Betriebssysteme I – Sommersemester 2009
Zusammenfassung

Hans-Georg Eßer
Hochschule München

07/2009

Gliederung

Betriebssysteme I

2. Prozesse und Threads
3. Interrupts
4. Scheduler
5. Synchronisation und Deadlocks
6. Speicherverwaltung und Dateisysteme

Prozesse

Prozess: Programm, das in den Speicher geladen wurde und ausgeführt wird / werden soll
Mehr als nur der Programmcode:
- Eigener Adressraum
- Stack, Stack-Pointer
- Programmzähler
- Umgebung
- Hardware-Register

Process Control Block (**PCB**):
- Identifier (PID)
- Registerwerte inkl. Befehlszähler
- Speicherbereich des Prozess
- Liste offener Dateien und Sockets
- Verwaltungsinformationen

Prozess-Zustände

- **laufend / running:** gerade aktiv
- **bereit / ready:** würde gerne laufen
- **blockiert / blocked / waiting:** wartet auf I/O

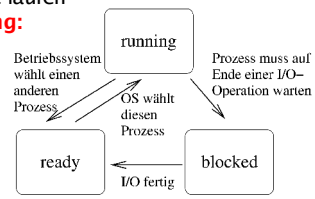

- **suspendiert:** vom Anwender unterbrochen
- **schlafend / sleeping:** wartet auf Signal (IPC)
- **ausgelagert / swapped:** Daten nicht im RAM

Prozess-Hierarchien / fork/exec

- Prozesse erzeugen einander
- Erzeuger heißt **Vaterprozess** (parent process), der andere **Kindprozess** (child process)
- Kinder sind selbständig (also: eigener Adressraum, etc.)
- Nach Prozess-Ende: Rückgabewert an Vaterprozess

Prozesse unter Linux/Unix:

fork (): dupliziert aktiven Prozess
- Vater erhält bei fork() die PID des Sohnes zurück
- Sohn erhält bei fork() den Wert 0 zurück

exec (): fremdes Programm in laufenden Prozess laden
- überschreibt aktuellen Code
- exec () kehrt darum nie zurück

wait (): auf einen Sohnprozess warten

Threads

- einer von mehreren Aktivitätsstrangen in einem Prozess
- Gemeinsamer Zugriff auf Daten des Prozess (kein eigener Speicher)
- aber: Stack, Befehlszähler, Stack, Stack Pointer, Hardware-Register separat pro Thread
- Multi-Prozessor-System: Mehrere Threads echt gleichzeitig aktiv
- Ist ein Thread durch I/O blockiert, arbeiten die anderen weiter (nur bei Kernel Level Threads)
- Besteht Programm logisch aus parallelen Abläufen, ist die Programmierung mit Threads einfacher

User-Level- vs. Kernel-Level-Threads

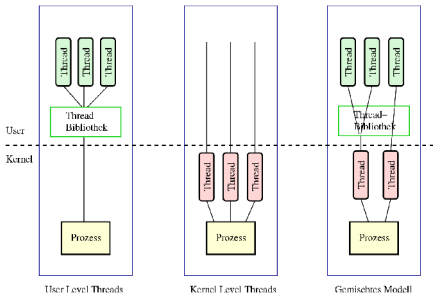

Thread-Zustände

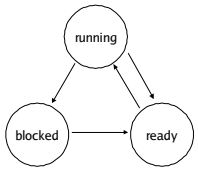

Prozess-Zustände suspended, sleeping, swapped etc. nicht auf Threads übertragbar

Interrupts

- **Effizienz** (I/O-Zugriff sehr langsam ➞ sehr lange Wartezeiten, wenn Prozesse warten, bis I/O abgeschlossen ist)
- **Programmierlogik** (Nicht immer wieder Gerätestatus abfragen, sondern abwarten, bis passender Interrupt kommt)
- **Kein Polling**
  (Polling: BS fragt regelmäßig bei allen Geräten nach, ob ein Ereignis stattgefunden hat)

Interrupts

Mehrfach-Interrupts

- Während Abarbeitung eines Interrupts alle weiteren ausschließen (DI, disable interrupts) ➞ Interrupt-Warteschlange
- Während Abarbeitung beliebige Interrupts zulassen
- Interrupt-Prioritäten: Nur Interrupts mit höherer Priorität unterbrechen solche mit niedrigerer

Multitasking und Interrupts

- Multitasking verbessert CPU-Nutzung:
  - I/O-lastiger Prozess wartet auf I/O-Events,
  - CPU-lastiger Prozess rechnet weiter
- Prozess stößt I/O-Operation an und legt sich schlafen (wartet auf Signal)

