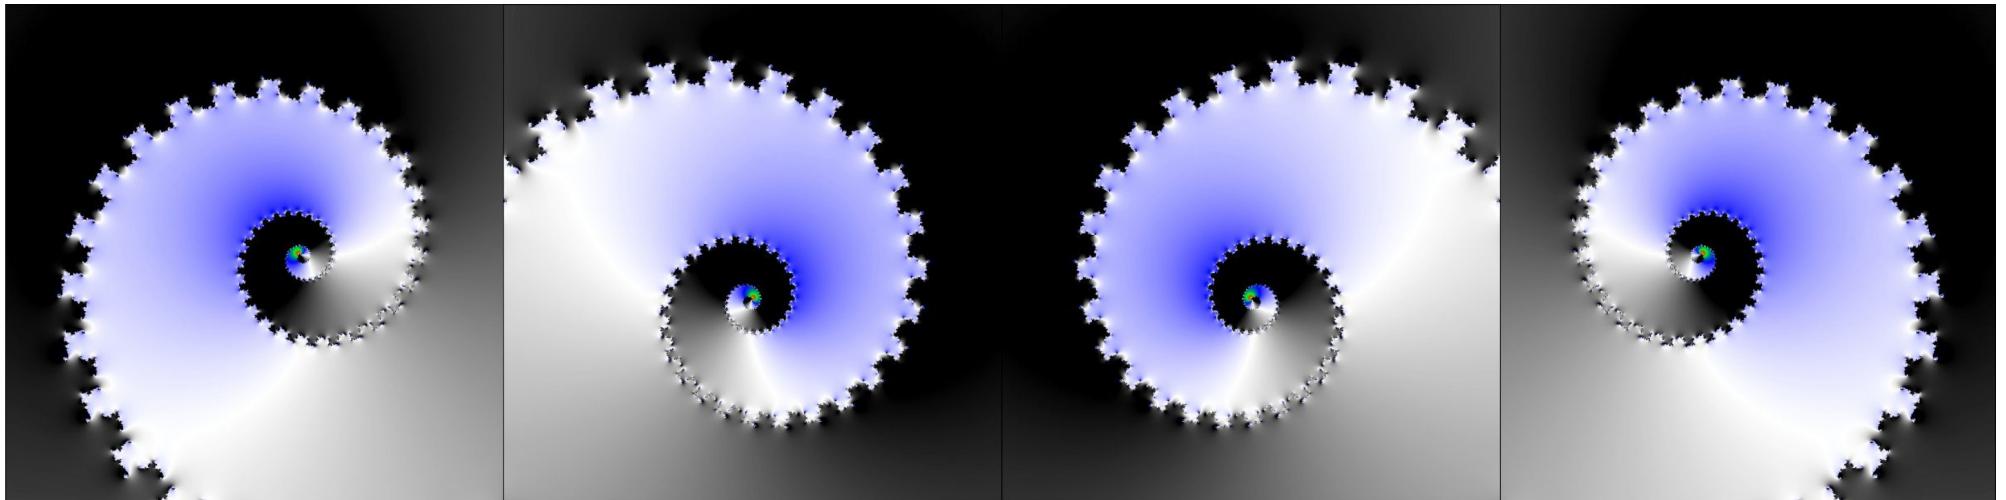


# Java-Concurrency für Fortgeschrittene



[arno.haase@haase-consulting.com](mailto:arno.haase@haase-consulting.com)

We should forget about small efficiencies, say about 97% of the time:

Premature Optimization is the root of all evil.

Yet we should not pass up our opportunities in that critical 3%.

Donald Knuth

Algorithmen

Konzepte

Ideen

Bibliotheken: JEE / Spring,  
Akka, LMAX, Servlet 3, ...

JDK: Atomic\*, Streams, synchronized,  
Locks, Fork/Join, ConcurrentHashMap, ...

Java Memory Model

Architektur



1. Java Memory Model
2. Konzepte und Paradigmen
3. Performance

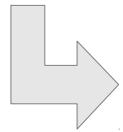
Tut Dein Computer,  
was Du programmiert hast?

ja

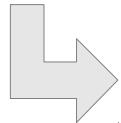
nein

# Transformationen

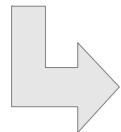
**Compiler:** Instruction Reordering,  
Zusammenfassen von Ausdrücken, ...



