformanceCounter+0x14`). Если нет, вызовем `ntdll!NtQueryPerformanceCounter`, создающий системный вызов `syscall`:

```
> uf ntdll!NtQueryPerformanceCounter
```

```
ntdll!NtQueryPerformanceCounter:
```

```
e6d8956f0  mov     r10,rcx
e6d8956f3  mov     eax,31h
e6d8956f8  test   byte ptr [SharedUserData+0x308 (e0308)],1
e6d895700  jne    ntdll!NtQueryPerformanceCounter+0x15 (e6d895705)
```

```
ntdll!NtQueryPerformanceCounter+0x12:
```

```
e6d895702  syscall
e6d895704  ret
```

```
ntdll!NtQueryPerformanceCounter+0x15:
```

```
e6d895705  int     2Eh
e6d895707  ret
```

Важный факт о быстром алгоритме (`ntdll!RtlQueryPerformanceCounter+0x14`): он вызывает `RDTC` напрямую, без системных вызовов. Это позволяет обеспечить малую длительность в простых ситуациях, когда можно применять `TSC` без каких-то проблем.

Еще один интересный факт: `QPC` использует смещенное значение `RDTC` — он помещает полное значение счетчика в `rdx`, а затем производит `shr rdx, c1`, где `c1` обычно равен `0xA`. Таким образом, 1 тик `QPC` равен 1024 тикам `rdtsc`. То же самое можно сказать и о `QPF`: номинальная частота Windows для измерений высокой точности в 1024 раза меньше частоты `RDTC`.

Примечание: в современном мире версии Windows меняются очень быстро, поэтому можно получить разные значения `asm` в различных версиях Windows на разных устройствах.

### Упражнение

Попытайтесь повторить этот эксперимент и объяснить полученный код сборки.

## API для проставления отметок времени в Unix

В Unix существует множество временных функций:

- Linux — `clock_gettime`, `clock_settime`, `clock_getres` ([http://man7.org/linux/man-pages/man2/clock\\_gettime.2.html](http://man7.org/linux/man-pages/man2/clock_gettime.2.html));
- macOS — `mach_absolute_time`, `mach_timebase_info` ([https://developer.apple.com/library/mac/#qa/qa1398/\\_index.html](https://developer.apple.com/library/mac/#qa/qa1398/_index.html));
- Oracle Solaris — `gethrtime` ([https://docs.oracle.com/cd/E23824\\_01/html/821-1465/gethrtime-3c.html](https://docs.oracle.com/cd/E23824_01/html/821-1465/gethrtime-3c.html));

- PowerPC — `read_real_time` (<http://ps-2.kev009.com/tl/techlib/manuals/adoclib/aixprgdd/genprog/highrest.htm>);
- все системы Unix — `gettimeofday`, `settimeofday` (<http://linux.die.net/man/2/gettimeofday>).

Давайте кратко обсудим некоторые из них.

## clock\_gettime, clock\_settime, clock\_getres

В Linux существуют следующие полезные функции для проставления отметок времени:

```
int clock_getres(clockid_t clock_id, struct timespec *res);
int clock_gettime(clockid_t clock_id, struct timespec *tp);
int clock_settime(clockid_t clock_id, const struct timespec *tp);
```

Вот полезная информация из документации: «Функция `clock_getres()` находит разрешение (точность) указанного `clock_id` и, если `res` ненулевое, сохраняет его в структуре `timespec`, указанной `res`. Разрешение таймера зависит от реализации и не может быть конфигурировано конкретным процессом. Если значение времени, указанное с помощью аргумента `tp` `clock_settime()`, не является кратным `res`, оно округляется до кратного `res`. Функции `clock_gettime()` и `clock_settime()` выводят и устанавливают время определенного таймера `clk_id`».

`clock_gettime` позволяет получить значение `timespec`:

```
struct timespec {
    time_t tv_sec; /* секунды */
    long tv_nsec; /* наносекунды */
};
```

У структуры `timespec` два поля: `tv_sec` для секунд и `tv_nsec` для наносекунд. Поэтому минимальным возможным разрешением функций, выдающих `timespec`, является 1 нс.

Аргумент `clock_id` является ID нужного нам таймера. Вот некоторые его типичные значения:

- `CLOCK_REALTIME` — общесистемный таймер реального времени. Его установка требует соответствующих прав доступа;
- `CLOCK_REALTIME_COARSE` — более быстрая, но менее точная версия `CLOCK_REALTIME`. Используйте, если вам нужны очень быстрые, но не идеально детализированные отметки времени. Доступно начиная с Linux 2.6.32;
- `CLOCK_MONOTONIC` — таймер, который нельзя переустановить, он представляет монотонное время, начиная с некой неопределенной стартовой точки;
- `CLOCK_MONOTONIC_COARSE` — более быстрая, но менее точная версия `CLOCK_MONOTONIC`. Используйте, если вам нужны очень быстрые, но не идеально детализированные отметки времени. Доступно начиная с Linux 2.6.32;

- `CLOCK_MONOTONIC_RAW` — похоже на `CLOCK_MONOTONIC`, но предоставляет доступ к необработанному времени, основанному на аппаратных средствах и не подвергшемуся изменениям NTP или увеличениям, производимым `adjtime(3)`. Доступно начиная с Linux 2.6.28;
- `CLOCK_BOOTTIME` — идентично `CLOCK_MONOTONIC`, но также включает время режима ожидания системы. Доступно начиная с Linux 2.6.39;
- `CLOCK_PROCESS_CPUTIME_ID` — таймер высокой точности для каждого процесса от процессора;
- `CLOCK_THREAD_CPUTIME_ID` — счетчик времени процессора, специфичный для отдельных потоков.

Для отметок времени высокой точности нужно использовать `CLOCK_MONOTONIC` (если этот вариант доступен на вашем устройстве), но есть и другие опции, например `CLOCK_REALTIME` для таймера реального времени или `CLOCK_THREAD_CPUTIME_ID` для счетчика времени процессора, специфичного для отдельных потоков.

Пример применения:

```
struct timespec ts;
uint64_t timestamp;
clock_gettime(CLOCK_MONOTONIC, &ts);
timestamp = (static_cast<uint64_t>(ts.tv_sec) * 1000000000) +
            static_cast<uint64_t>(ts.tv_nsec);
```

С точки зрения внутреннего устройства функция `clock_gettime(CLOCK_MONOTONIC...)` основана на текущем аппаратном таймере высокой точности (обычно это TSC, но может быть и HPET или ACPI PM).

Чтобы уменьшить длительность `clock_gettime`, ядро Linux использует `vsyscalls` (виртуальные системные вызовы) и `VDSOs` (виртуальные динамически связанные общие объекты) вместо прямого системного вызова `syscall`.

Если доступен инвариантный TSC, `clock_gettime(CLOCK_MONOTONIC...)` будет применять его напрямую с помощью команды `rdtsc`. Конечно, это добавит некоторые ограничения, но в целом стоит брать `clock_gettime` вместо `rdtsc`, поскольку это решает многие проблемы с переносимостью<sup>1</sup>.

`clock_gettime` доступна на macOS, начиная с версии macOS 10.12 Sierra.

