

ORACLE®

Java Platform Performance BoF

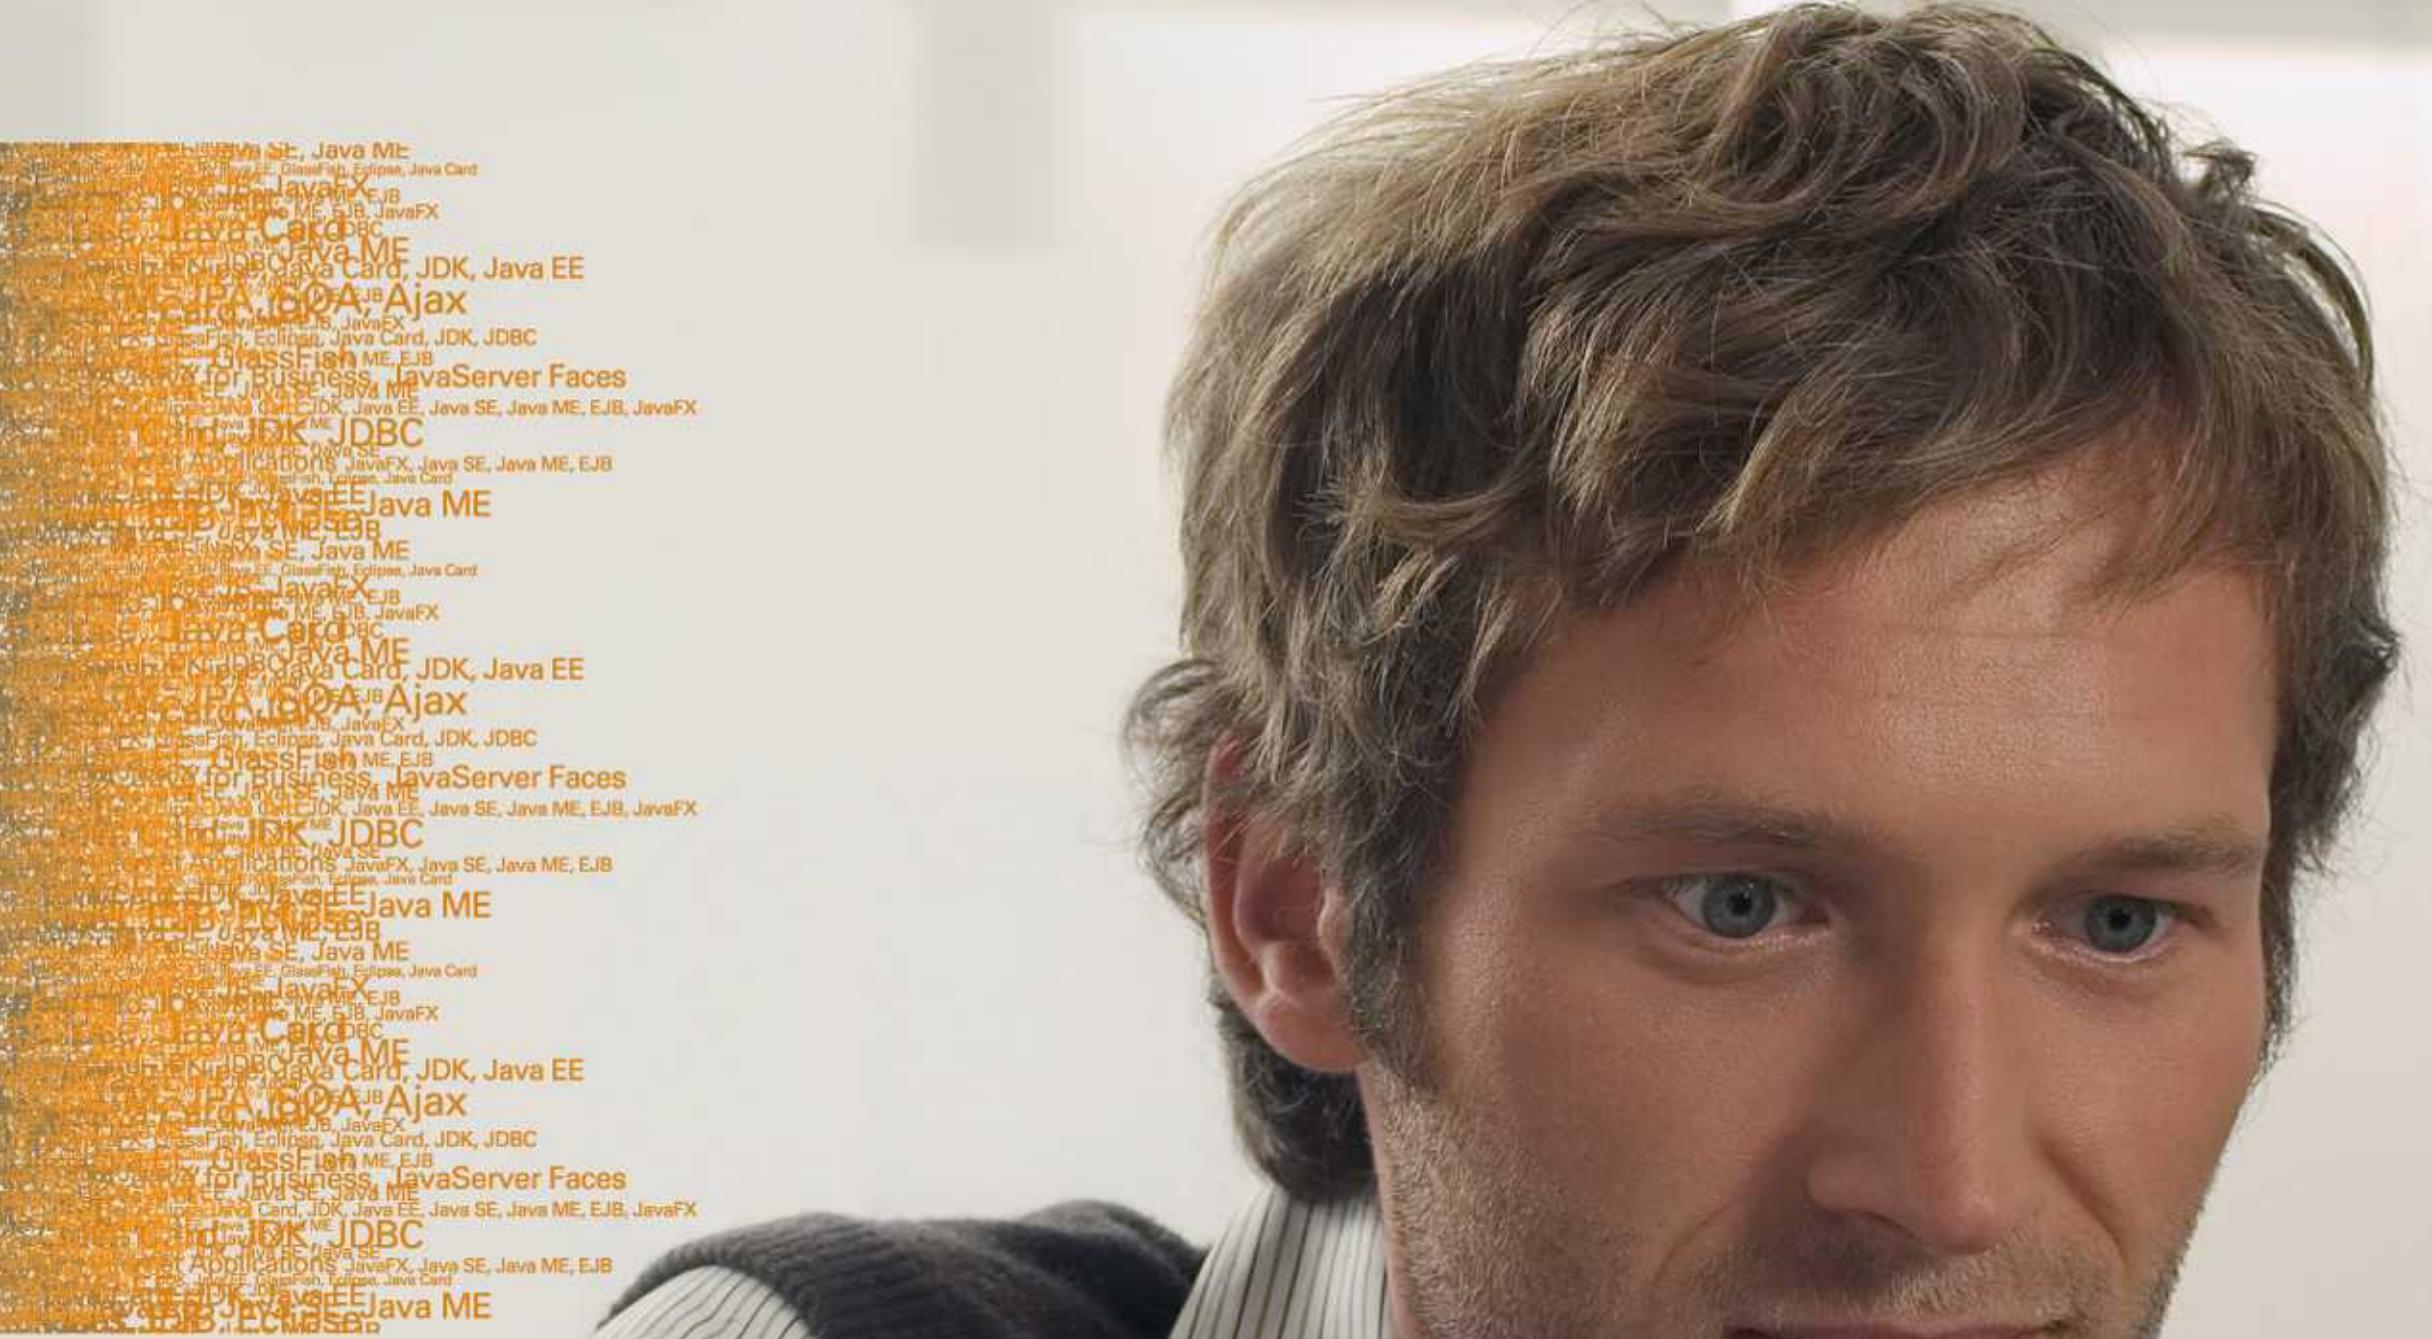
Sergey Kuksenko, Aleksey Shipilev

О чём у нас

- Отвечаем на вопросы по Java Performance
 - В основном, предварительно собранные в разных местах Рунета
 - Есть возможность задать вопрос прямо здесь
 - Пишем на бумажке, передаём вперёд ;)
- Сначала вводные слова про:
 - Performance Engineering
 - Startup
 - JIT
 - Concurrency and synchronization
- Другие сессии:
 - “Искусное тестирование производительности (Java)”, завтра, 11-45
 - “Диагностика и настройка GC”, сегодня, только что закончилось
 - “JDK7”, параллельно с нами



Performance Engineering



Performance Engineering

абстрактно и отлично об отлиниях в абстракциях

- Computer Science → Software Engineering
 - Строим приложения по функциональным требованиям
 - В большой степени абстрактно, в “идеальном мире”
 - Теоретически неограниченная свобода – искусство!
 - Можно строить воздушные замки
 - Рассуждения при помощи формальных методов
- Software Performance Engineering
 - “Real world strikes back!”
 - Исследуем взаимодействие софта с железом на типичных данных
 - Производительность уже нельзя оценить
 - Производительность можно только измерить
 - Естественно-научные методы



Performance Engineering

первый шаг

- Классические ошибки первого шага
 - “я вижу, что метод *foo()* реализован неэффективно”
 - “по профилю видно, что метод *bar()* – самый горячий и занимает 5%”
 - “по-моему, у нас тормозит БД, и необходимо перейти с DB_X на DB_Y”
- Правильный первый шаг:
 - Необходимо выбрать метрику
 - ops/sec, transactions/sec
 - время исполнения
 - время отклика
 - Убедиться в корректности метрики
 - релевантна (учитывает реальный сценарий работы приложения)
 - повторяема

ЦЕЛЬ → улучшение метрики!



Performance Engineering

анализ узких мест (tips)

- **Низкая утилизация CPU**
 - Высокая дисковая, сетевая активность
 - Конфликт блокировок
 - Конфликт ресурсов ОС
 - Слабая параллелизация приложения
- **Высокая утилизация ядра ОС**
 - Частые блокировки
 - Частое обращение к ОС
- **Высокая утилизация CPU**
 - Неоптимальная архитектура приложения
 - Неправильное использование API
 - Неоптимизированные горячие методы
 - Неоптимальные настройки GC



Performance Engineering

инструменты для анализа системы

	Solaris	Linux	Windows	Что смотрим
Сеть	netstat, dtrace	netstat	perfmon	количество соединений, объем трафика
Диск	iostat, dtrace	iostat	perfmon	количество обращений к диску, задержка
Память	vmstat, prstat, dtrace	vmstat, top	perfmon	подкачка страниц, размер памяти
Процессы	ps, vmstat, mpstat, prstat, dtrace	ps, vmstat, top	perfmon	количество нитей, состояние нитей, переключения контекста
Ядро ОС	mpstat, lockstat, plockstat, dtrace, intrstat, vmstat	vmstat	perfmon	kernel time, блокировки, системные вызовы, прерывания ...

