

Systemprogrammierung

Prozesseinplanung

15./18. Dezember 2008

Überblick

Prozesseinplanung

- Prozessorzuteilungseinheit
- Ebenen der Prozessorzuteilung
- Zustandsübergänge
- Gütemerkmale
- Verfahrensweisen
- Grundlegende Strategien
- Fallstudien
- Zusammenfassung

Programmfaden

Einplanungseinheit (engl. *unit of scheduling*) für die Vergabe der CPU

Ablaufplanung von Fäden erfolgt **betriebsmittellorientiert** und ist ggf. **ereignisgesteuert** oder **zeitgesteuert**

- ▶ die Laufbereitschaft eines Fadens hängt von der Verfügbarkeit all jener Betriebsmittel ab, die für seinen Ablauf erforderlich sind
- ▶ die Bereitstellung von Betriebsmitteln (ggf. durch andere Fäden) kann die sofortige Einplanung von Fäden bewirken
- ▶ oder die Einplanung erfolgt in fest vorgegebenen Zeitintervallen

Einplanung eines Fadens ist nicht gleichzusetzen mit **Einlastung**:

- ▶ Einplanung ist der Vorgang der Reihenfolgenbildung von Aufträgen
- ▶ Einlastung ist der Moment der Zuteilung von Betriebsmitteln

Vorgänge, die ent- oder gekoppelt (**zeitversetzt**/**zeitgleich**) sein können

Fadenverläufe

Stoßbetrieb (engl. *burst mode*)

Laufphase: **CPU-Stoß** (engl. *CPU burst*)


- ▶ aktive Phase eines Fadens (auch: Rechenphase)
 - ▶ alle zur Ausführung erforderlichen Betriebsmittel sind verfügbar
- ▶ der Faden ist **eingelastet**, ihm wurde die CPU zugeteilt

Wartephase: E/A-Stoß (engl. *I/O burst*), im weitesten Sinn

- ▶ inaktive Phase eines Fadens (auch: E/A-Phase)
 - ▶ nicht alle zur Ausführung erforderlichen Betriebsmittel sind verfügbar
- ▶ Ein-/Ausgabe abwarten bedeutet, auf Betriebsmittel zu warten
 - ▶ **konsumierbare Betriebsmittel**: Eingabedaten, Nachrichten, Signale
 - ▶ **wiederverwendbare Betriebsmittel**: Puffer, Geräte, ..., die CPU
- ▶ die Betriebsmittel werden letztlich durch andere Fäden bereitgestellt
 - ▶ ein E/A-Gerät kann dabei als „externer Faden“ betrachtet werden

Fadenverläufe (Forts.)

Lauf-, E/A- und Wartephase von Fäden



Fadenverläufe (Forts.)

Zusammenfassung

Fäden durchlaufen (im BS) einen **Kontrollfluss** zur **Einplanung** und **Einlastung** anderer Fäden:

1. der laufende Faden stößt einen E/A-Vorgang an (*actuate*)
2. er wartet passiv auf die Beendigung der Ein-/Ausgabe (*schedule*)
 - Anforderung eines wiederverwend-/konsumierbaren Betriebsmittels
3. und lastet einen eingeplanten, laufbereiten Faden ein (*dispatch*)
4. die Beendigung der Ein-/Ausgabe wird signalisiert (*interrupt*)
 - Bereitsstellung des konsumierbaren Betriebsmittels „Signal“
5. der auf dieses Ereignis wartende Faden wird eingeplant (*schedule*)
6. der Faden wird eingelastet, sobald er an der Reihe ist (*dispatch*)

Sonderfall: ein Faden plant und lastet sich selbst ein, wenn sich die CPU mangels anderer laufbereiter Fäden im **Leerlauf** (engl. *idle state*) befindet

Fäden als Mittel zur Leistungsoptimierung

Arbeitsteilung in nebenläufigen/parallelen Systemen

Überlappung von Lauf- und Wartephasen erhöht die Rechnerauslastung

- ▶ die Wartephase eines Fadens als Laufphase anderer Fäden nutzen
- ▶ die Stöße anderer Fäden zum „Auffüllen“ von Wartephasen nutzen

Auslastung von CPU und Peripherie (E/A-Geräte) steigert sich

- ▶ eine CPU kann zu einem Zeitpunkt nur einen CPU-Stoß verarbeiten
- ▶ parallel dazu können jedoch mehrere E/A-Stöße laufen
 - ▶ ausgelöst während eines CPU-Stoßes: in der Laufphase eines Fadens wurden mehrere E/A-Vorgänge gestartet
 - ▶ ausgelöst von mehreren CPU-Stößen: die Wartephase eines Fadens wurde mit Laufphasen anderer Fäden gefüllt
- ▶ Folge: CPU und E/A-Geräte sind andauernd mit Arbeit beschäftigt

☞ bei weniger Prozessoren als Fäden, sind Fäden zu serialisieren

Zwangsserialisierung von Programmfäden

In Bezug auf eine Instanz des Betriebsmittels „CPU“

Verlängerung der **absoluten Ausführungsdauer** später „eintreffender“ laufbereiter Fäden ist zu beobachten:

- ▶ Ausgangspunkt seien n Fäden mit gleichlanger Bearbeitungsdauer k
- ▶ der erste Faden wird um die Zeitdauer 0 verzögert
- ▶ der zweite Faden um die Zeitdauer k , der i -te Faden um $(i - 1) \cdot k$
- ▶ der letzte von n Fäden wird verzögert um $(n - 1) \cdot k$

$$\frac{1}{n} \cdot \sum_{i=1}^n (i - 1) \cdot k = \frac{n - 1}{2} \cdot k$$

Vergrößerung der **mittleren Verzögerung** ist proportional zur Fadenanzahl

Subjektive Empfindung der Fadenverzögerung

Nur bis zu einer bestimmten Last (# eingeplanter Fäden) ...