**Hotspot:** Register Allocation, Instruction  
Reordering, Escape Analysis, ...



**Prozessor:** Branch Prediction, Speculative  
Evaluation, Prefetch, ...



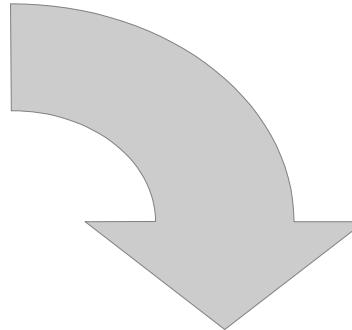
**Caches:** Store Buffers, Private Shared  
Caches, ...

Die sichtbaren Auswirkungen sind auf  
allen Ebenen gleich.



# Beispiel: Abbruchbedingung

```
boolean shutdown = false;  
...  
void doIt() {  
    while (!shutdown) {  
        ...  
    }  
}
```



```
boolean shutdown = false;  
...  
void doIt() {  
    boolean b = shutdown;  
    while (!b) {  
        ...  
    }  
}
```



# Threads (naiv)

- Threads arbeiten abwechselnd.
- Jeder Thread tut, was im Quelltext steht.
- Wenn er unterbrochen wird, sehen andere Threads den Zwischenzustand.
- Synchronisation dient dazu, Änderungen atomar zu machen.

# Threads (etwas weniger naiv)

- Es gibt mehrere CPUs, die Threads wirklich gleichzeitig abarbeiten.
- Jeder Thread tut, was im Quelltext steht.
- Datenzugriffe gehen ins RAM.
- Wenn Threads auf die selben Daten zugreifen, ist das automatisch nach einander.

# Die Wahrheit

- Innerhalb eines Threads sieht es aus, *als ob* er den Quelltext ausführen würde.
- Dinge in verschiedenen Threads passieren in einer definierten Reihenfolge, wenn die Synchronisation das vorschreibt („happens-before“).
- *Und nicht mehr!*

# Korrekte Synchronisation

- Keine Race Conditions:
  - Wenn mehrere Threads auf eine Variable zugreifen
  - und mindestens einer schreibt,
  - müssen sie über „happens-before“ geordnet sein.
- Dann läuft das Programm, *als ob*
  - alle Speicherzugriffe sequentiell passieren,
  - tatsächlich auf RAM zugreifen,
  - und zwar in der „happens-before“-Reihenfolge



# Beispiel: volatile

- Wenn
  - Thread T1 eine volatile-Variable  $v$  schreibt
  - Thread T2 anschließend  $v$  liest
- Dann
  - sind alle Änderungen aus T1 bis zum Zugriff auf  $v$  'vor' dem Zugriff in T2

# Memory Barriers

- Hilfsmittel zur Implementierung des JMM
  - Assembler-Befehle
  - „synchronisieren“ CPUs und Caches
  - Begrenzen Reordering
- Teuer!
  - Direkte Kosten: Cache-Flush
  - Begrenzen Optimierungen
- Wo setzt Java sie?
  - synchronized, Locks
  - volatile
  - nach Konstruktor (für final-Attribute), ...

**Concurrency  
ist  
komplex!**



# Ein einfacher Logger

```
public class Logger {  
    public void log (String msg, Object... params) {  
        String s = doFormat (msg, params);  
        doLog (s);  
    }  
  
    private String doFormat (String msg, Object... params) {...}  
    private void doLog (String msg) {...}  
}
```

# thread-sicher?

```
public class Logger {  
    public synchronized void log (String msg, Object... params) {  
        String s = doFormat (msg, params);  
        doLog (s);  
    }  
  
    private String doFormat (String msg, Object... params) {...}  
    private void doLog (String msg) {...}  
}
```



# versteckte Deadlocks

```
public class X {  
    public synchronized void doIt () {  
        log.log ("doing it");  
        ...  
    }  
    public synchronized String toString () { ... }  
    ...  
}
```

x.doIt();

lock (x)

log.log("...") → lock (log)

log.log ("%s", x);

lock (log)

x.toString() → lock (x)