Performance Engineering

tools, tools, tools again, more tools

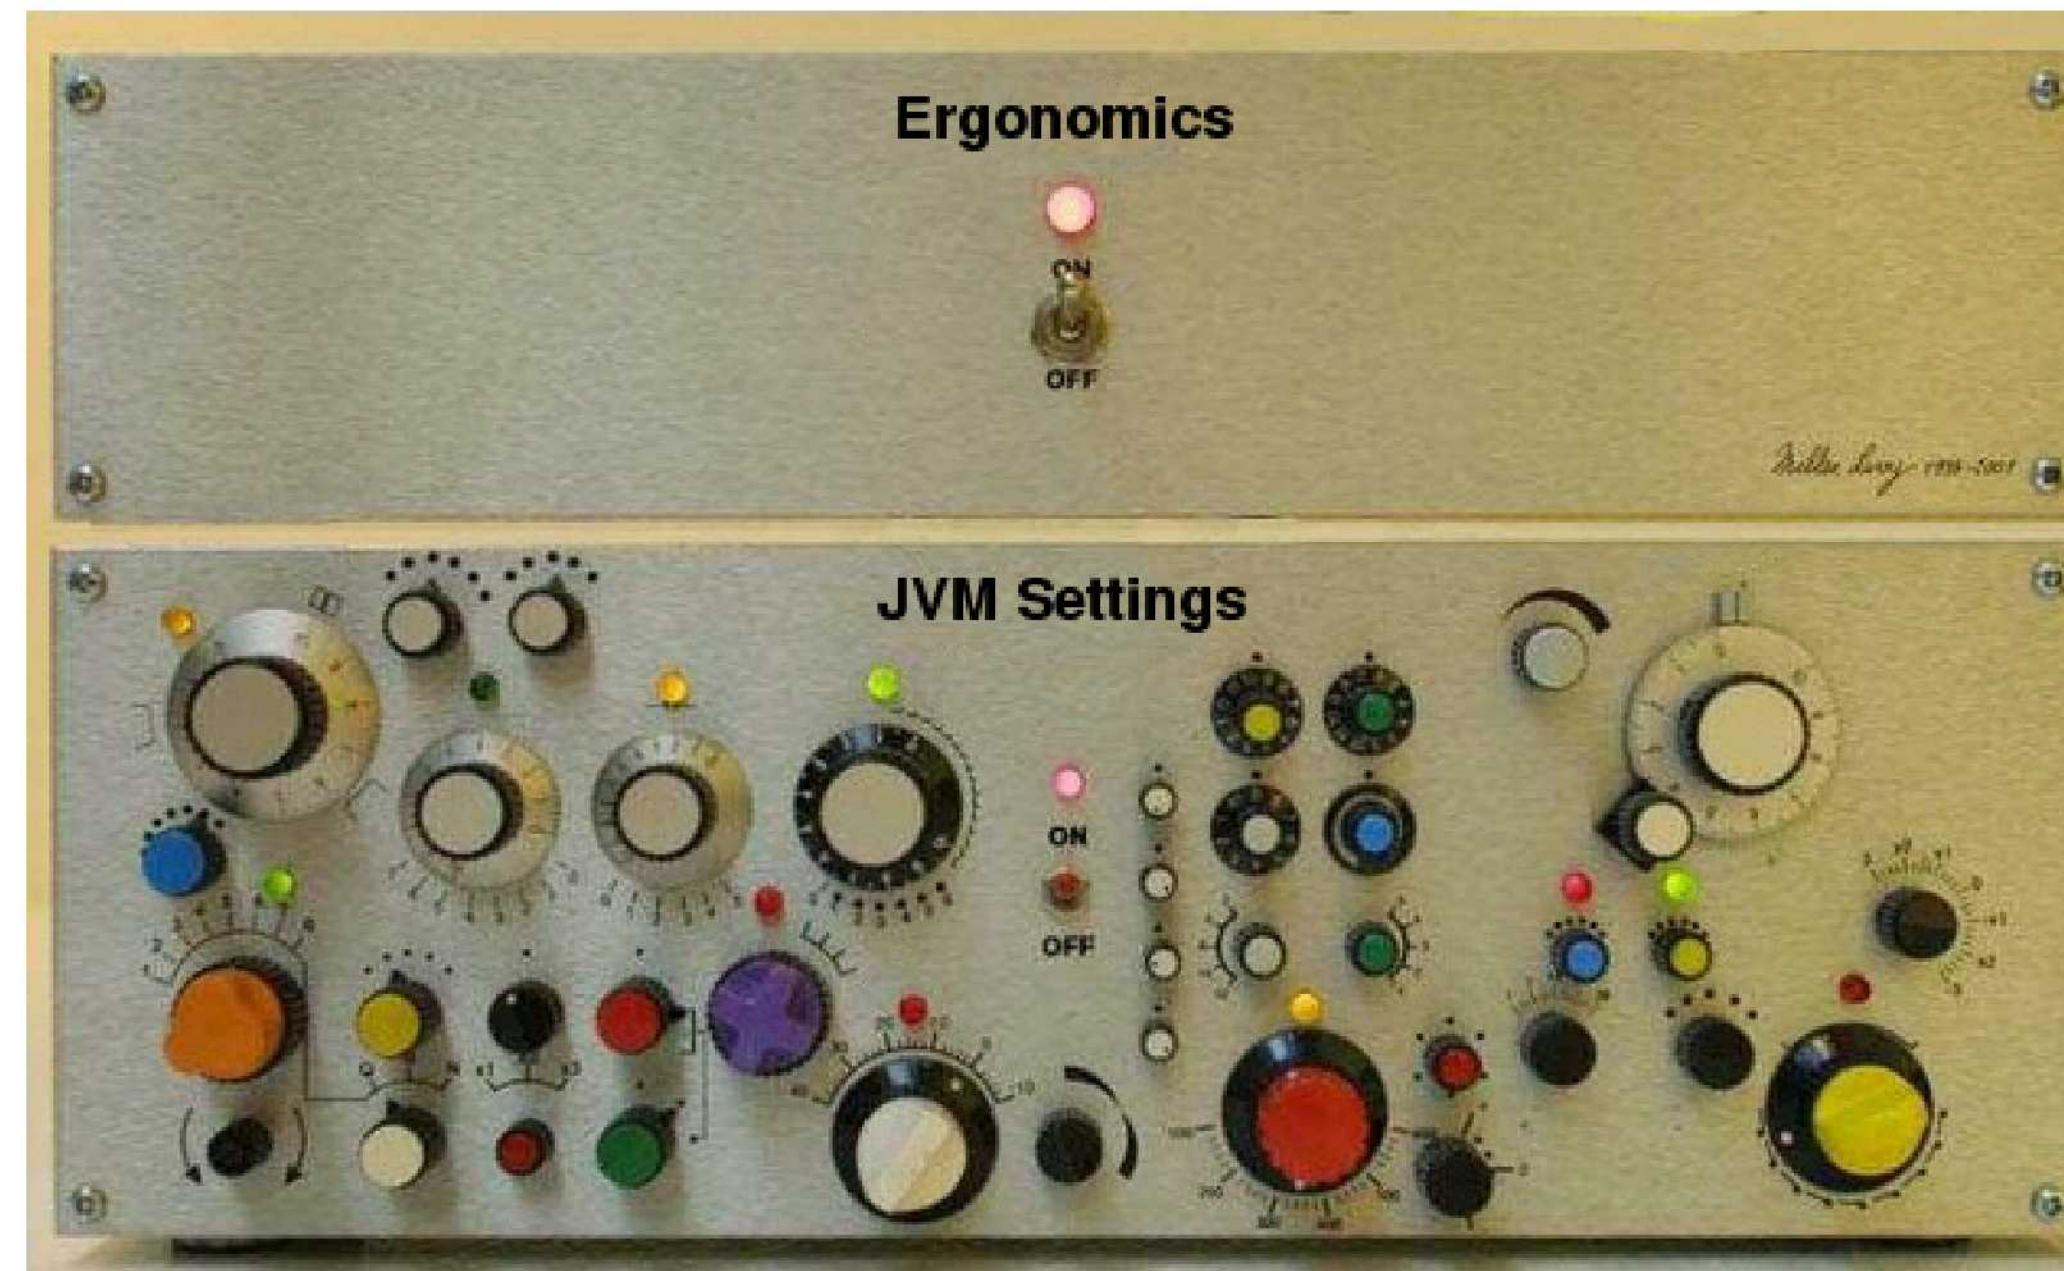
- VisualVM
 - <http://visualvm.dev.java.net>
- JRockit Mission Control
 - <http://www.oracle.com/technetwork/middleware/jrockit/mission-control/index.html>
- Sun Studio Analyzer
 - <http://www.oracle.com/technetwork/server-storage/solarisstudio/overview/index.html>
- DTrace
 - <http://www.oracle.com/technetwork/systems/dtrace/dtrace/index.html>
- Ещё могут быть полезны:
 - JProbe
 - Optimizelit
 - YourKit



JVM tuning

настройка параметров JVM

- Что настраивать?
 - <http://blogs.sun.com/watt/resource/jvm-options-list.html>
 - <http://www.oracle.com/technetwork/java/javase/tech/vmoptions-jsp-140102.html>



JVM tuning

настройка параметров JVM

- **JVM сама подбирает оптимальные параметры своей работы**
 - Server vs. Client
 - Large pages (Solaris)
 - CompressedOops (64-bit VM)
- **Так что же настраивать?**
 - GC/Heap tuning
 - -XX:+UseNUMA (Solaris, Linux)
 - -XX+:UseLargePages (Linux, Windows)
 - <http://www.oracle.com/technetwork/java/javase/tech/largememory-jsp-137182.html>
- **Не забыть**
 - Использовать последнюю версию JDK



