Threads – Einführung

- Die Ausführung eines Java-Programms besteht in Wahrheit nicht aus einem, sondern mehreren parallel laufenden Threads.
- Ein Thread ist ein sequentieller Ausführungsstrang.
- Der Aufruf eines Programms startet einen Thread `main`, der die Methode `main()` des Programms ausführt.
- Ein weiterer Thread, den das Laufzeitsystem parallel startet, ist die Garbage Collection.
- Die Garbage Collection soll mittlerweile nicht mehr erreichbare Objekte beseitigen und den von ihnen belegten Speicherplatz der weiteren Programmausführung zur Verfügung stellen.

Threads – Anwendungen

- Mehrere Threads sind auch nützlich, um
  - ...mehrere Eingabe-Quellen zu überwachen (z.B. Maus, Tastatur) ↑Graphik;
  - ...während der Blockierung einer Aufgabe etwas anderes Sinnvolles erledigen zu können;
  - ...die Rechenkraft mehrerer Prozessoren auszunutzen.
- Neue Threads können deshalb vom Programm selbst erzeugt und gestartet werden.
- Dazu stellt Java die Klasse `Thread` und das Interface `Runnable` bereit.

Version A

```
1  public class MyThread extends Thread {
2      public void hello(String s) {
3          System.out.println(s);
4      }
5      public void run() {
6          hello("I'm running ...");
7      } // end of run()
8      public static void main(String[] args) {
9          MyThread t = new MyThread();
10         t.start();
11         System.out.println("Thread has been started
               ...");
12     } // end of main()
13 } // end of class MyThread
```


Erläuterungen

- Neue Threads werden für Objekte aus (Unter-) Klassen der Klasse `Thread` angelegt.
- Jede Unterklasse von `Thread` sollte die Objekt-Methode `public void run();` implementieren.
- Ist `t` ein `Thread`-Objekt, dann bewirkt der Aufruf `t.start();` das folgende:
  1. ein neuer Thread wird initialisiert;
  2. die (parallele) Ausführung der Objektmethode `run()` für `t` wird angestoßen;
  3. die eigene Programmausführung wird hinter dem Aufruf fortgesetzt.

Version B

```
1  public class MyRunnable implements Runnable {
2      public void hello(String s) {
3          System.out.println(s);
4      }
5      public void run() {
6          hello("I'm running ...");
7      } // end of run()
8      public static void main(String[] args) {
9          Thread t = new Thread(new MyRunnable());
10         t.start();
11         System.out.println("Thread has been started
               ...");
12     } // end of main()
13 } // end of class MyRunnable
```


Erläuterungen

- Auch das Interface `Runnable` verlangt die Implementierung einer Objektmethode `public void run();`
- `public Thread(Runnable obj);` legt für ein `Runnable`-Objekt `obj` ein `Thread`-Objekt an.
- Ist `t` das `Thread`-Objekt für das `Runnable` `obj`, dann bewirkt der Aufruf `t.start();` das folgende:
  1. ein neuer Thread wird initialisiert;
  2. die (parallele) Ausführung der Objekt-Methode `run()` für `obj` wird angestoßen;
  3. die eigene Programm-Ausführung wird hinter dem Aufruf fortgesetzt.

Mögliche Ausführungen

Entweder

```
Thread has been started ...
I'm running ...
```

oder

```
I'm running ...
Thread has been started ...
```


Scheduling

- Ein Thread kann nur eine Operation ausführen, wenn ihm ein Prozessor (CPU) zur Ausführung zugeteilt worden ist.
- Im Allgemeinen gibt es mehr Threads als CPUs.
- Der Scheduler verwaltet die verfügbaren CPUs und teilt sie den Threads zu.
- Bei verschiedenen Programmläufen kann diese Zuteilung verschieden aussehen!!!
- Es gibt verschiedene Strategien, nach denen sich Scheduler richten können (↑Betriebssysteme). Z.B.:
  - Zeitscheibenverfahren
  - Naives Verfahren

Zeitscheibenverfahren

Strategie

- Ein Thread erhält eine CPU nur für eine bestimmte Zeitspanne (Time Slice), in der er rechnen darf.
- Danach wird er unterbrochen. Dann darf ein anderer.

Beispiel: Zeitscheibenverfahren

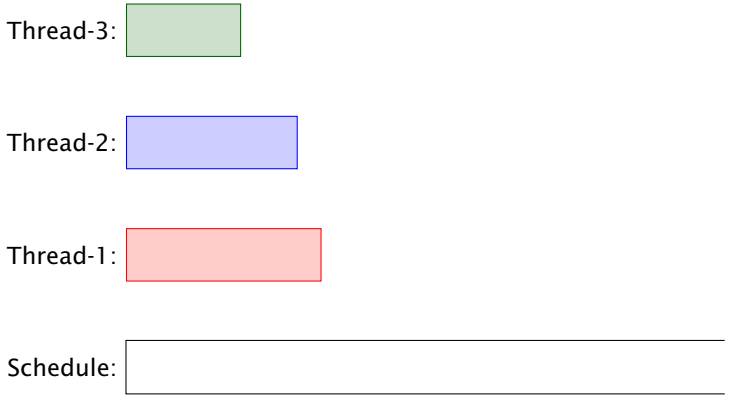

Beispiel: Zeitscheibenverfahren

Eine andere Ausführung:

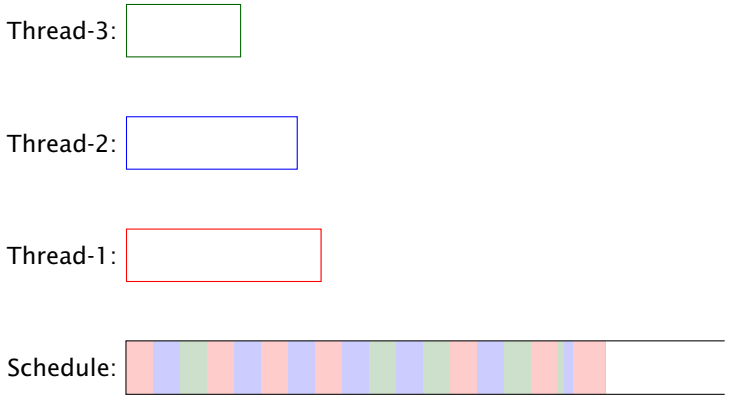

Erläuterungen – Zeitscheibenverfahren

- Ein Zeitscheiben-Scheduler versucht, jeden Thread fair zu behandeln, d.h. ab und zu Rechenzeit zuzuordnen — egal, welche Threads sonst noch Rechenzeit beanspruchen.
- Kein Thread hat jedoch Anspruch auf einen bestimmten Time-Slice.
- Für den Programmierer sieht es so aus, als ob sämtliche Threads „echt“ parallel ausgeführt werden, d.h. jeder über eine eigene CPU verfügt.

