Algorithmen und Programmierung IV: Nichtsequentielle Programmierung

Robert Tolksdorf
Basiert auf ALP IV, SS 2003
Klaus-Peter Löhr
Freie Universität Berlin

 © Peter Löhr, Robert Tolksdorf, Berlin

Überblick

 © Peter Löhr, Robert Tolksdorf, Berlin

Inhalt

- Prozeßprioritäten
- Auswahlstrategien
- Alterungsmechanismen

4 Ablaufsteuerung

Ablaufsteuerung

- Ablaufsteuerung *(scheduling)* =

- Zuteilung von *Betriebsmitteln (resources)*
  - wiederverwendbaren oder
  - verbrauchbaren

  an Prozesse, z.B.

  - Prozessor (wiederverwendbar),
  - Speicher (wiederverwendbar),
  - Nachrichten (verbrauchbar),
  - Ereignisse (verbrauchbar)

[5] © Peter Löhr, Robert Tolksdorf, Berlin

4.1 Prozeßprioritäten

- Def.:
  Priorität eines Prozesses =

  einem Prozess *(task, thread, ...)* zugeordnetes Attribut, üblicherweise eine natürliche Zahl, das zur Entscheidung über die Zuteilung von Betriebsmitteln herangezogen wird.

- Priorität wird einem Prozess bei der Erzeugung (explizit oder implizit) zugeteilt und kann eventuell programmgesteuert verändert werden.

[6] © Peter Löhr, Robert Tolksdorf, Berlin

Beispiel Java

- **Java:**
  - Thread.MIN_PRIORITY = 1
  - Thread.NORM_PRIORITY = 5
  - Thread.MAX_PRIORITY = 10
- Der *Urprozess (main thread)* hat die Priorität 5.
- Ein Thread *vererbt* seine Priorität an seine Kinder.
- *Abfragen* der Priorität mit `int getPriority()`
- *Ändern* der Priorität mit `void setPriority(int p)`

 © Peter Löhr, Robert Tolksdorf, Berlin

Beispiel Java

- Die JVM *kann* bei der Zuteilung von Prozessorkapazität an die Threads die Prioritäten berücksichtigen, muß aber nicht.
- Typische, sinnvolle Prioritätenvergabe:
  - 2-3 Rechnen
  - 4-6 Ein/Ausgabe
  - 7-9 schnelle Ein/Ausgabe (Interaktion, harte Realzeit-Anforderungen)
- Nicht vergessen: im *Mehrprozessbetrieb* erhält die JVM bereits vom Betriebssystem nur ein Teil der Prozessorkapazität!

 © Peter Löhr, Robert Tolksdorf, Berlin

Prioritätenvergabe vs. Synchronisation

- **Achtung 1:**
  Prioritätenvergabe ist kein Ersatz für Synchronisation!
- **Achtung 2:**
  Gefahr der **Prioritätsumkehr** *(priority inversion)*,
  z.B. bei Einprozessorsystem:
  - 3 Prozesse A, B, C mit abfallenden Prioritäten a,b,c
  - C betritt kritischen Abschnitt k, weckt B und wird von B verdrängt, d.h. belegt weiterhin k;
  - B weckt A und wird von A verdrängt,
  - A blockiert beim Eintrittsversuch in k;
  - solange B nicht blockiert, hat A keine Chance!
- *Lösungstechnik:* spezielle Sperroperationen, die für temporäre Prioritätserhöhung sorgen.

 © Peter Löhr, Robert Tolksdorf, Berlin

4.2 Auswahlstrategien

- *Problem:*
  Wenn *mehrere* Prozesse auf Betriebsmittelzuteilung bzw. auf ein bestimmtes Ereignis warten (mit **when**, wait, **P**, join, ...)

  und

  beim Eintreten des Ereignisses *nicht alle* aufgeweckt werden können/sollen, welche ?
- → Auswahlstrategie *(scheduling policy)*

 © Peter Löhr, Robert Tolksdorf, Berlin

Fairness

- Def.:
  Eine Auswahlstrategie heißt fair, wenn jedem wartenden Prozess garantiert ist, daß ihm nicht permanent und systematisch andere Prozesse vorgezogen werden.
- Genauer:
  - streng fair:
    wenn ein Prozess blockiert, kann eine *obere Schranke* für die Anzahl der Prozesse angegeben werden, die ihm vorgezogen werden;
  - schwach fair:
    sonst

 © Peter Löhr, Robert Tolksdorf, Berlin

Unfairness

- Bei unfairer Auswahlstrategie droht den Prozessen unbestimmte Verzögerung
  (indefinite delay, starvation)
- Achtung:
  In Java gibt es keinerlei Fairness-Garantien !