Linux-Interrupt-Handler

Für jedes Gerät:

- Interrupt Request (IRQ) Line
- Interrupt Handler (Interrupt Service Routine, ISR) ➞ Teil des Gerätetreibers
- läuft in speziellem Context (Interrupt Context)

top half

- Interrupt Handler startet sofort, erledigt zeitkritische Dinge
- bestätigt (der Hardware) den Erhalt des Interrupts, setzt Gerät zurück etc.

bottom half / Tasklet

- startet später, macht die eigentliche Arbeit
- kein Prozess (struct tasklet_struct), läuft direkt im Kernel; im Interrupt-Context
- Zwei Prioritäten: *tasklet_hi_schedule*, *tasklet_schedule*

Scheduler

- Rechenzeit (CPU) an Prozesse verteilen

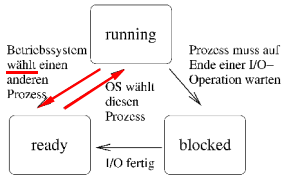

- Scheduling-Prinzipien: **präemptiv** vs. **kooperativ**
- Scheduling-Verfahren:
  - FIFO, Shortest Job First
  - Shortest Remaining Time, Round Robin, Priority, Lottery

Scheduler

- **Kooperatives Scheduling:**
  - Prozess rechnet bis zum nächsten I/O-Aufruf oder `exit()`
  - Scheduler wird nur bei Prozess-Blockieren oder freiwilliger CPU-Aufgabe aktiv
- **Präemptives (unterbrechendes) Scheduling:**
  - Timer aktiviert regelmäßig Scheduler, der neu entscheiden kann, „wo es weiter geht“

- **I/O-lastig:** Prozess hat zwischen I/O-Phasen nur kurze Berechnungsphasen (CPU)
- **CPU-lastig:** Prozess hat zwischen I/O-Phasen lange Berechnungsphasen

Scheduling-Ziele

- **[A1] Ausführdauer:** Wie lange läuft der Prozess insgesamt?
- **[A2] Reaktionszeit:** Wie schnell reagiert der Prozess auf Benutzerinteraktion?
- **[A3] Deadlines** einhalten
- **[A4] Vorhersehbarkeit:** Gleichartige Prozesse sollten sich auch gleichartig verhalten, was obige Punkte angeht
- **[A5] Proportionalität:** „Einfaches" geht schnell
- **[S1] Durchsatz:** Anzahl der Prozesse, die pro Zeit fertig werden
- **[S2] Prozessorauslastung:** Zeit, die der Prozessor aktiv war
- **[S3] Fairness:** Prozesse gleich behandeln, keiner darf „verhungern"
- **[S4] Prioritäten** beachten
- **[S5] Ressourcen** gleichmäßig einsetzen

Anforderungen an Betriebssystem

Stapelverarbeitung

- S3 Fairness
- S4 Prioritäteneinsatz
- S5 Ressourcen-Balance
- S1 Durchsatz
- A1 Ausführdauer
- S2 Prozessor-Auslastung

Interaktives System

- S3 Fairness
- S4 Prioritäteneinsatz
- S5 Ressourcen-Balance
- A2 Reaktionszeit
- A5 Proportionalität

Scheduler für Batch-Betrieb

- Kein interaktiver Betrieb (kein Login etc.)
- Job-Management-Tool nimmt Jobs an
- Long term scheduler entscheidet, wann ein Job gestartet wird – evtl. basierend auf Informationen über Ressourcenverbrauch und erwartete Laufzeit des Programms

Scheduling-Verfahren für Batch-Betrieb

- First Come, First Served (FCFS)
- Shortest Job First (SJF)
- Shortest Remaining Time (SRT)
- Priority Scheduling

Scheduler für Batch-Betrieb

First Come, First Served (FCFS)
- Warteschlange, kooperativ (keine Unterbrechung)
- Blockierende Prozesse stellen sich wieder in Warteschlange an
- gut für lange Prozesse, schlecht für I/O-lastige Prozesse

Shortest Job First (SJF)
- kooperativ
- nächster Burst (Rechendauer bis zum Blockieren) muss bekannt sein (woher? Burst-Prognose-Verfahren);
  Prozess mit dem kürzesten Burst auswählen
- minimiert durchschnittliche Laufzeit über alle Prozesse

Shortest Remaining Job Next (SRJ)
- ähnlich SJF, aber *mit* Unterbrechungen
- Scheduler prüft Reihenfolge bei neuen Jobs
- Prozess mit kürzerer Restlaufzeit unterbricht den laufenden