Startzeiten von Fäden verzögern sich im Mittel um: $\frac{n-1}{2} \cdot t_{cpu}$

- ▶ mit t_{cpu} gleich der mittleren Dauer eines CPU-Stoßes
- ▶ sofern $t_{cpu} \geq t_{ea}$, der mittleren Dauer eines E/A-Stoßes
- ▶ die Praxis liefert als Regelfall jedoch ein anderes Bild: $t_{cpu} \ll t_{ea}$

Wartephasen bei E/A-Operationen dominieren die Fadenverzögerung

- ▶ zwischen CPU- und E/A-Stößen besteht eine große Zeitdiskrepanz
- ▶ der proportionale Verzögerungsfaktor bleibt weitestgehend verborgen
- ▶ er greift erst ab einer bestimmten Anzahl von Programmfäden
- ▶ sehr häufig ist die Fadenverzögerung daher nicht wahrnehmbar

☞ **Überlast** durch zuviel eingeplante Fäden **ist zu vermeiden**

Dauerhaftigkeit von Zuteilungsentscheidungen

Logische Ebenen der Prozesseinplanung

langfristige Einplanung (engl. *long-term scheduling*) [s – min]

- ▶ **Lastkontrolle**, Grad an Mehrprogrammbetrieb einschränken
- ▶ Programme laden und/oder zur Ausführung zulassen
- ▶ Prozesse der mittel- bzw. kurzfristigen Einplanung zuführen

mittelfristige Einplanung (engl. *medium-term scheduling*) [ms – s]


- ▶ Teil der **Umlagerungsfunktion** (engl. *swapping*)
- ▶ Programme vom Hinter- in den Vordergrundspeicher bringen
- ▶ Prozesse der langfristigen Einplanung zuführen

kurzfristige Einplanung (engl. *short-term scheduling*) [μ s – ms]

- ▶ **Einlastungsreihenfolge** der Prozesse festlegen — obligatorisch

Phasen der Prozesseinplanung

Lang- und mittelfristige Einplanung sind optional



Voraussetzung für Mehrprozessbetrieb ist die **kurzfristige Einplanung**

- ▶ laufbereite Prozesse erwarten die Zuteilung des wiederverwendbaren Betriebsmittels „CPU“, d.h. den Start ihrer Laufphase
- ▶ suspendierte Prozesse erwarten die Zuteilung eines konsumierbaren Betriebsmittels „Signal“, d.h. das Ende ihrer Wartephase

Prozesszustand vs. Einplanungsebene

Prozesse haben in Abhängigkeit von der Einplanungsebene (S. 9-9) zu einem Zeitpunkt einen **logischen Zustand**:

kurzfristig (engl. *short-term*)

- ▶ bereit, laufend, blockiert

mittelfristig (engl. *medium-term*, *mid-term*)

- ▶ schwebend bereit, schwebend blockiert

langfristig (engl. *long-term*)

- ▶ erzeugt, gestoppt, beendet

Anwendungsfälle legen fest, welche der Einplanungsebenen von einem Betriebssystem wirklich zur Verfügung zu stellen sind, nicht umgekehrt.

Kurzfristige Einplanung

Festlegung der Prozessorzuteilungsreihenfolge

Betriebssystem bietet **Mehrprozessbetrieb** (engl. *multi-processing*) auf Basis der **Serialisierung von Programmfäden**:

bereit (engl. *ready*) zur Ausführung durch den Prozessor (die CPU)

- ▶ der Prozess ist auf der Bereitliste (engl. *ready list*)
- ▶ das Einplanungsverfahren bestimmt die Listenposition

laufend (engl. *running*), erfolgte Zuteilung des Betriebsmittels „CPU“

- ▶ der Prozess vollzieht seinen CPU-Stoß
- ▶ zu einem Zeitpunkt pro CPU nur ein laufender Prozess

blockiert (engl. *blocked*) auf ein bestimmtes Ereignis

- ▶ der Prozess erwartet die Zuteilung eines Betriebsmittels
 - ▶ mit Ausnahme des Betriebsmittels „CPU“
- ▶ ggf. vollzieht der Prozess auch seinen E/A-Stoß

Spezialfall: „blockiert“ $\mapsto$ „laufend“ $\leadsto$ voll verdrängend (S. 9-17)

Mittelfristige Einplanung

Festlegung der Umlagerungsreihenfolge

Betriebssystem implementiert die **Umlagerung** (engl. *swapping*) von kompletten Programmen bzw. logischen Adressräumen:

schwebend bereit (engl. *ready suspend*)

- ▶ Adressraum des Prozesses ist ausgelagert
 - ▶ verschoben in den Hintergrundspeicher
 - ▶ „*swap-out*“ ist erfolgt
 - ▶ „*swap-in*“ wird erwartet
- ▶ die Einlastung des Prozesses ist außer Kraft
 - ▶ genauer: aller Fäden des Adressraums

schwebend blockiert (engl. *blocked suspend*)

- ▶ ausgelagerter ereigniserwartender Prozess
- ▶ Ereigniseintritt $\mapsto$ „schwebend bereit“

Variante: „schwebend bereit“ $\mapsto$ „bereit“ $\leadsto$ langfristige Einplanung

Langfristige Einplanung

Festlegung der Zulassungsreihenfolge

Betriebssystem verfügt über Funktionen zur **Lastkontrolle** und steuert den Grad an Mehrprogrammbetrieb:

erzeugt (engl. *created*) und fertig zur Programmverarbeitung

- ▶ Prozess ist instanziiert, Programm wurde zugeordnet
- ▶ ggf. steht die Speicherzuteilung jedoch noch aus

gestoppt (engl. *stopped*) und erwartet seine Fortsetzung

- ▶ Prozess wurde angehalten (z.B. `^Z` bzw. `kill(2)`)
- ▶ Gründe: Überlast, **Verklemmungsvermeidung**, ...


beendet (engl. *ended*) und erwartet seine Entsorgung

- ▶ Prozess ist terminiert, Betriebsmittelfreigabe erfolgt
- ▶ ggf. muss ein anderer Prozess den „Kehraus“ vollenden

Achtung: „gestoppt“ werden können auch bereite/blockierte Prozesse

Abfertigungszustände im Zusammenhang

Je nach Betriebssystem/-art sind weitere „Zwischenzustände“ anzufinden



Einplanungs-/Auswahlzeitpunkt

Übergänge in den Zustand „bereit“ aktualisieren die Bereitliste:

- ▶ eine Entscheidung über die **Einlastungsreihenfolge** wird getroffen
- ▶ eine **Funktion der Einplanungsstrategie** wird ausgeführt

Einplanung (engl. *scheduling*) bzw. **Umplanung** (engl. *rescheduling*):

- ▶ nachdem ein Prozess erzeugt worden ist: *begin*
- ▶ wenn ein Prozess freiwillig die CPU abgibt: *relinquish*
- ▶ falls das von einem Prozess erwartete Ereignis eingetreten ist: *signal*
- ▶ sobald ein Prozess wieder aufgenommen werden kann: *continue*

Prozesse können dazu gedrängt werden, die CPU freiwillig abzugeben

- ▶ sofern **verdrängende** (engl. *preemptive*) **Prozesseinplanung** erfolgt

Verdrängende Prozesseinplanung

Ereigniseintritt → Einplanung → Einlastung

Verdrängung (engl. *preemption*) des laufenden Prozesses von der CPU bedeutet folgendes:

1. ein Ereignis tritt ein, dessen Behandlungsverlauf zum Planer führt
 - ▶ der das Ereignis ggf. **erwartende Prozess** wird eingeplant
2. der (vom Ereignis unterbrochene) **laufende Prozess** wird eingeplant
3. ein **eingeplanter Prozess** wird ausgewählt und eingelastet
 - ▶ ggf. handelt es sich dabei um den unter 1. eingeplanten Prozess

Einplanung und Einlastung von Prozessen erfolgt nicht immer zeitnah zum Ereigniseintritt (d.h., dem Moment der Verdrängungsaufforderung):

- ▶ die Verdrängung eines Prozesses verzögert sich ggf. unbestimmt lang
- ▶ Ursache dafür ist u.a. die Architektur von Betriebssystem(kern)en

☞ ggf. entstehende **Latenzzeiten** können Anwendungen beeinträchtigen

Latenzzeiten und Determinismus

Verdrängung als Querschnittsbelang von Betriebssystemen

Einplanungslatenz (engl. *scheduling latency*) ist unvermeidbar, nicht jedoch ihre Unbestimmtheit — **deterministische Einplanung**:

- ▶ zu jedem Zeitpunkt ist der nachfolgende Schritt eindeutig festgelegt
 - ▶ unabhängig von Systemlast/-aktivitäten in dem Moment
- ▶ die Latenzzeit ist konstant oder mit fester oberer Schranke variabel

Einlastungslatenz (engl. *dispatching latency*), die Zeitspanne zwischen Einplanung und Verdrängung, führt zur weiteren Differenzierung:

verdrängend (engl. *preemptive*) ~ „programmierte Verdrängung“

- ▶ Einlastung nur an bestimmten Stellen freigegeben
- ▶ **Verdrängungspunkte** (engl. *preemption points*)


voll verdrängend (engl. *full preemptive*) ≡ Einlastung **jederzeit** erlaubt

zu guter Letzt: **Unterbrechungslatenz** (engl. *interrupt latency*)...


Latenzzeiten in Bezug zum Betriebsmodus

Asynchrone Programmunterbrechungen bleiben eine Quelle der Ungewissheit

voll verdrängend



1. Behandlung
 - ▶ **Interrupt**
2. Einplanung
3. Einlastung
4. **Synchronisation**



Dimensionen der Prozesseinplanung

Kriterien zur Aufstellung einer Einlastungsreihenfolge von Prozessen

benutzerorientierte Kriterien fokussieren auf Benutzerdienlichkeit

- ▶ d.h. das vom jeweiligen Benutzer wahrgenommene Systemverhalten
- ▶ bestimmen im großen Maße die Akzeptanz des Systems
 - ▶ bedeutsam für die Anwendungsdomäne in technischer Hinsicht
 - ▶ z.B. Einhaltung und Durchsetzung von Gütemerkmalen

systemorientierte Kriterien haben Systemperformanz im Vordergrund

- ▶ d.h. die effektive und effiziente Auslastung der Betriebsmittel
- ▶ bestimmen im großen Maße die „Rentabilität“ des Systems
 - ▶ bedeutsam für die Anwendungsdomäne in kommerzieller Hinsicht
 - ▶ z.B. Amortisierung hoher Anschaffungskosten von Großrechnern

Ausschlusskriterien sind dies nicht, vielmehr eine Schwerpunktsetzung:

- ▶ gute Systemperformanz ist auch der Benutzerdienlichkeit förderlich

Benutzerorientierte Kriterien

Charakteristische Anforderungserkmale bestimmter Anwendungsdomänen

Antwortzeit Minimierung der Zeitdauer von der Auslösung eines Systemaufrufs bis zur Entgegennahme der Rückantwort, bei gleichzeitiger Maximierung der Anzahl interaktiver Prozesse.

Durchlaufzeit Minimierung der Zeitdauer vom Starten eines Prozesses bis zu seiner Beendigung, d.h., der effektiven Prozesslaufzeit und aller anfallenden Prozesswartezeiten.

Termineinhaltung Starten und/oder Beendigung eines Prozesses (bis) zu einem fest vorgegebenen Zeitpunkt.

Vorhersagbarkeit Deterministische Ausführung des Prozesses unabhängig von der jeweils vorliegenden Systemlast.

Systemorientierte Kriterien

Wünschenswerte Anforderungsmerkmale vieler Anwendungsdomänen

- Durchsatz** Maximierung der Anzahl vollendeter Prozesse pro vorgegebener Zeiteinheit, d.h., der (im System) geleisteten Arbeit.
- Prozessorauslastung** Maximierung des Prozentanteils der Zeit, während der die CPU Prozesse ausführt, d.h., „sinnvolle“ Arbeit leistet.
- Gerechtigkeit** Gleichbehandlung der auszuführenden Prozesse und Zusicherung, den Prozessen innerhalb gewisser Zeiträume die CPU zuzuteilen.
- Dringlichkeiten** Vorzugbehandlung des Prozesses mit der höchsten (statischen/dynamischen) Priorität.
- Lastausgleich** Gleichmäßige Betriebsmittelauslastung; ggf. auch Vorzugbehandlung der Prozesse, die stark belastete Betriebsmittel eher selten belegen.