 © Peter Löhr, Robert Tolksdorf, Berlin

Faire Auswahlstrategien

- Typische Auswahlstrategien und ihre Fairness:

	Strategie	Fairness
1.	zufällig	schwach fair
2.	der Reihe nach *(first-come, first-served, FCFS, first-in, first-out, FIFO)*	streng fair
3.	prioritätsgesteuert	unfair
4.	anwendungsspezifisch	(je nachdem)

 © Peter Löhr, Robert Tolksdorf, Berlin

4.2.1 Anpassung der Auswahlstrategie

- *Ausgangslage:*
  Verfügbare Sprachkonstrukte verfolgen eine unpassende Strategie

- *Beispiele:*
  - strenge Fairness benötigt, aber in Java nicht garantiert
  - Semaphore mit FCFS verfügbar, aber Auswahl sollte eigentlich prioritätsgesteuert erfolgen
  - anwendungsspezifische Strategie benötigt

 © Peter Löhr, Robert Tolksdorf, Berlin

Anpassung der Auswahlstrategie

- *Konsequenz:*
  im Eigenbau

1. *entweder* wiederverwendbare Varianten der Synchronisationskonstrukte bereitstellen → 4.2.1.1
2. *oder* ad-hoc-Strategie programmieren → 4.2.1.2

4.2.1.1 Prioritätsgesteuerte Semaphore

```
interface Semaphore { // scheduling unspecified
void P();
void V();
}

class Sema implements Semaphore { // FCFS
...
}

class  PrioSema implements Semaphore {
public PrioSema(int init) { count = init; }
private int count;
private final Sema mutex = new Sema(1);
private final PrioSet prios = new PrioSet();
```

Prioritätsgesteuerte Semaphore

```
class PrioSet { // set of pairs (int, Sema)
.....
public void add(int prio, Sema sema) {...}
   // adds pair (prio,sema)

public Sema rem() {...}
   // delivers semaphore with highest priority
   // and removes entry
}
```

 © Peter Löhr, Robert Tolksdorf, Berlin

Prioritätsgesteuerte Semaphore

```
public void P() { // this is the modified P
   mutex.P();
   count--;
   if(count>=0) mutex.V();
   else {
         Sema ready = new Sema(0);
         prios.add(Thread.currentThread().getPriority(), ready);
         mutex.V();
         ready.P();
   }
}
```

 © Peter Löhr, Robert Tolksdorf, Berlin

Prioritätsgesteuerte Semaphore

```
public void V() { // this is the modified V
        mutex.P();
        count++;
        if(count<=0) {
           Sema ready = prios.rem();
           ready.V(); }
        mutex.V();
}
}
```

- *Beachte:*
  1. Die Semaphore ready sind private Semaphore, d.h. bei ihnen blockiert jeweils höchstens ein Thread.
  2. Die kritischen Abschnitte (mutex) sind kurz genug, dass sie keinen Engpass darstellen.
  - →Daher ist es *irrelevant*, welche Auswahlstrategie von Sema praktiziert wird.

 © Peter Löhr, Robert Tolksdorf, Berlin

Wahl einer Sperroperation:

- langfristiges Sperren realer Betriebsmittel: Auswahlstrategie wählen, ggfls. selbst implementieren

- kurzfristiges Sperren kritischer Abschnitte: Auswahlstrategie irrelevant
  - sofern kein Engpass bei der Benutzung der Ressource bzw. des kritischen Abschnitts vorliegt !
  - sonst: Entwurf revidieren –
    lange Prozesswarteschlangen sind in jedem Fall unsinnig – wie auch immer die Auswahl praktiziert wird.

 © Peter Löhr, Robert Tolksdorf, Berlin

4.2.1.2 Anforderungsbezogene Auswahl

- bei jeder Art von Anforderung *mehrerer Ressourcen* z.B.
  - verallgemeinerte P/V-Operationen (3.3.1)
  - request(n) , release(n)
  - und ähnliche
- Häufig ist Effizienz wichtiger als Fairness, z.B.
  - gute Ressourcen-Ausnutzung
  - kurze Reaktionszeiten

 © Peter Löhr, Robert Tolksdorf, Berlin

Anforderungsbezogene Auswahl

- Beispiele für effizienzorientierte Auswahlstrategien bei request(n)/ release(n):

- *SRF (smallest request first):*
  die *kleinsten* Anforderungen sollen vorrangig bedient werden
- *LRF (largest request first):*
  die *größten* Anforderungen sollen vorrangig bedient werden
- (jedenfalls nicht die, welche am längsten warten; weitere Alternativen sind möglich.)