Naives Scheduling

Strategie

- Erhält ein Thread eine CPU, darf er laufen, so lange er will...
- Gibt er die CPU wieder frei, darf ein anderer Thread arbeiten...

Beispiel – Naives Scheduling

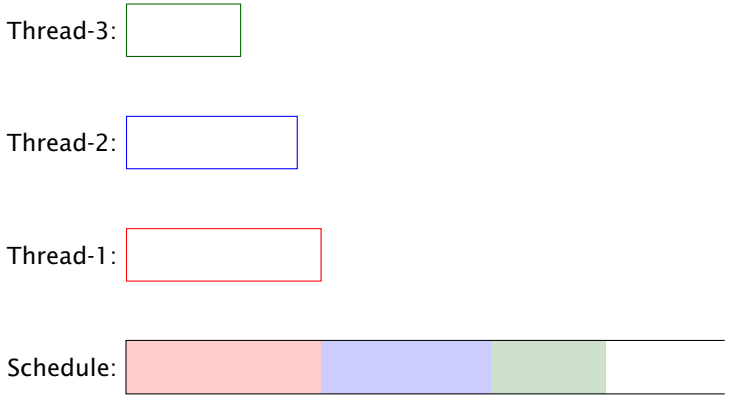

Beispiel

```
1  public class Start extends Thread {
2      public void run() {
3          System.out.println("I'm running...");
4          while (true);
5      }
6      public static void main(String[] args) {
7          (new Start()).start();
8          (new Start()).start();
9          (new Start()).start();
10         System.out.println("main is running...");
11         while (true);
12     }
13 } // end of class Start
```


Beispiel

Ausgabe (bei naivem Scheduling)

```
main is running...
```

Weil `main` nie fertig wird, erhalten die anderen Threads keine Chance, sie verhungern.

Faires Scheduling mit Zeitscheibenverfahren würde z.B. liefern:

```
I'm running...
main is running...
I'm running...
I'm running...
```

Implementierung in Java

- Java legt nicht fest, wie intelligent der Scheduler ist.
- Die aktuelle Implementierung unterstützt faires Scheduling.
- Programme sollten aber für jeden Scheduler das gleiche Verhalten zeigen. Das heißt:
- . . . Threads, die aktuell nichts sinnvolles zu tun haben, z.B. weil sie auf Verstreichen der Zeit oder besseres Wetter warten, sollten stets ihre CPU anderen Threads zur Verfügung stellen.
- . . . Selbst wenn Threads etwas Vernünftiges tun, sollten sie ab und zu andere Threads laufen lassen.

  Achtung: Threadwechsel ist teuer!!!
- Dazu verfügt jeder Thread über einen Zustand, der bei der Vergabe von Rechenzeit beücksichtigt wird.

Threadzustände

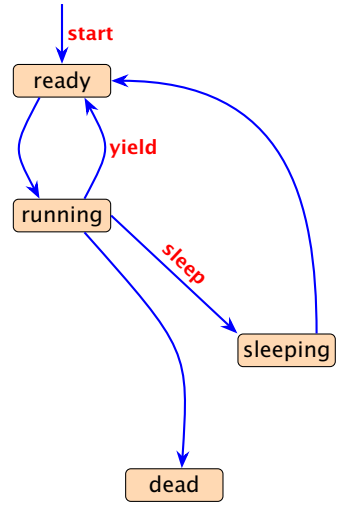

Threadzustände

- `public void start();` legt einen neuen Thread an, setzt den Zustand auf ready und übergibt damit den Thread dem Scheduler zur Ausführung.
- Der Scheduler ordnet den Threads, die im Zustand ready sind, Prozessoren zu („dispatching“). Aktuell laufende Threads haben den Zustand running.
- `public static void yield();` setzt den aktuellen Zustand zurück auf ready und unterbricht damit die aktuelle Programmausführung. Andere ausführbare Threads erhalten die Gelegenheit zur Ausführung.
- `public static void sleep(int msec) throws InterruptedException;` legt den aktuellen Thread für `msec` Millisekunden schlafen, indem der Thread in den Zustand sleeping wechselt.

Threadzustände

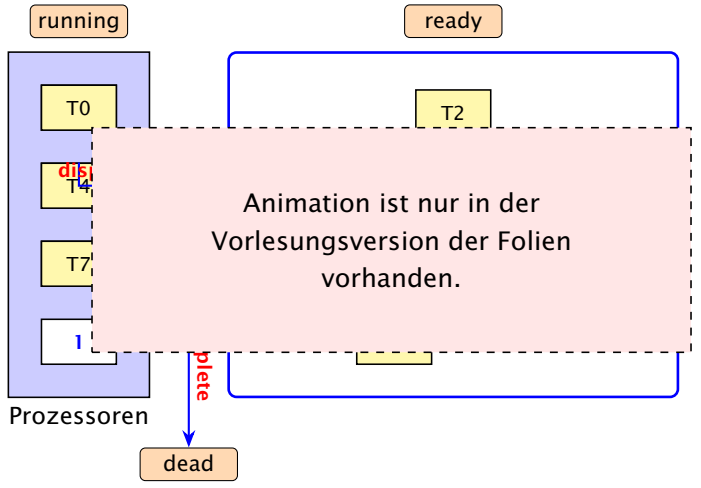

16.1 Futures

- Die Berechnung eines Zwischenergebnisses kann lange dauern.
- Während dieser Berechnung kann möglicherweise etwas anderes Sinnvolles berechnet werden.

Idee:

- Berechne das Zwischenergebnis in einem eigenen Thread.
- Greife auf den Wert erst zu, wenn sich der Thread beendet hat.

