Betriebssysteme und nebenläufige Programmierung

SoSe 2025

Roland Wismüller
Betriebssysteme / verteilte Systeme
roland.wismueller@uni-siegen.de
Tel.: 0271/740-4050, Büro: H-B 8404

Stand: 1. April 2025

Betriebssysteme und nebenläufige Programmierung

SoSe 2025

7 Scheduling

7 Scheduling ...

Inhalt:

- Einführung
- Kriterien für das Scheduling
- Scheduling-Verfahren: allgemeine Aspekte
- Scheduling-Algorithmen

- Tanenbaum 2.5
- Stallings 9
- Nehmer/Sturm 5.3

7.1 Einführung

Teilaufgabe des BS: Mehrprogammbetrieb

- „Gleichzeitige“ Abarbeitung mehrerer Threads (und damit auch mehrerer Programme) im schnellen Wechsel
- Bisher behandelt:
  - Mechanismus des Threadswechsels
- Jetzt: **Thread-Scheduling**
  - Auswahlstrategie: welcher Thread darf als nächstes wie lange (und ggf. auf welcher CPU) rechnen?
  - Verwaltung des Betriebsmittels Prozessor

- (Daneben: weitere Scheduling-Aufgaben, ☞ **8.3.3, 9.3**)

7.1 Einführung ...

Scheduling beeinflußt Nutzbarkeit des Systems

- Beispiel: interaktiver Thread (I) und Hintergrundthread (H)
  - Darstellung als **Gantt-Diagramm**

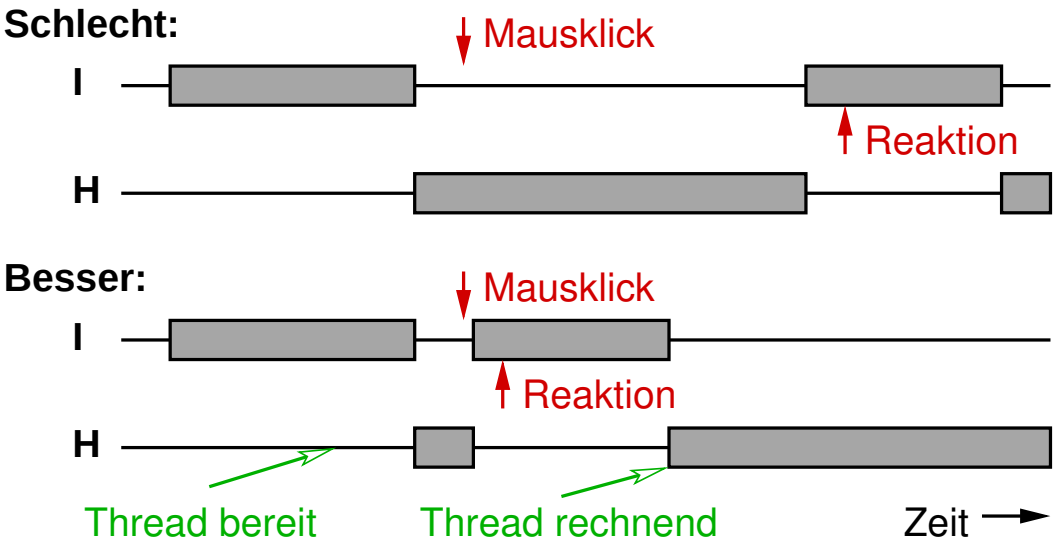

7.2 Kriterien für das Scheduling

Vorbemerkung: Betriebsarten eines Systems

- Stapelverarbeitungs-Betrieb
  - System arbeitet nicht-interaktive Aufträge ab
  - häufig bei Großrechnern
- Interaktiver Betrieb
  - typisch für Arbeitsplatzrechner, Server
- Echtzeitbetrieb
  - Steueraufgaben, Multimedia-Anwendungen