# Asynchrones Logging

```
final ExecutorService exec =
    Executors.newSingleThreadExecutor();

public void log (String msg, Object... args) {
    exec.execute (() -> {
        String formatted = doFormat (msg, args);
        doLog (formatted);
    });
}
```



# Parallelisieren?

- Formatieren kann teuer sein
  - `toString()`: Callbacks in Anwendungscode!
- Thread-Pool zum Logging?
  - Reihenfolge der Nachrichten geht verloren!
  - ... und `doLog` ist nicht thread-sicher

# Future<String>

```
final ExecutorService exec =
    Executors.newSingleThreadExecutor();

public void log (String msg, Object... args) {
    final Future<String> formatted =
        CompletableFuture.supplyAsync(() -> doFormat(msg, args));
exec.execute (() -> {
    try {
        doLog (formatted.get());
    }
    catch (Exception exc) {
        exc.printStackTrace();
    }
});
```



# Concurrency: Shared Mutable State

- Locks: Blocking
  - Read/Write und andere Optimierungen
- *Ein Worker-Thread mit Message-Queue*: Non-Blocking
  - Actor als Variante
- Auch „Lock-Frei“ hat shared state
- Jeder Ansatz kostet!



# Worker Threads

- Queues
  - Bounded / Unbounded
  - Blocking / Non-Blocking
  - Single / Multi Producers / Consumers
  - Optimiert für Lesen oder Schreiben (oder Mix)
  - Sonder-Features: Priority, remove(), Batch, ...
- Future für Ergebnisse
  - `.thenAccept(...)` / `.thenAcceptAsync(...)`