<sup>1</sup> В хранилище Linux есть интересная запись: «x86: tsc мешает времени течь в обратном направлении» (<https://github.com/torvalds/linux/commit/d8bb6f4c1670c8324e4135c61ef07486f7f17379>).

## mach\_absolute\_time

Если вам нужно написать переносимый код, поддерживающий старые версии macOS (до версии 10.12), основным API для проставления отметок времени будет `mach_absolute_time`. Эта функция выдает тики в виде беззнаковых 64-битных целых чисел.

Для перехода от этих тиков к реальному времени нужна следующая структура:

```
struct mach_timebase_info {
    uint32_t numer;
    uint32_t denom;
};
```

Получить `mach_timebase_info` для вашей системы можно с помощью функции `mach_timebase_info`. Если умножить количество тиков на `numer` и затем разделить на `denom`, вы получите время в наносекундах.

Пример использования:

```
mach_timebase_info_data_t timebase;
mach_timebase_info(&timebase);
uint64_t timestamp = mach_absolute_time();
uint64_t timestampInNanoseconds = timestamp * timebase.numer / timebase.denom;
```

## gettimeofday

Функция `gettimeofday` доступна почти везде и позволяет получить текущие дату и время, а также часовой пояс. Мы можем установить текущие дату и время с помощью функций `settimeofday`. Вот их сигнатуры:

```
int gettimeofday(struct timeval *tv, struct timezone *tz);
int settimeofday(const struct timeval *tv, const struct timezone *tz);
```

Функции работают со структурой `timeval`, похожей на `timespec`:

```
struct timeval {
    time_t tv_sec; /* секунды */
    suseconds_t tv_usec; /* микросекунды */
};
```

Будьте внимательны: первое поле в обоих типах — секунды, а второе — наносекунды в `timespec` и микросекунды в `timeval`. Минимальное возможное разрешение `gettimeofday` — 1 нс.

Пример использования:

```
struct timeval tv;
if (gettimeofday(&tv, NULL) == 0)
{
    return tv.tv_sec * 1000000000 +
           tv.tv_usec * 1000; // наносекунды
}
```

## Подводя итог

В этом разделе мы узнали много полезной информации о программных таймерах. Давайте вкратце ее повторим.

В Windows существует три группы API для проставления отметок времени: системный таймер, системные тики и таймер высокого разрешения.

Системный таймер используется для функций WinAPI, например `GetSystemTime`, `GetLocalTime` и `GetSystemTimeAsFileTime`. У него невысокая корректность. Обычно его разрешение между 0,500 и 15,625 мс. Это значение можно изменить вручную с помощью `timeBeginPeriod/timeEndPeriod` или `NtQueryTimerResolution/NtSetTimerResolution`. Текущие значения можно получить с помощью `ClockRes`, а `powercfg` поможет получить список приложений, которые пытаются изменить это значение. `Thread.Sleep` также задействует системный таймер скрытно, поэтому `Thread.Sleep(1)` может легко дойти до 15 мс.

Системные тики могут быть получены с помощью функций WinAPI `GetTickCount` и `GetTickCount64`.

Для измерений высокой точности можно использовать `QueryPerformanceCounter` и `QueryPerformanceFrequency` (для API в режиме ядра следует применять `KeQueryPerformanceCounter`). Если вам нужно получить текущие дату и время с максимальным уровнем точности, следует использовать `GetSystemTimePreciseAsFileTime`.

В Unix много API для проставления отметок времени: `clock_gettime`, `clock_gettime`, `clock_getres`, `mach_absolute_time`, `mach_timebase_info`, `gethrtime`, `read_real_time`, `gettimeofday` и `settimeofday`. Некоторые из них доступны только в конкретных дистрибутивах Unix. Наилучшим вариантом для Linux является `clock_gettime` (он доступен, если определено `HAVE_CLOCK_MONOTONIC`). Лучший вариант для macOS — `mach_absolute_time` (он доступен, если определено `HAVE_MACH_ABSOLUTE_TIME`, начиная с версии 10.12, в macOS доступен и `clock_gettime`). `Gettimeofday` доступен почти везде, так что это хороший запасной вариант, но у этого API корректность хуже, чем у `clock_gettime` и `mach_absolute_time`.

Теперь мы знаем, какие API для проставления отметок времени можно найти в разных операционных системах. А что можно сказать об управляемых API? Давайте проверим, что можно найти на платформе .NET!

## API для проставления отметок времени на платформе .NET

В этом разделе рассмотрим три основных API для проставления отметок времени на платформе .NET:

- `DateTime.UtcNow`;
- `Environment.TickCount`;
- `Stopwatch.GetTimestamp`.

Кратко обсудим использование и внутреннее устройство каждого из этих API. Подробный обзор исходного кода для .NET Framework, .NET Core и Mono находится в приложении к данной книге. Мы также произведем бенчмаркинг каждого из API и вычислим их длительность и разрешение. Исходный код бенчмарков также есть в приложении. Для представленных здесь значений была применена следующая конфигурация.

**Настройки бенчмарка.** Устройство (одно и то же для всех бенчмарков) — Mac mini, Intel Core i7-3615QM CPU 2.30GHz (Ivy Bridge). Операционные системы — Windows 10.0.15063.1155, macOS High Sierra 10.13.4, Ubuntu 16.04. Среда исполнения — .NET Framework 4.6 (CLR 4.0.30319.42000), Mono 5.12.0, .NET Core 1.1.8, .NET Core 2.1.0. Аппаратные таймеры — TSC, HPET, ACPI PM. Интервал таймера текущего времени Windows (CTI) — 5000, 156 250. Для бенчмаркинга используется BenchmarkDotNet v0.10.14. Исходный код всех бенчмарков и подробные результаты можно найти в приложении.

Рекомендуем попробовать запустить каждый бенчмарк в вашем собственном окружении и затем объяснить результаты.

Этот раздел поможет понять внутреннее устройство API и их базовые характеристики, которые могут повлиять на показатели.

### `DateTime.UtcNow`

`System.DateTime` — широко используемый тип для .NET. Многие разработчики постоянно его применяют, но не все знают, как он работает на самом деле. Структура `Dateime` представляет момент времени, обычно выражаемый в форме даты и времени. Вот некоторые важные свойства `Dateime`.

- `int Year`, `int Month`, `int Day`, `int Hour`, `int Minute`, `int Second`, `int Millisecond` — получают соответствующие компоненты даты, представленные данным моментом. Все значения являются неотрицательными.

- `long Ticks` — получает количество тиков, представляющих дату и время данного момента, выраженные в виде значения в диапазоне между `DateTime.MinValue.Ticks` и `DateTime.MaxValue.Ticks`. Один тик равняется 100 нс. Количество тиков показывает количество промежутков в 100 нс, прошедших с 00:00:00 1 января 1 года (0:00:00 UTC 1 января 1 года по григорианскому календарю).
- `DateTimeKind Kind` — получает значение, указывающее, основано ли время, представленное данным моментом, на локальном времени (`DateTimeKind.Local`), UTC (`DateTimeKind.Utc`) или ни на том ни на другом `DateTimeKind.Unspecified`).

`DateTime` предоставляет два важных свойства: `UtcNow` (текущие дата и время на локальном компьютере по UTC) и `Now` (текущие *локальные* дата и время на локальном компьютере). `DateTime.Now` основан на `DateTime.UtcNow`, поэтому мы сосредоточимся только на `DateTime.UtcNow`.