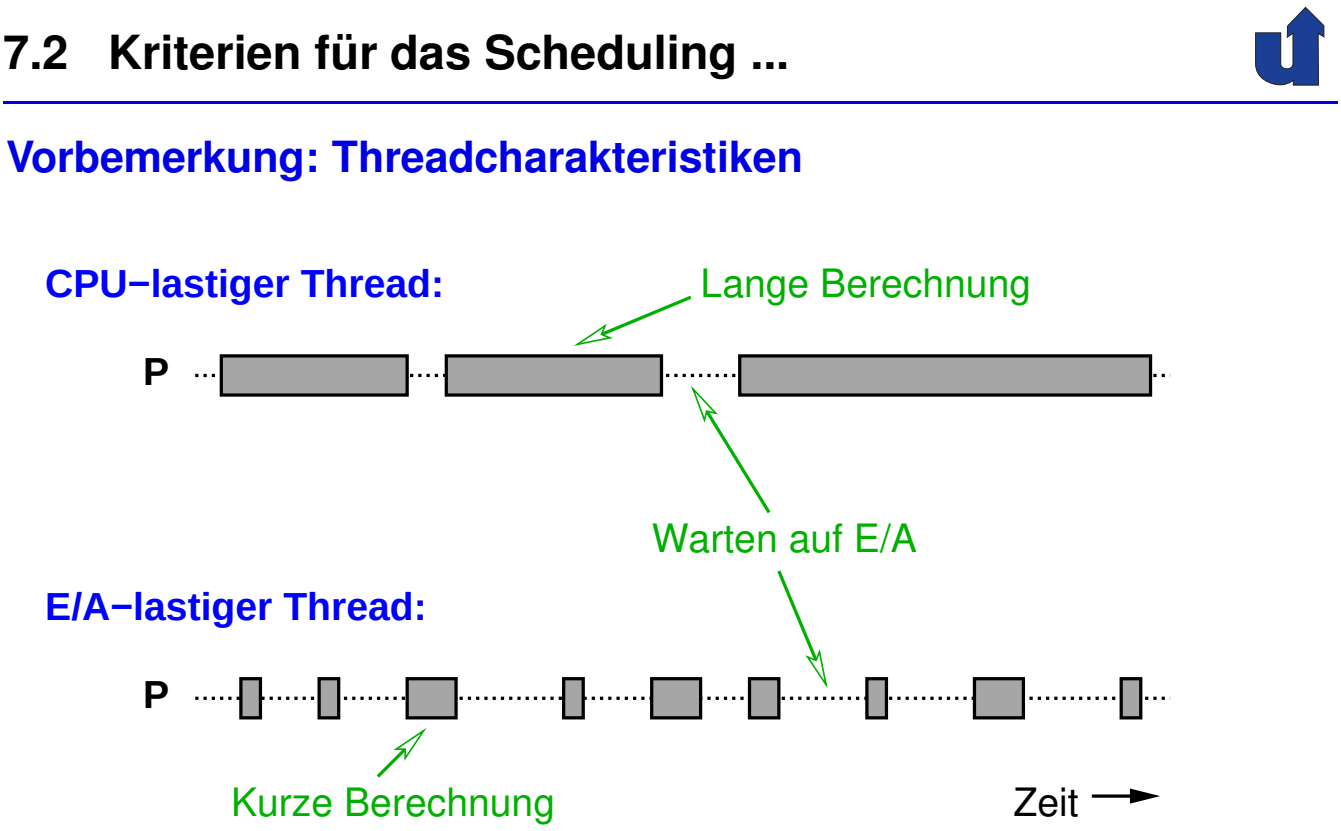

Vorbemerkung: Threadcharakteristiken

Kriterien für das Scheduling (Benutzersicht)

- Minimierung der Durchlaufzeit (Stapelbetrieb)
  - Zeit zwischen Eingang und Abschluß eines Jobs (inkl. aller Wartezeiten)
- Minimierung der Antwortzeit (Interaktiver Betrieb)
  - Zeit zwischen Eingabe einer Anfrage und Beginn der Ausgabe
- Einhaltung von Terminen (Realzeitbetrieb)
  - Ausgabe muß nach bestimmter Zeit erfolgt sein
- Vorhersehbarkeit
  - Durchlaufzeit / Antwortzeit i.W. unabhängig von Auslastung des Systems

Kriterien für das Scheduling (Systemsicht)

- Maximierung des Durchsatzes (Stapelbetrieb)
  - Anzahl der fertiggestellten Jobs pro Zeiteinheit
- Optimierung der Prozessorauslastung (Stapelbetrieb)
  - prozentualer Anteil der Zeit, in der Prozessor beschäftigt ist
- Balance
  - gleichmäßige Auslastung aller Ressourcen
- Fairness
  - vergleichbare Threads sollten gleich behandelt werden
- Durchsetzung von Prioritäten
  - Threads mit höherer Priorität bevorzugt behandeln

Scheduling-Kriterien nicht gleichzeitig erfüllbar

- z.B. Prozessorauslastung $\leftrightarrow$ kurze Antwortzeit
- Scheduling-Ziele und -Verfahren von Betriebsart abhängig
  - Stapelverarbeitung: hoher Durchsatz, gute Auslastung
    - bevorzuge Aufträge, die freie Ressourcen nutzen
  - Interaktiver Betrieb: kurze Antwortzeiten
    - bevorzuge Threads, die auf E/A (Benutzereingabe) gewartet haben und nun rechenbereit sind
  - Echtzeitbetrieb: Einhaltung von Zeitvorgaben
    - bevorzuge Threads, deren Ausführungsfristen ablaufen

7.3 Scheduling-Verfahren: allgemeine Aspekte

Ebenen des Schedulings

- Langfristiges Scheduling (Eingangs-Scheduler)
  - bei Systemen mit Stapelverarbeitung von Jobs:
    - welcher Job wird als nächstes zugelassen?
      D.h. wann werden Prozesse für den Job erzeugt?
  - Ziel z.B. Mischung aus CPU- und E/A-lastigen Prozessen
- Mittelfristiges Scheduling (Speicher-Scheduler)
  - Auslagern und Suspendieren von Prozessen (z.B. bei Speicherengpässen)
  - legt Multiprogramming-Grad fest
- Kurzfristiges Scheduling (CPU-Scheduler)
  - Zuteilung der CPU(s) an bereite Threads

7.3 Scheduling-Verfahren: allgemeine Aspekte ...

Nicht-präemptives und präemptives Scheduling

- **Nicht-präemptives Scheduling**
  - Thread darf so lange rechnen, bis er freiwillig die CPU aufgibt oder blockiert
  - sinnvoll bei Stapelverarbeitung und teilw. Echtzeitsystemen
- **Präemptives Scheduling**
  - Scheduler kann einem Thread die CPU zwangsweise entziehen
    - wenn ein anderer Thread (mit höherer Priorität) rechenbereit geworden ist
    - nach Ablauf einer bestimmten Zeit
  - unterstützt interaktive Systeme und Echtzeitsysteme

7.3 Scheduling-Verfahren: allgemeine Aspekte ...

Scheduling-Zeitpunkte (CPU-Scheduler)

- Bei Beendigung eines Threads
- Bei freiwilliger CPU-Aufgabe eines Threads
- Bei Blockierung eines Threads
  - Grund der Blockierung kann/sollte berücksichtigt werden
  - z.B. bei P()-Operation: weise CPU dem Thread zu, der Semaphor belegt ⇒ kürzere Blockierung
- Bei Erzeugung eines Threads
- Bei E/A-Interrupt
  - evtl. werden blockierte Threads rechenbereit
- Regelmäßig bei Timer-Interrupt