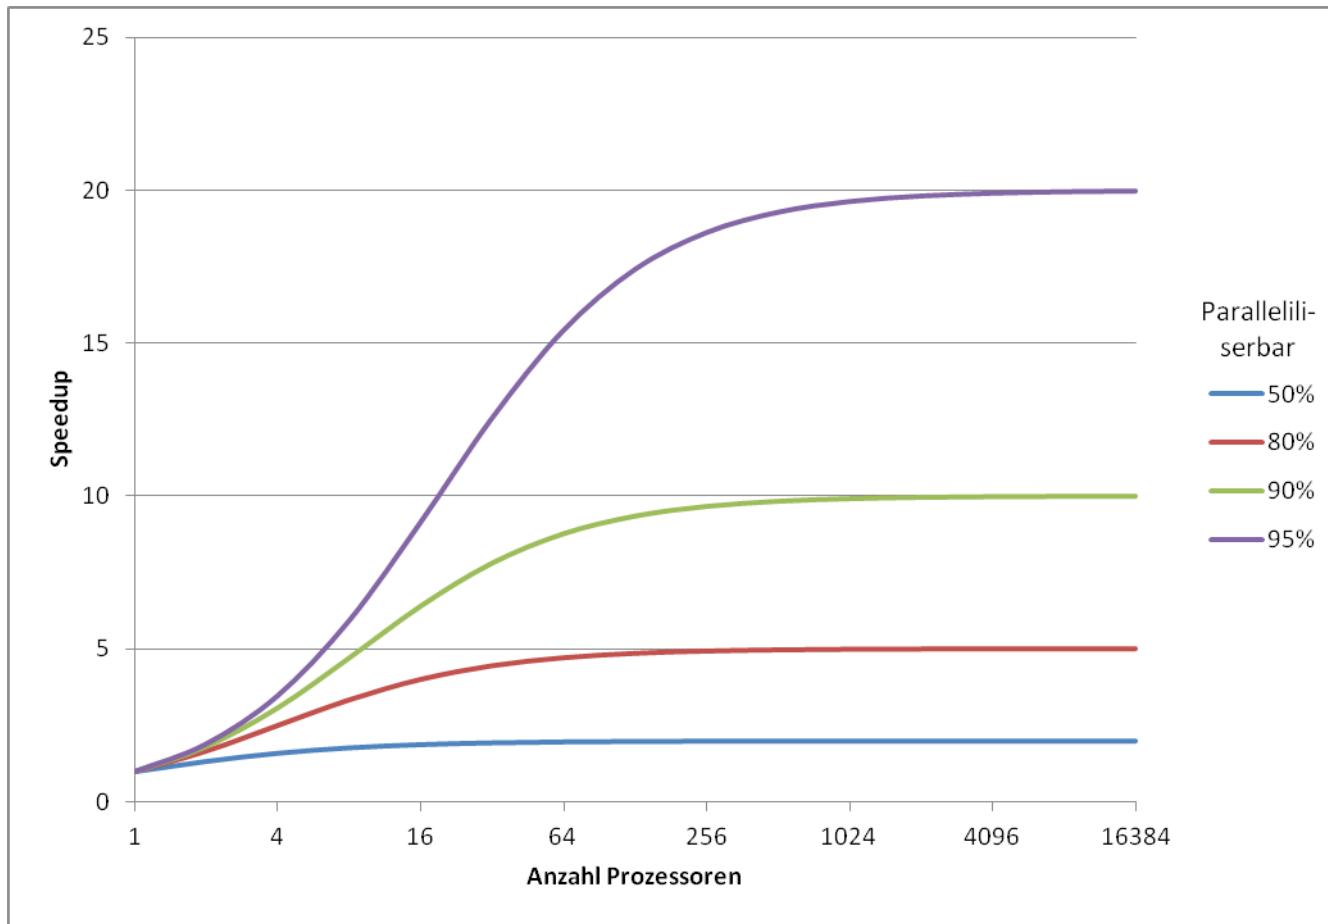


# Welcher Thread-Pool?

- mit Seiteneffekten
  - (meist) Reihenfolge wichtig → Executors.newSingleThreadExecutor()
- non-blocking ohne Seiteneffekte
  - ForkJoinPool.commonPool()
- blocking
  - Eigenen ExecutorService je Kontext
  - Tuning, Monitoring, ...
- Größere Probleme zerlegen und aufteilen
  - Messen, ob das hilft!
- *Nicht ad hoc!*



# Amdahl's Law



# Geteilte Ressourcen zwingen zum Warten!

- genauer: *veränderliche* Ressourcen
  - Locks, I/O, ...
- Verstecktes Sharing
  - ReadLock: Counter
  - UUID.randomUUID()
  - volatile: Geteilter Hauptspeicher
  - Cache Lines (Locality, Poisoning)
  - Festplatten, DVDs, Netzwerk
  - ...
- Lösungen: Isolation oder Immutability



# Lock-freie Programmierung

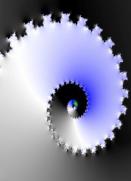
- Shared Mutable State
- Lock Free
  - Aufrufer müssen nie warten
  - Abarbeitung kann sich aber verzögern
  - z.B. asynchron entkoppelt
  - Responsive, schont Ressourcen
- Wait Free
  - Abarbeitung verzögert sich nicht
  - Spezielle Algorithmen und Datenstrukturen
  - Extremst schwierig; Grundlagenforschung, Work in Progress
  - ConcurrentHashMap, ConcurrentLinkedQueue



# CAS-Schleife

```
final AtomicInteger n = new AtomicInteger (0);

int max (int i) {
    int prev, next;
    do {
        prev = n.get();
        next = Math.max (prev, i);
    } while (! n.compareAndSet (prev, next));
    return next;
}
```



# Funktionale Programmierung

- *Ohne Seiteneffekte*
  - Alle Objekte sind immutable, bei Änderung neues Objekt
  - != Verwendung von Lambdas: JDK-Collections, Guice, ...
  - Scala, Clojure; a-base
- anderer Programmierstil
  - effizientes Kopieren: teilweise Wiederverwendung
  - funktionale Algorithmen
- Automatisch stabiler State, auch concurrent



# Performance-Tuning von Concurrency

```
public class StockExchange {  
    private final Map<Currency, Double> rates = new HashMap<>();  
    private final Map<String, Double> pricesInEuro = new HashMap<>();  
  
    public void updateRate (Currency currency, double fromEuro) {  
        rates.put (currency, fromEuro);  
    }  
  
    public void updatePrice (String wkz, double euros) {  
        pricesInEuro.put (wkz, euros);  
    }  
  
    public double currentPrice (String wkz, Currency currency) {  
        return pricesInEuro.get (wkz) * rates.get (currency);  
    }  
}
```