16.1 Futures

Eine Future startet die Berechnung eines Werts, auf den später zugegriffen wird. Das generische Interface

```
public interface Callable<T> {
    T call () throws Exception;
}
```

aus java.util.concurrency beschreibt Klassen, für deren Objekte ein Wert vom Typ T berechnet werden kann.

```
1 public class Future<T> implements Runnable {
2     private T value = null;
3     private Exception exc = null;
4     private Callable<T> work;
5     private Thread task;
6 // continued...
```

Implementierung

```
7     public Future<T>(Callable<T> w) {
8         work = w;
9         task = new Thread (this);
10        task.start();
11    }
12    public void run() {
13        try {value = work.call();}
14        catch (Exception e) { exc = e;}
15    }
16    public T get() throws Exception {
17        task.join();
18        if (exc != null) throw exc;
19        return value;
20    }
21 }
```


Erläuterungen

- Der Konstruktor erhält ein Callable-Objekt.
- Die Methode run() ruft für dieses Objekt die Methode call() auf und speichert deren Ergebnis in dem Attribut value — bzw. eine geworfene Exception in exc ab.
- Der Konstruktor legt ein Thread-Objekt für die Future an und startet diesen Thread, der dann run() ausführt.
- Die Methode get() wartet auf Beendigung des Threads. Dazu verwendet sie die Objekt-Methode public final void join() throws InterruptedException der Klasse Thread...
- Dann liefert get() den berechneten Wert zurück — falls keine Exception geworfen wurde. Andernfalls wird die Exception exc erneut geworfen.

Die Join-Operation

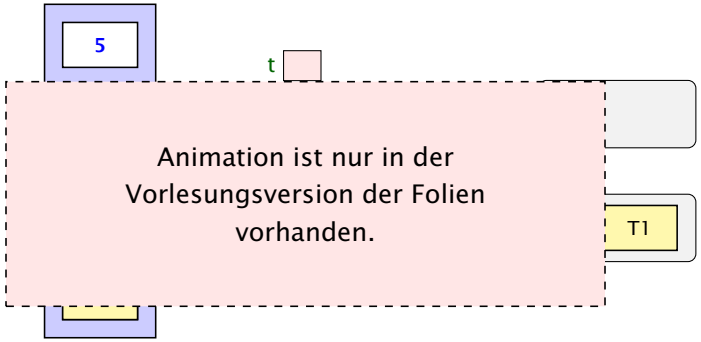

Erläuterungen

- Für jedes Threadobjekt `t` gibt es eine Schlange `ThreadQueue joiningThreads`.
- Threads, die auf Beendigung des Threads `t` warten, werden in diese Schlange eingefügt.
- Dabei gehen sie konzeptuell in einen Zustand joining über und werden aus der Menge der ausführbaren Threads entfernt.
- Beendet sich ein Thread, werden alle Threads, die auf ihn warteten, wieder aktiviert...

Die Join-Operation

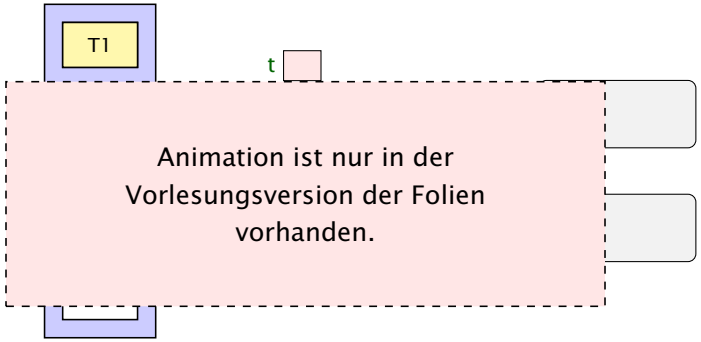

Threadzustände

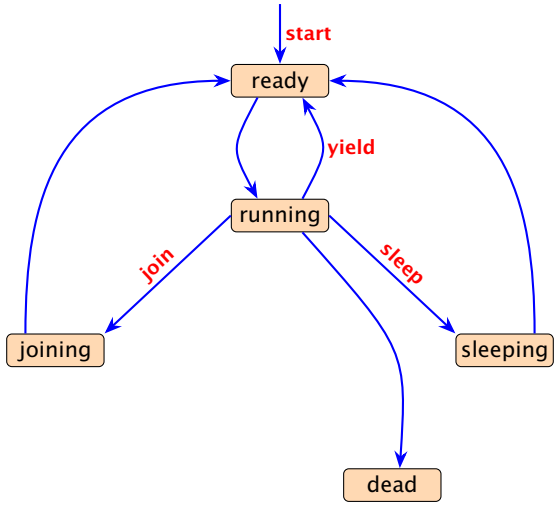

Weiteres Beispiel

```
1  public class Join implements Runnable {
2      private static int count = 0;
3      private int n = count++;
4      private static Thread[] task = new Thread[3];
5      public void run() {
6          try {
7              if (n>0) {
8                  task[n-1].join();
9                  System.out.println("Thread-"+n+
10                         " joined Thread-"+(n-1));
11             }
12         } catch (InterruptedException e) {
13             System.err.println(e.toString());
14         }
15     } // continued...
```


Weiteres Beispiel

```
16     public static void main(String[] args) {
17         for(int i=0; i<3; i++)
18             task[i] = new Thread(new Join());
19         for(int i=0; i<3; i++)
20             task[i].start();
21     }
22 } // end of class Join
```

liefert:

```
> java Join
Thread-1 joined Thread-0
Thread-2 joined Thread-1
```


Variation

```
1  public class CW implements Runnable {
2      private static int count = 0;
3      private int n = count++;
4      private static Thread[] task = new Thread[3];
5      public void run() {
6          try { task[(n+1) % 3].join(); }
7          catch (InterruptedException e) {
8              System.err.println(e.toString());
9          }
10     }
11     public static void main(String[] args) {
12         for(int i=0; i<3; i++)
13             task[i] = new Thread(new CW());
14         for(int i=0; i<3; i++) task[i].start();
15     }
16 } // end of class CW
```


Variation

- Das Programm terminiert möglicherweise nicht...
- `task[0]` wartet auf `task[1]`,
  `task[1]` wartet auf `task[2]`,
  `task[2]` wartet auf `task[0]`

  ist möglich...

`t.join` angewendet auf einen nicht gestarteten Thread, hat keine Auswirkungen. Deshalb kann das Programm je nach Scheduling auch durchlaufen...

Deadlock

- Jeder Thread geht in einen Wartezustand (hier: joining) über und wartet auf einen anderen Thread.
- Dieses Phänomen heißt auch Circular Wait oder Deadlock oder Verklemmung — eine unangenehme Situation, die man in seinen Programmen tunlichst vermeiden sollte.

Die Vermeidung von Deadlocks ist ein sehr schwieriges Problem.

16.2 Monitore

- Damit Threads sinnvoll miteinander kooperieren können, müssen sie miteinander Daten austauschen.
- Zugriff mehrerer Threads auf eine gemeinsame Variable ist problematisch, weil nicht feststeht, in welcher Reihenfolge die Threads auf die Variable zugreifen.
- Ein Hilfsmittel, um geordnete Zugriffe zu garantieren, sind Monitore.