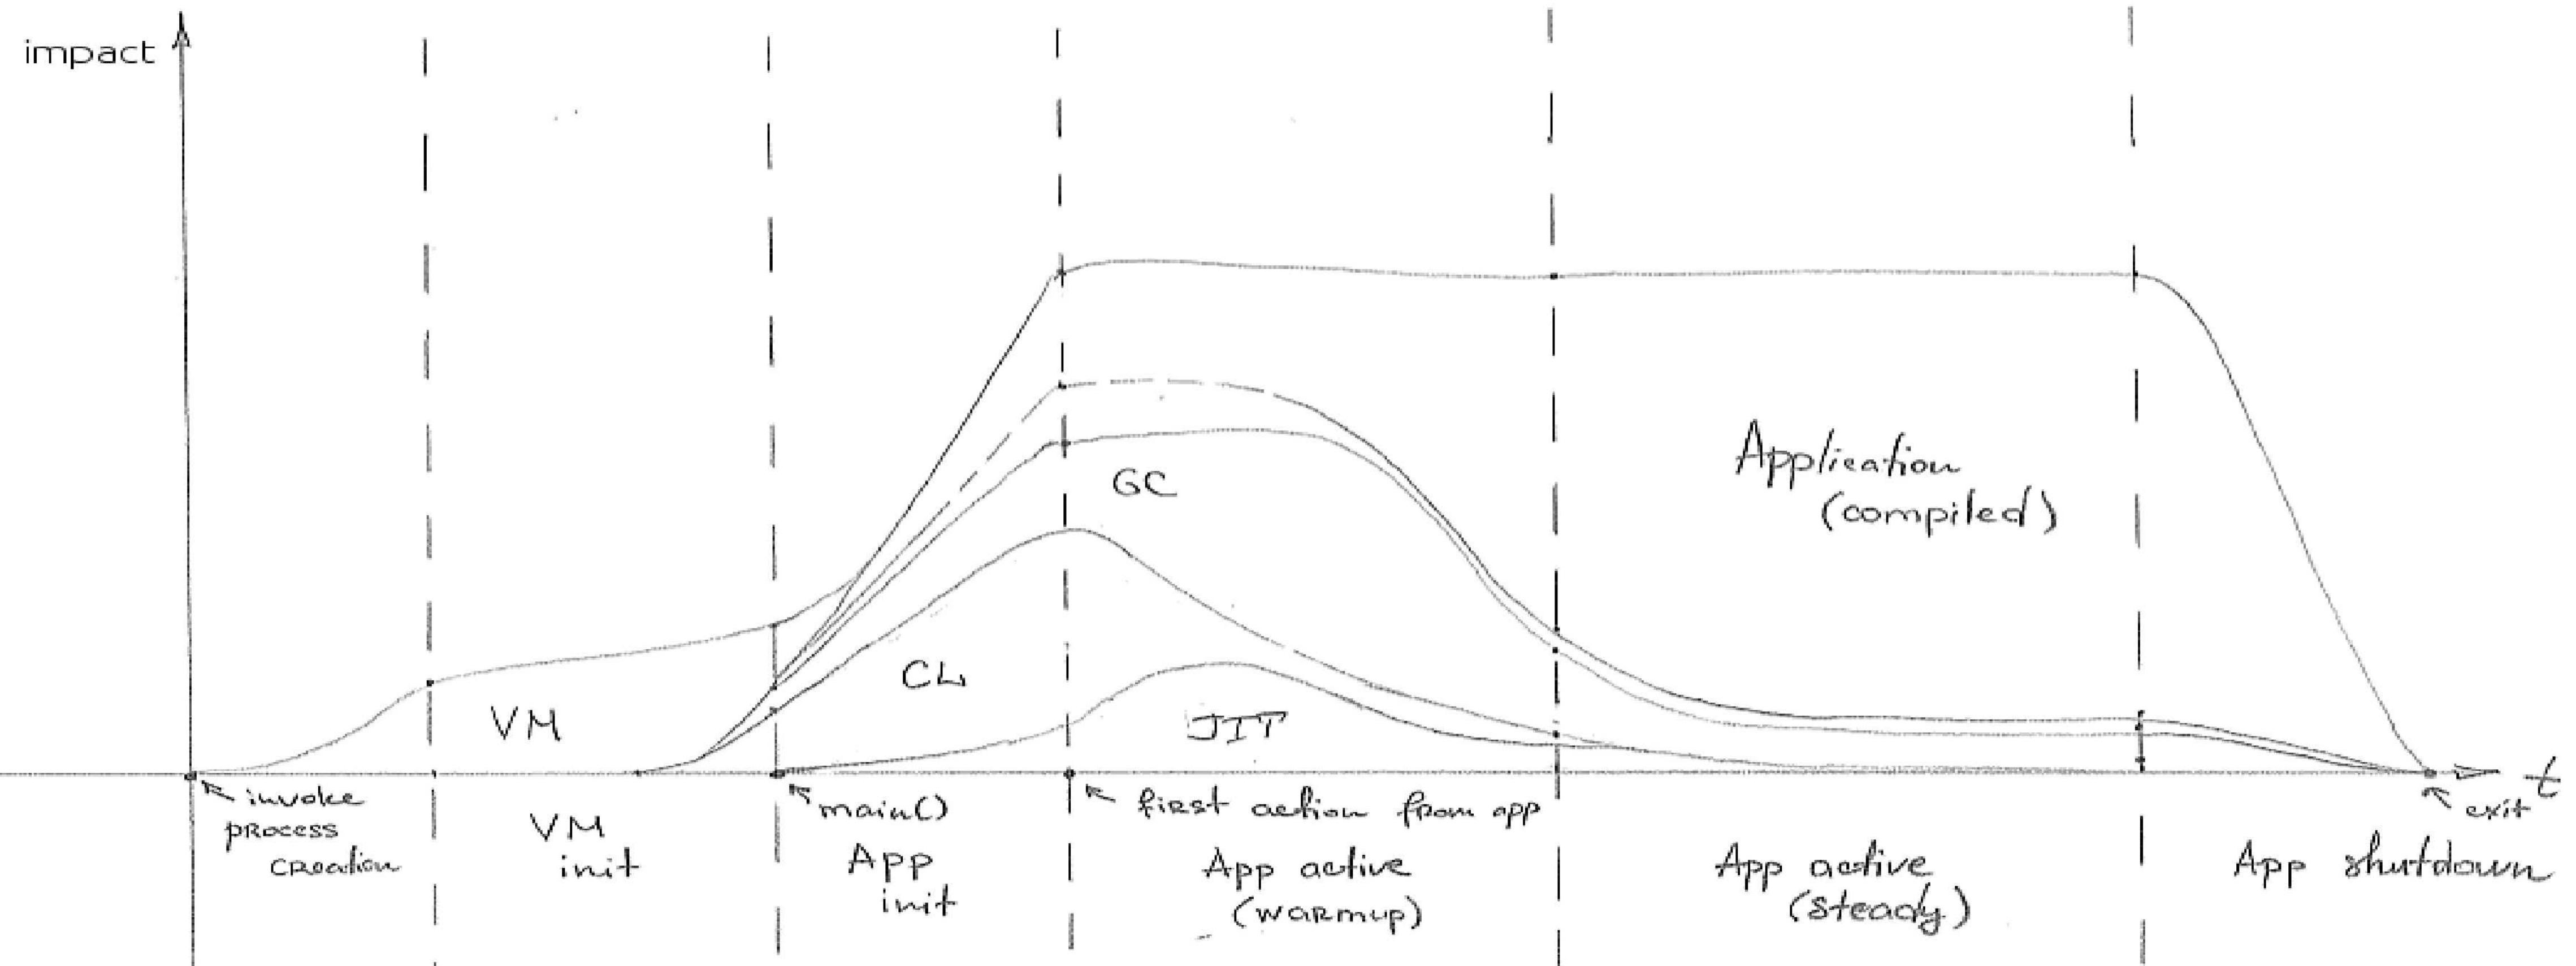
Startup



ORACLE®

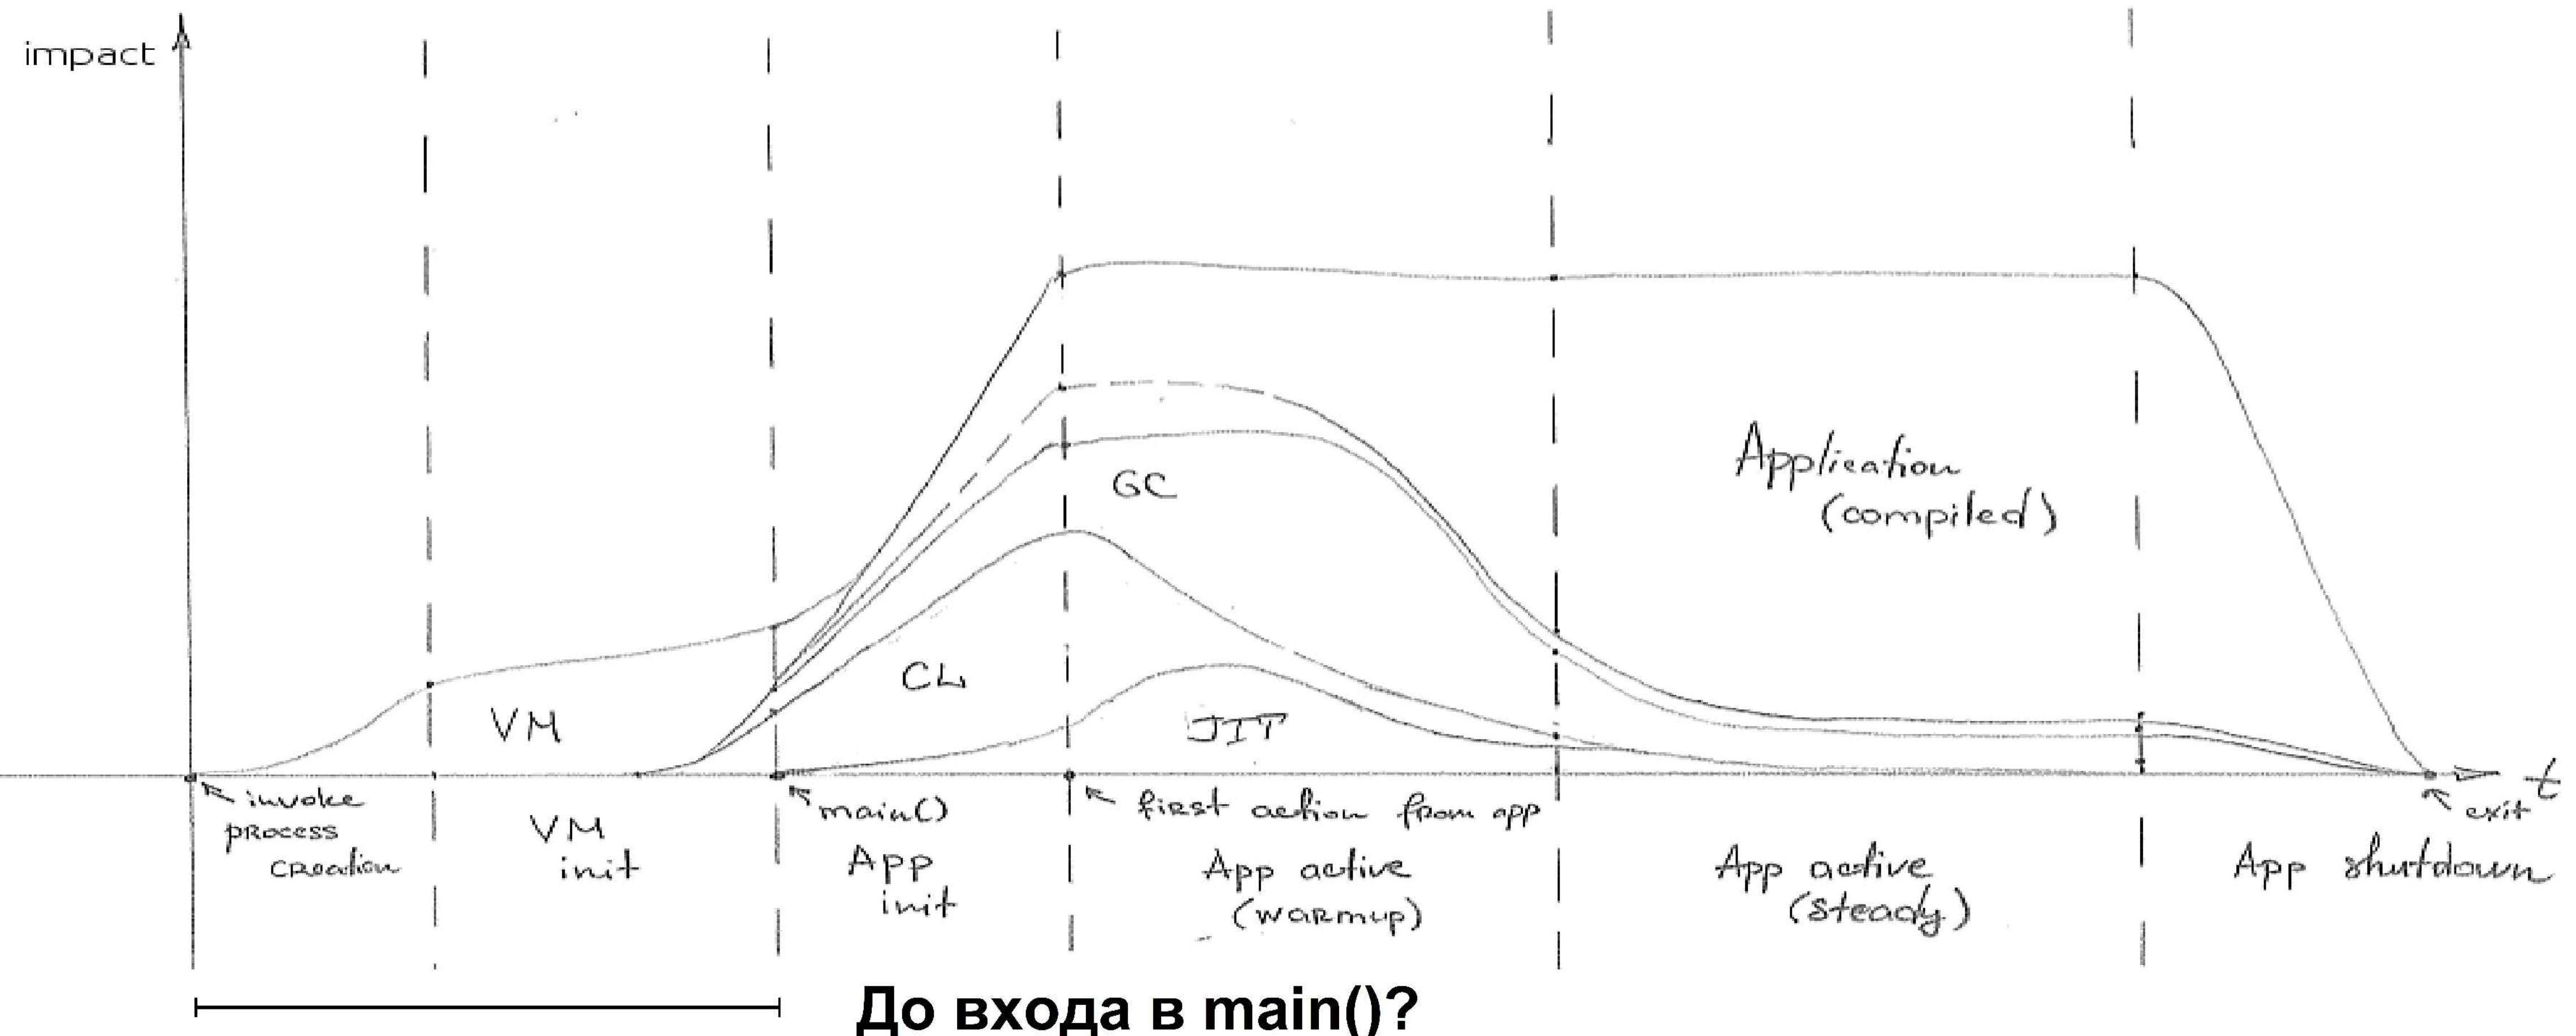
Startup

как измерять?