# Wait-Free: ConcurrentHashMap

```
public class StockExchange {  
    private final Map<Currency, Double> rates =  
        new ConcurrentHashMap<>();  
    private final Map<String, Double> pricesInEuro =  
        new ConcurrentHashMap<>();  
  
    } ...
```

# Feine Locks: Collections.synchronizedMap

```
public class StockExchange {  
    private final Map<Currency, Double> rates =  
        Collections.synchronizedMap (new HashMap<>());  
    private final Map<String, Double> pricesInEuro =  
        Collections.synchronizedMap (new HashMap<>());  
  
    } ...
```



# Globe Locks

```
public class StockExchange {  
    ...  
    public synchronized void updateRate (...) {  
        ...  
    }  
    public synchronized void updatePrice (...) {  
        ...  
    }  
    public synchronized double currentPrice (...) {  
        ...  
    }  
}
```



# Funktional: Immutable Maps

```
public class StockExchange {  
    private final AtomicReference<AMap<Currency, Double>> rates =  
        new AtomicReference<> (AHashMap.empty ());  
    ...  
  
    public void updateRate (Currency currency, double fromEuro) {  
        AMap<Currency, Double> prev, next;  
        do {  
            prev = rates.get ();  
            next = prev.updated (currency, fromEuro);  
        }  
        while (! rates.compareAndSet (prev, next));  
    }  
    ...  
}
```



# Variante: reduzierte Update-Garantie

```
public class StockExchange {  
    private volatile AMap<Currency, Double> rates =  
        AHashMap.empty ();  
    ...  
  
    public void updateRate (Currency currency, double fromEuro) {  
        rates = rates.updated (currency, fromEuro);  
    }  
  
    ...  
}
```



# Queue mit Worker-Thread

```
public class StockExchange {  
    private final Map<Currency, Double> rates = new HashMap<>();  
    ...  
  
    private final BlockingQueue<Runnable> queue = ...;  
  
    public StockExchange() {  
        new Thread(() -> {  
            while (true) queue.take().run();  
        }).start();  
    }  
  
    public void updateRate (Currency currency, double fromEuro) {  
        queue.put (() -> rates.put (currency, fromEuro));  
    }  
  
    ...  
}
```