Beispiel — Erhöhen einer Variablen

```
1  public class Inc implements Runnable {
2      private static int x = 0;
3      private static void pause(int t) {
4          try {
5              Thread.sleep((int) (Math.random()*t*1000));
6          } catch (InterruptedException e) {
7              System.err.println(e.toString());
8          }
9      }
10     public void run() {
11         String s = Thread.currentThread().getName();
12         pause(3); int y = x;
13         System.out.println(s+ " read "+y);
14         pause(4); x = y+1;
15         System.out.println(s+ " wrote "+(y+1));
16     }
17 // continued...
```

Beispiel

```
18     public static void main(String[] args) {
19         (new Thread(new Inc())).start();
20         pause(2);
21         (new Thread(new Inc())).start();
22         pause(2);
23         (new Thread(new Inc())).start();
24     }
25 } // end of class Inc
```

- `public static Thread currentThread();` liefert (eine Referenz auf) das ausführende Thread-Objekt.
- `public final String getName();` liefert den Namen des Thread-Objekts.
- Das Programm legt für 3 Objekte der Klasse `Inc` Threads an.
- Die Methode `run()` inkrementiert die Klassen-Variable `x`.

Beispiel

Mögliche Ausführung

```
> java Inc
Thread-0 read 0
Thread-0 wrote 1
Thread-1 read 1
Thread-2 read 1
Thread-1 wrote 2
Thread-2 wrote 2
```

x wurde dreimal erhöht, hat aber am Ende den Wert 2!!!

Beachte, dass das gleiche auch passieren könnte, wenn wir in der Methode `run()`, direkt `x=x+1` schreiben würden.

Erklärung

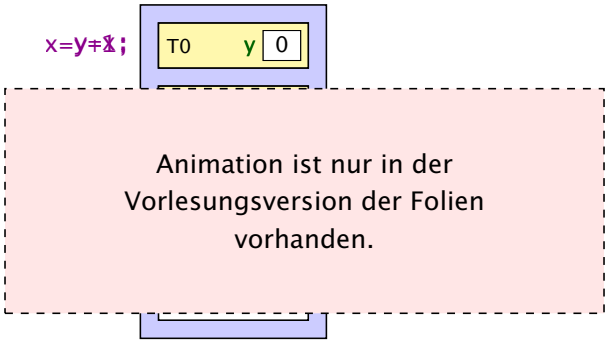

Monitore — Idee

- Inkrementieren der Variable x sollte ein atomarer Schritt sein, d.h. nicht von parallel laufenden Threads unterbrochen werden können.
- Mithilfe des Schlüsselworts `synchronized` kennzeichnen wir Objekt-Methoden einer Klasse L als ununterbrechbar.
- Für jedes Objekt `obj` der Klasse L kann zu jedem Zeitpunkt nur ein Aufruf `obj.synchMeth(...)` einer `synchronized`-Methode `synchMeth()` ausgeführt werden. Die Ausführung einer solchen Methode nennt man kritischen Abschnitt („critical section“) für die gemeinsame Resource `obj`.
- Wollen mehrere Threads gleichzeitig in ihren kritischen Abschnitt für das Objekt `obj` eintreten, werden alle bis auf einen blockiert.

Threadzustände

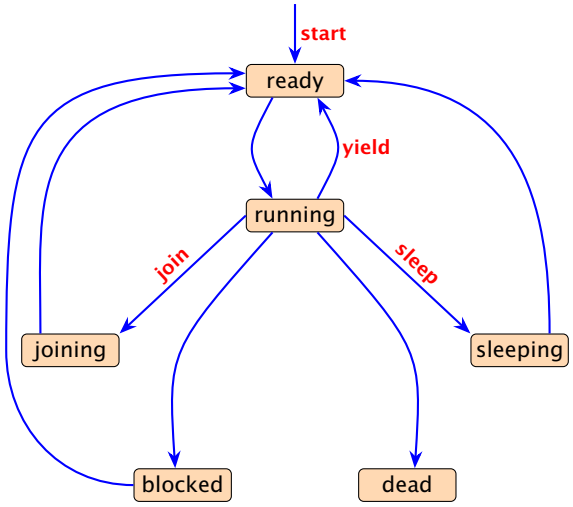

Locks

Dieses ist nur eine mentales Modell dafür was bei Eintritt/Austritt aus einer synchronized Methode passiert. Man kann diese Attribute nicht direkt zugreifen, und die Implementierung könnten in der Realität ganz anders aussehen.

- Ein Objekt obj mit synchronized-Methoden verfügt über:
  1. boolesches Flagboolean locked; sowie
  2. eine Warteschlange ThreadQueue blockedThreads.
- Vor Betreten seines kritischen Abschnitts führt ein Thread (implizit) die atomare Operation obj.lock() aus:

```
private void lock() {
    if (!locked) locked = true; // betrete krit. Abschnitt
    else {                      // Lock bereits vergeben
        Thread t = Thread.currentThread();
        blockedThreads.enqueue(t);
        t.state = blocked;       // blockiere
    }
} // end of lock()
```

Locks

- Verlässt ein Thread seinen kritischen Abschnitt für obj (evt. auch mittels einer Exception), führt er (implizit) die atomare Operation obj.unlock() aus:

```
1 private void unlock() {
2     if (blockedThreads.empty())
3         locked = false; // Lock frei geben
4     else {              // Lock weiterreichen
5         Thread t = blockedThreads.dequeue();
6         t.state = ready;
7     }
8 } // end of unlock()
```

- Dieses Konzept nennt man Monitor.

Beispiel

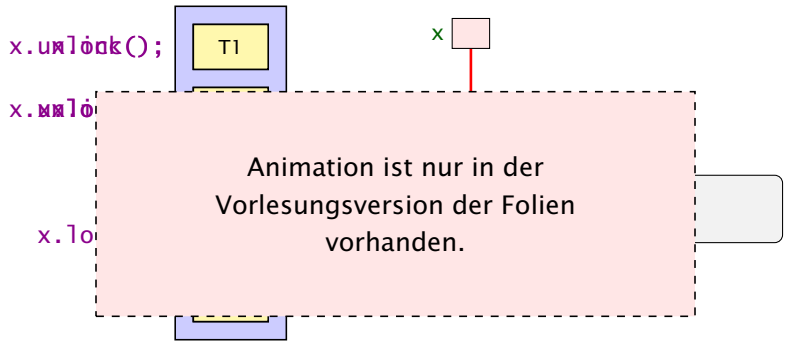

Implementierung

```
class Count {
    private int count = 0;
    public synchronized void inc() {
        String s = Thread.currentThread().getName();
        int y=count; System.out.println(s+" read "+y);
        count=y+1;   System.out.println(s+" wrote "+count);
    }
} // end of class Count
public class IncSync implements Runnable {
    private static Count x = new Count();
    public void run() { x.inc(); }
    public static void main(String[] args) {
        (new Thread(new IncSync())).start();
        (new Thread(new IncSync())).start();
        (new Thread(new IncSync())).start();
    }
} // end of class IncSync
```