Определить разницу между двумя типами `DateTime` можно с помощью класса `TimeSpan`:

```
DateTime a = DateTime.UtcNow;
// <Измеряемая логика>
DateTime b = DateTime.UtcNow;
TimeSpan span = b - a;
```

Некоторые из важных свойств `TimeSpan`.

- `int Days`, `int Hours`, `int Minutes`, `int Seconds`, `int Milliseconds` — соответствуют таким же свойствам `DateTime`. Будьте внимательны: эти значения представляют *соответствующий компонент времени*. Поэтому диапазон значений секунд составляет  $-59 \dots 59$ , а миллисекунд —  $-999 \dots 999$ .
- `double TotalDays`, `double TotalHours`, `double TotalMinutes`, `double TotalSeconds`, `double Milliseconds`, `long Ticks` — выражают все прошедшее время в конкретном временном промежутке.

Пример измерений с помощью `DateTime`:

```
DateTime start = DateTime.UtcNow;
// Логика
DateTime end = DateTime.UtcNow;
TimeSpan elapsed = end - start;
Console.WriteLine(elapsed.TotalMilliseconds);
```

С точки зрения внутреннего устройства он использует разные собственные API в зависимости от окружения:

- Windows, .NET Framework/.NET Core 1.x/Mono — `GetSystemTimeAsFileTime`;
- Windows, .NET Core 2.x — `GetSystemTimePreciseAsFileTime` (если он доступен) или `GetSystemTimeAsFileTime` (запасной вариант);

- Unix, .NET Core 1.x/Mono — `gettimeofday`;
- Unix, .NET Core 2.x — `clock_gettime` (если он доступен) или `gettimeofday` (запасной вариант).

Начиная с версии .NET Core 2.0, было решено использовать `GetSystemTimePreciseAsFileTime` вместо `GetSystemTimeAsFileTime` для улучшения корректности (см. [coreclr#5061](https://github.com/dotnet/coreclr/issues/5061) (<https://github.com/dotnet/coreclr/issues/5061>) и [coreclr#9736](https://github.com/dotnet/coreclr/pull/9736) (<https://github.com/dotnet/coreclr/pull/9736>)). Но появилась другая проблема: в неправильно сконфигурированных системах `GetSystemTimePreciseAsFileTime` смещается и выдает неправильные результаты (см. [coreclr#14187](https://github.com/dotnet/coreclr/issues/14187) (<https://github.com/dotnet/coreclr/issues/14187>)). Поэтому решили создать обходной путь (см. [coreclr#14283](https://github.com/dotnet/coreclr/pull/14283) (<https://github.com/dotnet/coreclr/pull/14283>)) — теперь .NET Core проверяет, можно ли доверять `GetSystemTimePreciseAsFileTime`. Если `GetSystemTimePreciseAsFileTime` смещен, среда исполнения берет в качестве запасного варианта `GetSystemTimeAsFileTime`.

Теперь измерим разрешение и длительность `DateTime.UtcNow`:

```
[Benchmark]
public long DateTimeNowLatency() => DateTime.Now.Ticks;

[Benchmark]
public long DateTimeNowResolution()
{
    long lastTicks = DateTime.Now.Ticks;
    while (DateTime.Now.Ticks == lastTicks)
    {
    }
    return lastTicks;
}

[Benchmark]
public long DateTimeUtcNowLatency() => DateTime.UtcNow.Ticks;

[Benchmark]
public long DateTimeUtcNowResolution()
{
    long lastTicks = DateTime.UtcNow.Ticks;
    while (DateTime.UtcNow.Ticks == lastTicks)
    {
    }
    return lastTicks;
}
```

Результаты этих бенчмарков представлены в табл. 9.4 («\*» означает любую среду исполнения, СТИ — текущий интервал системного таймера). Помните, что это всего лишь один пример возможных показателей в конкретных условиях. На вашем устройстве могут получиться другие результаты.

Таблица 9.4. Разрешение и длительность `DateTime.UtcNow`

ОС	Среда исполнения	Окружение	Разрешение, мкс	Длительность, нс
Windows	.NET Framework	TSC, CTI = 5000	500	6–7
Windows	.NET Framework	TSC, CTI = 156 250	15 625	6–7
Windows	Mono	TSC, CTI = 5000	500	19–20
Windows	Mono	TSC, CTI = 156 250	15 625	19–20
Windows	.NET Core 1.x	TSC, CTI = 5000	500	6–7
Windows	.NET Core 1.x	TSC, CTI = 156 250	15 625	6–7
Windows	.NET Core 2.x	TSC	0,4–0,5	18–19
macOS	*	TSC	1	36–40
Linux	Mono	TSC	1	26–30
Linux	.NET Core 1.x	TSC	1	26–30
Linux	.NET Core 2.x	TSC	0,1	26–30
Linux	*	HPET/ACPI PM	1,8–1,9	900–950

Эти числа и знание внутреннего устройства `DateTime.UtcNow` позволяют прийти к некоторым важным выводам.

- В Windows разрешение равно Windows CTI (за исключением .NET Core 2.0). Обычно оно составляет примерно 0,5... 15,625 мс и может быть изменено любым приложением.
- В Linux разрешение равно 1 мкс (за исключением .NET Core 2.0). Как упоминалось ранее, в Linux `DateTime.UtcNow` использует функцию `gettimeofday`. Она позволяет получить время в микросекундах. Поэтому 1 мкс — минимально возможное разрешение.
- В .NET Core 2.0 реализация `DateTime.UtcNow` изменилась — теперь он использует `GetSystemTimePreciseAsFileTime` в Windows и `clock_gettime(CLOCK_REALTIME)` в Unix. Поэтому разрешение снизилось до 0,4... 0,5 мкс в Windows и 0,1 мкс в Linux.

Как вы могли заметить, показаны только результаты `DateTime.UtcNow`. Попробуйте повторить эти бенчмарки с `DateTime.Now` в своем окружении и объяснить результаты.

Обычно `DateTime` — это правильный выбор, если вам нужно знать реальное текущее время (например, для журнала событий), но не требуется высокая точность. Следует понимать, что показатели могут быть испорчены, если текущее время меняется при измерениях (подробнее об этом — в следующем разделе). Если вам нужно измерить какой-то промежуток времени, а не просто поставить приблизительную отметку в файле журнала, наверное, стоит выбрать API лучше. Так что проверим, какие еще виды API для проставления отметок у нас есть. Следующий называется `Environment.TickCount`.

## Environment.TickCount

`System.Environment.TickCount` выдает количество миллисекунд, прошедших с момента запуска системы. Измерить количество прошедших миллисекунд для некоей логики можно с помощью следующего кода:

```
int start = Environment.TickCount;
// <Измеряемая логика>
int end = Environment.TickCount;
int elapsedMilliseconds = end - start;
```

Внутренняя реализация зависит от ОС и среды исполнения.

- В Windows `TickCount` просто вызывает функцию WinAPI `GetTickCount64`.
- В Unix + .NET Core он использует функции `clock_gettime()`, `mach_absolute_time()`, `gethrtime()`, `read_real_time()`, `gettimeofday()`.
- В Unix + Mono применяет `mono_100ns_gettime()` — `get_boot_time()`.