Betriebsart vs. Einplanungskriterien

Prozesseinplanung impliziert eine Betriebsart und umgekehrt

allgemein Gerechtigkeit, Lastausgleich

- ▶ **Durchsetzung der jeweiligen Strategie**

Stapelbetrieb Durchsatz, Durchlaufzeit, Prozessorauslastung

interaktiver Betrieb Antwortzeit; **Proportionalität**:

Für bestimmte Prozesse ein Laufzeitverhalten „simulieren“, das nicht unbedingt dem technischen Leistungsvermögen des Rechensystems entspricht:
☞ Geschwindigkeit ist Hexerei?

- ▶ Benutzer haben meist eine inhärente Vorstellung über die Dauer bestimmter Aktionen.
- ▶ Dieser (oft auch falschen) Vorstellung sollte das System aus Gründen der Benutzerakzeptanz möglichst entsprechen.

Echtzeitbetrieb Dringlichkeit, Termineinhaltung, Vorhersagbarkeit

- ▶ oft im Konflikt mit Gerechtigkeit/Lastausgleich

Kooperativ vs. Präemptiv

Souverän ist die Anwendung oder das Betriebssystem

cooperative scheduling voneinander abhängiger Prozesse

- ▶ „unkooperative“ Prozesse können die **CPU monopolisieren**
- ▶ während der Programmausführung müssen Systemaufrufe erfolgen
 - ▶ **Endlosschleifen ohne Systemaufrufe** im Anwendungsprogramm verhindern Prozesse anderer Anwendungsprogramme
- ▶ alle Systemaufrufe müssen den Scheduler durchlaufen

preemptive scheduling voneinander unabhängiger Prozesse

- ▶ Prozessen wird die CPU entzogen, zugunsten anderer Prozesse
- ▶ der laufende Prozess wird **ereignisbedingt** von der CPU **verdrängt**
 - ▶ Endlosschleifen beeinträchtigen andere Prozesse nicht (bzw. kaum)
- ▶ die Ereignisbehandlung aktiviert (direkt/indirekt) den Scheduler
- ▶ Monopolisierung der CPU ist nicht möglich: **CPU-Schutz**

Deterministisch vs. Probabilistisch

Mit oder ohne *à priori* Wissen

deterministic scheduling bekannter, exakt vorberechneter Prozesse

- ▶ alle **CPU-Stoßlängen** und ggf. auch **Termine** sind bekannt
 - ▶ bei (strikten) Echtzeitsystemen mindestens die Stoßlänge des „schlimmsten Falls“ (engl. *worst-case execution time*, WCET)
- ▶ die genaue Vorhersage der CPU-Auslastung ist möglich
- ▶ das System stellt die Einhaltung von **Zeitgarantien** sicher
- ▶ die Zeitgarantien gelten unabhängig von der jeweiligen Systemlast

probabilistic scheduling unbekannter Prozesse

- ▶ exakte CPU-Stoßlängen sind unbekannt, ggf. auch Termine
- ▶ die CPU-Auslastung kann lediglich abgeschätzt werden
- ▶ das System kann Zeitgarantien weder geben noch einhalten
- ▶ Zeitgarantien sind durch die Anwendung sicherzustellen

Statisch vs. Dynamisch

Entkoppelt von oder gekoppelt mit der Programmausführung

offline scheduling statisch, vor der Programmausführung

- ▶ **Komplexität** verbietet Ablaufplanung im laufenden Betrieb
 - ▶ zu berechnen, ob die Einhaltung aller Zeitvorgaben garantiert werden kann, ist ein NP-vollständiges Problem
 - ▶ die Berechnungskomplexität wird zum kritischen Faktor, wenn auf jede abfangbare katastrophale Situation zu reagieren ist
- ▶ Ergebnis der Vorberechnung ist ein **vollständiger Ablaufplan**
 - ▶ u.a. erstellt per Quelltextanalyse spezieller „Übersetzer“
 - ▶ oft zeitgesteuert abgearbeitet als Teil der Prozesseinlastung
- ▶ die Verfahren sind zumeist beschränkt auf **strikte Echtzeitsysteme**

online scheduling dynamisch, während der Programmausführung

- ▶ Stapelsysteme, interaktive Systeme, verteilte Systeme
- ▶ schwache und feste Echtzeitsysteme

Asymmetrisch vs. Symmetrisch

An eine CPU gebundene oder ungebundene Programmausführung

asymmetric scheduling ist abhängig von Eigenschaften der Ebene_{2/3}


- ▶ obligatorisch in einem asymmetrischen Multiprozessorsystem
 - ▶ Rechnerarchitektur mit **programmierbare Spezialprozessoren**
 - ▶ z.B. Grafik- und/oder Kommunikationsprozessoren einerseits und ein Feld konventioneller (gleichartiger) CPUs andererseits
 - ▶ Prozesse sind an bestimmte Prozessoren gebunden
- ▶ optional in einem symmetrischen Multiprozessorsystem (s.u.)
 - ▶ das Betriebssystem hat freie Hand über die Prozessorvergabe
- ▶ Prozesse in funktionaler Hinsicht ungleich verteilen (müssen)

symmetric scheduling ist abhängig von Eigenschaften der Ebene₂

- ▶ identische Prozessoren, alle geeignet zur Programmausführung
- ▶ Prozesse werden gleich auf die Prozessoren verteilt: **Lastausgleich**


Asymmetrisch vs. Symmetrisch (Forts.)

Jedem Prozessor seine eigene oder allen Prozessoren eine gemeinsame Bereitliste



separate Bereitlisten

- ▶ ungleichmäßige Auslastung
- ▶ Unterbrechungssynchronisation



gemeinsame Bereitliste

- ▶ gleichmäßige Auslastung
- ▶ Multiprozessorsynchronisation

Klassische Einplanungs- bzw. Auswahlverfahren

Überblick

kooperativ FCFS

- ▶ wer zuerst kommt, mahlt zuerst...

gerecht

verdrängend RR, VRR

- ▶ jeder gegen jeden...

reihum

probabilistisch SPN (SJF), SRTF, HRRN

- ▶ die Kleinen nach vorne...

priorisierend

mehrstufig MLQ, FB (MLFQ)

- ▶ Rasterfahndung...