Beispiel

liefert:

```
> java IncSync
Thread-0 read 0
Thread-0 wrote 1
Thread-1 read 1
Thread-1 wrote 2
Thread-2 read 2
Thread-2 wrote 3
```

Achtung:

- Die Operation `lock()` erfolgt nur, wenn der Thread nicht bereits vorher das Lock des Objekts erworben hat.
- Ein Thread, der das Lock eines Objekts `obj` besitzt, kann weitere Methoden für `obj` aufrufen, ohne sich selbst zu blockieren.

Locks — im Detail

Diese Art von Locks heißen auch Reentrant Locks oder Rekursive Locks. Sie haben teilweise einen schlechten Ruf.

- Um das zu garantieren, legt ein Thread für jedes Objekt `obj`, dessen Lock er nicht besitzt, aber erwerben will, einen neuen Zähler an:

  ```
  int countLock[obj] = 0;
  ```

- Bei jedem Aufruf einer `synchronized`-Methode `m(...)` für `obj` wird der Zähler inkrementiert, für jedes Verlassen (auch mittels Exceptions) dekrementiert:

  ```
  if (0 == countLock[obj]++) lock();
  obj.m(...)
  if (--countLock[obj] == 0) unlock();
  ```

- `lock()` und `unlock()` werden nur ausgeführt, wenn

  ```
  (countLock[obj] == 0)
  ```

Beispiel: synchronized

```
1  public class StopThread extends Thread {
2      private static boolean stopRequested;
3
4      public void run() {
5          int i = 0;
6          while (!stopRequested)
7              i++;
8      }
9      public static void main(String[] args) {
10         Thread background = new StopThread();
11         background.start();
12         try {Thread.sleep(5);}
13         catch (InterruptedException e) {};
14         stopRequested = true;
15     }
16 }
```

Beispiel: synchronized

Das Programm terminiert (eventuell) nicht.

Die Änderung der Variablen `stopRequested` wird dem anderen Prozess nie mitgeteilt.

Wenn man auf die Variable durch `synchronized`-Methoden zugreift, ist sichergestellt, dass die Kommunikation korrekt durchgeführt wird.

Beispiel: synchronized

```
1  public class StopThreadCorrect extends Thread {
2      private static boolean stopRequested;
3      private static synchronized void setStop() {
4          stopRequested = true;
5      }
6      private static synchronized boolean getStop() {
7          return stopRequested;
8      }
9      public void run() {
10         int i = 0;
11         while (!getStop()) i++;
12     }
13     public static void main(String[] args) {
14         Thread background = new StopThreadCorrect();
15         background.start();
16         try {Thread.sleep(5);}
17         catch (InterruptedException e) {};
18         setStop();
19     }
20 }
```

16.3 Semaphore

Aufgabe:

- Zwei Threads möchten mehrere/viele Daten-Objekte austauschen.
- Der eine Thread erzeugt die Objekte einer Klasse `Data` (Producer).
- Der andere konsumiert sie (Consumer).
- Zur übergabe dient ein Puffer, der eine feste Zahl `N` von `Data`-Objekten aufnehmen kann.

Beispiel

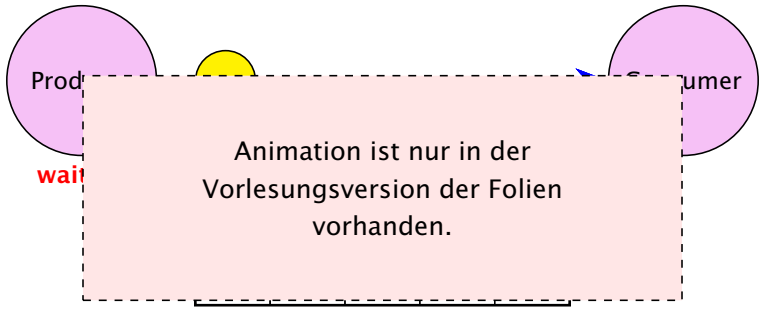

Consumer/Producer

1.Idee

- Wir definieren eine Klasse `Buffer`, die (im wesentlichen) aus einem Feld der richtigen Größe, sowie zwei Verweisen `int first, last` zum Einfügen und Entfernen verfügt:

```
1 public class Buffer {
2     private int cap, free, first, last;
3     private Data[] a;
4     public Buffer(int n) {
5         free = cap = n; first = last = 0;
6         a = new Data[n];
7     }
8 // continued...
```

- Einfügen und Entnehmen sollen synchrone Operationen sein...

Consumer/Producer

Probleme

- Was macht der Consumer, wenn der Producer mit der Produktion nicht nachkommt, d.h. der Puffer leer ist?
- Was macht der Producer, wenn der Consumer mit der Weiterverarbeitung nicht nach kommt, d.h. der Puffer voll ist?

Lösungsvorschlag: Warten...

Beispiel

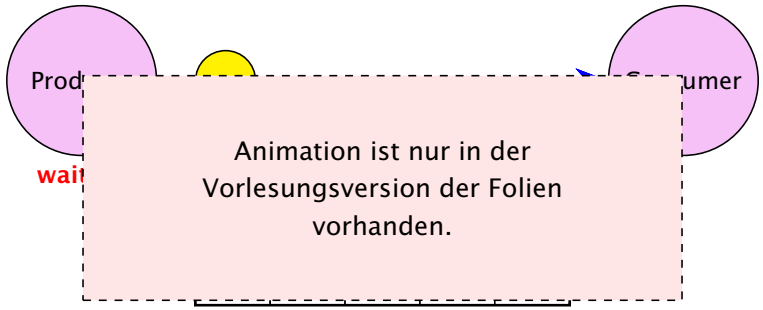

Umsetzung

- Jedes Objekt (mit `synchronized`-Methoden) verfügt über eine weitere Schlange `ThreadQueue waitingThreads` am Objekt wartender Threads sowie die Objekt-Methoden:

```
public final void wait() throws InterruptedException;
public final void notify();
public final void notifyAll();
```

- Diese Methoden dürfen nur für Objekte aufgerufen werden, über deren Lock der Thread verfügt!!!