} nur bei prä–emptivem Scheduling

7.4 Scheduling-Algorithmen

- Legen fest, welcher Thread auf einer CPU als nächstes ausgeführt wird und wie lange er rechnen darf
- Bei Multiprozessor-Systemen prinzipiell:
  - jede CPU führt Algorithmus unabhängig von den anderen aus
  - Zugriffe auf Bereit-Warteschlange unter wechselseitigem Ausschluß
- Detailaspekt: ***Cache-Affinity*** / ***Affinity Scheduling***
  - ein einmal auf einer CPU ausgeführter Thread sollte nach Möglichkeit auf dieser CPU bleiben
    - Daten des Threads sind im Cache dieser CPU!
  - jeder Thread erhält eine (oder mehrere) bevorzugte CPU(s)
  - einfache Realisierung: getrennte Warteschlangen für jede CPU
    - falls leer: Warteschlangen anderer CPUs inspizieren

Anmerkungen zu Folie 340:

Etwas mehr zum Thema Multiprozessor-Scheduling findet sich im Tanenbaum-Buch, Kap. 8.1.4.

340-1

7.4 Scheduling-Algorithmen ...

7.4.1 *First Come First Served* (FCFS)

- Nicht-präemptives Verfahren

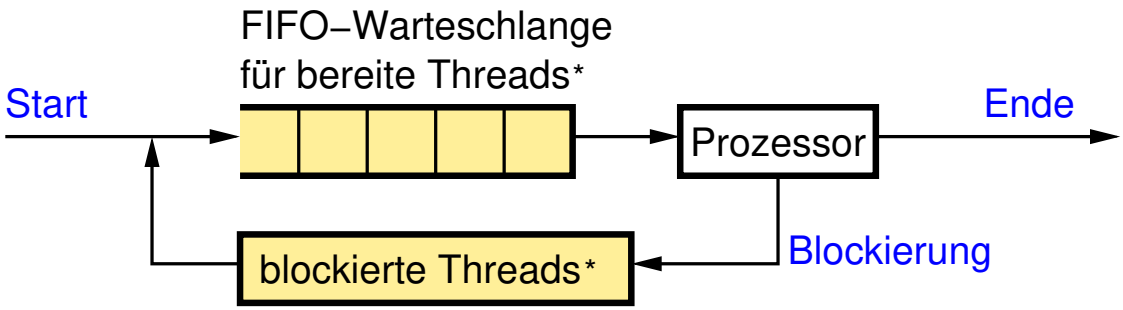

- Der am längsten wartende bereite Thread* darf als nächstes rechnen
  - nach Aufhebung einer Blockierung reiht sich ein Thread* wieder hinten in die Warteschlange ein

* bzw. Job(s) bei Stapelbetrieb

7.4.1 *First Come First Served* (FCFS) ...

(Animierte Folie)

Diskussion

- Sehr einfacher Algorithmus
- Stellt gute CPU-Auslastung sicher
- Vorwiegend für Stapelverarbeitung
- Durchlaufzeit wird nicht optimiert (siehe gleich: SJF)
- Balance evtl. schlecht durch Convoy-Effekt

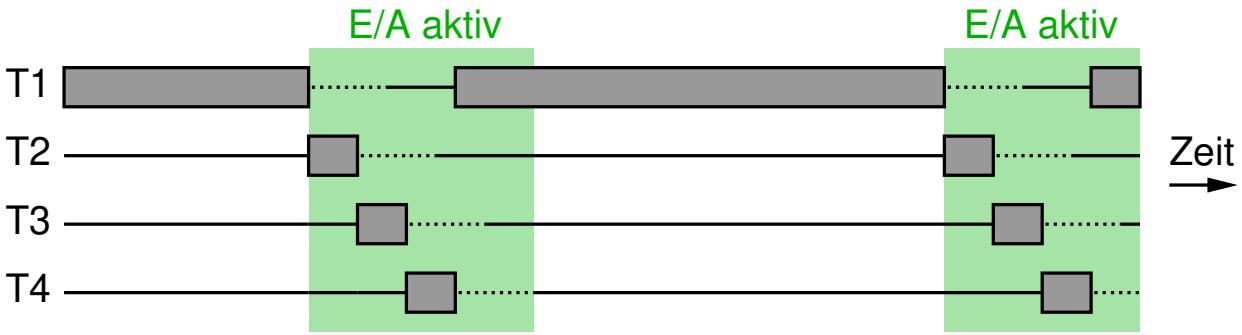

7.4 Scheduling-Algorithmen ...

7.4.2 *Shortest Job First* (SJF)

- Ziel: Optimierung der Durchlaufzeit
- Strategie: kürzester Job wird zuerst gerechnet
  - Dauer muß vorab bekannt sein (bei Stapelbetrieb i.a. erfüllt)
- SJF ist beweisbar optimal, falls alle Jobs gleichzeitig vorliegen
  - in der Regel: Jobs treffen nacheinander ein, Scheduler kann nur die Jobs berücksichtigen, die bereits bekannt sind
- Einfachster Fall: nicht-präemptiv, keine Blockierungen durch E/A
- In präemptiver Variante und bei Blockierungen durch E/A:
  - betrachte **Rest**laufzeiten
- Variante für interaktive Systeme:
  - betrachte CPU-Burst als Job, mit Schätzung der Dauer

Anmerkungen zu Folie 343:

SJF für interaktive Systeme

Die CPU wird dabei an den Thread mit dem kürzesten CPU-Burst vor der nächsten Blockierung (Interaktion) zugewiesen. Da die Dauer dieses CPU-Bursts aber vorher nicht bekannt ist, werden Schätzungen verwendet, die auf gemessenen Zeiten der bisherigen CPU-Bursts basieren.