FCFS (engl. *first come, first served*)

Fair, einfach zu implementieren (FIFO Queue), . . . , dennoch problematisch

Prozesse werden nach ihrer **Ankunftszeit** (engl. *arrival time*) eingeplant und in der sich daraus ergebenden Reihenfolge auch verarbeitet

- ▶ nicht-verdrängendes Verfahren, setzt kooperative Prozesse voraus

Gerechtigkeit zu Lasten hoher Antwortzeit und niedrigem E/A-Durchsatz

- ▶ suboptimal bei einem Mix von kurzen und langen CPU-Stößen

Prozesse mit $\left\{ \begin{array}{l} \text{langen} \\ \text{kurzen} \end{array} \right\}$ CPU-Stößen werden $\left\{ \begin{array}{l} \text{begünstigt} \\ \text{benachteiligt} \end{array} \right\}$

☞ **Konvoi(d)effekt**: mehrere kurze Aufträge folgen einem langen. . .

FCFS (Forts.)

Durchlaufzeit kurzer Prozesse im Mix mit langen Prozessen

Prozess	Zeiten					T_q/T_s
	Ankunft	T_s	Start	Ende	T_q	
A	0	1	0	1	1	1.00
B	1	100	1	101	100	1.00
C	2	1	101	102	100	100.00
D	3	100	102	202	199	1.99
Ø						26.00

T_s = Bedienzeit, T_q = Durchlaufzeit

normalisierte Durchlaufzeit (T_q/T_s): vergleichsweise sehr schlecht bei C

- ▶ sie steht in einem extrem schlechten Verhältnis zur Bedienzeit T_s
- ▶ typischer Effekt im Falle von kurzen Prozessen, die langen folgen

RR (engl. *round robin*)

Verdrängendes FCFS, Zeitscheiben, CPU-Schutz

Prozesse werden nach ihrer **Ankunftszeit** ein- und in regelmäßigen Zeitabständen (periodisch) umgeplant

- ▶ verdrängendes Verfahren, nutzt **periodische Unterbrechungen**
 - ▶ Zeitgeber (engl. *timer*) liefert asynchrone Programmunterbrechungen
- ▶ jeder Prozess erhält eine **Zeitscheibe** (engl. *time slice*) zugeteilt
 - ▶ obere Schranke für die CPU-Stoßlänge eines laufenden Prozesses

Verringerung der bei FCFS auftretenden Benachteiligung von Prozessen mit kurzen CPU-Stößen

- ▶ die **Zeitscheibenlänge** bestimmt die Effektivität des Verfahrens
 - ▶ zu lang, Degenierung zu FCFS; zu kurz, sehr hoher Mehraufwand
- ▶ Faustregel: etwas länger als die Dauer eines „typischen CPU-Stoßes“

RR (Forts.)

Leistungsprobleme bei einem Mix von Prozessen

E/A-intensive Prozesse schöpfen ihre Zeitscheibe selten voll aus

- ▶ sie beenden ihren CPU-Stoß freiwillig
 - ▶ vor Ablauf der Zeitscheibe

CPU-intensive Prozesse schöpfen ihre Zeitscheibe meist voll aus

- ▶ sie beenden ihren CPU-Stoß unfreiwillig
 - ▶ durch Verdrängung

 **Konvoi(d)effekt:** mehrere kurze CPU-Stöße folgen einem langen. . .

CPU-Zeit ist zu Gunsten CPU-intensiver Prozesse ungleich verteilt

- ▶ E/A-intensive Prozesse werden schlechter bedient
- ▶ E/A-Geräte sind schlecht ausgelastet

 **Varianz der Antwortzeit** E/A-intensiver Prozesse ist groß

VRR (engl. *virtual round robin*)

RR mit Vorzugswarteschlange und variablen Zeitscheiben

Prozesse werden mit Beendigung ihres E/A-Stoßes **bevorzugt eingeplant**, jedoch nicht (zwingend) bevorzugt/sofort eingelastet

- ▶ Einreihung in eine der Bereitliste vorgeschalteten **Vorzugsliste**
 - ▶ FIFO $\leadsto$ evtl. Benachteiligung hoch-interaktiver Prozesse; daher...
 - ▶ aufsteigend sortiert nach dem **Zeitscheibenrest** eines Prozesses
- ▶ **Umplanung** bei Beendigung des jeweils laufenden CPU-Stoßes
 - ▶ die Prozesse auf der Vorzugsliste werden zuerst eingelastet
 - ▶ sie bekommen die CPU für die Restdauer ihrer Zeitscheibe zugeteilt
 - ▶ bei Ablauf dieser Zeitscheibe werden sie in die Bereitsliste eingereiht

Vermeidung der bei RR möglichen ungleichen Verteilung von CPU-Zeiten

- ▶ bevorzugt werden interaktive Prozesse mit kurzen CPU-Stößen
- ▶ erreicht durch strukturelle Maßnahmen...

SPN (engl. *shortest process next*)

Zeitreihen bilden, analysieren und verwerten

Prozesse werden nach ihrer **erwarteten Bedienzeit** eingeplant

- ▶ Grundlage dafür ist *à priori* Wissen über die **Prozesslaufzeiten**:
 - Stapelbetrieb** Programmierer setzen **Frist** (engl. *time limit*)
 - Produktionsbetrieb** Erstellung einer **Statistik** durch Probeläufe
 - Dialogbetrieb** **Abschätzung** von CPU-Stoßlängen zur Laufzeit
- ▶ Abarbeitung einer aufsteigend nach Prozesslaufzeiten sortierten Bereitsliste
 - ▶ Abschätzung erfolgt vor (statisch) oder zur (dynamisch) Laufzeit

Verkürzung von Antwortzeiten und Steigerung der Gesamtleistung des Systems auf Kosten länger laufender Prozess

- ▶ ein **Verhungern** (engl. *starvation*) dieser Prozesse ist möglich

SPN (Forts.)

