

# 8. Einplanung einzelner Jobs in prioritätsbasierten Systemen

## 8.1. Modellannahmen und Vorgehen

- **Voraussetzungen**

- *Jobs / nichtperiodische Tasks*

unterbrechbar, voneinander unabhängig

sporadisch: harte Deadline

aperiodisch: keine (oder weiche) Deadline

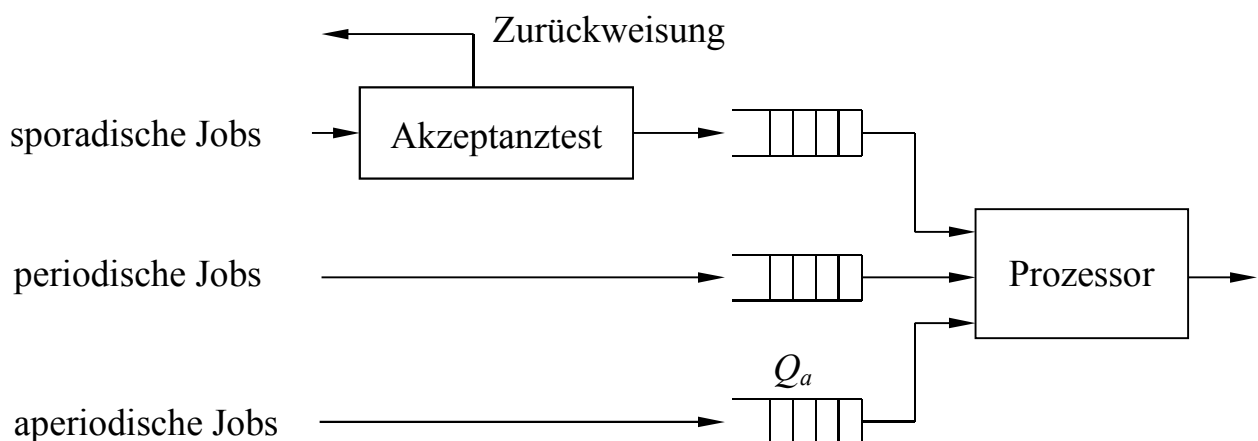
Abstand sowie Ausführungszeit und Deadline beliebig  
(Werte zur Ankunftszeit bekannt)

- **Vorgehen**

periodisch: Zulassung → garantierte Deadline-Einhaltung

sporadisch: Akzeptanztest

aperiodisch: Beendigung „baldmöglichst“




Generelle Annahme: keine sporadischen Jobs im System

- **Einfache Ansätze für aperiodische Jobs**

- **Ausführung im Hintergrund**

dann, wenn keine periodischen Tasks bearbeitet werden

Beispiel 8.1. a)  $\tau_1 = (3; 1)$ ,  $\tau_2 = (10; 4)$   $A = (0,1; 0,8)$ .




einfache Implementation, aber schlechtes Antwortzeitverhalten

- **Ausführung durch Unterbrechung**

sofortige Ausführung bei Ankunft

Beispiel 8.1. b)



minimale Antwortzeit, aber Gefährdung der Jobs mit harter Deadline

- **Ausführung durch Aufschieben periodischer Jobs – „slack stealing“**

durch „slack stealer“ mit höchster Priorität, sofern Zeit frei

effizient, aber aufwendige Analyse der verfügbaren Zeit (slack)


– **Periodische Ausführung mittels „Polling Server“**

PS polling server: periodische Task ( $t_s; e_s$ ).



Wenn in neuer Periode  $Q_a$  bei Ausführungsbeginn leer ist, suspendiert sich PS für restliche Periode selbst. Andernfalls Abarbeitung der Jobs aus  $Q_a$  längstens für die Dauer  $e_s$ .

Beispiel 8.1. c)  $\tau_1 = (3; 1)$ ,  $\tau_2 = (10; 4)$ ,  $A = (0,1; 0,8)$ .

$$\tau_{PS} = (2,5; 0,5)$$



Beispiel 8.1. d) Verzögerte Ausführung



- **Begriffe**

- **Periodischer Server** ( $t_s; e_s$ ):

Task mit einem *Konto*  $K$  zur periodischen Ausführung aperiodischer Jobs; definiert durch Regeln für *Verbrauch* und *Auffüllung* des Kontos.