Meist wird ein exponentieller, gleitender Mittelwert eingesetzt (*Aging*):

$$S_{n+1} = \alpha T_n + (1-\alpha) S_n \quad \text{mit } \alpha \in [0,1]$$

Dabei ist S_{n+1} der neue Mittelwert, T_n die gemessene Länge des letzten CPU-Burst und S_n der bisheriger Mittelwert.

Ein Meßwert wirkt sich mit zunehmendem Alter immer weniger auf den Mittelwert aus, wobei der Faktor α bestimmt, wie stark das Gewicht des Meßwerts mit seinem Alter abnimmt: ein Meßwert T_i geht in den Mittelwert S_n mit dem Gewicht $\alpha(1-\alpha)^{n-i}$ ein ($i \leq n$).

343-1

7.4.2 *Shortest Job First* (SJF) ...

Beispiel (alle Jobs liegen gleichzeitig vor)

Vier Jobs in FCFS−Reihenfolge

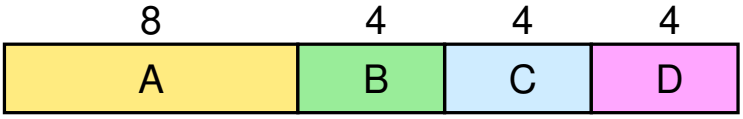

Mittlere Durchlaufzeit:
(8+12+16+20)/4 = 14

Dieselben Jobs in SJF−Reihenfolge

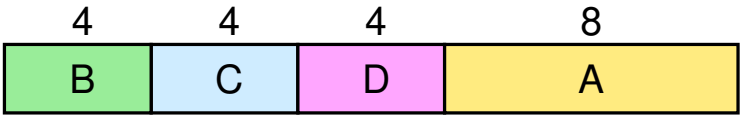

Mittlere Durchlaufzeit:
(4+8+12+20)/4 = 11

7.4.2 *Shortest Job First* (SJF) ...

(Animierte Folie)

Beispiel (die Jobs treffen nacheinander ein)

Job	Ankunftszeit	Bedienzeit
A	0	8
B	2	5
C	6	2
D	11	3

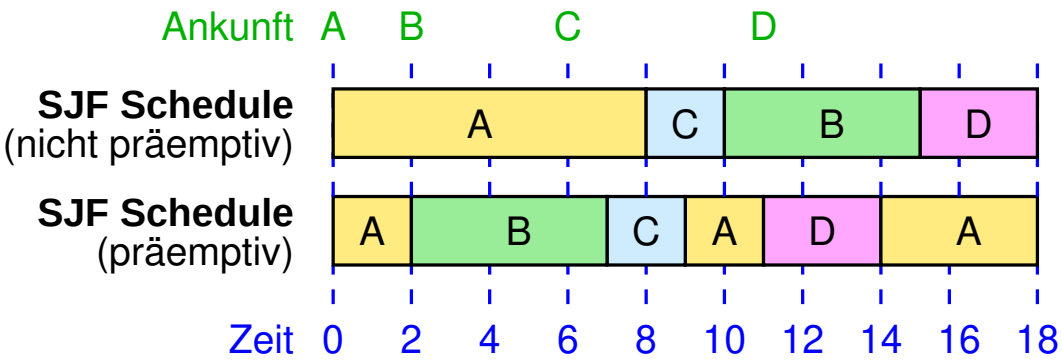

Mittlere Durchlaufzeit:

(8+13+4+7)/4 = 8

(18+5+3+3)/4 = 7,25

7.4 Scheduling-Algorithmen ...

7.4.3 *Round Robin* (RR), Zeitscheibenverfahren

- Präemtive Variante von FCFS
- Jeder Thread darf höchstens eine bestimmte Zeit (**Quantum**, **Zeitscheibe**, ***Time Slice***) rechnen

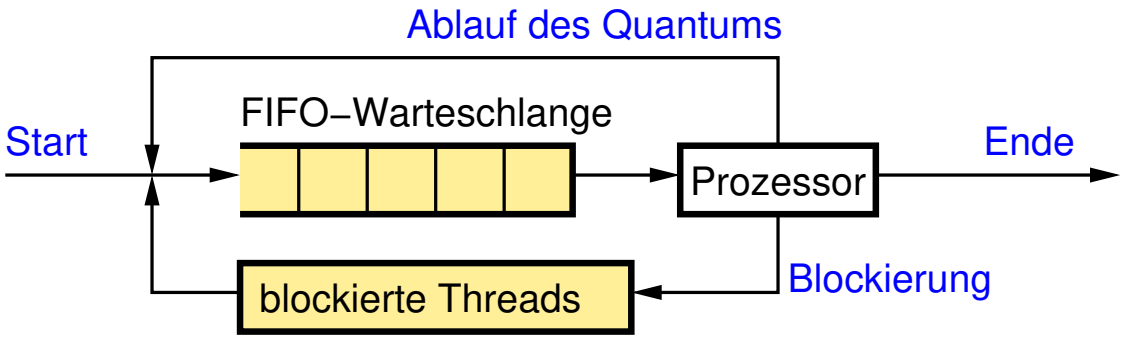

Diskussion

- Einfach zu realisieren
  - FIFO-Warteschlange aller rechenbereiten Threads und Timer-Interrupt
- Frage: Länge des Quantums
  - kurzes Quantum:
    - kurze Antwortzeiten
    - schlechte CPU-Nutzung durch häufige Threadwechsel
  - langes Quantum: umgekehrt
  - Praxis: 10 - 100 ms
- RR ist nicht fair:
  - E/A-lastige Threads werden benachteiligt