Umsetzung

- Ausführen von `wait();` setzt den Zustand des Threads auf waiting, reiht ihn in eine geeignete Warteschlange ein, und gibt das aktuelle Lock frei:

```
public void wait() throws InterruptedException {
    Thread t = Thread.currentThread();
    t.state = waiting;
    waitingThreads.enqueue(t);
    unlock();
}
```

Beispiel

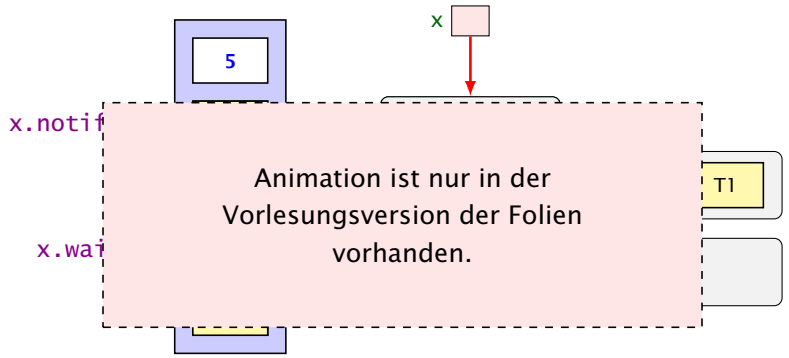

Umsetzung

- Ausführen von `notify();` weckt den ersten Thread in der Warteschlange auf, d.h. versetzt ihn in den Zustand blocked und fügt ihn in `blockedThreads` ein:

```
public void notify() {
    if (!waitingThreads.isEmpty()) {
        Thread t = waitingThreads.dequeue();
        t.state = blocked;
        blockedThreads.enqueue(t);
    }
}
```

- `notifyAll();` weckt alle wartenden Threads auf d.h. fügt alle in `blockedThreads` ein:

```
public void notifyAll() {
    while (!waitingThreads.isEmpty()) notify();
}
```

Beispiel

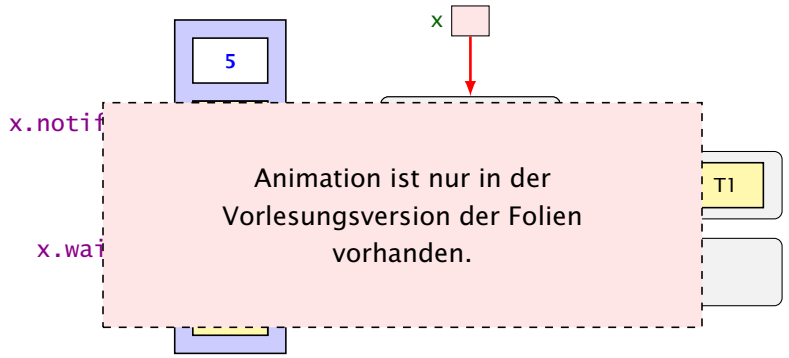

Threadzustände

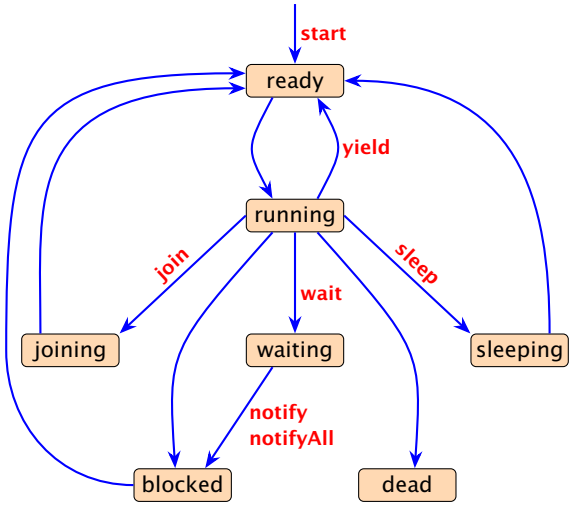

Implementierung

```
 9     public synchronized void produce(Data d)
10                         throws InterruptedException {
11         if (free==0) wait(); free--;
12         a[last] = d;
13         last = (last+1) % cap;
14         notify();
15     }
16     public synchronized Data consume()
17                         throws InterruptedException {
18         if (free==cap) wait(); free++;
19         Data result = a[first];
20         first = (first+1) % cap;
21         notify();
22         return result;
23     }
24 } // end of class Buffer2
```


Erläuterungen

- Ist der Puffer voll, d.h. keine Zelle frei, legt sich der Producer schlafen.
- Ist der Puffer leer, d.h. alle Zellen frei, legt sich der Consumer schlafen.
- Gibt es für einen Puffer genau einen Producer und einen Consumer, weckt das `notify()` des Consumers stets den Producer (und umgekehrt).
- Was aber, wenn es mehrere Producers gibt? Oder mehrere Consumers?

Consumer/Producer

2. Idee: Wiederholung des Tests

- Teste nach dem Aufwecken erneut, ob Zellen frei sind.
- Wecke nicht einen, sondern alle wartenden Threads auf...

```
 9     public synchronized void produce(Data d)
10                         throws InterruptedException {
11         while (free==0) wait();
12         free--;
13         a[last] = d;
14         last = (last+1) % cap;
15         notifyAll();
16     }
```


Consumer/Producer

```
16     public synchronized Data consume()
17                         throws InterruptedException {
18         while (free==cap) wait();
19         free++;
20         Data result = a[first];
21         first = (first+1) % cap;
22         notifyAll();
23         return result;
24     }
25 } // end of class Buffer2
```

- Wenn ein Platz im Puffer frei wird, werden sämtliche Threads aufgeweckt — obwohl evt. nur einer der Producer bzw. nur einer der Consumer aktiv werden kann.

Consumer/Producer

3. Idee: Semaphore

- Producers und Consumers warten in verschiedenen Schlangen.
- Die Producers warten darauf, dass `free > 0` ist.
- Die Consumers warten darauf, dass `cap-free > 0` ist.

```
1  public class Sema {
2      private int x;
3      public Sema(int n) { x = n; }
4      public synchronized void up() {
5          x++; if (x <= 0) this.notify();
6      }
7      public synchronized void down()
8                  throws InterruptedException {
9          x--; while (x < 0) this.wait();
10     }
11 } // end of class Sema
```

Semaphore

- Ein Semaphor enthält eine private `int`-Objekt-Variable und bietet die `synchronized`-Methoden `up()` und `down()` an.
- `up()` erhöht die Variable, `down()` erniedrigt sie.
- Ist die Variable positiv, gibt sie die Anzahl der verfügbaren Resourcen an.
  Ist sie negativ, zählt sie die Anzahl der wartenden Threads.
- Eine `up()`-Operation weckt genau einen wartenden Thread auf.