Номинальное разрешение всегда равно 1 мс, а номинальная частота — 1 кГц.

Теперь измерим разрешение и длительность `Environment.TickCount`:

```
[Benchmark]
public long TickCountLatency() => Environment.TickCount;
```

```
[Benchmark]
public long TickCountResolution()
{
    long lastTimestamp = Environment.TickCount;
    while (Environment.TickCount == lastTimestamp)
    {
    }
    return lastTimestamp;
}
```

Результаты этих бенчмарков представлены в табл. 9.5. Помните, что это всего лишь один пример возможных показателей в конкретных условиях. На вашем устройстве могут получиться другие результаты.

Эти числа и знание внутреннего устройства `Environment.TickCount` позволяют прийти к некоторым важным выводам.

- Разрешение в Windows равно 15,625 мс при любой среде исполнения. Вы могли заметить, что это не целое число. Реальная разница между двумя последовательными вызовами `TickCount` — это всегда целое число (обычно 0, 15 или 16). Технически измерить временной промежуток 15,625 мс с помощью значений двух отметок времени нельзя. Но это точное значение между двумя увеличениями числа на счетчике.

- Разрешение в macOS равно 1 мс для любой среды исполнения.
- Разрешение в Linux равно 3,9... 4,0 мс для любой среды исполнения.
- Длительность не очень велика. В Windows с .NET Core и .NET Framework она составляет 2...3 нс. Но в некоторых окружениях может достигать 80 нс (например, macOS + .NET Core 2.x).

Таблица 9.5. Разрешение и длительность Environment.TickCount

ОС	Среда исполнения	Разрешение, мс	Длительность, нс
Windows	.NET Framework	15,625	2–3
Windows	.NET Core	15,625	2–3
Windows	Mono	15,625	11–12
macOS	Mono	1	30–40
macOS	.NET Core 1.x	1	30–40
macOS	.NET Core 2.x	1	70–80
Linux	Mono	3,9–4,0	12–20
Linux	.NET Core	3,9–4,0	8–10

Хорошо, мы поняли, что `Environment.TickCount` — тоже не лучший API для представления отметок при бенчмаркинге. Теперь пора обсудить самый мощный из API — `Stopwatch`!

## Stopwatch.GetTimestamp

Класс `Stopwatch` является лучшим инструментом для измерений времени высокой точности в .NET. Мы уже многократно его использовали, поэтому просто вспомним основные случаи применения. Пара методов `StartNew()/Stop()` позволяет измерять время любой операции:

```
// Простое измерение времени
Stopwatch stopwatch = Stopwatch.StartNew();
// <Измеряемая логика>
stopwatch.Stop();
```

Потом мы можем получить данные о прошедшем времени с помощью `Elapsed`, `ElapsedMilliseconds` или `ElapsedTicks`:

```
// Прошедшее время в разных единицах измерения
TimeSpan elapsed = stopwatch.Elapsed;
long elapsedMilliseconds = stopwatch.ElapsedMilliseconds;
long elapsedTicks = stopwatch.ElapsedTicks;
double elapsedNanoseconds = stopwatch.ElapsedTicks * 1_000_000_000.0 /
    Stopwatch.Frequency;
```

После этого можем перезапустить `Stopwatch` и применять его снова без дополнительных размещений:

```
// Использование уже существовавшего Stopwatch
stopwatch.Restart();
// <Измеряемая логика>
stopwatch.Stop();
```

С точки зрения внутреннего устройства он вызывает `Stopwatch.GetTimestamp()`, который можно использовать напрямую. Таким образом, мы можем сравнить несколько отметок времени без копий `Stopwatch`:

```
// Измерения без копии Stopwatch
long timestamp1 = Stopwatch.GetTimestamp();
// <Измеряемая логика>
long timestamp2 = Stopwatch.GetTimestamp();
double elapsedSeconds = (timestamp2 - timestamp1) * 1.0 /
    Stopwatch.Frequency;
```

Реализация зависит от операционной системы и среды исполнения:

- *Windows (.NET Framework, .NET Core, Mono)* — функции `WinAPI QueryPerformanceFrequency` и `QueryPerformanceCounter`;
- *Linux (.NET Core, Mono)* — в качестве основного инструмента использует `clock_gettime` (запасной — `gettimeofday`);
- *macOS (.NET Core 2.0.x, .NET Core 2.1.0-2.1.2)* — в качестве основного инструмента применяет `clock_gettime` (запасные — `mach_absolute_time` и `gettimeofday`);
- *macOS (.NET Core 1.x, .NET Core 2.1.3+, Mono)* — в качестве основного инструмента использует `mach_absolute_time` (запасной — `gettimeofday`).

В .NET Core 2.0 появилась интересная проблема (см. [corefx#30391](https://github.com/dotnet/corefx/issues/30391) (<https://github.com/dotnet/corefx/issues/30391>)). В .NET Core 1.0 существовала следующая реализация `Stopwatch.GetTimestamp()`: мы пытались вызвать `clock_gettime`, затем — `mach_absolute_time` (если `clock_gettime` был недоступен), а далее вызывали `gettimeofday` (если `mach_absolute_time` был недоступен). `clock_gettime` доступен в macOS, начиная с версии macOS 10.12. .NET Core 1.0 поддерживает macOS 10.11<sup>1</sup>, поэтому она компилировалась на основе SDK macOS 10.11, где не поддерживается `clock_gettime`. В итоге .NET Core 1.0 использует `mach_absolute_time` в качестве временного ресурса для `Stopwatch.GetTimestamp()`. В .NET Core 2.0 было решено убрать поддержку macOS 10.11: теперь поддерживается только macOS 10.12+<sup>2</sup>. .NET Core 2.0 компилировалась на основе SDK macOS 10.12, где поддерживается `clock_gettime`. Таким образом, без каких-либо изменений в исходном коде основным временным ресурсом для `Stopwatch.GetTimestamp()` становится `clock_gettime`.

<sup>1</sup> См. <https://github.com/dotnet/core/blob/master/release-notes/1.0/1.0-supported-os.md>.

<sup>2</sup> См. <https://github.com/dotnet/core/blob/master/release-notes/2.0/2.0-supported-os.md>.

К сожалению, у него более низкая корректность, чем у `mach_absolute_time` в macOS: разрешение по умолчанию `clock_gettime` равно 1000 нс. Эта проблема была исправлена в .NET Core 3.0 (см. `coreclr#18505` (<https://github.com/dotnet/coreclr/pull/18505>) и `corefx#30457` (<https://github.com/dotnet/corefx/pull/30457>)). Исправление было бэкпортировано в .NET 2.1.3 (но оно недоступно в .NET Core 2.0.x).

Значение `Stopwatch.Frequency` зависит и от окружения:

- *Windows (.NET Framework, .NET Core) с включенным HPET* — частота TSC, деленная на 1024 (обычно около  $2 \cdot 10^6 \dots 4 \cdot 10^6$ );
- *Windows (.NET Framework, .NET Core) с отключенным HPET* — 14 318 180;
- *Windows/Linux/macOS (Mono)* —  $10^7$ ;
- *Linux/macOS (.NET Core)* —  $10^9$ .