Zeitscheibenlänge

Lange Zeitscheibe:

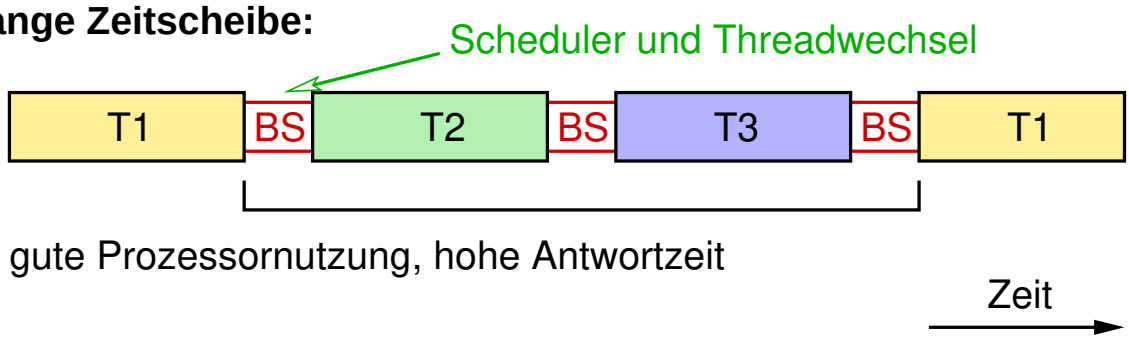

gute Prozessornutzung, hohe Antwortzeit

Kurze Zeitscheibe:

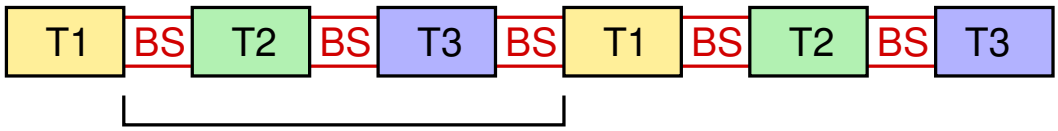

kurze Antwortzeit, schlechte Prozessornutzung

7.4.3 *Round Robin* (RR), Zeitscheibenverfahren ...

Fairness

T1 E/A–lastiger Thread

T2 CPU–lastiger Thread

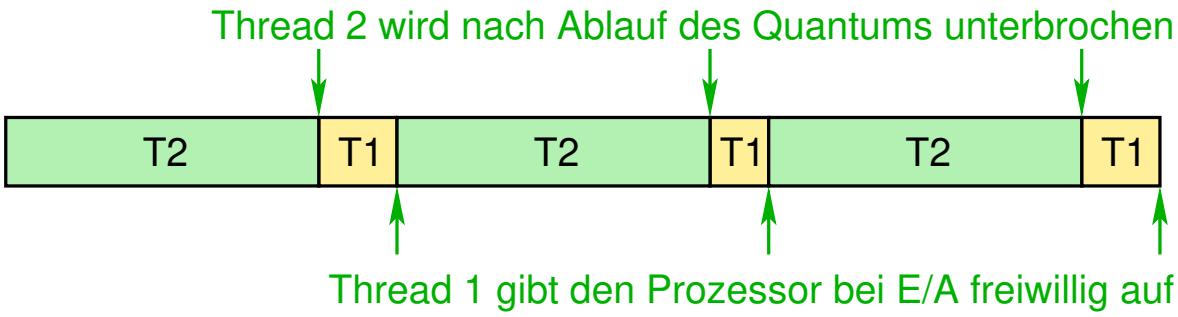

- Thread 1 ist gegenüber Thread 2 benachteiligt

7.4 Scheduling-Algorithmen ...

7.4.4 Prioritätenbasiertes Scheduling

- Jeder Thread erhält eine (unterschiedliche) Priorität
  - CPU wird an den Thread mit der höchsten Priorität zugeteilt
- I.d.R. präemptiv
- Statische Prioritäten
  - Priorität eines Threads bei Erzeugung festgelegt
  - häufig bei Realzeit-Systemen
- Dynamische Prioritäten
  - Priorität kann laufend geändert werden, abhängig vom Verhalten des Threads (**Feedback Scheduling**)
  - z.B.: Priorität bestimmt durch Länge des letzten CPU-Bursts des Threads ($\sim$ SJF)

Prioritätsinversion

- Problem bei wechselseitigem Ausschluß:
  - hoch priorisierter Thread **H** muss ggf. warten, bis ein Thread **L** mit niedriger Priorität ein Semaphor **s** freigibt
  - Thread **M** mit mittlerer Priorität kann **L** (und damit auch **H**) beliebig lange aufhalten
- Beispiel:

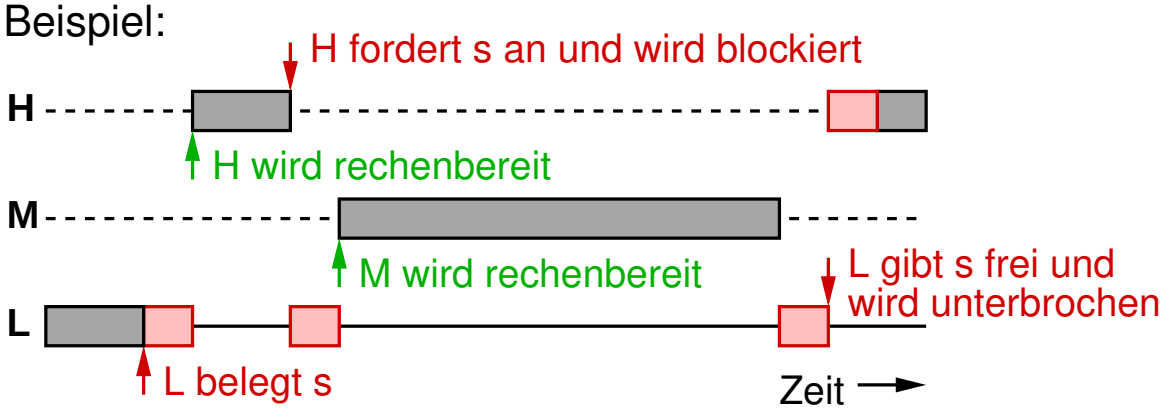

Prioritätsinversion ...