Abschätzung der Dauer eines CPU-Stoßes

Mittelwertbildung über alle CPU-Stoßlängen eines Prozesses:

$$S_{n+1} = \frac{1}{n} \cdot \sum_{i=1}^n T_i = \frac{1}{n} \cdot T_n + \frac{n-1}{n} \cdot S_n$$

- ▶ Problem dieser Berechnung ist die **gleiche Wichtung** aller CPU-Stöße
- ▶ jüngere CPU-Stöße eine größere Wichtung geben: **Lokalität**

Messung der Dauer eines CPU-Stoßes geschieht bei Prozesseinlastung:

- ▶ Stoppzeit T_2 von P_x entspricht (in etwa) der Startzeit T_1 von P_y
 - ▶ gemessen in **Uhrzeit** (engl. *clock time*) oder **Uhrtick** (engl. *clock tick*)
- ▶ Akkumulation der Differenzen $T_2 - T_1$ für jeden Prozess P_i

SPN (Forts.)

Wichtung der CPU-Stöße, Dämpfungsfiter (engl. *decay filter*) einsetzen

Dämpfung (engl. *decay*) der am weitesten zurückliegenden CPU-Stöße:

$$S_{n+1} = \alpha \cdot T_n + (1 - \alpha) \cdot S_n$$

- ▶ für den konstanten Wichtungsfaktor α gilt dabei: $0 < \alpha < 1$
- ▶ drückt die **relative Wichtung** einzelner CPU-Stöße der Zeitreihe aus
- ▶ teilweise Expansion der Gleichung führt zu:
 - ▶ $S_{n+1} = \alpha T_n + (1 - \alpha)\alpha T_{n-1} + \dots + (1 - \alpha)^i \alpha T_{n-i} + \dots + (1 - \alpha)^n S_1$
- ▶ Beispiel der Entwicklung für $\alpha = 0.8$:
 - ▶ $S_{n+1} = 0.8 T_n + 0.16 T_{n-1} + 0.032 T_{n-2} + 0.0064 T_{n-3} + \dots$

SRTF (engl. *shortest remaining time first*)

Verdrängendes SPN, Verhungerungsgefahr, Effektivität von VRR

Prozesse werden nach ihrer **erwarteten Bedienzeit** eingeplant und in unregelmäßigen Zeitabständen **sporadisch** umgeplant

- ▶ sei T_{et} die erwartete CPU-Stoßlänge eines eintreffenden Prozesses
- ▶ sei T_{rt} die verbleibende CPU-Stoßlänge des laufenden Prozesses
- ▶ der laufende Prozess wird verdrängt, wenn gilt: $T_{et} < T_{rt}$

Umplanung erfolgt ereignisbedingt und (ggf. voll) verdrängend

- ▶ z.B. bei Beendigung des E/A-Stoßes eines wartenden Prozesses
- ▶ allgemein: bei Aufhebung der Wartebedingung für einen Prozess

Verdrängung führt zu besseren Antwort- und Durchlaufzeiten:

- ▶ gegenüber VRR steht der *Overhead* zur CPU-Stoßlängenabschätzung

HRRN (engl. *highest response ratio next*)

SRTF ohne Verhungern der Prozesse

Prozesse werden nach ihrer **erwarteten Bedienzeit** eingeplant und periodisch unter Berücksichtigung ihrer **Wartezeit** umgeplant

- ▶ in regelmäßigen Zeitabständen wird ein Verhältnisswert R berechnet:

$$R = \frac{w + s}{s}$$

w aktuell abgelaufene Wartezeit eines Prozesses

s erwartete (d.h., abgeschätzte) Bedienzeit eines Prozesses

- ▶ **periodische Aktualisierung** aller Einträge in der Bereitliste
- ▶ ausgewählt wird der Prozess mit dem größten Verhältnisswert R

Alterung (engl. *aging*) von Prozessen meint einen Anstieg der Wartezeit

- ▶ **Alterung entgegenwirken** (engl. *anti-aging*) beugt Verhungern vor

MLQ (engl. *multilevel queue*)

Unterstützt Mischbetrieb: Vorder- und Hintergrundbetrieb


Prozesse werden nach ihrem **Typ** (d.h., nach den für sie zutreffend geglaubten Eigenschaften) eingeplant

- ▶ Aufteilung der Bereitliste in separate („getypte“) Listen
 - ▶ z.B. für System-, Dialog- und Stapelprozesse
- ▶ mit jeder Liste eine **lokale Einplanungsstrategie** verbinden
 - ▶ z.B. SPN, RR und FCFS
- ▶ zwischen den Listen eine **globale Einplanungsstrategie** definieren
 - statisch** Liste einer bestimmten Prioritätsebene fest zuordnen
 - ▶ Verhungerungsgefahr für Prozesse tiefer liegender Listen
 - dynamisch** die Listen im Zeitmultiplexverfahren wechseln
 - ▶ z.B. 40 % System-, 40 % Dialog- 20 % Stapelprozesse

Prozessen Typen zuordnen ist eine statische Entscheidung: sie wird zum Zeitpunkt der Prozesserzeugung getroffen

MLQ (Forts.)

Mischbetrieb mit System-, Dialog- und Stapelprozessen



FB (engl. *feedback*)

Begünstigt kurze/interaktive Prozesse, ohne die relativen Stoßlängen kennen zu müssen

Prozesse werden nach ihrer **Ankunftszeit** ein- und in regelmäßigen Zeitabständen (periodisch) umgeplant


- ▶ Hierarchie von Bereitlisten, je nach Anzahl der **Prioritätsebenen**
 - ▶ erstmalig eintreffende Prozesse steigen oben ein
 - ▶ Zeitscheibenablauf drückt den laufenden Prozess weiter nach unten
- ▶ je nach Ebene verschiedene Einreihungsstrategien und -parameter
 - ▶ unterste Ebene arbeitet nach RR, alle anderen (höheren) nach FCFS
 - ▶ die Zeitscheibengrößen nehmen von oben nach unten zu

Bestrafung (engl. *penalization*) von Prozessen mit langen CPU-Stößen

- ▶ Prozesse mit kurzen CPU-Stößen laufen relativ schnell durch
- ▶ Prozesse mit langen CPU-Stößen fallen nach unten durch
 - ▶ ggf. wird der Alterung entgegengewirkt: Prozesse wieder anheben

FB (Forts.)