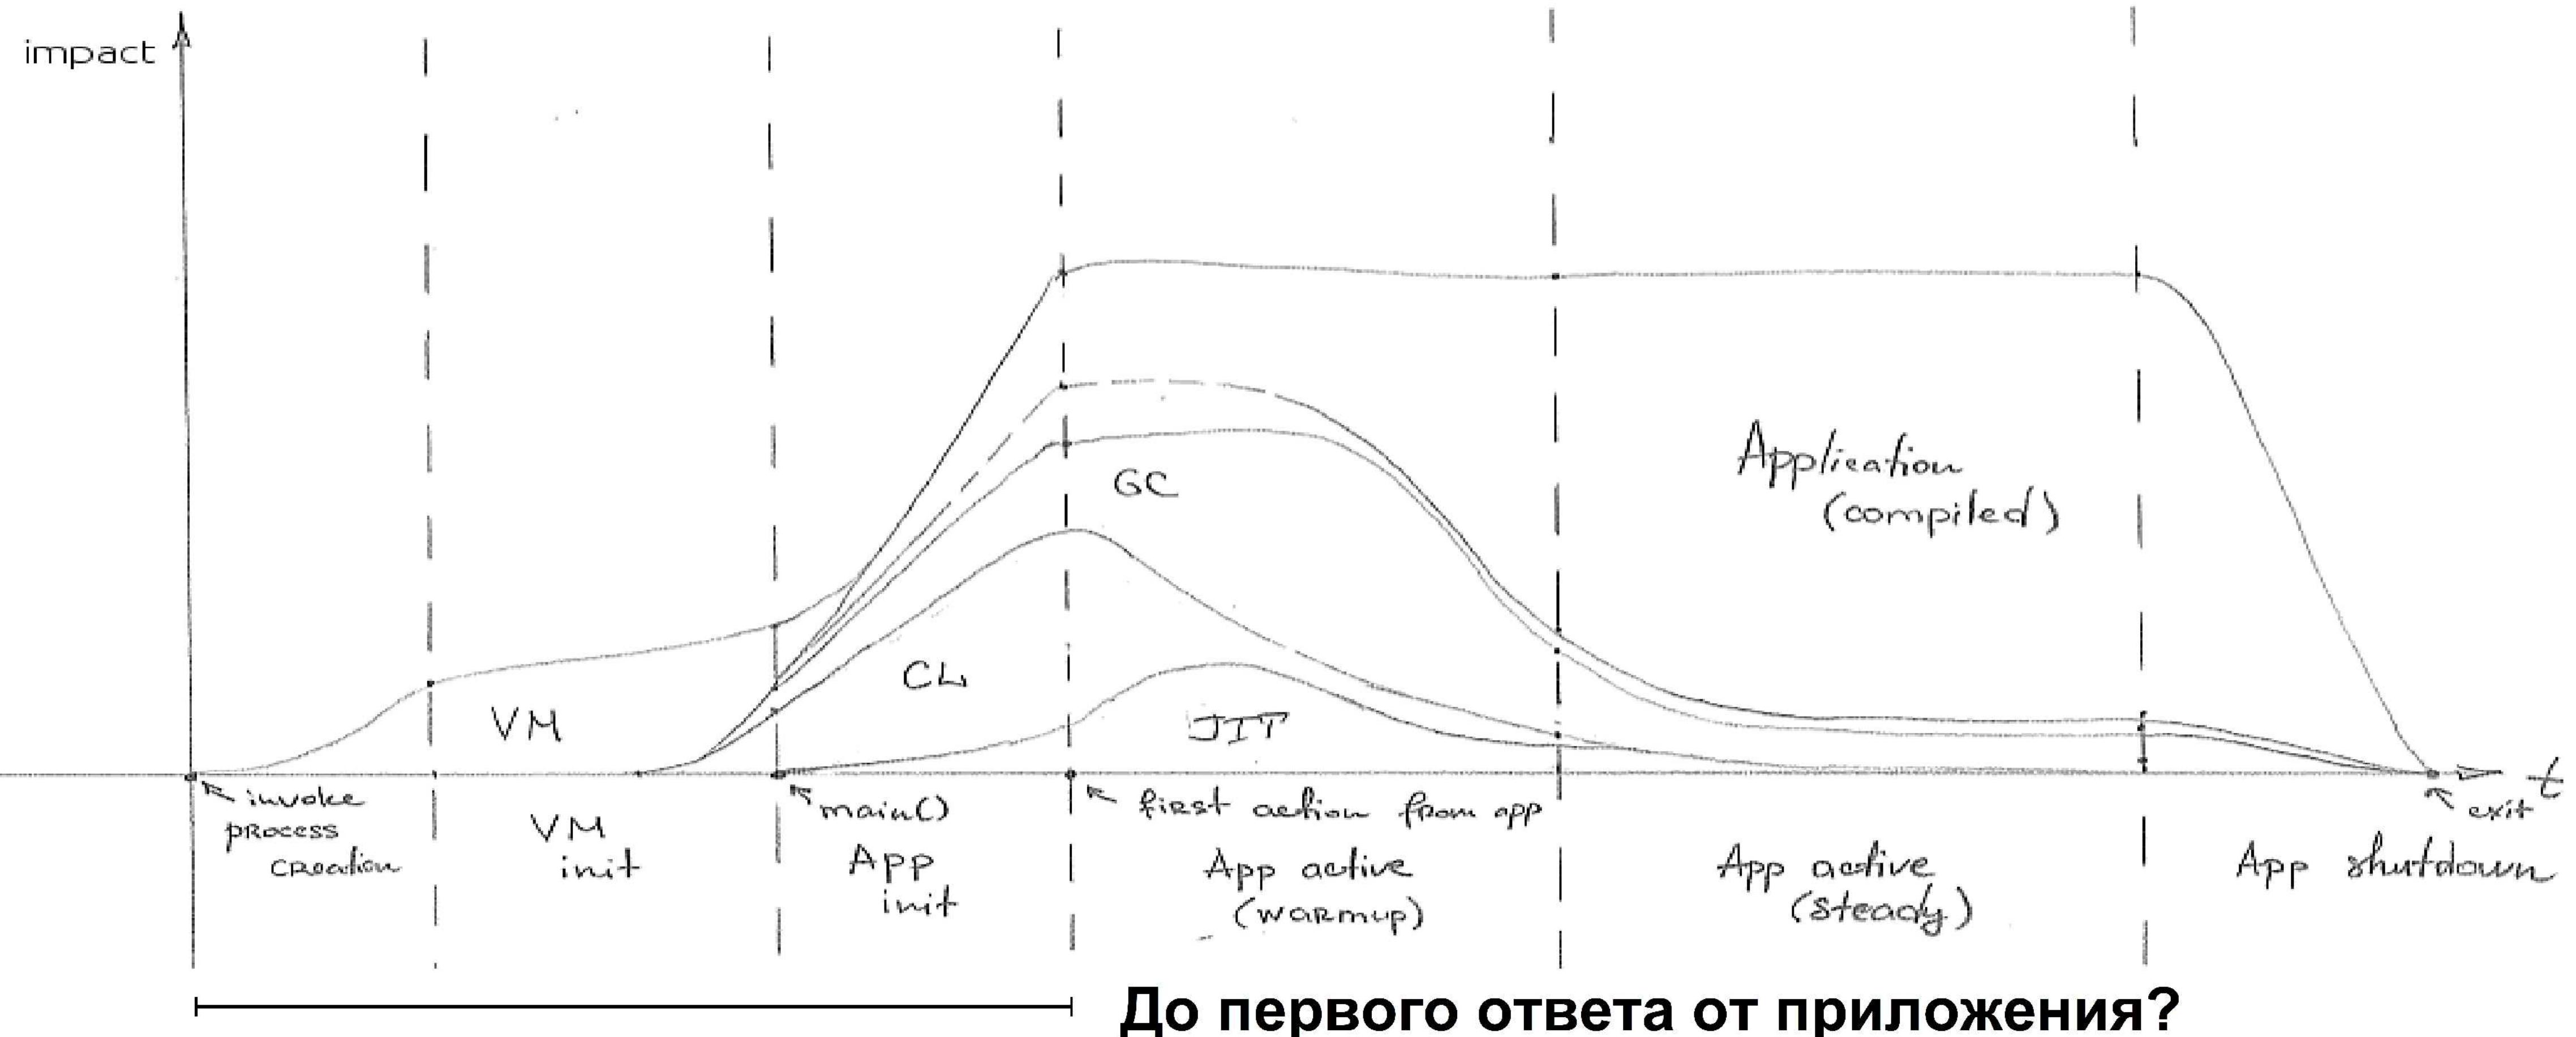
Startup

как измерять?



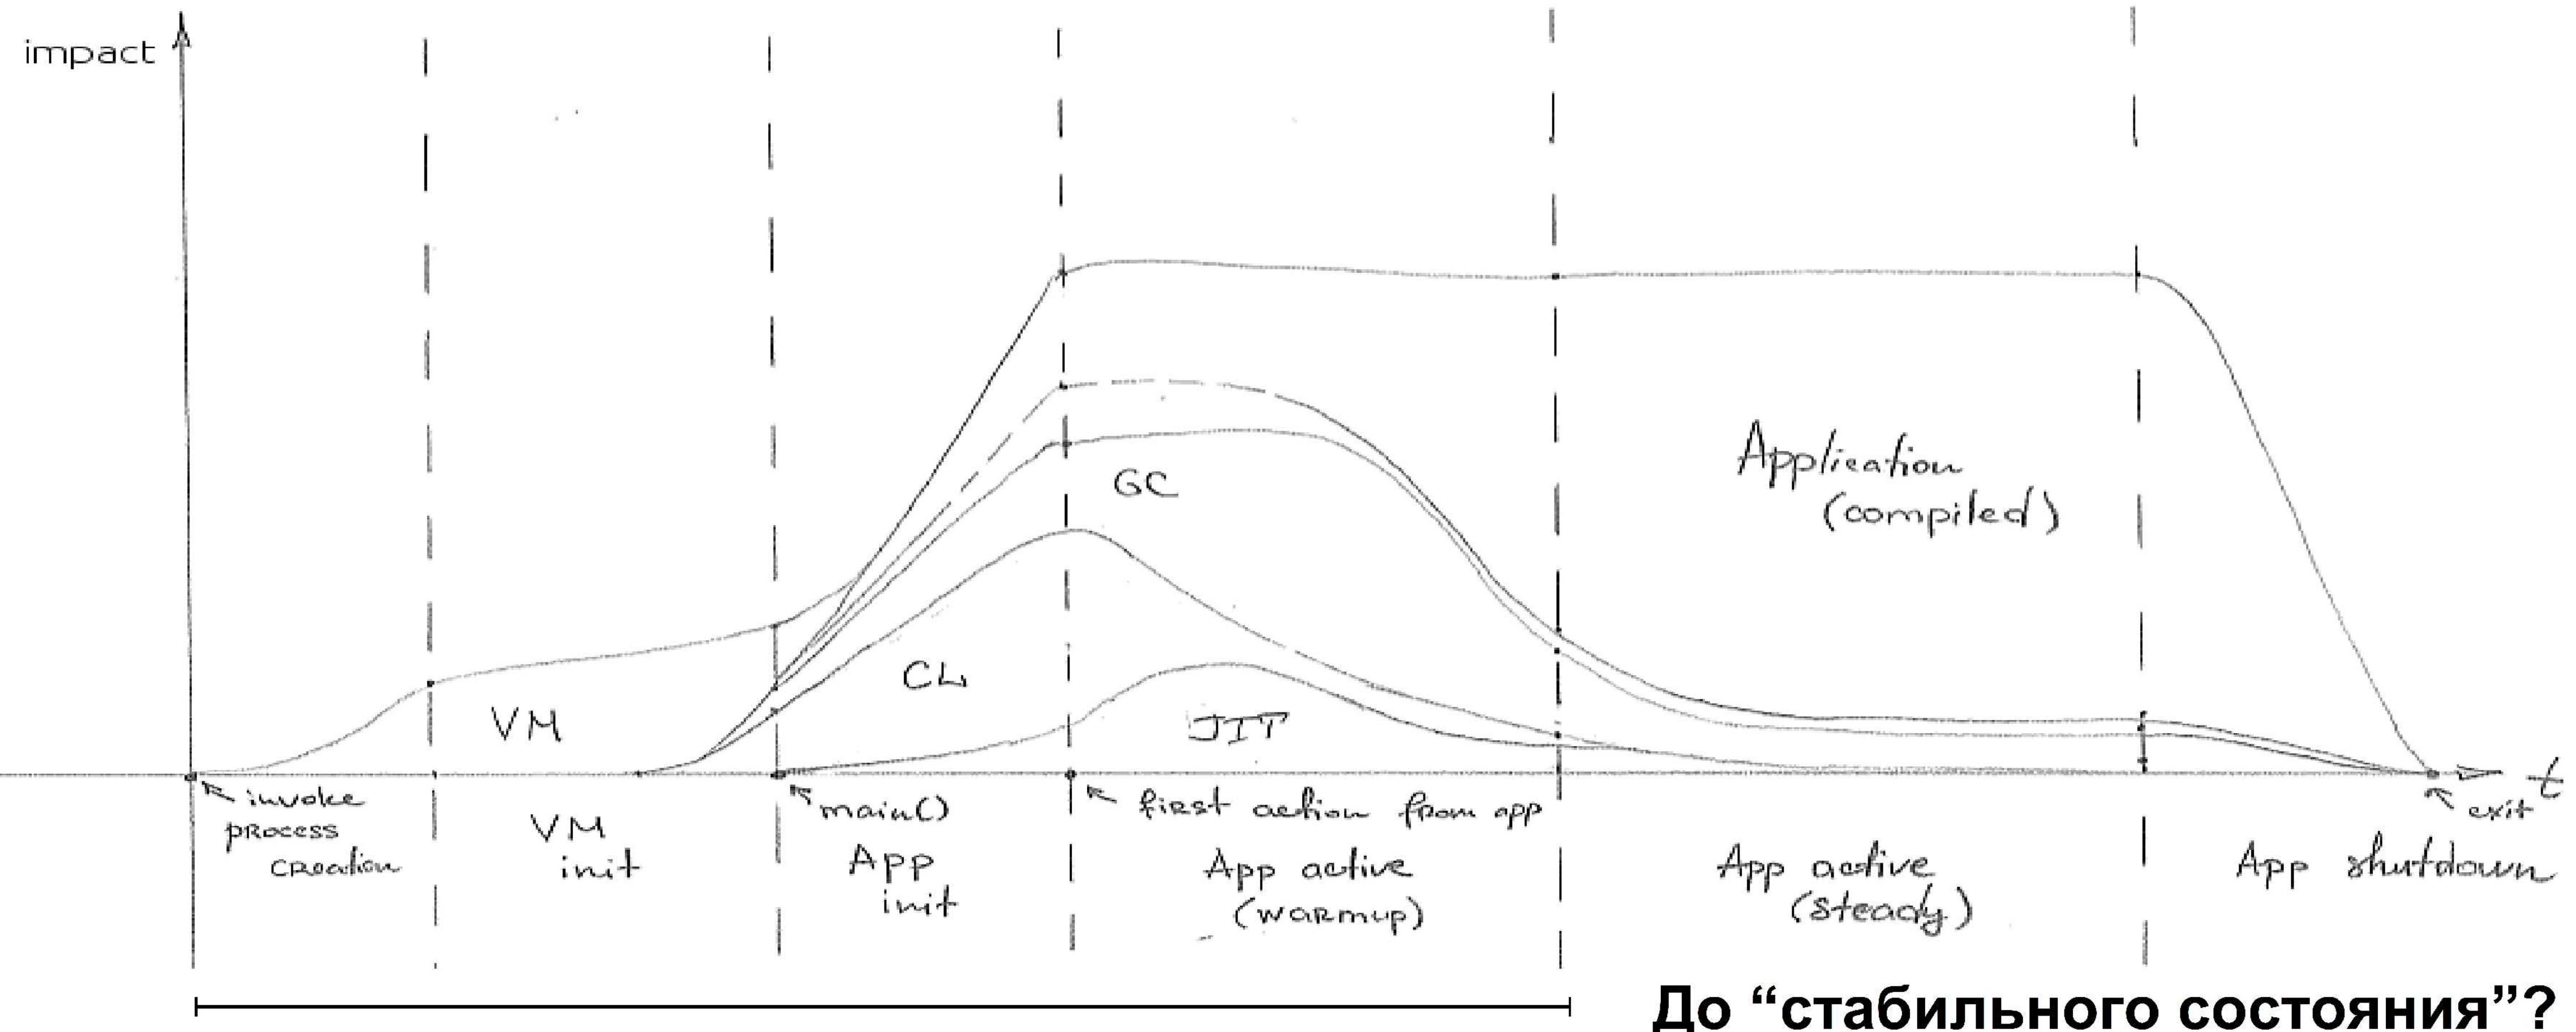
Startup

как измерять?