Scheduling als periodische Task; dabei verbraucht Server seinen Kredit, bis Konto *ausgeschöpft* ist.

$e_s$ : **Kredit** (execution budget) gespeichert auf einem *Konto*

$t_s$ : Abstand der Konto-Auffüllung (replenishment)

Konto wird zum Auffüllungszeitpunkt **auf**  $e_s$  aufgefüllt.

$u_s = \frac{e_s}{t_s}$ : **Größe** (Umfang, size) des Servers

Server ist *im Rückstand, beschäftigt* (backlogged), wenn  $Q_a \neq \emptyset$

*im Leerlauf* (idle), wenn  $Q_a = \emptyset$

*(ausführungs-)bereit* (eligible for execution)

bei positivem Kontostand und wenn er im Rückstand ist.

- **Bandbreiten-einhaltender Server** (bandwidth-preserving server):  
modifizierter Polling-Server mit besserer Leistung.

Formen:

- \* deferrable servers
- \* sporadic servers
- \* constant utilization / total bandwidth servers
- \* weighted fair-queueing servers.

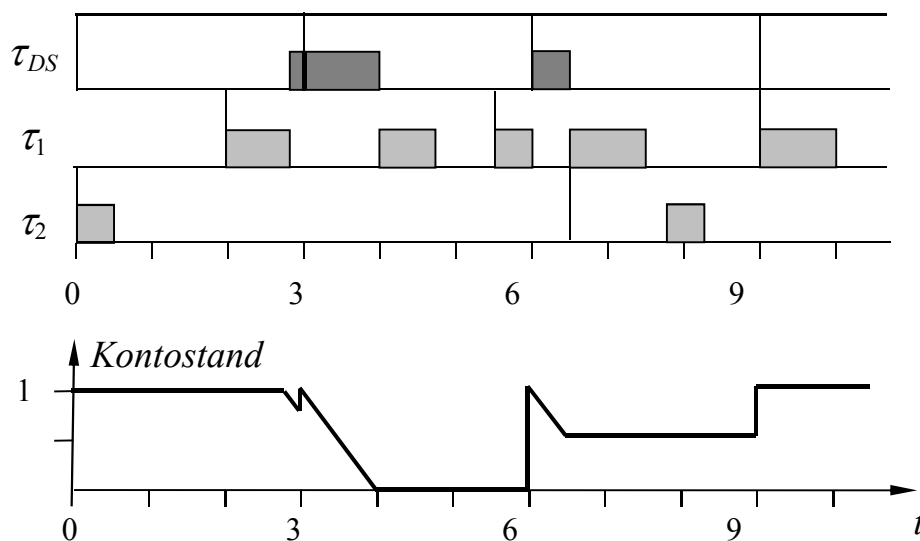
## 8.2. Verzögerte Ausführung – „Deferrable Server“

- **Regeln**

Konto wird zu jedem Periodenbeginn  $k \cdot t_s$  auf  $e_s$  aufgefüllt; es wird verbraucht, wenn Server arbeitet.

- **Beispiel 8.2.**

$$\tau_1 = (2; 3,5; 1,5) \quad \tau_2 = (6,5; 0,5) \quad \tau_{DS} = (3; 1) \quad A = (2,8; 1,7)$$



- **Eigenschaften**

- Hinreichende Bedingung für kritischen Zeitpunkt komplizierter.
- Grenzauslastung für Einplanbarkeit mit statischen Prioritäten (schedulable utilization) nur bekannt für RMS und dann nur, falls Deadlines und Periodenenden übereinstimmen und wenn gilt:

$$t_s < t_1 < \dots < t_n < 2t_s \quad \text{und} \quad t_n > t_s + e_s.$$

- Analyse des Zeitbedarfs:  $w(t)$  ergänzen um  $\left(1 + \left\lceil \frac{t - e_s}{t_s} \right\rceil\right) \cdot e_s$

- **Bewertung**

einfach, aber längere Antwortzeit für niedriger priorisierte Jobs möglich.  
Verbesserung durch „Sporadic Server“ (verbraucht nie mehr Zeit als eine entsprechende periodische Task).