# Vergleichstest

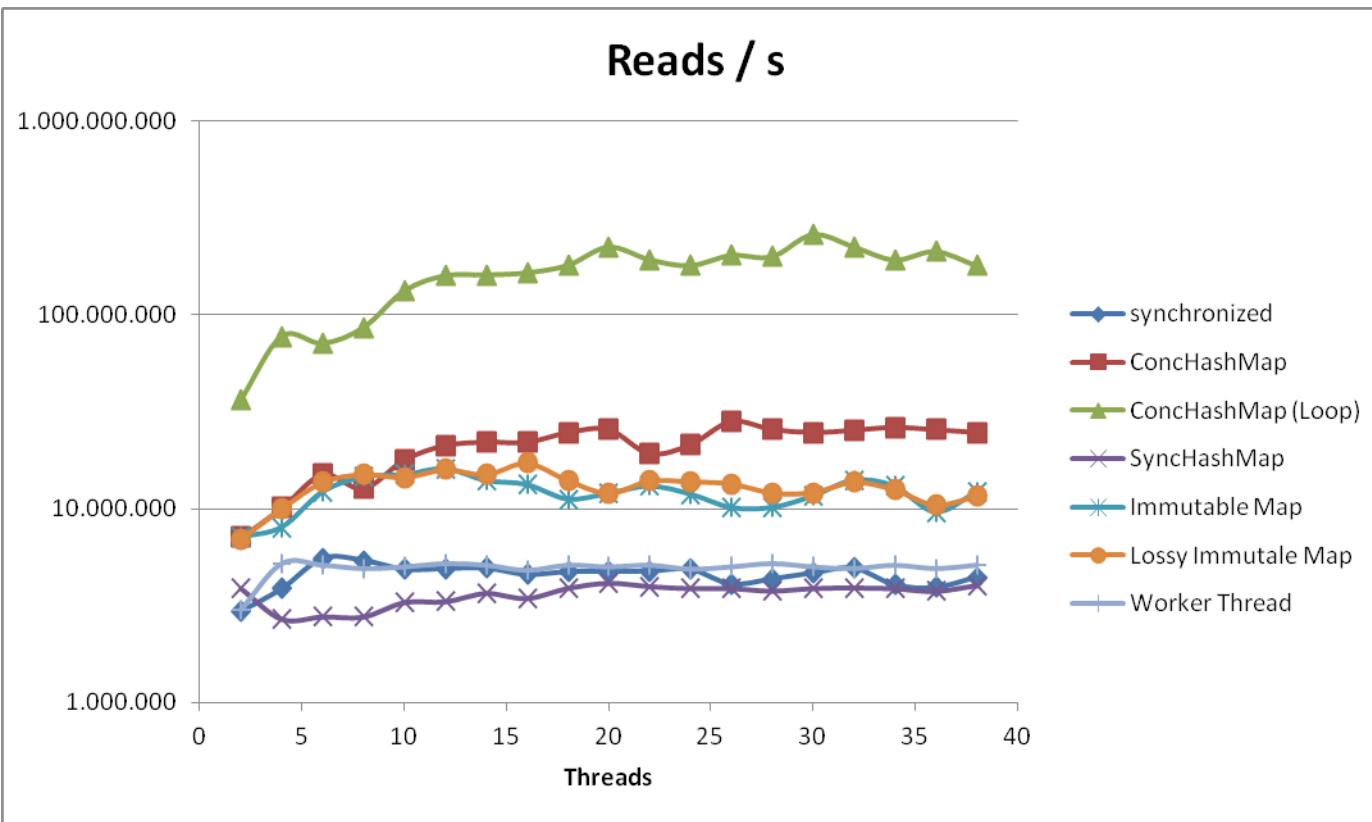
```
for (int i=0; i<1_000_000; i++) {  
    stockExchange.updatePrice ("abc", 1.23);  
}
```

```
volatile int v=0;  
...  
for (int i=0; i<1_000_000; i++) {  
    v=v;  
    stockExchange.updatePrice ("abc", 1.23);  
}
```