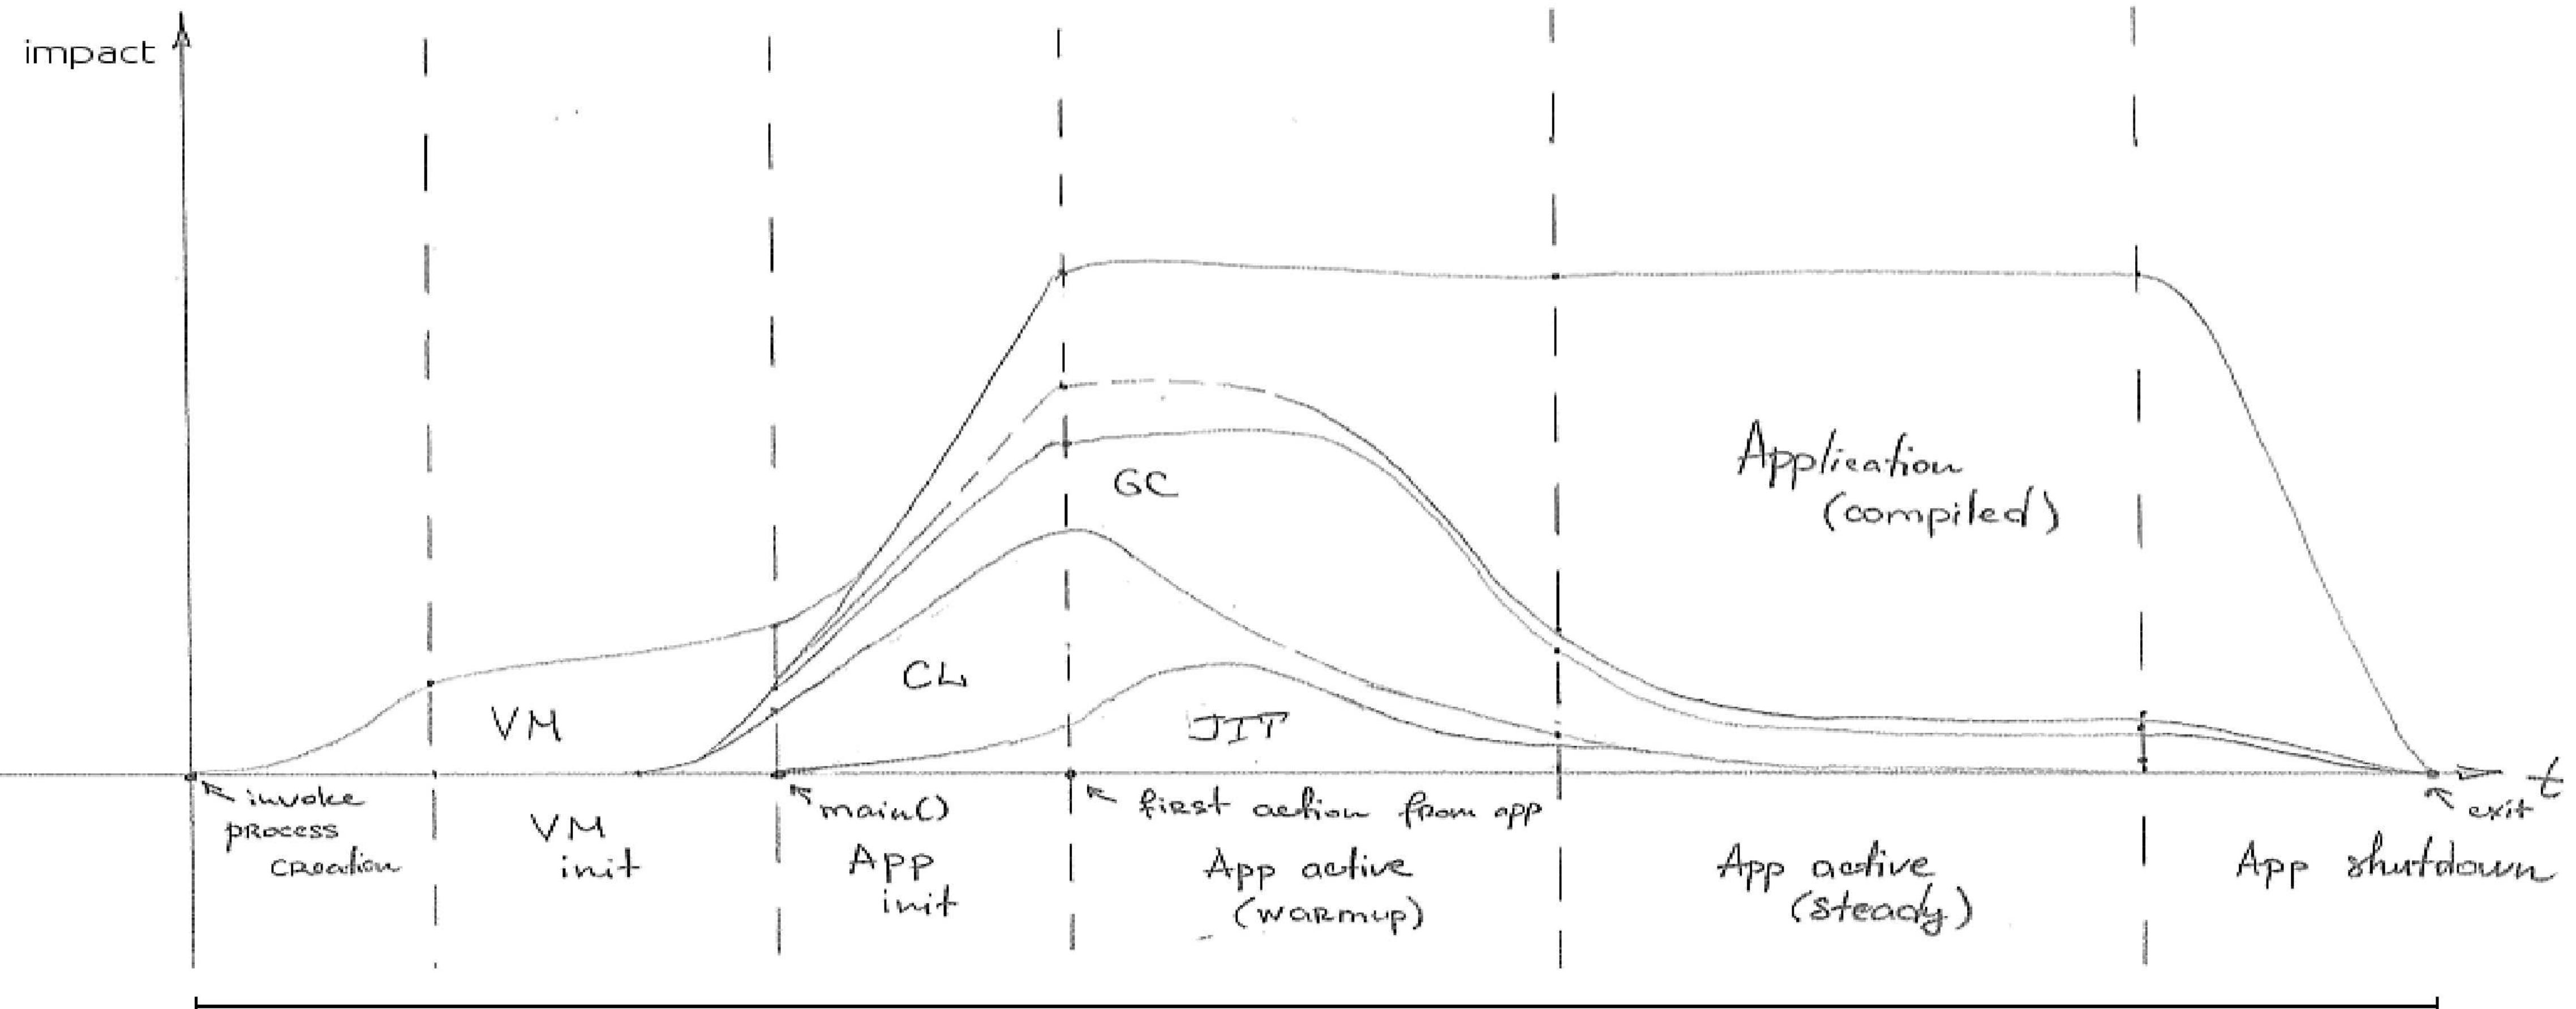
Startup

как измерять?



Startup

как измерять?



Время на пуск-остановку?

Startup

Eclipse

- **Типичная конфигурация:**
 - 2x2 Intel i5 2.6 Ghz, Ubuntu 10.10 i686, JDK 6u25
 - Eclipse JDT (Galileo)
- **Типичные метрики:**
 - 6.000 загруженных классов
 - 1.000 методов скомпилировано
 - 512 Mb зарезервированного пространства в куче
 - 25 Mb кучи использовано после старта
- **Известные “проблемы”:**
 - Загрузка и верификация классов
 - JIT-компиляция



Startup

Eclipse

- **Метрика: секунд на запуск-завершение**
 - Файловые кеши прогреты, практически нулевой дисковый I/O

	default	CDS	CDS + no-verify
абсолютное время	5.83 [5.74; 5.92]	4.81 [4.73; 4.84]	4.61 [4.56; 4.74]
загрузка классов	5.01 [4.91; 5.11]	3.39 [3.12; 3.66]	3.01 [2.94; 3.08]
компиляция	0.51 [0.43; 0.59]	0.51 [0.44; 0.58]	0.51 [0.42; 0.60]

Startup

длинные приложения

- **Важно только для коротких приложений**
 - Чем дольше работает приложение, тем меньше удельные затраты на загрузку классов и компиляцию
- **Пример: 8 часа работает IntelliJ IDEA 10.x:**
 - 26.600 классов загружено
 - 5315 методов скомпилировано
 - Загрузка классов:
 - Всего потрачено 202 с., ~0.7% общего времени
 - 10 мсек на класс
 - Компиляция:
 - Всего потрачено 112 с., ~0.03% общего времени
 - 20 мсек на метод