### 8.3. Sporadische Server – „Sporadic Servers“

- **Voraussetzungen, Begriffe und Bezeichnungen**

Scheduling mittels fester Prioritäten

1 Server  $S$  mit  $t_s$ ,  $e_s$  und Priorität  $pr_s$

$$T_H = \{\tau \mid pr_\tau \succ pr_s\}$$

- **Arbeitsintervall (busy interval)**

von  $S$ : jedes maximale Intervall mit  $Q_a \neq \emptyset$

bzgl.  $T_H$ : jedes maximale Intervall, in dem Tasks aus  $T_H$  aktiv sind

- **Zeiten**

$t_r$  letzter Zeitpunkt einer Auffüllung des Kontos

$t_f > t_r$  Aktivierungszeitpunkt von  $S$

$t_e$  letzter *effektiver* Zeitpunkt einer Kontoauffüllung

$t$  aktuelle Zeit

BEGIN Beginn eines Arbeitsintervalls bzgl.  $T_H$

END Ende eines Arbeitsintervalls bzgl.  $T_H$ , falls vor  $t$  (sonst  $\infty$ )

---

- **Varianten**

Hintergrund-Arbeit (Sporadic/Background Server)

kumulative Auffüllung

„originale“ sporadische Server (SPRUNT / SHA / LEHOCZKY, 1989)

Prioritätstausch

Systeme mit dynamischen Prioritäten

- **Einfacher sporadischer Server (Simple sporadic server)**

- **Verbrauch**

Konto wird verbraucht in den Fällen:

(C1)  $S$  ist aktiv.

(C2)  $S$  hat seit  $t_r$  (irgendwann) gearbeitet und  $END < t$ .

- **Auffüllung**

(R1) Anfangs und bei jeder Auffüllung:  $K := e_s, t_r := t$ .

(R2)  $S$  wird aktiv ( $t = t_f$ ):

$$t_e := \begin{cases} t_f & \text{falls } END < t_f \\ \max(t_r, BEGIN) & \text{falls } END = t_f \end{cases} \quad t_r := t_e + t_s$$

(R3) Nächste Auffüllung erfolgt zum nächsten Auffüllungszeitpunkt (aktueller Wert von  $t_r$ ) außer

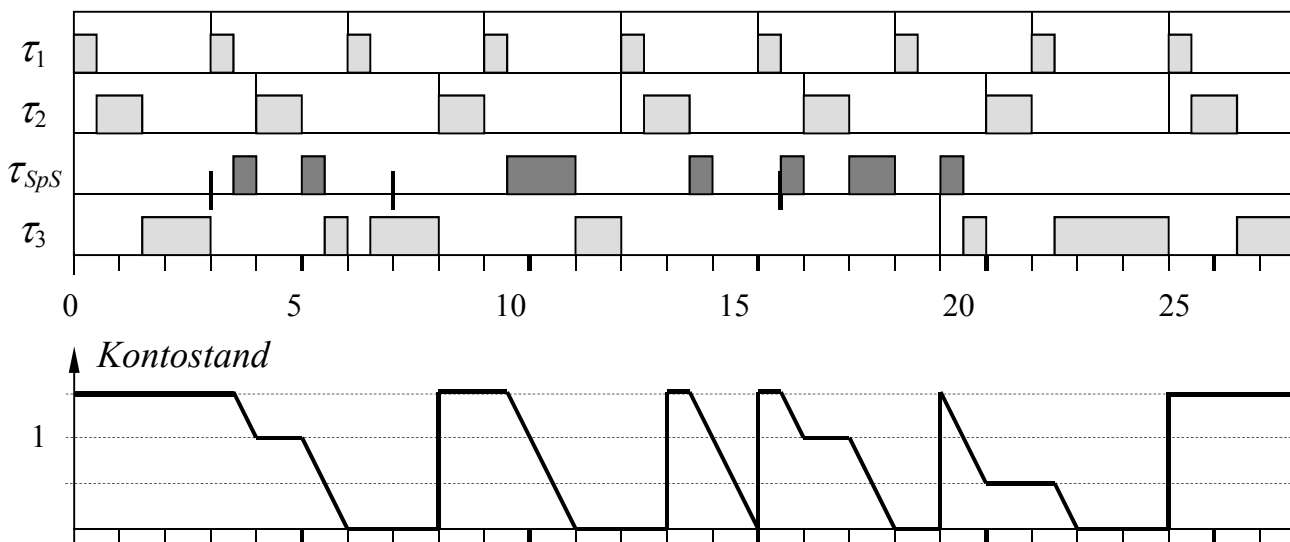
(a)  $t_e + t_s < t_f$ : Auffüllung, wenn Konto erschöpft