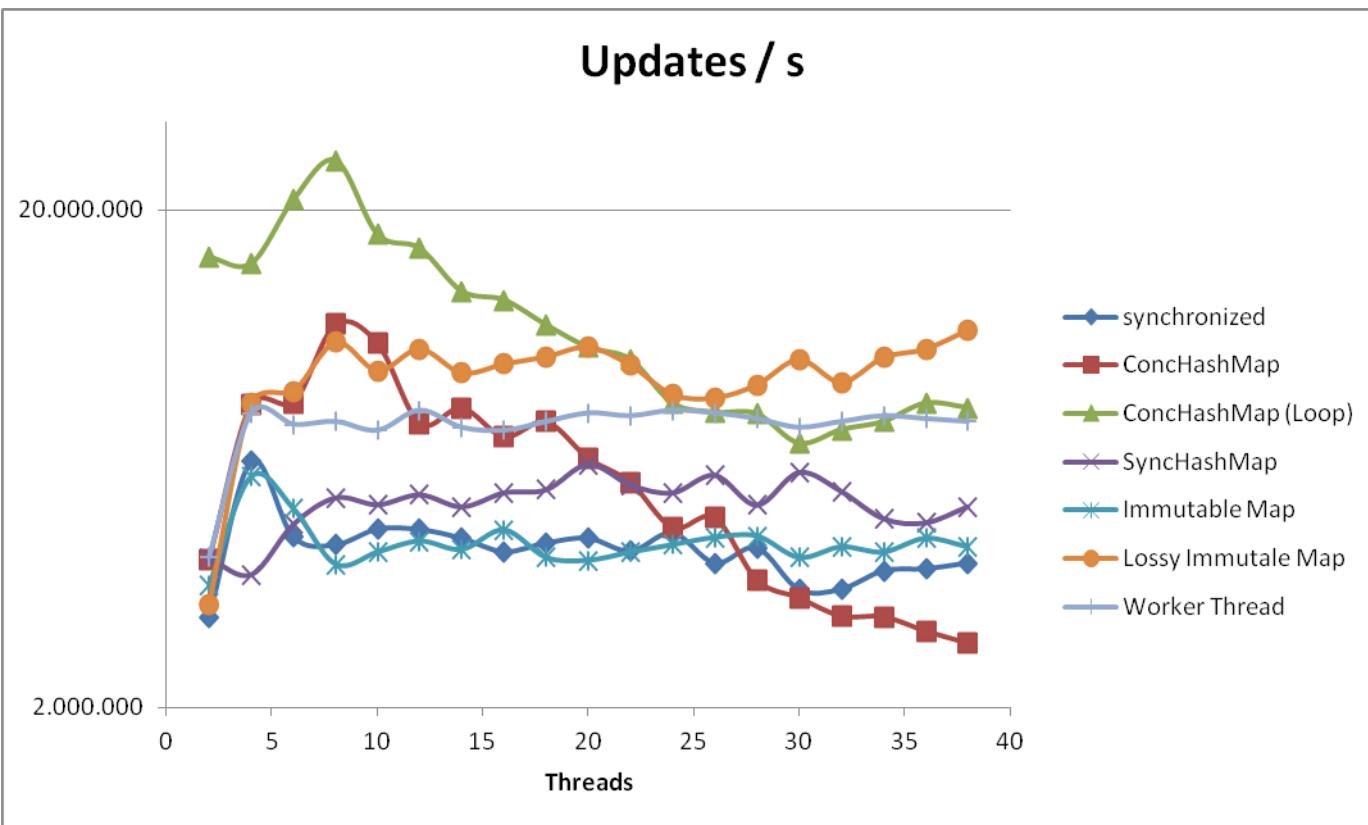
```
volatile int v=0;  
final LinkedList<String> l = new LinkedList<>();  
...  
for (int i=0; i<1_000_000; i++) {  
    l.add ("abc");  
    v=v;  
    stockExchange.updatePrice (l.remove(), 1.23);  
}
```