Concurrency

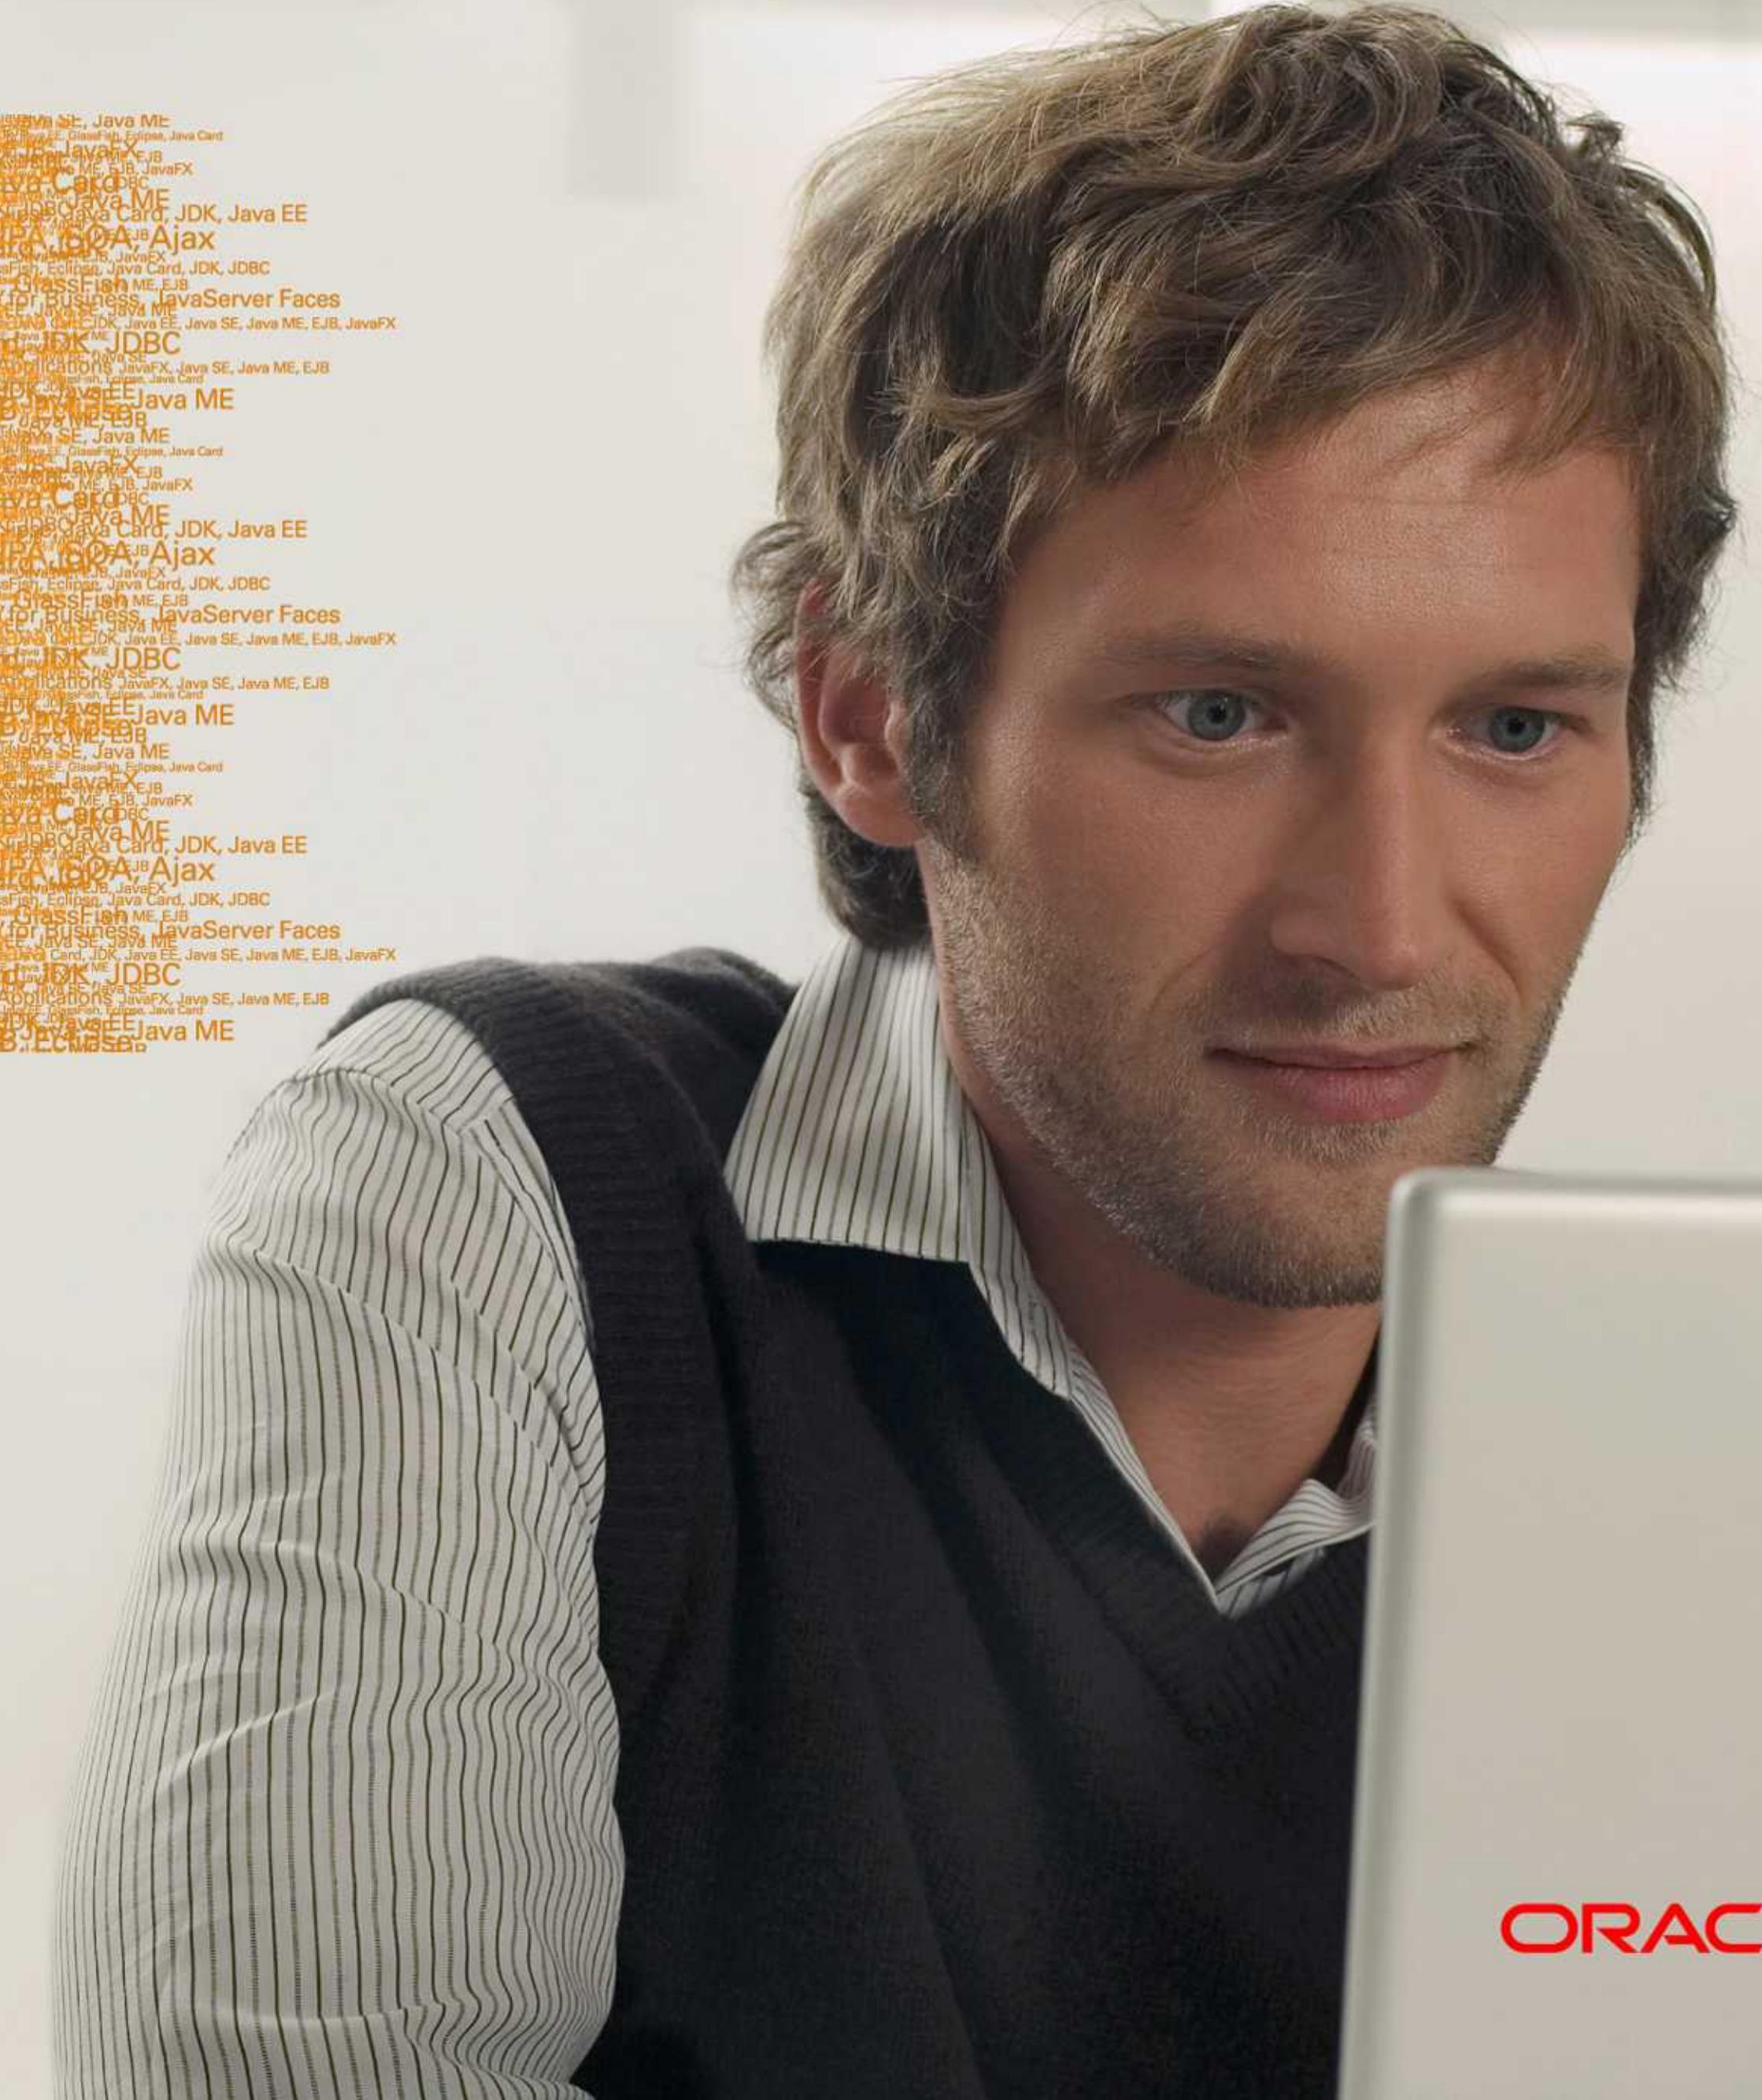


Concurrency

общие соображения

- **Не изобретайте велосипедов**
 - Лучше не слишком оптимальный, но надёжный код
 - Проще поставить ещё сервер и туда скалироваться
 - JRE никогда не соптимизирует самописные синхронизаторы
- **Пользуйтесь java.util.concurrent.***
 - Не отменяет требований к вменяемости разработчиков
 - Думаете, что нашли баг?
 - <http://g.oswego.edu/dl/concurrency-interest/>
- **Проверяйте ваши гипотезы**

JIT



JIT

факты

- ... есть
- ... работает
- ... работает хорошо
- ... знает о железе всё:
 - Количество и тип CPU
 - Поддерживаемые инструкции (SSE, AVX, VIS)
 - Топологию памяти (в т.ч. размеры кэшей и их характеристики)
- ... знает о приложении много всего:
 - Иерархию загруженных классов
 - Актуальную статистику создания объектов
 - Горячий код
 - Какие ветвления исполнялись
 - Какие значения использовались
 - Многое другое
- ... не боится использовать эти знания для компиляции



JIT

ОПТИМИЗАЦИИ

compiler tactics
delayed compilation
tiered compilation
on-stack replacement
delayed reoptimization
program dependence graph representation
static single assignment representation
proof-based techniques
exact type inference
memory value inference
memory value tracking
constant folding
reassociation
operator strength reduction
null check elimination
type test strength reduction
type test elimination
algebraic simplification
common subexpression elimination
integer range typing
flow-sensitive rewrites
conditional constant propagation
dominating test detection
flow-carried type narrowing
dead code elimination

language-specific techniques
class hierarchy analysis
devirtualization
symbolic constant propagation
autobox elimination
escape analysis
lock elision
lock fusion
de-reflection
speculative (profile-based) techniques
optimistic nullness assertions
optimistic type assertions
optimistic type strengthening
optimistic array length strengthening
untaken branch pruning
optimistic N-morphic inlining
branch frequency prediction
call frequency prediction
memory and placement transformation
expression hoisting
expression sinking
redundant store elimination
adjacent store fusion
card-mark elimination
merge-point splitting

loop transformations
loop unrolling
loop peeling
safepoint elimination
iteration range splitting
range check elimination
loop vectorization
global code shaping
inlining (graph integration)
global code motion
heat-based code layout
switch balancing
throw inlining
control flow graph transformation
local code scheduling
local code bundling
delay slot filling
graph-coloring register allocation
linear scan register allocation
live range splitting
copy coalescing
constant splitting
copy removal
address mode matching
instruction peepholing
DFA-based code generator

JIT

performance urban legends

копируйте поля в локальные переменные!

вызов виртуального метода - дорого

immutable классы – плохо

Java медленна потому, что нельзя вручную выключить проверку выхода индекса за границы массива

final дает лучшую производительность

Reflection – дорого

избегайте get/set методов внутри самого класса

native методы дорогие, System.arraycopy()
нативный – значит ...

volatile запрещает JIT оптимизировать доступ к полю

вручную вылизанный метод лучше аналога из classlib

вручную выполненный inline – хорошо

создание объектов дорого – используйте Object pooling

JIT

как писать код

- **Используйте стандартные библиотеки**
 - Зачем писать собственный стандартный контейнер?
- **Используйте высокоуровневый API:**
 - java.util.*
 - java.util.concurrent.*
 - NIO, NIO.2
 - вообще библиотеки
- **Код должен правильным и понятным**
 - Сначала правильно
 - Потом алгоритмически “быстро”
 - Код не должен быть JIT-oriented
- **Правильно используйте возможности языка**
 - EPIC FAIL: штатная передача управления exception'ами
 - FAIL: Возврат “исключения” через return <код_ошибки>
 - FAIL: int вместо Enum или boolean



- Как получить ассемблерный код метода?
 - Обычным дебаггером ;)
 - JVMTI
 - **-XX:+PrintAssembly**
 - <http://wikis.sun.com/display/HotSpotInternals/PrintAssembly>

НЕСМОТРЯ НА ДЕТАЛЬНЫЙ
АНАЛИЗ ТЕКУЩЕЙ СИТУАЦИИ, Я
ТАК И НЕ СМОГ СОСТАВИТЬ
ЧЁТКОЕ ПРЕДСТАВЛЕНИЕ ОБ
ОБСУЖДАЕМОЙ ПРОБЛЕМЕ В
СИЛУ ВОЗНИКШЕГО
КОНГИТИВНОГО ДИССОНАНСА.



Q/A

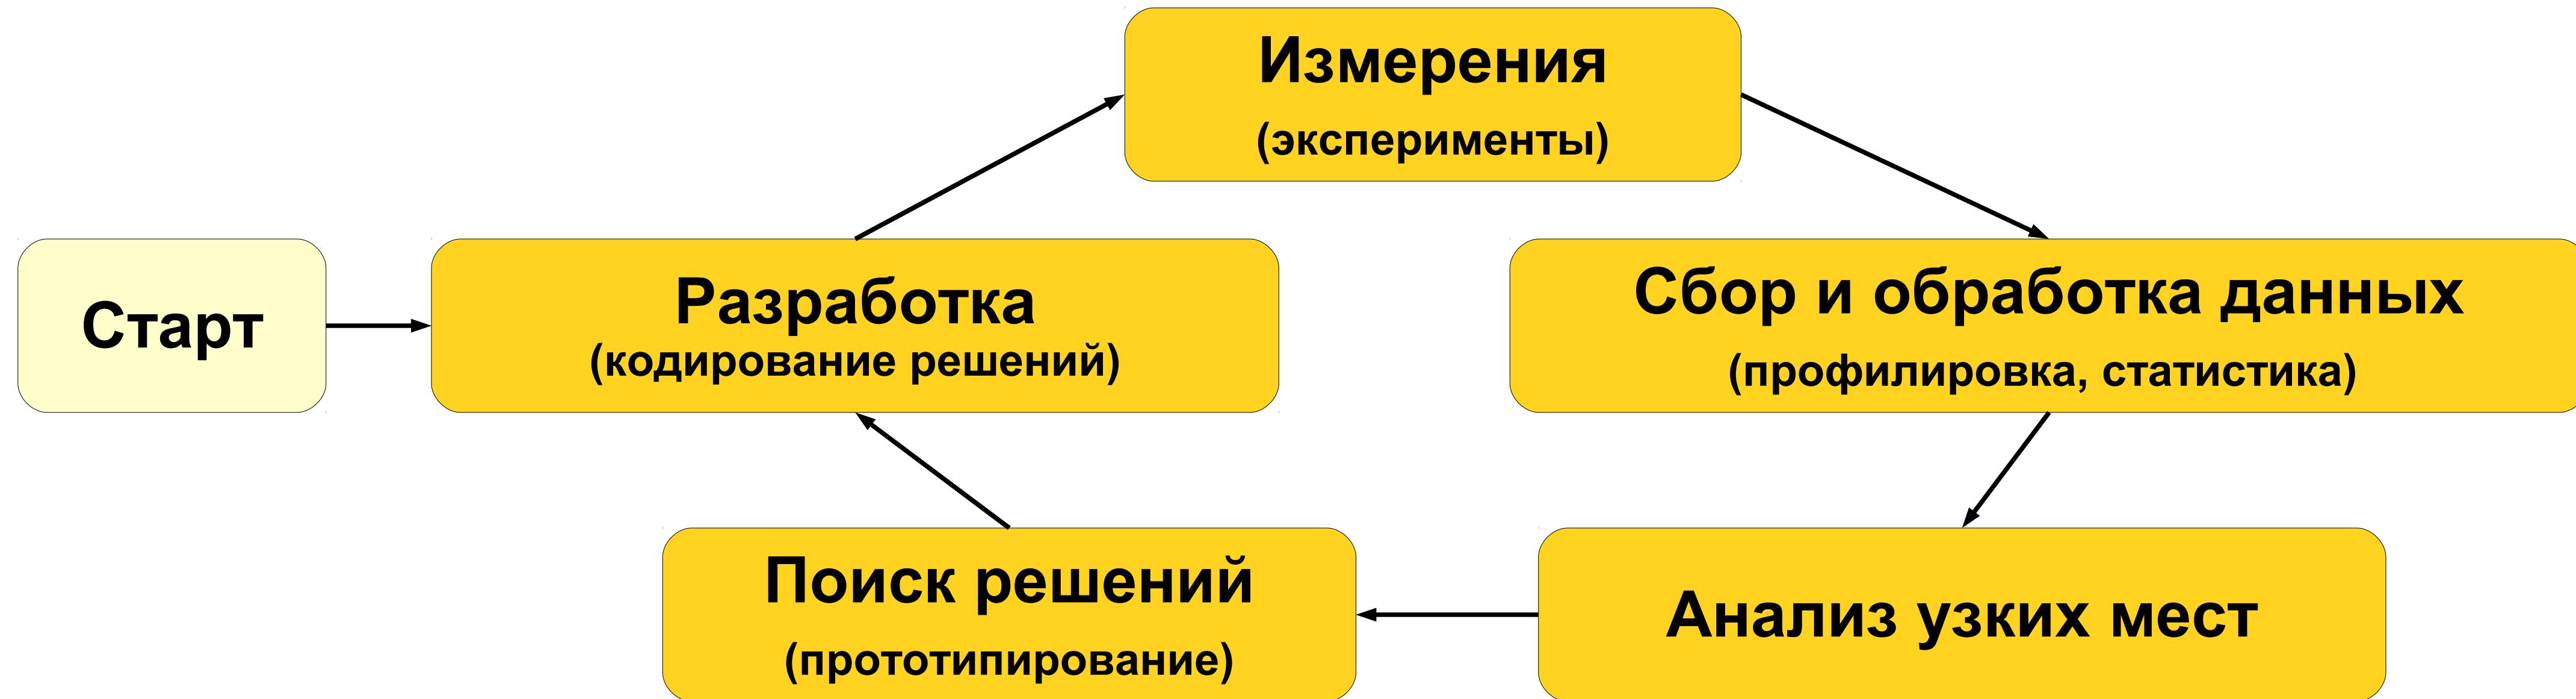
Appendix



ORACLE®

Performance Engineering

итеративный подход



Важно:

- Одно изменение за цикл!
- Документировать все изменения

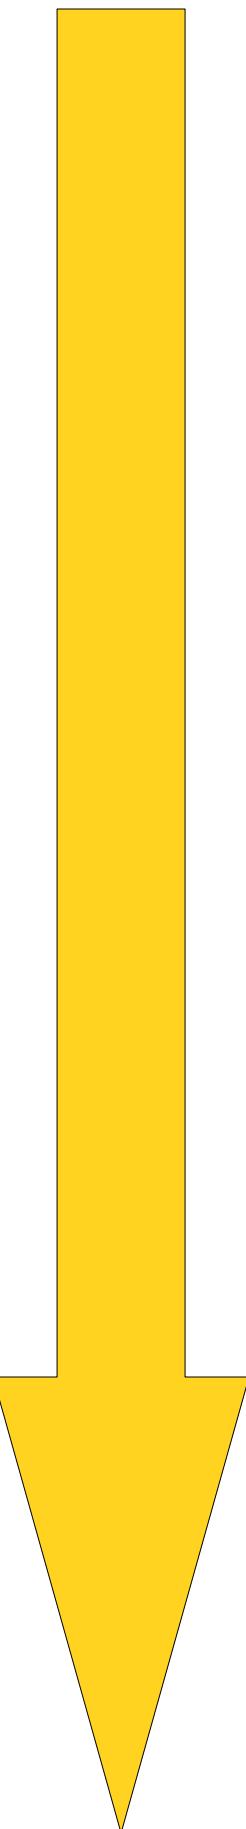
Performance Engineering

анализ узких мест

- **Что ограничивает скорость работы приложения?**
 - CPU
 - Ядро ОС
 - I/O (Сеть, Диск)

Performance Engineering

”нисходящий” метод поиска узких мест



- Уровень системы
 - Сеть
 - Диск
 - Database
 - Операционная система
 - Процессор/память
- Уровень приложения
 - Блокировки, синхронизация
 - Execution Threads
 - API
 - Алгоритмические проблемы
- Уровень JVM
 - Выбор JVM
 - Heap tuning
 - JVM tuning

Java 7, Java 8

Что ожидать в области производительности

- **Java 7**
 - invokedynamic
 - NIO.2
 - Concurrency and Collection updates (Fork/Join)
 - XRender pipeline for Java2D (client)
- **Java 8 (или позже)**
 - Модульность
 - λ-выражения (замыкания)
 - Collection updates (filter, map, reduce)



Обратная совместимость

- Мешает ли улучшать производительность JVM?
 - Да, поэтому иногда расширяемся:
 - invokedynamic
 - Модульность
- Стоит ли расширяться по первому требованию?
 - Нет, развитие JVM/JIT, реализация новых методов оптимизации позволяет получить больший выигрыш
 - Вложенные классы
 - Reflection



Лучшая ОС для Java

угадайте, какая?

Solaris

- Высокопроизводительный TCP/IP стек
 - low-latency
 - up to 50% faster
- DTrace
 - мониторинг
- NUMA
 - MPO, Memory Placement Optimization
- Large Pages
 - Автоматическая аллокация
 - Разные размеры



Concurrency

элементная база

- **OS Threading**
 - мьютексы
 - mutex_lock()/mutex_unlock()
 - conditional waits
 - cond_wait()/cond_signal()
 - WaitForSingleObject
- **Compare-and-Swap (CAS)**
 - $\text{CAS}(x_1, x_2, x_3) = \{ \text{if } (x_1 == x_2) \{ x_1 = x_3 \}; \}$
 - атомарная операция, поддерживаемая в “железе”: из нескольких одновременных CAS'ов успешно завершается только один
 - Миф: локальный CAS блокирует шину, и стоит больше на многопроцессорных системах
 - Факт: глобальный CAS требует трафика нашине



Concurrency

atomics

- **java.util.concurrent.Atomic***
 - обеспечивают атомарные операции над примитивами и указателями
 - альтернатива: synchronized {} или Lock'и
- **Трюк в использовании CAS'a:**
 - Изменение состояния атомика делается при помощи одного CAS'a
 - Чтение состояния не требует CAS'a

```
public final int incrementAndGet() {  
    for (;;) {  
        int current = get();  
        int next = current + 1;  
        if (compareAndSet(current, next))  
            return next;  
    }  
}
```

```
mov    %ecx,%edx  
mov    0x8(%ecx),%eax  
lea    0x8(%ecx),%edi  
mov    %eax,%ecx  
inc    %ecx  
lock  cmpxchg %ecx,(%edi)  
mov    $0x0,%ebx  
jne    [ok]  
mov    $0x1,%ebx  
test   %ebx,%ebx  
je     [ok]
```



Concurrency

volatile

- **Volatile определяет порядок чтения-записей в поле**
 - НЕ обеспечивает атомарности
 - Реализуется расстановкой барьеров
 - Какие из них вставляются в код, зависит от Hardware Memory Model
 - Эффект барьера зависит от HMM

PUSHL EBP	
SUB ESP, 8	push %ebp
MOV EBX, [ECX + #12]	sub \$0x8,%esp
MEMBAR-acquire	mov 0xc(%ecx),%ebx
MEMBAR-release	inc %ebx
INC EBX	mov %ebx,0xc(%ecx)
MOV [ECX + #12],EBX	lock addl \$0x0,(%esp)
MEMBAR-volatile	add \$0x8,%esp
LOCK ADDL [ESP + #0], 0	pop %ebp
ADD ESP,8	test %eax,0xb779c000
POPL EBP	ret
TEST PollPage,EAX	
RET	

Concurrency

intrinsic synchronization

- `synchronized(object) { }`, 4 состояния:
 - **Init**
 - **Biased**
 - Захватывается одним “владеющим” потоком, нет конфликтов
 - Захват владельцем: проверка на threadID
 - Захват не-владельцем: переход либо в Biased, либо в Thin
 - **Thin**
 - Захватывается несколькими потоками, но конфликтов нет
 - Захват: CAS
 - Конфликтный захват: переход в Fat
 - **Fat**
 - Захватываетсяическими потоками, конфликт на блокировке
 - Вызов примитива синхронизации из ОС

Concurrency

java.util.concurrent.Lock

- Построены на базе j.u.c.**AbstractQueueSynchronizer**
 - Использует CAS
 - Использует Unsafe.park()/unpark() → cond_wait()/cond_signal()/WaitForSingleObject()
- **ReentrantLock**
 - По семантике эквивалентен synchronized {}
 - Ставит потоки во внутреннюю очередь и делает park()
 - Non-Fair (default)
 - Не гарантирует отсутствие starvation, ибо barging FIFO (CAS)
 - Лучшая производительность
 - Fair
 - Гарантирует отсутствие starvation, FIFO
 - Честность в обмен на производительность

Concurrency

атомарный счётчик

```
private AtomicInteger atomic = new AtomicInteger();
private ReentrantLock lock = new ReentrantLock();
private final Object intrinsicLock = new Object();
private int primCounter = 0;

@GenerateMicroBenchmark
public void testAtomicInteger() {
    atomic.incrementAndGet();
}

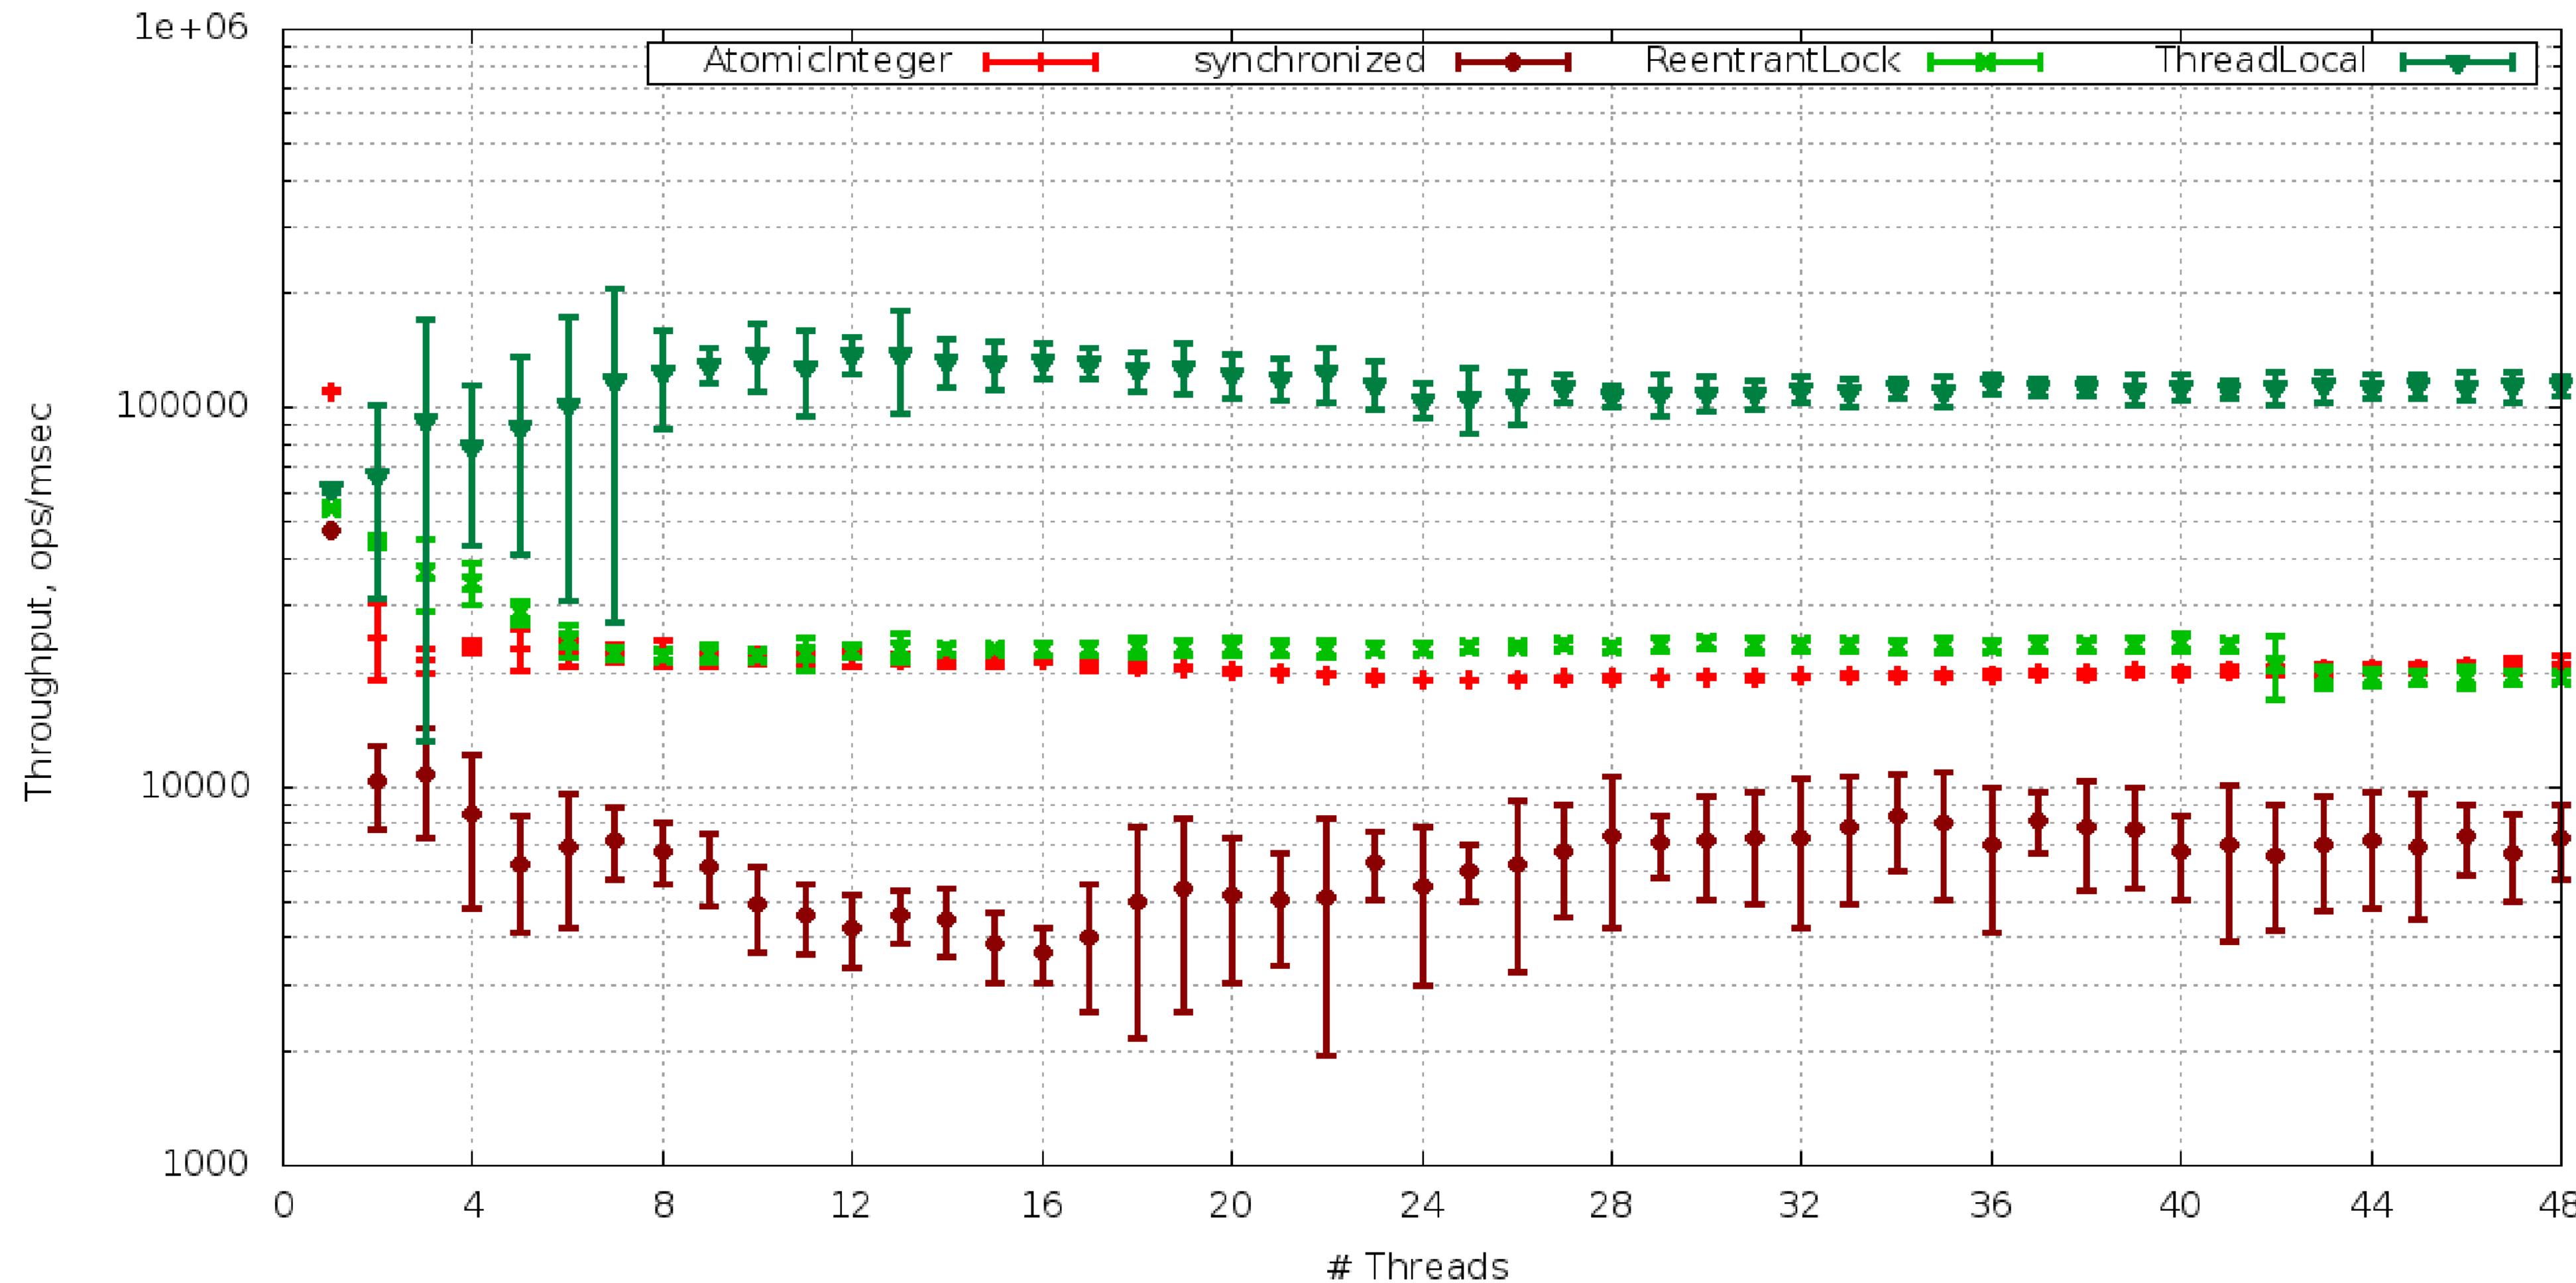
@GenerateMicroBenchmark
public void testReentrantLock() {
    lock.lock();
    primCounter++;
    lock.unlock();
}

@GenerateMicroBenchmark
public void testIntrinsicLock() {
    synchronized (intrinsicLock) {
        primCounter++;
    }
}
```