Теперь измерим разрешение и длительность `Stopwatch`:

```
[Benchmark]
public long StopwatchLatency() => Stopwatch.GetTimestamp();
```

```
[Benchmark]
public long StopwatchResolution()
{
    long lastTimestamp = Stopwatch.GetTimestamp();
    while (Stopwatch.GetTimestamp() == lastTimestamp)
    {
    }
    return lastTimestamp;
}
```

Результаты этих бенчмарков представлены в табл. 9.6 («\*» означает любую среду исполнения). Помните, что это всего лишь один пример возможных показателей в конкретных условиях. На вашем устройстве могут получиться другие результаты.

Эти числа и знание внутреннего устройства `Stopwatch` позволяют прийти к некоторым важным выводам.

- *Windows + TSC* — в этом случае мы получаем  $\text{Resolution} \approx (1 \text{ c} / \text{Stopwatch.Frequency}) \approx (1 \text{ c} / (\text{rdstc Frequency} / 1024))$ .
- *HPET/ACPI PM* — бенчмарки показывают, что  $\text{Resolution} \approx 2 \cdot \text{Latency}$ , поскольку мы вызываем `Stopwatch.GetTimestamp` как минимум дважды за один вызов метода `Resolution`. Трудно сказать что-то о реальном разрешении, поскольку количество тиков HPET или ACPI PM гораздо меньше, чем длительность. При использовании на практике можно предположить, что разрешение имеет тот же порядок, что и длительность.
- *macOS/Linux + TSC* — в Mono `Resolution` составляет 100 нс, поскольку это значение 1 тика и его можно достичь. В .NET Core 1 тик равен 1 нс и используется

`rdtsc`, работающий с частотой — в данном примере — 2,3 ГГц. Таким образом, ситуация похожа на случай с HPET или ACPI PM: длительность гораздо больше, чем разрешение. Поэтому сложно оценить его с помощью микробенчмарка.

**Таблица 9.6.** Разрешение и длительность Stopwatch

ОС	Среда исполнения	Таймер	Разрешение, нс	Длительность, нс
Windows	*	TSC	400–500	15–25
Windows	*	HPET	1800–1900	900–950
macOS	Mono	TSC	100	30–40
macOS	.NET Core 1.x	TSC	70–80	30–40
macOS	.NET Core 2.0.x	TSC	1000	90–100
macOS	.NET Core 2.1.3+	TSC	70–80	30–40
Linux	Mono	TSC	100	25–30
Linux	.NET Core	TSC	70–80	30–40
Linux	*	HPET/ACPI PM	1800–1900	900–950

`Stopwatch` — лучший из доступных API для измерений высокой точности в .NET, но это не означает, что все измерения на основе `Stopwatch` верны. Зная его внутреннее устройство, вы можете не только получить сырые числа, но и правильно их интерпретировать и оценить погрешности.

## Подводя итог

В .NET есть несколько способов проставить отметки времени.

- `Stopwatch` является лучшим решением, когда нужны отметки высокой точности. При выключенном HPET его обычное разрешение — около 300... 500 нс в Windows и 70... 100 нс в Linux/macOS. При включенном HPET ситуация ухудшается, поскольку реальное разрешение увеличивается до ~ 2000 нс.
- `Environment.TickCount` — лучшее решение для Windows, если вам не очень важна точность ( $\pm 1$  с достаточно), но нужна очень малая длительность (2–3 нс).
- `DateTime.Now/DateTime.UtcNow` — лучшее решение, когда вам не очень важна точность и нужно связать отметки времени и реальное время (например, для журнала событий).

Поэтому, если вы хотите написать правильный бенчмарк, лучше всего дружить со `Stopwatch`. Однако для создания точных бенчмарков и получения правильных результатов требуется еще много рутинных действий.

## Подводные камни при проставлении отметок времени

API для проставления отметок времени кажутся простыми, но использовать их правильно не всегда легко. В этом разделе мы обсудим самые распространенные ошибки, которые совершают разработчики, применяющие `DateTime`, `Environment.TickCount` и `Stopwatch`.

### Низкое разрешение

Разрешение отметок времени зависит от разных факторов, включая среду исполнения и ОС. В общем, можно ожидать появления следующих значений:

- `DateTime.UtcNow` — 0,1... 15 625 мкс;
- `Environment.TickCount` — 1000... 15 625 мкс;
- `Stopwatch.GetTimestamp` — 0,07... 2 мкс.

Если разрешение отметок времени равно  $q$ , то итоговая случайная погрешность измерений составит примерно  $\pm 2q$  (потому что у нас две отметки времени: до и после). Таким образом, если измеряемая операция занимает несколько минут, волноваться о разрешении таймера не стоит. Но если она длится несколько наносекунд, погрешность слишком высока. Даже 1000 повторений операции не спасут: в худшем случае разрешение `Stopwatch` равно 2 мкс, то есть мы получим ошибку  $\pm 4$  нс.

### Переполнение счетчика

Все счетчики API для проставления отметок времени представлены целочисленными типами и могут справиться лишь с ограниченным количеством значений. Конечно, в любой момент может произойти переполнение счетчика. Проверим, нужно ли нам об этом беспокоиться.

- **DateTime.**

Свойство `DateTime.Tick` содержит количество тиков с 1 января 1 года. Один тик равняется 100 нс. Тип этого свойства — `long`. Максимальное значение `long`  $\approx 9,22 \cdot 10^{18}$  нс. Но реальное максимальное значение `DateTime.Tick` составляет  $\approx 3,6 \cdot 10^{18}$  нс (в три раза меньше). Оно соответствует 23:59:59 31 декабря 9999 года. Таким образом, о переполнении счетчика не нужно будет волноваться еще 8000 лет.

- **Environment.TickCount.**

`TickCount` выдает значение `int`, которое может включать в себя отметки до  $(2^{31} - 1)$  мс, или 49 суток 17 ч 2 мин 47 с 295 мс. Если вы пишете систему, период непрерывной работы которой составит несколько месяцев, `Environment.TickCount` не самый подходящий инструмент для измерения времени. Некоторые разработчики думают, что `TickCount` равен 0 в загрузке системы. Но это не всегда верно, и ПО не должно использовать этот факт. Чтобы найти неверное применение `TickCount`, отладочные сборки Windows берут в качестве начального значения один час до перезагрузки 32-битного таймера (подробности см. в [Chen, 2014]).

- **Stopwatch.**

Теоретически длительность 1 тика `Stopwatch` может быть спорной. На практике минимальное используемое значение — 1 нс (`.NET Core + Unix`). `Stopwatch.GetTimestamp()` выдает значение `long`, что означает: он может работать  $\approx 9,22 \cdot 10^{18}$  нс, то есть примерно 292 года. Таким образом, проблемы переполнения в `Stopwatch` не возникнет.

Единственный API для проставления отметок времени, который может столкнуться с проблемой переполнения счетчика, — это `Environment.TickCount`. Он может работать с интервалами около 50 дней. Вы можете использовать его для кратковременных измерений, но мы не рекомендуем пользоваться им в сервисах, которые могут быть активными в течение нескольких месяцев.