Bestrafung lange laufender Prozesse und Bewährung lange wartender Prozesse



multilevel feedback queue (MLFQ)

Prioritäten setzende Verfahren

Statische Prioritäten (MLQ) vs. dynamische Prioritäten (VRR, SPN, SRTF, HRRN, FB)

Prozessvorrang bedeutet die bevorzugte Einlastung von Prozessen mit höherer Priorität und wird auf zwei Arten bestimmt:

statisch zum Zeitpunkt der **Prozesserzeugung** $\leadsto$ Laufzeitkonstante

- ▶ wird im weiteren Verlauf nicht mehr verändert
- ▶ erzwingt eine deterministische Ordnung zw. Prozessen

dynamisch zum Zeitpunkt der **Prozessausführung** $\leadsto$ Laufzeitvariable

- ▶ die Berechnung erfolgt durch das Betriebssystem
 - ▶ ggf. in Kooperation mit den Anwendungsprogrammen
- ▶ erzwingt keine deterministische Ordnung zw. Prozessen

Echtzeitverarbeitung bedingt Prioritäten setzende Verfahren

- ▶ jedoch nicht jedes solcher Verfahren eignet sich zum Echtzeitbetrieb
- ▶ Einplanung muss ein **deterministisches Laufzeitverhalten** liefern
 - ▶ entsprechend der jeweiligen Anforderungen der Anwendungsdomäne

Gegenüberstellung von Strategien und Verfahrensweisen

kooperativ/verdrängend vs. probabilistisch/deterministisch

	FCFS	RR	VRR	SPN	SRTF	HRRN	FB
kooperativ	✓			✓			
verdrängend		✓	✓		✓	✓	✓
probabilistisch				✓	✓	✓	
deterministisch		keine bzw. nicht von sich aus allein					

MLQ umfasst Eigenschaften der in dem Verfahren vereinten Strategien

- ▶ Priorisierung von Strategien liefert Nuancen im Laufzeitverhalten
- ▶ speziellen Anwendungsanforderungen (teilweise) entgegenkommen:
 - ▶ z.B. FCFS priorisieren $\leadsto$ „*number crunching*“ fördern

UNIX klassisch

Zweistufiges Verfahren, Antwortzeiten minimierend, Interaktivität fördernd

low-level kurzfristig; präemptiv, MLFQ, **dynamische Prozessprioritäten**

- ▶ einmal pro Sekunde: $prio = cpu_usage + p_nice + base$
- ▶ CPU-Nutzungsrecht mit jedem „Tick“ (1/10 s) verringert
 - ▶ Prioritätswert kontinuierlich um „Tickstand“ erhöhen
 - ▶ je höher der Wert, desto niedriger die Priorität
- ▶ über die Zeit gedämpftes CPU-Nutzungsmaß: cpu_usage
 - ▶ der Dämpfungsfaktor variiert von UNIX zu UNIX

high-level mittelfristig; mit **Umlagerung** arbeitend

Prozesse können relativ zügig den Betriebssystemkern verlassen

- ▶ gesteuert über die beim Schlafenlegen einstellbare **Aufweckpriorität**

UNIX 4.3 BSD

MLFQ (32 Warteschlangen, RR), dynamische Prioritäten (0–127)

Berechnung der **Benutzerpriorität** bei jedem vierten Tick (40 ms)

- ▶ $p_usrpri = PUSER + \left\lceil \frac{p_cpu}{4} \right\rceil + 2 \cdot p_nice$
 - ▶ mit $p_cpu = p_cpu + 1$ bei jedem Tick (10 ms)
 - ▶ **Gewichtungsfaktor** $-20 \leq p_nice \leq 20$ ➡ `nice(2)`
- ▶ Prozess mit Priorität P kommt in Warteschlange $P/4$

Glättung des Wertes der **Prozessornutzung** (p_cpu) jede Sekunde

- ▶ $p_cpu = \frac{2 \cdot load}{2 \cdot load + 1} \cdot p_cpu + p_nice$
- ▶ **Sonderfall**: Prozesse schliefen länger als eine Sekunde
 - ▶ $p_cpu = \left\lceil \frac{2 \cdot load}{2 \cdot load + 1} \right\rceil^{p_slptime} \cdot p_cpu$

UNIX 4.3 BSD (Forts.)

Glättung durch Dämpfungsfilter (engl. *decay filter*)

Annahme 1: ∅ Auslastung (*load*) sei 1 $\leadsto p_{cpu} = 0.66 \cdot p_{cpu} + p_{nice}$

Annahme 2: Prozess sammelt T_i Ticks im Zeitintervall i an, $p_{nice} = 0$:

$$\begin{aligned}
 p_{cpu} &= 0.66 \cdot T_0 \\
 &= 0.66 \cdot (T_1 + 0.66 \cdot T_0) = 0.66 \cdot T_1 + 0.44 \cdot T_0 \\
 &= 0.66 \cdot T_2 + 0.44 \cdot T_1 + 0.30 \cdot T_0 \\
 &= 0.66 \cdot T_3 + \dots + 0.20 \cdot T_0 \\
 &= 0.66 \cdot T_4 + \dots + 0.13 \cdot T_0
 \end{aligned}$$

☞ nach fünf Sekunden gehen nur noch etwa 13 % der „Altlast“ ein

UNIX Solaris

MLQ (4 Klassen) und MLFQ (60 Ebenen, Tabellensteuerung)

<i>quantum</i>	<i>tqexp</i>	<i>slprt</i>	<i>maxwait</i>	<i>lwait</i>	Ebene
200	0	50	0	50	0
200	0	50	0	50	1
...					
40	34	55	0	55	44
40	35	56	0	56	45
40	36	57	0	57	46
40	37	58	0	58	47
40	38	58	0	58	48
40	39	58	0	59	49
40	40	58	0	59	50
40	41	58	0	59	51
40	42	58	0	59	52
40	43	58	0	59	53
40	44	58	0	59	54
40	45	58	0	59	55
40	46	58	0	59	56
40	47	58	0	59	57
40	48	58	0	59	58
20	49	59	32000	59	59

/usr/sbin/dispatch -c TS -g

MLQ (Klasse)		Priorität
<i>time-sharing</i>	TS	0–59
<i>interactive</i>	IA	0–59
<i>system</i>	SYS	60–99
<i>real time</i>	RT	100–109

MLFQ in Klasse TS bzw. IA:

quantum Zeitscheibe (ms)
tqexp Ebene bei Bestrafung
slprt Ebene nach Deblockierung
maxwait ohne Bedienung (s)
lwait Ebene bei Bewährung

Besonderheit: *dispatch table* (TS, IA) kapselt sämtliche Entscheidungen

► kunden-/problemspezifische Lösungen durch verschiedene Tabellen

UNIX Solaris (Forts.)