(b) System wird leer vor  $t_e + t_s$ , wieder beschäftigt bei  $t_b$ :  
Auffüllung bei  $\min(t_e + t_s, t_b)$ .

- **Beispiel 8.3.**

$$\tau_1 = (3; 0,5) \quad \tau_2 = (4; 1) \quad \tau_3 = (19; 4,5) \quad \tau_{SpS} = (5; 1,5)$$

$$A = (3; 1) \quad B = (7; 2) \quad C = (15,5; 2)$$



## 8.4. Einplanung mittels dynamischer Prioritäten

System-Scheduling nach EDF.

- „Constant Utilization Server“ (CU-Server)

- *Bezeichnungen und Voraussetzungen*

$u_s$  Größe (definiert den Server)

$e_s$  Konto / Kredit des Servers;  
Server ist ausführungsbereit bei positivem Kontostand

$d$  Deadline

$e$  Ausführungszeit des „1.“ Jobs von  $Q_a$ ;  
ein Job wird erst bei seiner Beendigung aus  $Q_a$  gelöscht.

- *Regeln*

*Verbrauch* nur während der Ausführung.

*Auffüllung:*

(1) Initialisierung:  $e_s = 0$ ,  $d = 0$ .

(2) Bei Ankunft eines Jobs mit Ausführungszeit  $e$  zur Zeit  $t$ ,  
falls  $Q_a = \emptyset$  und  $t \geq d$ :

$d := t + e/u_s$ ,  $e_s := e$  (andernfalls nichts).

(3) Ist der Server zu seinem Deadline-Zeitpunkt  $d$  beschäftigt:


$d := t + e/u_s$ ,  $e_s := e$  (andernfalls nichts).




– **Beispiel 8.4. a)**

$$\tau_1 = (3; 0,5) \quad \tau_2 = (4; 1) \quad \tau_3 = (19; 4,5)$$

$$A = (3; 1) \quad B = (6,75; 2) \quad C = (15,5; 2) \quad u_s = 0,25$$



– **Beispiel 8.4. b)**



– **Bewertung**

besseres Antwortzeitverhalten als sporadischer Server

günstigere Einplanbarkeit

Problem: Verschwendung von Leerlaufzeiten des Prozessors

- „Total Bandwidth Server“ (TB-Server)

Voraussetzungen und Verbrauchs-Regel wie bisher.

- **Auffüllung:**

(1) Initialisierung:  $e_s = 0, d = 0$ .

(2) Bei Ankunft eines Jobs mit Ausführungszeit  $e$  zur Zeit  $t$ :

$$d := \max(d, t) + e/u_s, \quad e_s := e \quad \text{im Fall } Q_a = \emptyset \quad (\text{sonst nichts}).$$

(3) Bleibt der Server bei Beendigung eines aperiodischen Jobs beschäftigt:

$$d := d + e/u_s, \quad e_s := e \quad (\text{sonst nichts}).$$

- **Beispiel 8.4. b)**

- **Bewertung**

Gleiche Deadlines wie CU-Server, aber frühere Auffüllung und damit geringere Antwortzeiten.

Einplanbarkeit: Gegeben sei ein System mit

- \* unabhängigen, periodischen Tasks, Gesamt-Dichte  $D$
- \* (einem oder mehreren) CU- oder TB-Servern, Gesamt-Größe  $U$
- \* unterbrechbaren Tasks bzw. Jobs
- \* Scheduling nach EDF.

In einem solchen System halten alle Tasks und alle Server stets ihre Deadlines ein, wenn

$$D + U \leq 1.$$

Probleme: Fairneß und Aushungern.