## Компоненты времени и общие свойства

Когда мы работаем с `TimeSpan`, у нас есть свойства компонентов времени (`Days`, `Hours...`) и общие свойства (`TotalDays`, `TotalHours...`). Они сильно различаются между собой. Рассмотрим небольшой пример, иллюстрирующий это:

```
TimeSpan span = new TimeSpan(
    days: 8,
    hours: 19,
    minutes: 46,
    seconds: 57,
    milliseconds: 876
);
WriteLine("TimeSpan = {0}", span);

WriteLine("Days:           {0,3} TotalDays:           {1}",
    span.Days,           span.TotalDays);
WriteLine("Hours:          {0,3} TotalHours:          {1}",
    span.Hours,          span.TotalHours);
```

```

WriteLine("Minutes:      {0,3} TotalMinutes:      {1}",
        span.Minutes,      span.TotalMinutes);
WriteLine("Seconds:     {0,3} TotalSeconds:     {1}",
        span.Seconds,     span.TotalSeconds);
WriteLine("Milliseconds: {0,3} TotalMilliseconds: {1}",
        span.Milliseconds, span.TotalMilliseconds);
WriteLine(" Ticks: {0}",
        span.Ticks);

```

Вот результат:

```

TimeSpan = 8.19:46:57.8760000
Days:      8 TotalDays:      8.82428097222222
Hours:     19 TotalHours:     211.782743333333
Minutes:   46 TotalMinutes:   12706.9646
Seconds:   57 TotalSeconds:   762417.876
Milliseconds: 876 TotalMilliseconds: 762417876
          Ticks:      7624178760000

```

Разница огромна! Например, `Hours = 19` (целочисленный компонент времени меньше 24), а `TotalHours = 211.782743333333` (общее свойство `double`, которое может быть намного больше 24). Поэтому данные значения легко перепутать и написать что-то в таком роде:

```

var start = DateTime.UtcNow;
Thread.Sleep(2500);
var end = DateTime.UtcNow;
WriteLine((end - start).Milliseconds); // выводит 500 вместо 2500

```

Это очень распространенная ошибка, которую легко допустить, но трудно потом найти.

## Изменения в текущем времени

Если вы используете `DateTime.UtcNow` или `DateTime.Now`, показатели могут быть испорчены, если текущее время изменилось при бенчмаркинге. Обсудим несколько возможных причин подобных событий.

## Синхронизация времени

Если вы включили синхронизацию времени, текущее время может измениться в любой момент. Более того, у некоторых серверов несколько служб синхронизации времени. Часто рассказывают о серверах Linux, где одновременно включены `ntp` и `systemd-timesyncd`<sup>1</sup>. Такие службы могут иметь рассинхронизированные

<sup>1</sup> Например, здесь: <https://bugs.launchpad.net/ubuntu/+source/ntp/+bug/1597909>.

временные ресурсы с дельтой в несколько секунд. В этом случае они могут постоянно переводить время вперед-назад. Это приводит к периодическим ошибкам с неточным измерением времени.

## Зимнее время

`DateTime.Now` выдает локальные дату и время пользователя. Это значение использует текущие часовые пояса, что чревато сюрпризами. Например, переход на зимнее время в некоторых странах может случайно повлиять на ваш бенчмарк: если запустить бенчмарк в неудачный момент, появится ошибка в 1 ч.

## Изменения часовых поясов

Часовой пояс региона может меняться. К примеру, вот исторические данные по часовому поясу Нидерландов:

```
1909-1937: GMT+00:19:32.13
1937-1940: GMT+00:20
1940-1942: UTC+02:00
```

Другой пример: в 2011 году часовой пояс Самоа сменился с UTC-10 на UTC+14. Из-за этого отменили день 30 декабря. Только представьте, что кто-то в Самоа запускал в тот день бенчмарк на базе `DateTime` — в измерениях появилась бы ошибка в 1 сутки!

Почти всегда для измерений лучше использовать время UTC (`DateTime.UtcNow`).

## Время можно изменить вручную

Наконец, пользователь может в любой момент изменить системное время. Если это происходит при измерениях времени, показатели будут испорчены. Вероятно, вы сами не будете менять время вручную, но измерения времени могут происходить в реальном приложении. Например, пользователь может запустить приложение в фоновом режиме и решить изменить время.

## Последовательные чтения

Допустим, мы выполняем два последовательных чтения `Stopwatch.GetTimestamp()`:

```
var a = Stopwatch.GetTimestamp();
var b = Stopwatch.GetTimestamp();
var delta = b - a;
```

Можете ли вы назвать возможные значения дельты? Проверим это с помощью следующей программы, которая строит гистограмму дельты:

```
// (1)
const int N = 100000000;
var values = new long[N];
for (int i = 0; i < N; i++)
    values[i] = Stopwatch.GetTimestamp();
// (2)
var deltas = new long[N - 1];
for (int i = 0; i < N - 1; i++)
    deltas[i] = values[i + 1] - values[i];
// (3)
var table =
    from d in deltas
    group d by d into g
    orderby g.Key
    select new
    {
        Ticks = g.Key,
        Microseconds = g.Key * 1000000.0 / Stopwatch.Frequency,
        Count = g.Count()
    };
// (4)
WriteLine("Ticks      | Time(us) | Count  ");
WriteLine("-----|-----|-----");
foreach (var line in table)
{
    var ticks = line.Ticks.ToString().PadRight(8);
    var us = line.Microseconds.ToString("0.0").PadRight(8);
    var count = line.Count.ToString();
    WriteLine($"{ticks} | {us} | {count}");
}
```

Обсудим происходящее здесь.

1. Мы выполняем  $N$  измерений (в этом случае  $N = 100\,000\,000$ , но вы можете выбрать любое положительное значение). Измерение здесь заключается только в вызове `Stopwatch.GetTimestamp()`. У нас  $N$  последовательных измерений в массиве `value`. В цикле `for` есть небольшие ограничения, но в данном случае это неважно (к счастью, мы знаем длительность `GetTimestamp()` — она очень велика по сравнению с ограничениями одной итерации `for`).
2. Вычисляем разницу между каждой парой последовательных измерений и сохраняем ее в массив `deltas`.
3. Далее группируем `deltas` и вычисляем количество значений `delta` в каждой группе (LINQ позволяет делать это очень просто).

4. Печатаем результаты, выполнив красивое форматирование. Это означает — создаем таблицу с тремя графами: Тики (чистая разница между последовательными измерениями в тиках), Время, мкс (с тиками работать неудобно, поэтому переводим их в микросекунды) и Количество (сколько раз наблюдалась такая разница в нашем небольшом эксперименте).

Вот пример результата на macOS 10.13 + .NET Core 2.1.0 (средняя часть была удалена).

Ticks	Time(us)	Count
0	0.0	91961519
1000	1.0	7820660
2000	2.0	129139
3000	3.0	55617
4000	4.0	4378
5000	5.0	2619
6000	6.0	1484
7000	7.0	1272
...	...	...
822000	822.0	1
875000	875.0	1
1083000	1083.0	1
1177000	1177.0	1
1479000	1479.0	1
1991000	1991.0	1
2751000	2751.0	1
8317000	8317.0	1
12341000	12341.0	1

В этой псевдогистограмме есть три очень важные строки.