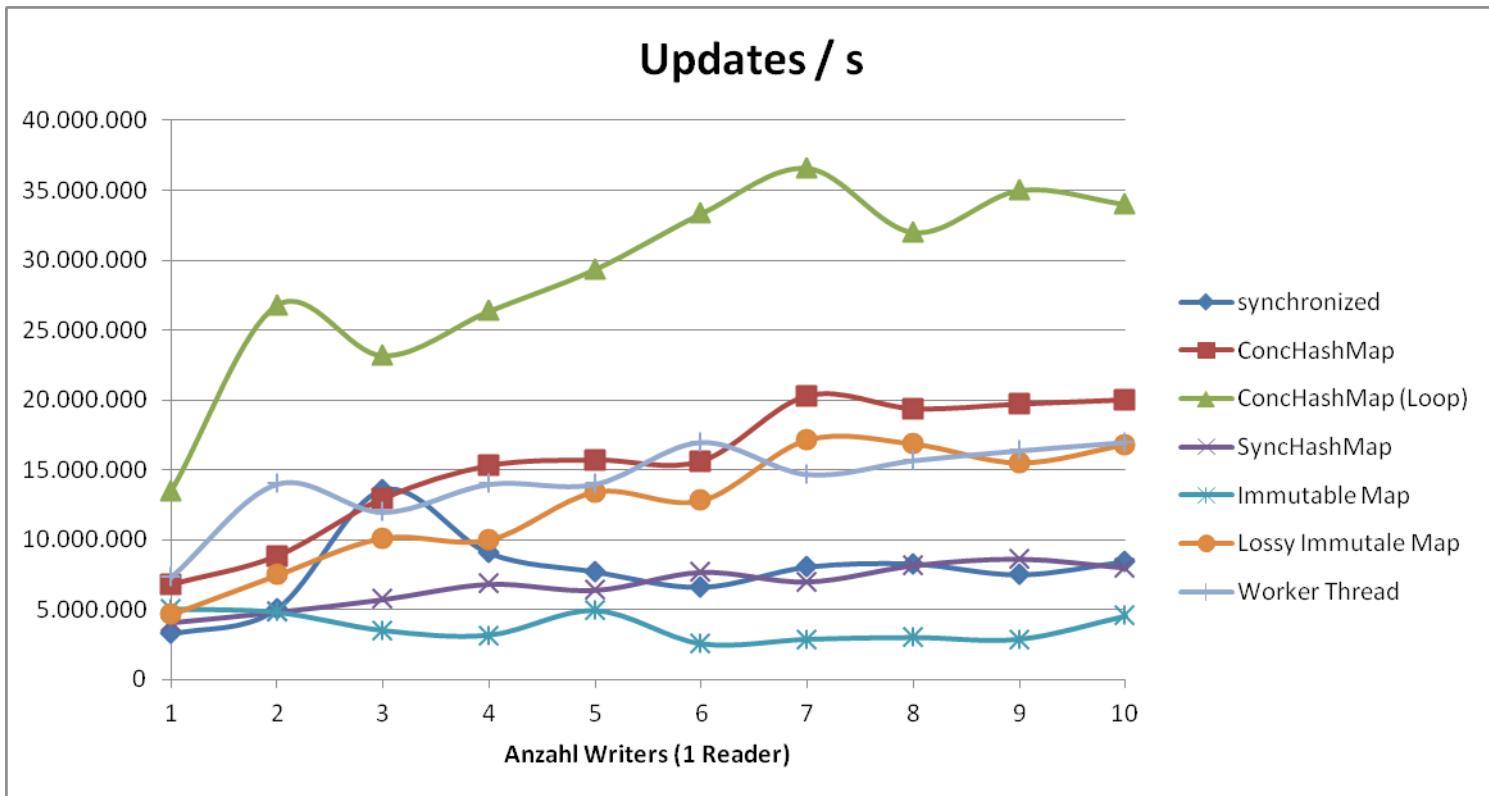
# Gemischte Last



# Gemischte Last



# Update-Last



# And the Winner is...

- ConcurrentHashMap
  - keine Konsistenz, primär Reads, algorithmische Zugriffe
- Queue mit Worker Thread
  - Transaktionaler Zugriff, zentrale Event-Queue
- Immutable Map
  - Stabile Daten während Read, primär Reads
  - lang laufende Reads
  - „lossy“ → auch schnelle Update
- Locks
  - nie besonders schnell → vorgegebenes Thread- und Datenmodell
  - Granularität: Lock je Operation

# Testen (1): Korrektheit

- „es funktioniert“ reicht nicht
  - JMM vs. JVM, Hardware, ...
- Reviews
- kontrollierte Unterbrechungen
- Shotgun

# Testen (2): Performance

- Zeit einplanen!
- realistische Hardware
- große Hardware
  - Multi-Core vs. Multi-Prozessor → HW-Optimierung für Cache-Austausch
  - Skalierungseffekte
- realistische Last-Szenarien (→ kennen!!! Annahmen dokumentieren!!!)
  - Virtualisierte Hardware
- Konkrete Fragen stellen - viele Stellschrauben
  - Pool-Größen, Cut-Off für serielle Verarbeitung
  - HW-Größen: RAM, #Cores, ...
  - Messreihen für alle Alternativen

# Praxis: Lokale Parallelisierung

- z.B. große Collection durchsuchen
  - Fork/Join-Beispiele
  - Stream-API
- Gewinne überprüfen
  - einfache APIs, laden zu „ad hoc“-Verwendung ein
  - ohne Grundlast wirkt es oft schnell
  - *vergrößert* in der Summe die CPU-Last – Vorteile nur bei CPU-Reserven. Mehr Kontext-Wechsel!
  - Messen: reale Hardware, reale Lastszenarien



# Fazit

- Concurrency ist schwierig
- Probleme genau verstehen
- Messen, messen, messen!
- OS und Hardware haben qualitativ Einfluss
- Korrektheit vor Performance
- Möglichst grobe Concurrency
- Share Nothing

# The End

- Links:
  - <http://channel9.msdn.com/Shows/Going+Deep/Cpp-and-Beyond-2012-Herb-Sutter-atomic-Weapons-1-of-2>
  - <http://github.com/arnohaase/a-base>