- Lösung: Prioritätsvererbung
  - Wenn ein hoch priorisierter Thread durch einen niedriger priorisierten Thread blockiert ist, erbt dieser für die Dauer der Blockierung die Priorität des blockierten Threads
- Im Beispiel:

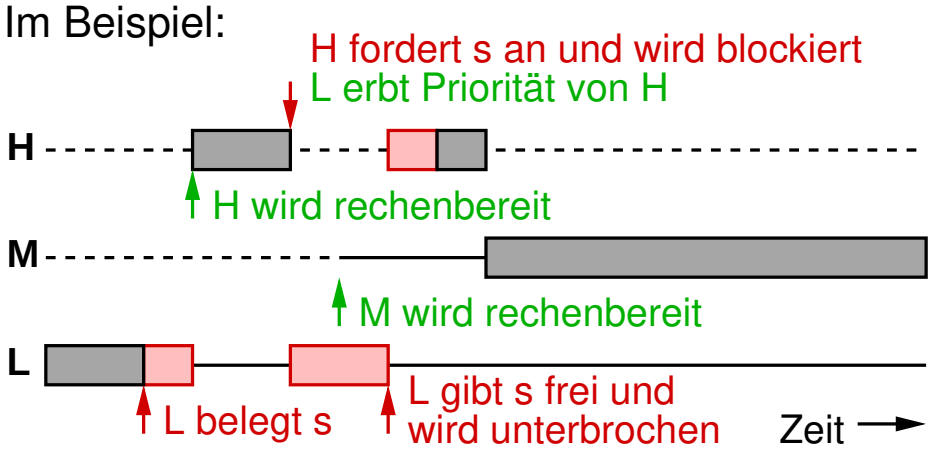

Anmerkungen zu Folie 352:

Mehr dazu finden Sie u.a. in

- William Stallings. *Operating Systems – Internals and Design Principles*. Eighth Edition. Pearson, 2015. Kap. 10.2, S. 488 ff.

352-1

7.4 Scheduling-Algorithmen ...

7.4.5 *Multilevel* Scheduling

- Mehrere Warteschlangen für bereite Threads
- Jede Warteschlange kann eigene Auswahlstrategie besitzen
- Zusätzlich: Strategie zur Auswahl der **aktuellen** Warteschlange
  - z.B. Prioritäten oder Round-Robin
- Statische Verfahren:
  - Thread wird fest einer Warteschlange zugeordnet
- Dynamische Verfahren:
  - Thread kann in Abhängigkeit seines Verhaltens zwischen Warteschlangen wechseln

Beispiel: Statisches *Multilevel* Scheduling

- Unterstützung verschiedener Betriebsarten in einem System
- Threads werden in Prioritäts**klassen** eingeteilt
  - pro Prioritätsklasse eine Warteschlange
  - unterschiedliche Scheduling-Strategien innerhalb der Warteschlangen

Priorität	Threadklasse	Strategie
1	Echtzeitthreads (Multimedia)	Prioritäten
2	Interaktive Threads	RR
3	E/A-intensive Threads	RR
4	Rechenintensive Stapel-Jobs	FCFS

Beispiel: Statisches *Multilevel* Scheduling ...