Anwendung – 1. Versuch

```
1  public class BufferFaulty {
2      private int cap, first, last;
3      private Sema free, occupied;
4      private Data[] a;
5      public BufferFaulty(int n) {
6          cap = n;
7          first = last = 0;
8          a = new Data[n];
9          free = new Sema(n);
10         occupied = new Sema(0);
11     }
12 // continued...
```


Anwendung – 1. Versuch

```
12     public synchronized void produce(Data d)
13                         throws InterruptedException {
14         free.down();
15         a[last] = d;
16         last = (last+1) % cap;
17         occupied.up();
18     }
19     public synchronized Data consume()
20                         throws InterruptedException {
21         occupied.down();
22         Data result = a[first];
23         first = (first+1) % cap;
24         free.up();
25         return result;
26     }
27 }
```

Deadlock

Deadlocks können noch viel viel subtiler sein...

- Gut gemeint — aber leider fehlerhaft...
- Jeder Producer benötigt zwei Locks gleichzeitig, um zu produzieren:
  1. dasjenige für den Puffer;
  2. dasjenige für einen Semaphor.
- Muss er für den Semaphor ein `wait()` ausführen, gibt er das Lock für den Semaphor wieder zurück... nicht aber dasjenige für den Puffer!!!
- Die Folge ist, dass niemand mehr eine Puffer-Operation ausführen kann, insbesondere auch kein `up()` mehr für den Semaphor $\Longrightarrow$ Deadlock

2. Versuch – Entkopplung der Locks

```
12      // Methoden sind nicht synchronized
13      public void produce(Data d) throws
14                                  InterruptedException {
15          free.down();
16          synchronized (this) {
17              a[last] = d; last = (last+1) % cap;
18          }
19          occupied.up();
20      }
21      public Data consume() throws
22                              InterruptedException {
23          Data result; occupied.down();
24          synchronized (this) {
25              result = a[first]; first = (first+1) % cap;
26          }
27          free.up(); return result;
28      }
29  } // end of corrected class Buffer
```

Erläuterung

- Das Statement `synchronized (obj ) { stmts }` definiert einen kritischen Bereich für das Objekt `obj`, in dem die Statement-Folge `stmts` ausgeführt werden soll.
- Threads, die die neuen Objekt-Methoden `void produce(Data d)` bzw. `Data consume()` ausführen, benötigen zu jedem Zeitpunkt nur genau ein Lock.

Man kann sich eine `synchronized`-Methode vorstellen, als hätte sie solch einen `synchronized (this)`-Block um den gesamten Funktionsrumpf.

16.4 RW-Locks

Ziel:

- eine Datenstruktur soll gemeinsam von mehreren Threads benutzt werden.
- Jeder Thread soll (gefühlt) atomar auf die Datenstruktur zugreifen.
- Lesende Zugriffe sollen die Datenstruktur nicht verändern, schreibende Zugriffe dagegen können die Datenstruktur modifizieren.

Implementierung

1. Idee: Synchronisiere Methodenaufrufe

```
1  public class HashTable<K,V> {
2      private List2<K,V> [] a;
3      private int n;
4      public HashTable (int n) {
5          a = new List2[n];
6          this.n = n;
7      }
8      public synchronized V lookup (K k) {...}
9      public synchronized void update (K k, V v) {...}
10 }
```


Arrays und Generics

Wir sagen `a = new List2[n]` anstatt `a = new List2<K,V>[n]`. Letzteres führt zu einem Compilerfehler.

```
1 // nicht moeglich...
2 List<Dog>[] a = new List<Dog>[100];
3 Object[] b = a;
4 List<Cat> cats = new List<Cat>();
5 cats.insert(new Cat("Garfield"));
6 // keine ArrayStoreException wegen Type-Erasure
7 b[0] = cats;
8 // das sollte eigentlich ok sein...
9 Dog d = a[0].remove(0);
```

Man sollte (wenn möglich) Generics und Arrays in Java nicht miteinander mischen.

Diskussion

- Zu jedem Zeitpunkt darf nur ein Thread auf die HashTable zugreifen.
- Für schreibende Threads ist das evt. sinnvoll.
- Threads, die nur lesen, stören sich gegenseitig aber überhaupt nicht!

$\Longrightarrow$ **ReaderWriterLock**

RW-Lock

- ist entweder im Lese-Modus, im Schreibmodus oder frei.
- Im Lese-Modus dürfen beliebig viele Leser eintreten, während sämtliche Schreiber warten müssen.
- Haben keine Leser mehr Interesse, ist das Lock wieder frei.
- Ist das Lock frei, darf ein Schreiber eintreten. Das RW-Lock wechselt nun in den Schreib-Modus.
- Im Schreib-Modus müssen sowohl Leser als auch weitere Schreiber warten.
- Ist ein Schreiber fertig, wird das Lock wieder frei gegeben. . .

Implementierung

```
1  public class RW {
2      private int countReaders = 0;
3
4      public synchronized void startRead ()
5                           throws InterruptedException {
6          while (countReaders < 0) wait ();
7          countReaders++;
8      }
9
10     public synchronized void endRead () {
11         countReaders--;
12         if (countReaders == 0) notifyAll ();
13     }
14 //continued...
```


Implementierung

```
15     public synchronized void startWrite ()
16                          throws InterruptedException {
17         while (countReaders != 0) wait ();
18         countReaders = -1;
19     }
20
21     public synchronized void endWrite () {
22         countReaders = 0;
23         notifyAll ();
24     }
25 }
```


Diskussion

- Die Methoden `startRead()`, und `endRead()` sollen eine Leseoperation eröffnen bzw. beenden.
- Die Methoden `startWrite()`, und `endWrite()` sollen eine Schreiboperation eröffnen bzw. beenden.
- Die Methoden sind `synchronized`, damit sie selbst atomar ausgeführt werden.
- Die unterschiedlichen Modi eines RW-Locks sind mit Hilfe des Zählers `count` implementiert.
- Ein negativer Zählerstand entspricht dem Schreib-Modus, während ein positiver Zählerstand die Anzahl der aktiven Leser bezeichnet...