 © Peter Löhr, Robert Tolksdorf, Berlin

Anforderungsbezogene Auswahl

- LRF mit Verwendung von PrioSet (4.2.1.1) mit Operationen

- **public** int top(int limit)
  - liefert den höchsten prio-Wert im PrioSet , der limit nicht übersteigt (0, falls kein solcher vorhanden)

- **public** Sema rem(int limit) (modifiziert)
  - liefert das zugehörige Semaphor und löscht den Eintrag

 © Peter Löhr, Robert Tolksdorf, Berlin

Anforderungsbezogene Auswahl

```
class  Resources {// LRF – largest request first
public Resources(int init) { avail = init; }
private int avail;
private final PrioSet claims = new PrioSet();

public void request(int claim) {
    Sema ready;
    synchronized(this) {
            if(claim<=avail) {
                        avail -= claim;
                        return;  }
            else {
                        ready = new Sema(0);
                        claims.add(claim,ready);
            }
    }
    ready.P();
}
```

 © Peter Löhr, Robert Tolksdorf, Berlin

Anforderungsbezogene Auswahl

```
public synchronized void release(int free) {
    avail += free;
    do {
      int claim = claims.top(avail);
      if(claim == 0) return;
      else {
            avail -= claim;
            claims.rem(avail).V();
      }
    } while(true);
}
}
```

- *Beachte:*
  - Das Blockieren in request muß *außerhalb* des kritischen Abschnitts erfolgen
  - In release werden i.a. gezielt *mehrere* Threads aufgeweckt
  - Durch Modifikation der Klasse PrioSet können *verschiedene* Strategien realisiert werden