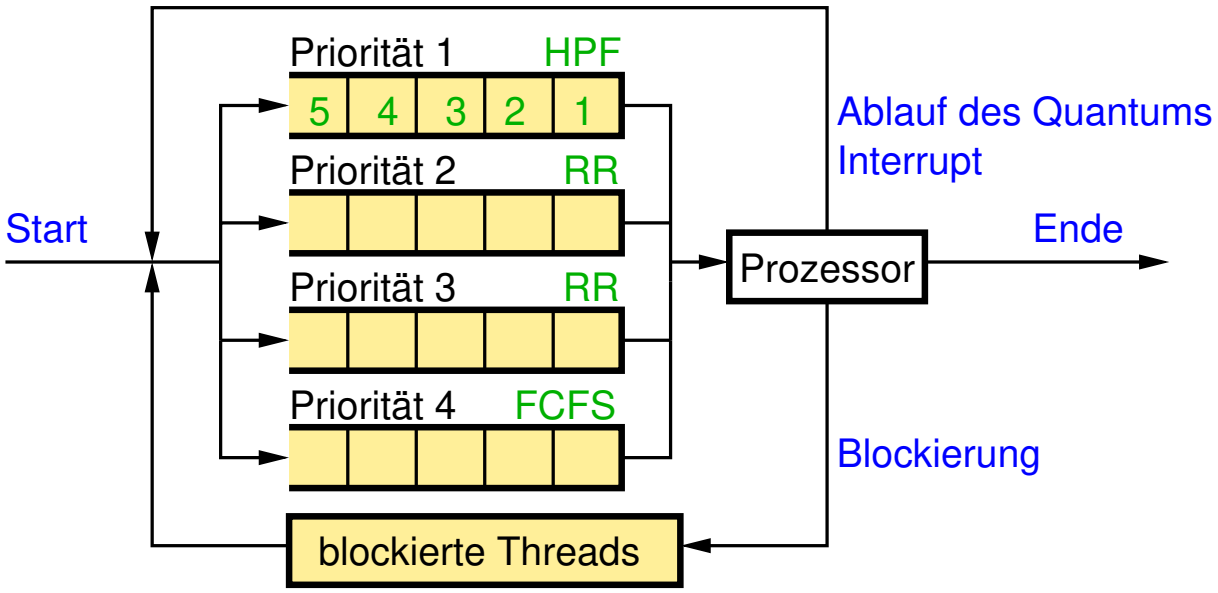

Beispiel: *Multilevel Feedback* Scheduling

- Dynamische Prioritäten und variable Zeitscheibenlänge
- Mehrere Warteschlangen mit unterschiedlicher Priorität
  - innerhalb einer Warteschlange: *Round Robin*
  - bei niedrigerer Priorität: längeres Quantum
- Falls Thread Quantum aufbraucht: erniedrigen der Priorität
  - CPU-lastiger Thread erhält längeres Quantum, wird seltener unterbrochen
- Sonst: Priorität nicht verändern bzw. wieder erhöhen
  - E/A-lastiger (bzw. interaktiver) Thread erhält bevorzugt die CPU, aber nur für kurze Zeit

7.5 Scheduling: Beispiele

7.5.1 Scheduling in BSD-Unix

- Priorisierte Warteschlangen mit *Round Robin*
- Threads, die durch BS-Aufruf im BS-Kern blockiert sind, erhalten hohe (negative) Priorität
  - nach Ende der Blockierung: Thread erhält bevorzugt die CPU, Priorität wird dann wieder auf alten Wert gesetzt
- Anpassung der normalen User-Priorität je nach CPU-Nutzung (Aging-Verfahren)

niedrige Priorität

⋮	⋮
2:	User Priorität 2
1:	User Priorität 1
0:	User Priorität 0
–1:	Kindprozeß terminiert
–2:	Terminalausgabe
–3:	Terminaleingabe
–4:	Seite auslagern
–5:	Warten auf Platte
⋮	⋮

hohe Priorität

Anmerkungen zu Folie 357:

Die normale User-Priorität bestimmt sich aus dem exponentiellen gleitenden Mittelwert der CPU-Nutzung: je höher die CPU-Nutzung desto niedriger die Priorität.

357-1

7.5 Scheduling: Beispiele ...

7.5.2 Scheduling in Windows NT / Vista

- 32 Prioritätsklassen
  - Priorität 16-31 (höchste)
    - Echtzeitklasse, statische Priorität
  - Priorität 1-15
    - normale Threads, dynamische Priorität
    - starke Prioritätserhöhung beim Warten auf Benutzereingabe, moderatere Erhöhung beim Warten auf E/A,
      - danach schrittweise Reduktion zum Ausgangswert
  - Priorität 0 (niedrigste)
    - *Idle*-Thread
- Innerhalb einer Klasse: *Round-Robin*

7.5.3 Scheduling in Linux (O(1) Scheduler)

- Jeder Thread wird in Linux einer Scheduling-Klasse zugeordnet:
  - `SCHED_FIFO`: „Echtzeit“-Threads mit FIFO Scheduling
  - `SCHED_RR`: „Echtzeit“-Threads mit Round Robin Scheduling
  - `SCHED_OTHER`: normale Threads
- „Echtzeit“-Threads besitzen lediglich höhere Priorität (0-99)
  - Priorität normaler Threads: 100-139
- Für jede Priorität: je zwei Warteschlangen pro CPU
  - *active*: Threads, die Zeitscheibe noch nicht aufgebraucht haben
  - *expired*: Threads, deren Quantum abgelaufen ist
- Zusätzliches Bit-Set zeigt an, welche Warteschlangen nicht leer sind

Vorgehensweise

- Scheduler wählt Thread mit höchster Priorität in *active* Warteschlange
  - falls Quantum aufgebraucht wird: Einreihen in *expired* Warteschlange
  - falls Thread blockiert: nach Blockierung wieder in *active* Warteschlange (mit entsprechend reduziertem Quantum)
- Falls *active* Warteschlange leer: Tausch der Warteschlangen
- Prioritäten der normalen Threads werden durch komplexe Heuristiken angepasst
  - interaktive (E/A-lastige) Threads sollen höhere Priorität erhalten

7.5.4 Linux: *Completely Fair Scheduler* (CFS)

- Ziel: jeder Thread bekommt einen fairen Anteil der CPU-Leistung
  - ohne aufwendige und problematische Heuristiken
- CFS simuliert eine ideale Multitasking-CPU
  - bei n Threads erhält jeder den Anteil $1/n$ der CPU-Leistung
- Dazu: die bisher erhaltene CPU-Zeit eines Threads wird ns-genau erfasst (*virtual runtime*)
  - neu erzeugte Threads erhalten als *virtual runtime* den Mittelwert aller anderen Threads
- Rechenbereite Threads werden nach *virtual runtime* sortiert in einen balancierten Baum (*Red-Black-Tree*) eingetragen
- Der Thread mit der kleinsten *virtual runtime* erhält die CPU

Anmerkungen zu Folie 361:

Der *Completely Fair Scheduler* (CFS) wird seit Linux Version 2.6.23 verwendet. Er ersetzt den O(1) Scheduler für die Scheduling-Klasse `SCHED_OTHER`. Die Klassen `SCHED_FIFO` und `SCHED_RR` werden im Wesentlichen noch wir vorher implementiert.