Diskussion

- `startRead()` führt erst dann kein `wait()` aus, wenn das RW-Lock entweder frei oder im Lese-Modus ist.
  Dann wird der Zähler inkrementiert.
- `endRead()` dekrementiert den Zähler wieder.
  Ist danach das RW-Lock frei, werden alle wartenden Threads benachrichtigt.
- `startWrite()` führt erst dann kein `wait()` aus, wenn das RW-Lock definitiv frei ist.
  Dann wird der Zähler auf -1 gesetzt.
- `endWrite()` setzt den Zähler wieder auf 0 zurück und benachrichtigt dann alle wartenden Threads.

Die HashTable mit RW-Lock

```
1  public class HashTable<K,V> {
2      private RW rw;
3      private List2<K,V> [] a;
4      private int n;
5      public HashTable (int n) {
6          rw = new RW();
7          a = new List2 [n];
8          this.n = n;
9      }
10 // continued...
```


Die HashTable mit RW-Lock

```
11     public V lookup (K key) throws
12                                  InterruptedException {
13         rw.startRead();
14         int i = Math.abs(key.hashCode() % n);
15         V result = (a[i] == null) ? null :
16                                      a[i].lookup(key);
17         synchronized (rw) {
18             rw.endRead();
19             return result;
20         }
21     }
22 //continued
```

- Da `lookup()` nicht weiß, wie mit einem interrupt umzugehen ist, wird die Exception weiter geworfen.
- Damit zwischen Freigabe des RW-Locks und der Rückgabe des Ergebnisses kein Schreibvorgang möglich ist, wird die Rückgabe des RW-Locks mit dem `return` gekoppelt.

Die HashTable mit RW-Lock

```
23     public void update (K key, V value) throws
24                                  InterruptedException {
25         rw.startWrite();
26         int i = Math.abs(key.hashCode() % n);
27         if (a[i] == null)
28             a[i] = new List2<K,V> (key,value,null);
29         else
30             a[i].update(key,value);
31         rw.endWrite();
32     }
33 }
```

- Die Methode `update(K key, V value)` der Klasse `List2<K,V>` sucht nach Eintrag für `key`. Wird dieser gefunden, wird dort das Wert-Attribut auf `value` gesetzt.

  Andernfalls wird ein neues Listenobjekt für das Paar `(key,value)` angefügt.

Diskussion

- Die neue Implementierung unterstützt nebenläufige Lesezugriffe auf die HashTable.
- Ein einziger Lesezugriff blockiert aber Schreibzugriffe — selbst, wenn sie sich letztendlich auf andere Teillisten beziehen und damit unabhängig sind...
- Genauso blockiert ein einzelner Schreibzugriff sämtliche Lesezugriffe, selbst wenn sie sich auf andere Teillisten beziehen...

$\Longrightarrow$ Eingrenzung der kritischen Abschnitte...

Erst suchen der richtigen Liste (nicht synchronisiert), dann Lese/Schreiben dieser Liste (synchronisiert).

Realisierung

```
1  class ListHead<K,V> {
2      private List2<K,V> list = null;
3      private RW rw = new RW();
4      public V lookup (K key) throws InterruptedException {
5          rw.startRead();
6          V result= (list==null) ? null : list.lookup(key);
7          synchronized (rw) {
8              rw.endRead();
9              return result;
10     }   }
11     public void update (K key, V value) throws
12                             InterruptedException {
13         rw.startWrite();
14         if (list == null)
15             list = new List2<K,V>(key,value,null);
16         else list.update(key,value);
17         rw.endWrite();
18 }   }
```

Diskussion

- Jedes Objekt der Klasse `ListHead` enthält ein eigenes RW-Lock zusammen mit einer Liste (eventuell `null`).
- Die Methoden `lookup()` und `update` wählen erst (unsynchronisiert) die richtige Liste aus, um dann geordnet auf die ausgewählte Liste zuzugreifen...

```
// in der Klasse HashTable:
public V lookup (K key) throws InterruptedException {
    int i = Math.abs(key.hashCode() % n);
    return a[i].lookup(key);
}
public void update (K key, V value)
                    throws InterruptedException {
    int i = Math.abs(key.hashCode() % n);
    a[i].update (key, value);
}
```

Lock Support in Java

- `ReentrantLock`
  `lock()`, `unlock()`, `tryLock()`, `newCondition()`

  `wait()`, `notify()` heißen `await()` und `signal()` und werden auf einem `Condition`-Objekt ausgeführt.
- Ein ReentrantLock kann in einer anderen Funktion/einem anderen Block (anders als `synchronized`) freigegeben werden.
- **Achtung**: Ein Reentrant-Lock kann nicht von einem anderen Thread freigegeben werden.

Lock Support in Java

```
1  class Test {
2      synchronized void put() throws
3                                  InterruptedException {
4          ...
5          while (...) wait();
6          ...
7      }
8  }
```

Lock Support in Java

```
1  class Test {
2      Lock lock = new ReentrantLock();
3      Condition cond = lock.newCondition();
4      void put() {
5          lock.lock();
6          try {
7              ...
8              while (...) cond.await()
9              ...
10         }
11         finally {
12             lock.unlock();
13         }
14     }
15 }
```


Semaphore Support in Java

- Klasse `Semaphore`,
- Konstruktor `Semaphore(int permits)`
- Hauptmethoden: `acquire()`, `release()`

Kann von einem anderen Thread `release()`d werden als von dem, der `acquire()` aufgerufen hat.

RW-Locks in Java

- Klasse `ReentrantReadWriteLock`
- `readLock()`, `writeLock` gibt das zugehörige readLock, bzw. writeLock zurück.

```
1 ...
2 ReentrantReadWriteLock rw;
3 rw.readLock().lock();
4 try {
5   ...
6 }
7 finally { rw.readLock().unlock(); }
8 ...
```


Warnung

Threads sind nützlich, sollten aber nur mit Vorsicht eingesetzt werden. Es ist besser,

- ... wenige Threads zu erzeugen als mehr.
- ... unabhängige Threads zu erzeugen als sich wechselseitig beeinflussende.
- ... kritische Abschnitte zu schützen, als nicht synchronisierte Operationen zu erlauben.
- ... kritsche Abschnitte zu entkoppeln, als sie zu schachteln.

Warnung

Finden der Fehler bzw. Überprüfung der Korrektheit ist ungleich schwieriger als für sequentielle Programme:

- Fehlerhaftes Verhalten tritt eventuell nur gelegentlich auf. . .
- bzw. nur für bestimmte Scheduler.
- Die Anzahl möglicher Programm-Ausführungsfolgen mit potentiell unterschiedlichem Verhalten ist gigantisch.
- Heisenbugs.

Ein Heisenbug ist ein Bug, der verschwindet wenn man das System beobachtet...