4.2.2 Fairness durch Alterungsmechanismen

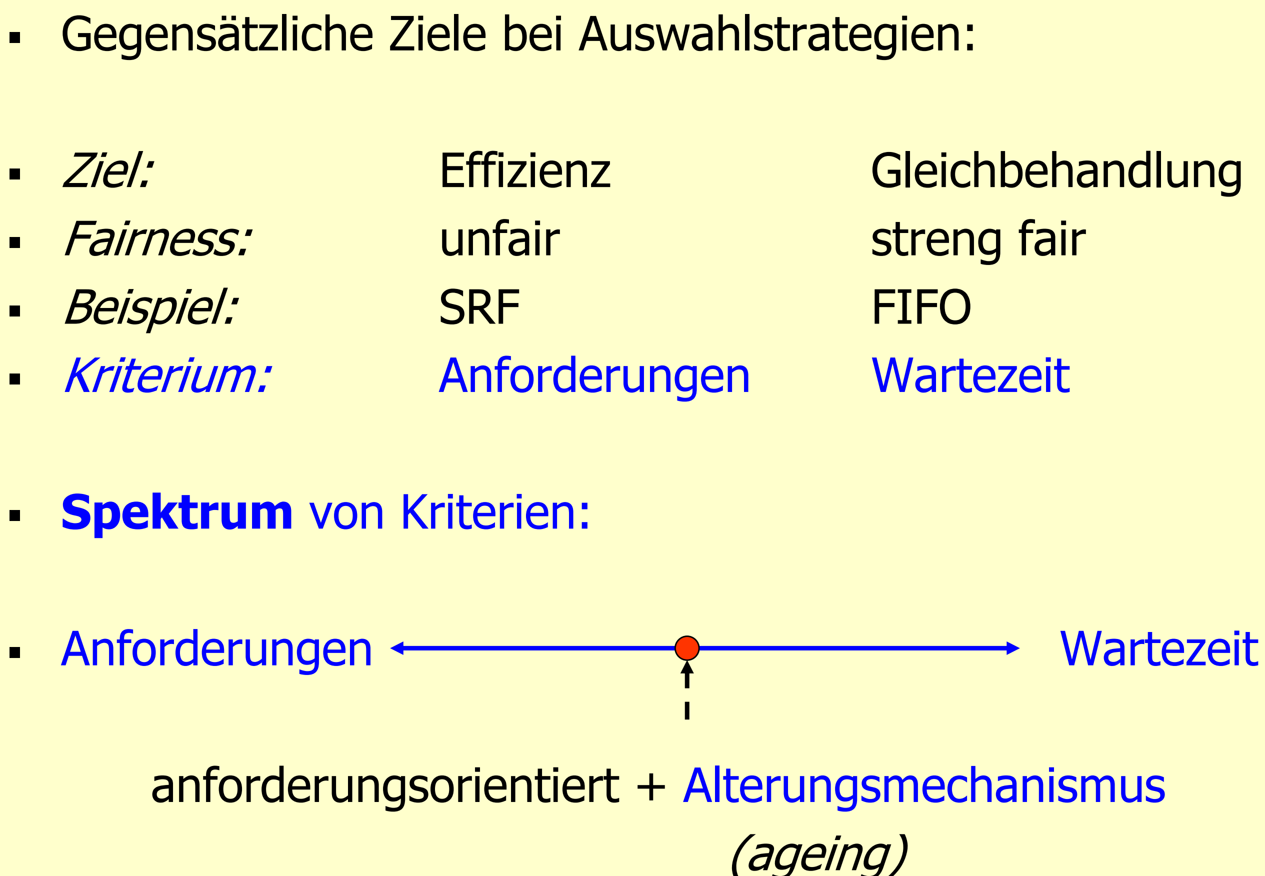

Alterungsmechanismen

- **Beispiel:**
  Alterungsmechanismus für SRF:
  - Auswahl nach *Rang*ordnung 1,2,3,...
    (hoher Rang = kleine Rangzahl)
  - *Rang* = Anforderung + *Malus*
  - *Malus* = Zeitpunkt des request, gemessen in
    Anzahl der begonnenen requests
  - Einem release wird genau dann stattgegeben, wenn die Anforderung erfüllt werden kann **und** den höchsten Rang hat. (Bei Gleichrangigkeit zweier erfüllbarer Anforderungen...)

Beispiel-Szenario

Thread	request	release	counter	added	grantee	available
			0			5
p	1		1		p	4
q	4		2		q	0
r	4		3	(7,4,R)		0
s	1		4	(5,1,S)		0
t	1		5	(6,1,T)		0
p		1			s	0
q		3			t	2
u	2		6	(8,2,U) !		2
q		1				3
s		1			r	0

Alterungsmechanismen

- **Buchführung** über Anforderungen und Ränge mittels

```
class Ranking { // set of triples (int rank, int claim, EVENT e)
.....
public void add(int rank, int claim, EVENT e){...}
   // adds triple (rank,claim,e)

public EVENT rem() {...}
   // delivers event with highest rank
   // and removes entry (if any, else null)

public int firstRank() {...}
   // delivers highest rank (if any, else MAX)

public int firstClaim() {...}
   // delivers corresponding claim (or MAX)
}
```


Alterungsmechanismen

```
MONITOR Resources { // SRF, with ageing
                            // Monitor and Events!
public  Resources(int n) {available = n;}
protected int available;
protected int counter;
protected final Ranking ranking = new Ranking();

public void release(int n) {
    available += n;
    tryWakeup();
}
protected void tryWakeup() {
    if(ranking.firstClaim() <= available){
          available -= ranking.firstClaim());
          ranking.rem().SIGNAL();
    }
}       // any version of SIGNAL does the job
```

Alterungsmechanismen

```
public void request(int claim) {
    counter++;
    int rank = claim + counter;
    if(rank <= ranking.firstRank() && claim <= available) {
        available -= claim;
        return; }
    else {
        EVENT ready = new EVENT();
        ranking.add(rank,claim,ready);
        ready.WAIT();
        tryWakeup();
    }
}

} // end monitor
```


Alterungsmechanismen

- **Flexible** Positionierung im Spektrum der Strategien:
  - anstelle von
    rank = claim + counter
  - Verwendung von
    rank = claim + **k***counter
- $k \in [0, m]$ (m = maximal mögliche Anforderung) ermöglicht *Tuning*
  - k = 0 : SRF
  - k = m: FIFO
    - $rank_i < rank_{i+1}$ für zwei aufeinanderfolgende requests

Zusammenfassung

Zusammenfassung

- Prozeßprioritäten
- Auswahlstrategien
  - Fairness
- Alterungsmechanismen