- **Первая строка (нулевое значение времени).** Мы получаем нулевую разницу между последовательными измерениями 91 961 519 раз!
- **Вторая строка (минимальное положительное значение времени).** В разделе «Терминология» мы говорили, что номинальное и реальное разрешения не всегда равны. Номинальное разрешение `Stopwatch` (1 тик) определяется `Stopwatch.Frequency`. Однако в некоторых случаях мы не можем измерить ровно 1 тик: реальное разрешение (минимальный возможный интервал, который можно измерить) содержит более 1 тика. Вторая строка гистограммы показывает это значение (иногда приблизительное). В данном примере `Stopwatch.Frequency` равна  $10^9$ . Таким образом, 1 тик = 1 нс.
- **Последняя строка (максимальное значение времени).** Как видите, один раз я получил дельту между двумя последовательными вызовами `GetTimestamp`, равняющуюся 12 341 000 тиков, или 12,3 мс! Заметьте, что здесь нет никакого метода — мы не пытаемся ничего измерить! Конечно же, это редкая ситуация.

Обычно получаются правдоподобные измерения. Но в этом никогда нельзя быть уверенными! Этот подход методологически неверен — таким бенчмаркам нельзя доверять. Хороший микробенчмарк всегда производит много вызовов метода. Он позволяет улучшить корректность, поскольку погрешность делится на количество вызовов.

Положительная разница между последовательными вызовами может вызвать странные ошибки. Поймете ли вы, в чем проблема следующего выражения?

```
var stopwatch = Stopwatch.StartNew();  
// ...некая логика  
var value = stopwatch.ElapsedMilliseconds > timeout  
    ? 0  
    : timeout - (int)stopwatch.ElapsedMilliseconds;
```

Ответ: мы не можем быть уверены в том, что два вызова `stopwatch.ElapsedMilliseconds` дадут одно и то же значение. Допустим, `timeout` равен `100`. Мы пытаемся оценить `stopwatch.ElapsedMilliseconds > timeout`: `stopwatch.ElapsedMilliseconds` выдает `99`, и значение выражения — `false`. Затем оцениваем `timeout - (int)stopwatch.ElapsedMilliseconds`. Но здесь другой `stopwatch.ElapsedMilliseconds`! Допустим, он выдаст `101`. Тогда итоговое значение будет `-1`! Вероятно, автор этого кода не ожидал появления здесь отрицательных значений.

Это пример реальной ошибки из библиотеки `AsyncIO`. Она уже исправлена (<https://github.com/somdoron/AsyncIO/commit/5c838f3d30d483dcadb4181233a4437fb5e7f327>), но успела повлечь за собой очень сложную ошибку в `Rider`. Мы провели несколько дней, исследуя ее, потому что подобные ошибки очень тяжело воспроизвести.

### Упражнение

Постройте эту гистограмму в разных окружениях и сравните результаты. Напишите ту же логику для `DateTime.Now`, `DateTime.UtcNow` и `Environment.TickCount`, сравните гистограммы разных API для проставления отметок времени.

## Подводя итог

В этом разделе мы обсудили пять подводных камней при проставлении отметок времени.

- **Низкое разрешение.**

Разрешения таймера обычно недостаточно для измерения метода, занимающего несколько наносекунд. В подобных случаях приходится вызывать его много раз за каждую итерацию, чтобы получить необходимый уровень точности.

- **Переполнение счетчика.**

`Environment.TickCount` переполняется примерно каждые 50 дней. Этот API не следует использовать для служб, которые могут быть активными несколько месяцев.

- **Компоненты времени и общие свойства.**

Еще одной распространенной ошибкой является применение таких свойств, как `TimeSpan.Milliseconds`, вместо `TimeSpan.TotalMilliseconds`. `Milliseconds` всегда выдает значения от  $-999$  до  $999$ . Если вам нужно сообщить *общее* количество прошедших миллисекунд, требуется свойство `TotalMilliseconds`.

- **Изменения в текущем времени.**

`DateTime.Now` и `DateTime.UtcNow` могут быть полезными для составления журнала, но мы не рекомендуем применять эти свойства для измерения времени. Они используют реальное время, которое может измениться по разным причинам, например из-за службы синхронизации времени.

- **Последовательные чтения.**

Разница между двумя последовательными вызовами API для проставления отметок времени может быть любым неотрицательным числом. Даже если вы применяете `Stopwatch` с разрешением 1 мкс, эта разница может составить несколько миллисекунд.

Даже используя `Stopwatch`, можно получить большие погрешности при измерении, если количество вызовов метода за одну итерацию недостаточно велико. `Stopwatch.Elapsed` выдает `TimeSpan`, который может быть неправильно применен.

## Выводы

В этой главе вы узнали многое о таймерах. Были освещены следующие темы.

- **Терминология.**

Мы обсудили основные единицы времени и частоты, включая распространенные обозначения (например, мкс, пс, ТГц), основные составляющие аппаратного таймера (генератор тиков, счетчик тиков, API счетчика тиков), погрешности дискретизации и основные характеристики таймера (теперь вы знаете, в чем разница между корректностью и точностью и между номинальным и реальным разрешением).

- **Аппаратные таймеры.**

На аппаратном уровне существует несколько ресурсов времени, например TSC, ACPI PM и HPET. Применение TSC — самый надежный способ получить

отметки времени в большинстве конфигураций. Частота TSC обычно близка к номинальной частоте процессора. ACPI PM (частота 3,579545 МГц) и HPET (частота 14,31818 МГц) обычно по умолчанию выключены в современных версиях операционных систем из-за своей большой длительности. Но вы все равно должны быть готовы столкнуться с ними. Значения частоты этих двух таймеров имеют долгую историю, которая началась, когда NTSC начал создавать новый стандарт для цветного телевидения.

- **API для проставления отметок времени в ОС.**

Операционные системы предоставляют множество API, взаимодействующих с аппаратными счетчиками на внутреннем уровне. В Windows лучшими API для проставления отметок времени высокого разрешения являются `QueryPerformanceCounter (QPC)` и `QueryPerformanceFrequency (QPF)`. Их значения не связаны с текущим локальным временем. Если вам нужно знать локальное время, можно использовать `GetSystemTime`, `GetLocalTime` и `GetSystemTimeAsFileTime`. Эти API применяют системный таймер Windows с разрешением 0,5... 5,625 мс. Если вам нужно текущее время с большей точностью, нужно взять `GetSystemTimePreciseAsFileTime`. В Unix можно использовать `clock_gettime/mach_absolute_time` (если он доступен) для проставления отметок высокой точности и `gettimeofday` для обычных отметок.

- **API для проставления отметок времени в .NET.**

Лучший API для проставления отметок времени с высоким разрешением — это `Stopwatch`. С точки зрения внутреннего устройства он использует лучшие из API, предоставляемых ОС. В Windows можно также применять `Environment.TickCount`, если вам не нужна высокая точность, но требуется очень малая длительность. `DateTime.Now` и `DateTime.UtcNow` могут оказаться полезными для ведения журнала событий.

- **Подводные камни при проставлении отметок времени.**

Даже при использовании `Stopwatch` вы все равно можете получить большие погрешности в небольших операциях из-за низкого разрешения или большой дельты между последовательными чтениями. `Stopwatch.Elapsed` — это `TimeSpan`, который можно применить неверно (например, взять свойство `Milliseconds` вместо `TotalMilliseconds`). Счетчик `Environment.TickCount` переполняется примерно через 50 дней. Измерения, основанные на `DateTime.Now` или `DateTime.UtcNow`, могут быть испорчены службой синхронизации времени или другими изменениями текущего времени.