CFS realisiert eine Variante des *Weighted Fair Queueing*s, das z.B. auch in Netzwerk-Geräten (Router/Switches) zum Paket-Scheduling eingesetzt wird.

Red-Black-Tree

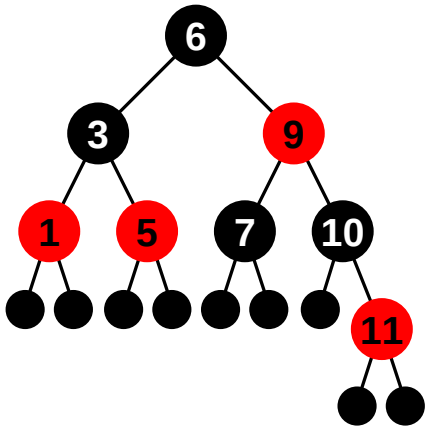

- Balancierter, binärer Suchbaum
  - Knoten sind entweder rot oder schwarz eingefärbt
  - jeder interne Knoten hat zwei Kinder
  - interne Knoten tragen Informationen
- Forderungen:
  - Wurzel und Blätter sind schwarz
  - rote Knoten haben zwei schwarze Kinder
  - jeder Pfad von einem Knoten zu einem Blatt hat dieselbe Zahl schwarzer Knoten
- Damit Baumhöhe bei n inneren Knoten: $\mathcal{O}(\log n)$
  - Einfügen / Suchen / Löschen in $\mathcal{O}(\log n)$

Anmerkungen zu Folie 362:

Red-Black-Trees sind u.a. auch die Grundlage für die Klassen `TreeSet` und `TreeMap` der Java Klassenbibliothek.

Eine detaillierte Beschreibung von *Red-Black-Trees* finden Sie u.a. in

- Thomas H. Cormen, Charles E. Leiserson, Ronald L. Rivest, Clifford Stein: Introduction to Algorithms (Third Edition), MIT Press, 2009
  https://sd.blackball.lv/library/Introduction_to_Algorithms_Third_Edition_(2009).pdf
- https://de.wikipedia.org/wiki/Rot-Schwarz-Baum

7.5.4 Linux: *Completely Fair Scheduler* (CFS) ...

Details

- Länge der Zeitscheibe:
  - Systemparameter *latency*: Zeit, bis jeder Thread einmal „drankommt“
  - Quantum = *latency* / N, wobei N = Zahl der rechenbereiten Threads
    - ggf. Sonderbehandlung, falls N zu groß
- Behandlung der Prioritäten (*nice*-Werte):
  - Quantum wird entsprechend der Priorität gewichtet
- Gruppen-Scheduling
  - erlaubt Definition von Gruppen von Threads
  - jede Gruppe erhält dann denselben Anteil der CPU-Leistung

7.5.4 Linux: *Completely Fair Scheduler* (CFS) ...

Multi-Core Scheduling

- Jeder Core hat eigene Thread-Warteschlangen (bzw. RB-Tree)
  - damit: Skalierbarkeit, keine Synchronisation notwendig
- Warteschlangen müssen zwischen Cores balanciert sein
  - z.B.: nicht alle hochprioren Threads bei einem Core
- Lastbalancierung ist aber teuer (Synchronisation, Caches)
  - seltene Durchführung; gute Verfahren notwendig
- Last berücksichtigt Prioritäten und durchschnittliche CPU-Nutzung
- Lastverteilung erfolgt hierarchisch
  - wegen hierarchischer Cache-/Speicherstruktur

Anmerkungen zu Folie 364:

Mehr zum Thema „Linux Schedling“ finden Sie u.a. in

- William Stallings. *Operating Systems – Internals and Design Principles*. Eighth Edition. Pearson, 2015. Kap. 10.3
- Andrew S. Tanenbaum, Herbert Bos. *Moderne Betriebssysteme*. 4. Auflage. Pearson, 2016. Kap. 10.3.4

Vertiefte Informationen zum Thema „Completely Fair Scheduler“ finden Sie u.a. unter

- https://en.wikipedia.org/wiki/Completely_Fair_Scheduler
- https://www.linuxjournal.com/node/10267
- https://developer.ibm.com/tutorials/l-completely-fair-scheduler
- https://opensource.com/article/19/2/fair-scheduling-linux
- https://www.ece.ubc.ca/~sasha/papers/eurosys16-final29.pdf

364-1

7.6 Zusammenfassung / Wiederholung

- Scheduling
  - Entscheidung welcher Thread wann wie lange (und ggf. auch welcher CPU) rechnen darf
  - Unterschiedliche Anforderungen, je nach Sichtweise und Betriebsmodus
  - Nicht-präemptives und präemptives Scheduling
    - präemptiv: BS kann einem Thread die CPU zwangsweise entziehen
- Scheduling-Algorithmen
  - FCFS: FIFO-Warteschlange rechenbereiter Threads, nicht-präemptiv
  - SJF: *Shortest Job First*
    - optimiert Durchlaufzeit von Jobs

7.6 Zusammenfassung / Wiederholung ...

- Scheduling-Algorithmen ...
  - *Round Robin* (RR): präemptive Version von FCFS
    - Threads dürfen nur bestimmte Zeit rechnen
  - Prioritätenbasiertes Scheduling:
    - nur der Thread mit höchster Priorität bekommt CPU (bzw. die n höchstprioren Threads bei n CPUs)
  - *Multilevel* Scheduling
    - mehrere Warteschlangen mit unterschiedlicher Auswahlstrategie
    - statisches *Multilevel* Scheduling
      - feste Zuordnung Thread $\rightarrow$ Warteschlange
    - *Multilevel Feedback* Scheduling
      - dynamische Zuordnung Thread $\rightarrow$ Warteschlange