Bestrafung vs. Bewährung nach Verdrängung

Beispiel:

- ▶ 1 × CPU-Stoß à 1000 ms
- ▶ 5 × E/A-Stoß → CPU-Stoß à 1 ms

#	Ebene	CPU-Stoß	Ereignis
1	59	20	Zeitscheibe
2	49	40	Zeitscheibe
3	39	80	Zeitscheibe
4	29	120	Zeitscheibe
5	19	160	Zeitscheibe
6	9	200	Zeitscheibe
7	0	200	Zeitscheibe
8	0	180	E/A-Stoß
9	50	1	E/A-Stoß
10	58	1	E/A-Stoß
11	58	1	E/A-Stoß
12	58	1	E/A-Stoß

Variante: nach 640 ms. . .

- ▶ der Prozess wird verdrängt und muss auf die erneute Einlastung warten
- ▶ der Alterung des wartenden Prozesses wird durch Anhebung seiner Priorität entgegengewirkt (*anti-aging*)
- ▶ die höhere Ebene erreicht, steigt der Prozess im weiteren Verlauf wieder ab

...			
7	0	20	<i>anti-aging</i>
8	50	40	Zeitscheibe
9	40	40	Zeitscheibe
10	30	80	Zeitscheibe
11	20	120	Zeitscheibe
12	10	80	E/A-Stoß
13	50	1	E/A-Stoß
...			

Linux 2.4

Epochen und Zeitquanten

Prozessen zugewiesene Prozessorzeit ist in **Epochen** unterteilt

beginnen alle lauffähige Prozess haben ihr Zeitquantum erhalten

enden alle lauffähigen Prozesse haben ihr Zeitquantum verbraucht

Zeitquanten (Zeitscheiben) variieren mit den Prozessen und Epochen

- ▶ jeder Prozess besitzt eine einstellbare **Zeitquantumbasis** (`nice(2)`)
 - ▶ 20 Ticks $\approx$ 210 ms
 - ▶ das Zeitquantum eines Prozesses nimmt periodisch (Tick) ab
- ▶ beide Werte addiert liefert die **dynamische Priorität** eines Prozesses
 - ▶ dynamische Anpassung: $quantum = quantum/2 + (20 - nice)/4 + 1$

Echtzeitprozesse (schwache EZ) besitzen **statische Prioritäten**: 1–99

Linux 2.4 (Forts.)

Einplanungsklassen und Gütefunktion

Prozesseinplanung unterscheidet zwischen drei *Scheduling-Klassen*:

FIFO	verdrängbare, kooperative Echtzeitprozesse	} eine Bereitliste
RR	Echtzeitprozesse derselben Priorität	
other	konventionelle („time-shared“) Prozesse	

Prozessauswahl greift auf eine *Gütefunktion* zurück:

☞ $O(n)$

$v = -1000$	der Prozess ist <i>Init</i>	—
$v = 0$	der Prozess hat sein Zeitquantum verbraucht	—
$0 < v < 1000$	der Prozess hat sein Zeitquantum nicht verbraucht	+
$v \geq 1000$	der Prozess ist ein Echtzeitprozess	++

Prozesse können bei der Auswahl einen *Bonus* („boost“) erhalten

- ▶ sofern sie sich mit dem Vorgänger den Adressraum teilen

Linux 2.5

Deterministische Prozesseinplanung: $O(1)$

Einplanung von Prozessen hat *konstante Berechnungskomplexität*:

Prioritätsfelder zwei Tabellen pro CPU: *active*, *expired*

Prioritätsebenen 140 Ebenen pro Tabelle

- ▶ 1–100 für Echtzeit-, 101–140 für sonstige Prozesse
- ▶ pro Ebene eine (doppelt verkettete) Bereitliste

Prioritäten gewöhnlicher Prozesse skalieren je nach *Interaktivitätsgrad*

- ▶ *Bonus* (–5) für interaktive Prozesse, *Strafe* (+5) für rechenintensive
- ▶ berechnet am Zeitscheibenende: $prio = MAX_RT_PRIO + nice + 20$

Ablauf des Zeitquantums befördert aktiven Prozess ins „*expired*“-Feld

- ▶ zum Epochenwechsel werden die Tabellen ausgetauscht
 - ▶ `void *aux = active; active = expired; expired = aux;`

Einplanung $\leadsto$ Einlastungsreihenfolge von Prozessen

Zuteilung von Betriebsmitteln an konkurrierende Prozesse

- ▶ Betriebssysteme treffen **Zuteilungsentscheidungen** auf drei Ebenen:
 - long-term scheduling* Lastkontrolle des Systems
 - medium-term scheduling* Umlagerung von Programmen
 - short-term scheduling* Einlastungsreihenfolge von Prozessen
- ▶ die Entscheidungskriterien haben verschiedene Dimensionen:
 - Benutzer** Antwort-/Durchlaufzeit, Termine, Vorhersagbarkeit
 - System** Durchsatz, Auslastung, Gerechtigkeit, Dringlichkeit, Lastausgleich
- ▶ Prozesseinplanung kennt z.T. sehr unterschiedlich **Verfahrensweisen**
 - ▶ kooperativ/verdrängend, deterministisch/probabilistisch
 - ▶ entkoppelt/gekoppelt, asymmetrisch/symmetrisch
- ▶ Dimension, Kriterium und Verfahrensweise $\leadsto$ **Einplanungsstrategien**
 - ▶ FCFS, RR, VRR, SPN, SRTF, HRRN, MLQ, FB (MLFQ)