Теперь вы узнали многое о внутреннем устройстве аппаратных и программных таймеров. Эти знания помогут вам в любой ситуации выбрать правильный таймер, разрабатывать более качественные бенчмарки и избегать частых ошибок.

## ИСТОЧНИКИ

[ACPI Specifications] Advanced Configuration and Power Interface Specification (Version 6.0). 2015. [www.uefi.org/sites/default/files/resources/ACPI\\_6.0.pdf](http://www.uefi.org/sites/default/files/resources/ACPI_6.0.pdf).

[Agner Instructions] *Fog A.* Instruction Tables. Lists of Instruction Latencies, Throughputs and Micro-Operation Breakdowns for Intel, AMD and VIA CPUs. [www.agner.org/optimize/instruction\\_tables.pdf](http://www.agner.org/optimize/instruction_tables.pdf).

[Agner Optimizing Assembly] *Fog A.* Optimizing Subroutines in Assembly Language. An Optimization Guide for X86 Platforms. [www.agner.org/optimize/optimizing\\_assembly.pdf](http://www.agner.org/optimize/optimizing_assembly.pdf).

[Agner Optimizing Cpp] *Fog A.* Optimizing Software in C++. An Optimization Guide for Windows, Linux and Mac Platforms. [www.agner.org/optimize/optimizing\\_cpp.pdf](http://www.agner.org/optimize/optimizing_cpp.pdf).

[Chen, 2014] *Chen R.* When Does GetTickCount Consider the System to Have Started? 2014. November 13. <https://blogs.msdn.microsoft.com/oldnewthing/20141113-00/?p=43623>.

[Cook, 2017] *Cook C.* When a Microsecond Is an Eternity: High Performance Trading Systems in C++ // Presented at the CppCon 2017. [www.youtube.com/watch?v=NH1Tta7purM](http://www.youtube.com/watch?v=NH1Tta7purM).

[Govindarajalu, 2002] *Govindarajalu B.* IBM PC AND CLONES: Hardware, Troubleshooting and Maintenance. Tata McGraw-Hill Education, 2002.

[HPET Specifications] IA-PC HPET (High Precision Event Timers) Specification (Version 1.0a). 2004. [www.intel.com/content/dam/www/public/us/en/documents/technicalspecifications/software-developers-hpet-spec-1-0a.pdf](http://www.intel.com/content/dam/www/public/us/en/documents/technicalspecifications/software-developers-hpet-spec-1-0a.pdf).

[Hsia, 2004] *Hsia C.* Why Was the Original IBM PC 4.77 Megahertz? 2004. August. [https://blogs.msdn.microsoft.com/calvin\\_hsia/2004/08/12/why-was-the-original-ibm-pc-4-77-megahertz/](https://blogs.msdn.microsoft.com/calvin_hsia/2004/08/12/why-was-the-original-ibm-pc-4-77-megahertz/).

[Intel Manual] Intel: Intel® 64 and IA-32 Architectures Software Developer's Manual (325462-061US). 2016. [www.intel.com/content/dam/www/public/us/en/documents/manuals/64-ia-32-architectures-software-developer-manual-325462.pdf](http://www.intel.com/content/dam/www/public/us/en/documents/manuals/64-ia-32-architectures-software-developer-manual-325462.pdf).

[Jones, 2000] *Jones A.* Splitting the Second: The Story of Atomic Time. CRC Press, 2000.

[Karna, 2017] *Karna S. K.* Microprocessors – GATE, PSUS AND ES Examination. Vikas Publishing House, 2017.

[Kidd, 2014] *Taylor R.* Power Management States: P-States, C-States, and Package C-States. 2014. April. <https://software.intel.com/en-us/articles/power-management-states-p-states-c-states-and-package-c-states>.

[MSSupport 895980] Programs That Use the QueryPerformanceCounter Function May Perform Poorly in Windows Server 2000, in Windows Server 2003 and in Windows XP. Microsoft Support, 2014. <https://support.microsoft.com/en-us/kb/895980>.

[Paterson, 2009] *Paterson T.* 2009. “IBM PC Design Antics.” May. <http://dosmandrive.blogspot.ru/2009/03/ibm-pc-design-antics.html>.

[Schlyter] *Schlyter P.* Analog TV Broadcast Systems. <http://stjarnhimlen.se/tv/tv.html>.

[Solntsev, 2017] *Solntsev A.* Flaky Tests (in Russian) // Presented at the Heisenbug Moscow, 2017. December 9. [www.youtube.com/watch?v=jLG3RXECQU8](http://www.youtube.com/watch?v=jLG3RXECQU8).

[Stephens, 1999] *Stephens R.* Measuring Differential Gain and Phase // Application Report SLOA040, 1999. [www.ti.com/lit/an/sloa040/sloa040.pdf](http://www.ti.com/lit/an/sloa040/sloa040.pdf).

[The Windows Timestamp Project] *Lentfer A.* Microsecond Resolution Time Services for Windows. [www.windowstimestamp.com/description](http://www.windowstimestamp.com/description).

*Андрей Акиньшин*

**Профессиональный бенчмарк:  
искусство измерения производительности**

Перевела с английского *А. Григорьева*

Руководитель дивизиона	<i>Ю. Сергиенко</i>
Руководитель проекта	<i>А. Питиримов</i>
Ведущий редактор	<i>Н. Гринчик</i>
Литературный редактор	<i>Н. Рощина</i>
Художественный редактор	<i>В. Мостипан</i>
Корректоры	<i>О. Андриевич, Е. Павлович, Е. Рафалюк-Бузовская</i>
Верстка	<i>Г. Блинов</i>

Изготовлено в России. Изготовитель: ООО «Прогресс книга».  
Место нахождения и фактический адрес: 194044, Россия, г. Санкт-Петербург,  
Б. Сампсониевский пр., д. 29А, пом. 52. Тел.: +78127037373.

Дата изготовления: 02.2022. Наименование: книжная продукция. Срок годности: не ограничен.

Налоговая льгота — общероссийский классификатор продукции ОК 034-2014, 58.11.12 — Книги печатные профессиональные, технические и научные.

Импортер в Беларусь: ООО «ПИТЕР М», 220020, РБ, г. Минск, ул. Тимирязева, д. 121/3, к. 214, тел./факс: 208 80 01.

Подписано в печать 10.12.21. Формат 70×100/16. Бумага офсетная. Усл. п. л. 46,440. Тираж 700. Заказ 0000.

*Джастин Зейтц, Тим Арнольд*

## **BLACK HAT PYTHON: ПРОГРАММИРОВАНИЕ ДЛЯ ХАКЕРОВ И ПЕНТЕСТЕРОВ, 2-е изд.**



Когда речь идет о создании мощных и эффективных хакерских инструментов, большинство аналитиков по безопасности выбирают Python. Во втором издании бестселлера Black Hat Python вы исследуете темную сторону возможностей Python — все от написания сетевых снифферов, похищения учетных данных электронной почты и брутфорса каталогов до разработки мутационных фаззеров, анализа виртуальных машин и создания скрытых троянов.