Concurrency

атомарный счётчик



Concurrency

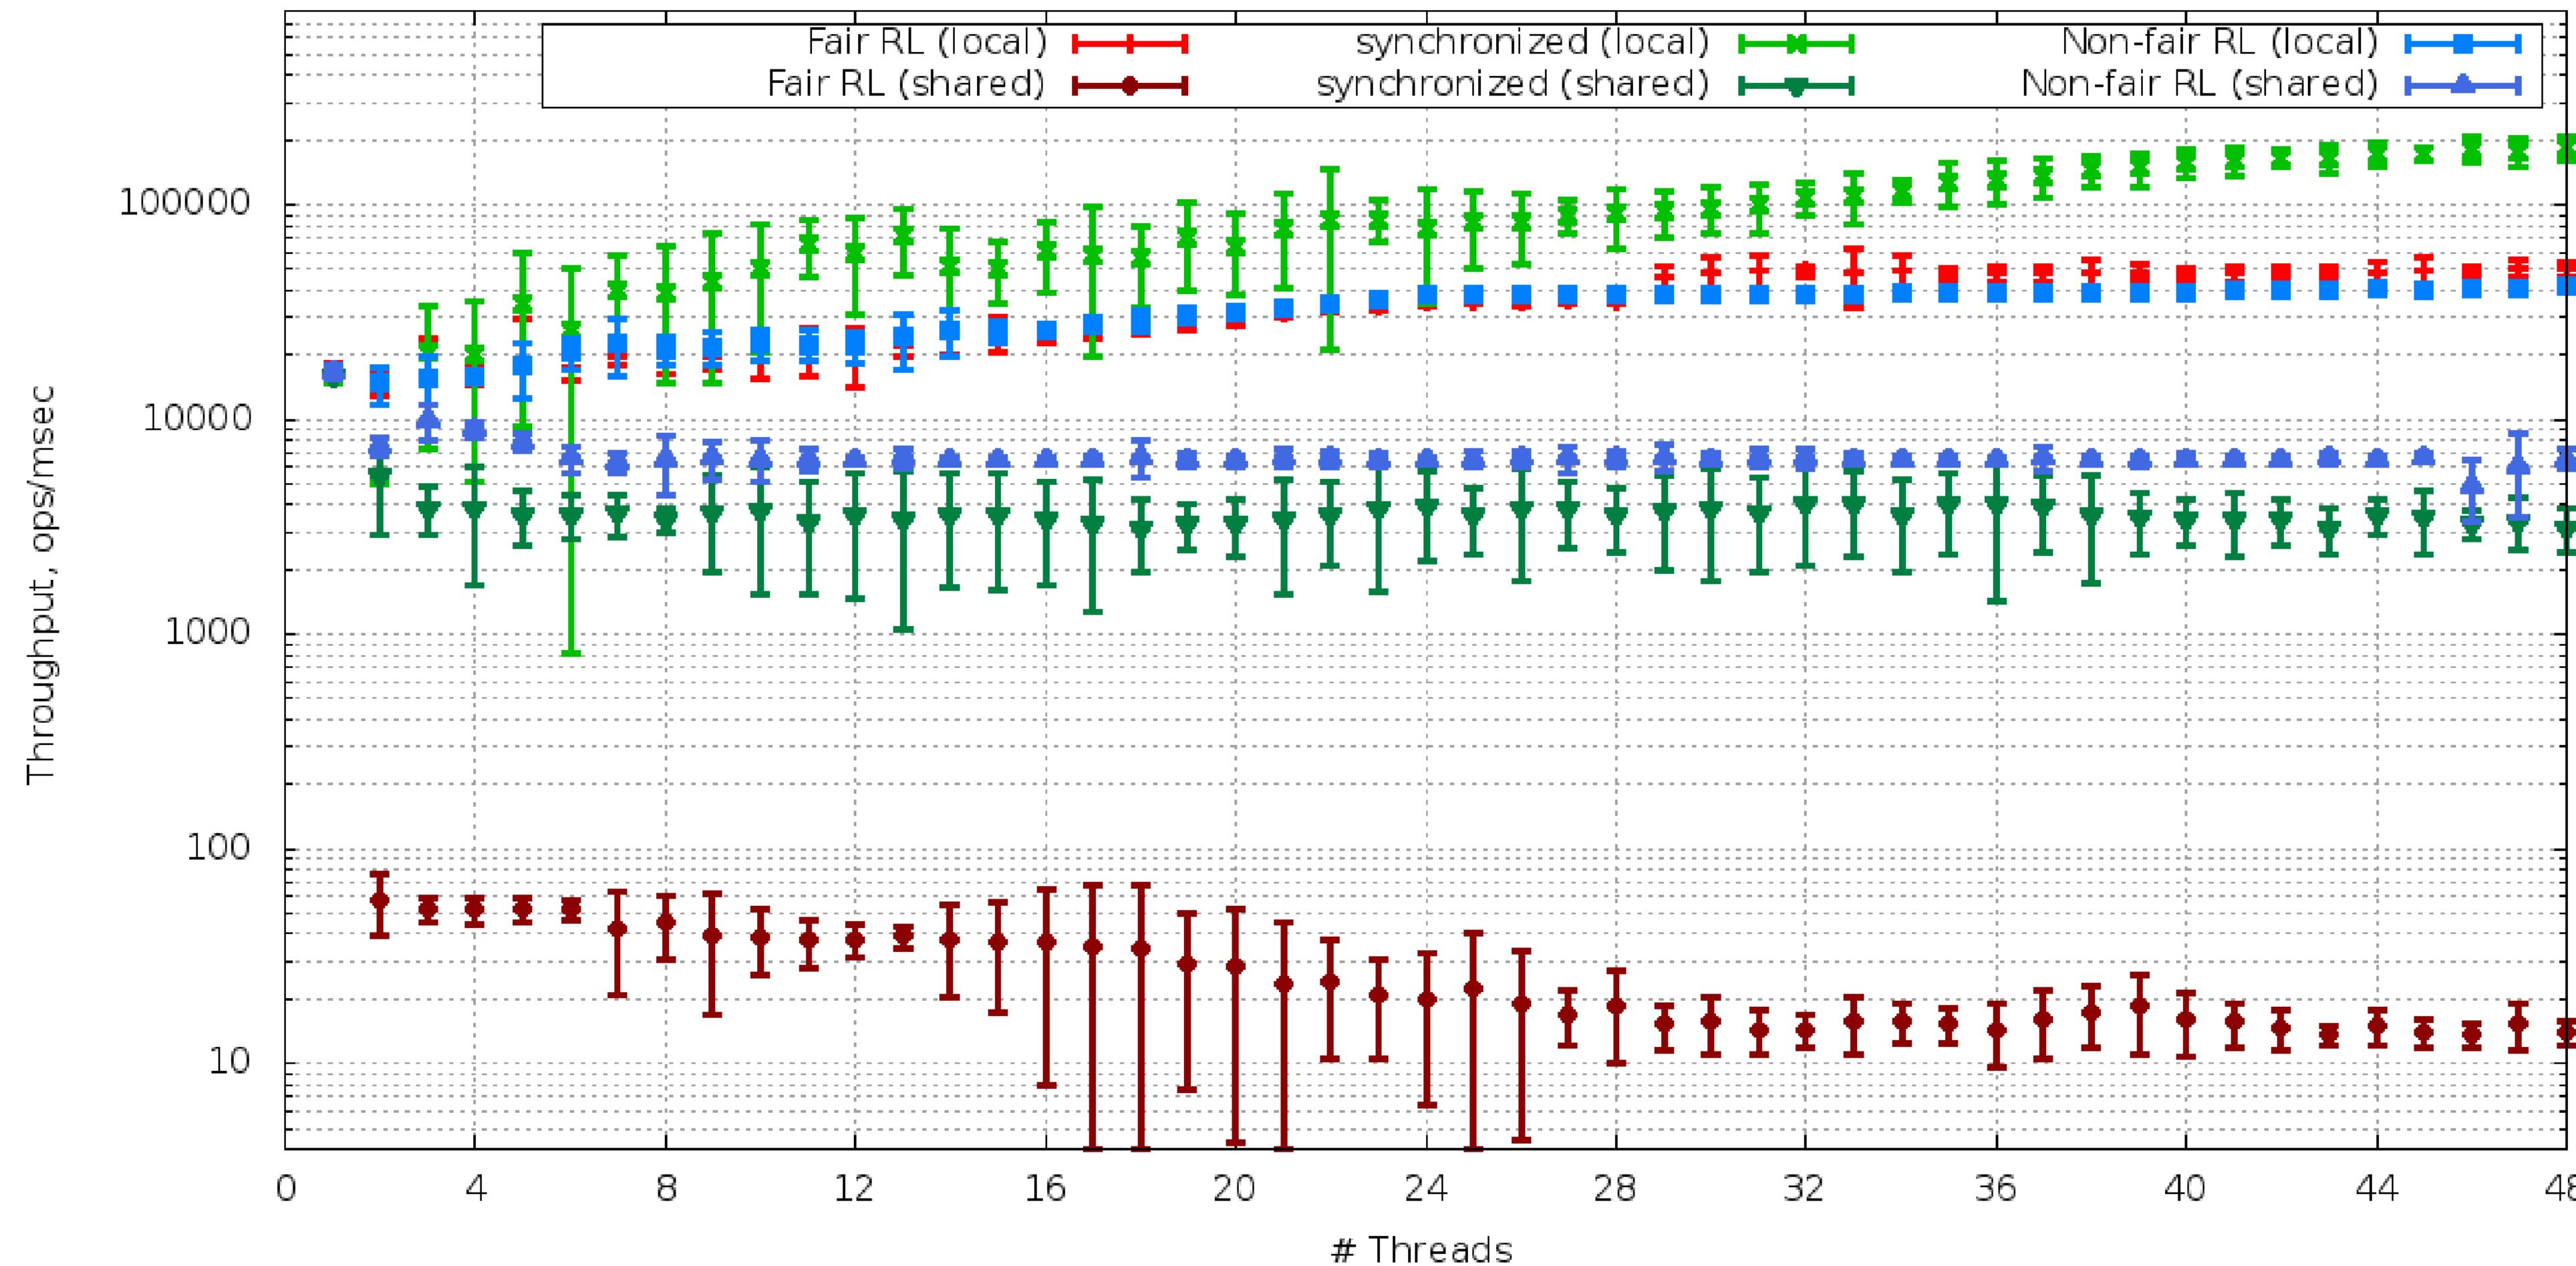
ReentrantLock vs. synchronized

- **Семантика одинакова**
 - Требования к видимости памяти
 - Рекурсивный
- **Плюсы j.u.c.RL**
 - Очередь потоков держится на стороне JVM
 - опционально, FIFO-политика при захвате-освобождении
 - позволяет быть “честным” на любой платформе
 - Barging FIFO policy
 - lock() может быть сразу удовлетворён, даже если в очереди есть потоки
 - сильно улучшает производительность при конфликте блокировок
 - Допускается несколько Condition
- **Минусы j.u.c.RL**
 - Нет scope'ов, требуется ручной unlock() через finally



Concurrency

производительность захвата





The preceding is intended to outline our general product direction. It is intended for information purposes only, and may not be incorporated into any contract. It is not a commitment to deliver any material, code, or functionality, and should not be relied upon in making purchasing decisions.

The development, release, and timing of any features or functionality described for Oracle's products remains at the sole discretion of Oracle.