Scheduler für interaktive Systeme

- Typisch: Interaktive und Hintergrund-Prozesse
- Desktop- und Server-PCs
- Eventuell mehrere / zahlreiche Benutzer, die sich die Rechenkapazität teilen
- Scheduler für interaktive Systeme prinzipiell auch für Batch-Systeme brauchbar (aber nicht umgekehrt)

Scheduling-Verfahren für interaktive Systeme

- Round Robin (RR)
- Virtual Round Robin (VRR)
- Prioritäten-Scheduler
- Lotterie-Scheduler

Scheduler für interaktive Systeme

Round Robin / Time-Slicing
- wie FCFS, aber mit Unterbrechung
- jeder Prozess erhält Zeitscheibe (Quantum)
- läuft der Prozess bei Ablauf noch ➞ unterbrechen
- zum Quantum:
  - groß ➞ Verzögerungen; klein ➞ häufige Context Switches
  - oft: etwas größer als typische Zeit, die für Interaktion nötig ist
- bevorzugt CPU-lastige Prozesse (I/O-lastige brauchen immer nur Teil ihres Quantums)

Virtual Round Robin
- Round Robin, aber: I/O-lastigen Pr. helfen ➞ „Restguthaben"
- hat Prozess Quantum nicht verbraucht?
  ➞ merken und Prozess in Extra-Queue stecken
- Scheduler bevorzugt Prozesse in Extra-Queue und lässt sie ihr Restguthaben aufbrauchen

Scheduler für interaktive Systeme

Prioritäten-Scheduler

- Prioritätsklassen oder individuelle Prioritätswerte
- Scheduler bevorzugt Prozesse mit hoher Priorität
- Prior. statisch vergeben oder dynamisch regelmäßig neu ber.
- Vorsicht: **Prioritätsinversion** (Ausweg: **Aging**)
- Variante: Verschiedene Quantenlängen (hohe Priorität: kleines Quantum; dynamisch anpassen)

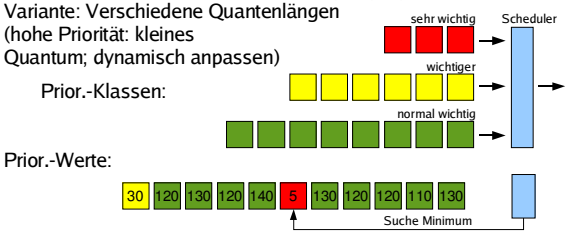

Scheduler für interaktive Systeme

Lotterie-Scheduler

- Prozesse besitzen Lose, Scheduler zieht ein Los
- Prioritäten: über Anzahl der Lose, die ein Prozess besitzt
- Gruppenbildung / Kooperation: Prozesse können einander Lose überlassen (etwa ein Client einem Server)

Kritische Abschnitte

- Programmteil, der auf gemeinsame Daten zugreift
- Nicht „den Code schützen“, sondern die Daten
- Formulierung: kritischen Bereich „betreten“ und „verlassen“
- Anforderung an parallele Threads:
  - maximal ein Thread gleichzeitig im kritischen Abschnitt
  - Kein Thread, der außerhalb kritischer Bereiche ist, darf einen anderen blockieren
  - Kein Thread soll ewig auf Betreten des kritischen Bereichs warten
  - Deadlocks vermeiden (z. B.: zwei Prozesse sind in verschiedenen krit. Bereichen und blockieren sich gegenseitig)

Gegenseitiger Ausschluss

- Tritt nie mehr als ein Thread gleichzeitig in den kritischen Bereich ein, heißt das „**gegenseitiger Ausschluss**“ (englisch: **mut**ual **ex**clusion)
- Es ist Aufgabe der Programmierer, diese Bedingung zu garantieren
- Das Betriebssystem bietet Hilfsmittel („Synchronisationswerkzeuge), mit denen gegenseitiger Ausschluss durchgesetzt werden kann, schützt aber nicht vor Programmierfehlern

Aktives und passives Warten

- **Aktives Warten** (busy waiting):
  - Ausführen einer Schleife, bis eine Variable einen bestimmten Wert annimmt.
  - Der Thread ist bereit und belegt die CPU.
  - Die Variable muss von einem anderen Thread gesetzt werden.
- **Passives Warten** (sleep and wake):
  - Ein Thread blockiert und wartet auf ein Ereignis, das ihn wieder in den Zustand „bereit“ versetzt.
  - Der blockierte Thread verschwendet keine CPU-Zeit.
  - Ein anderer Thread muss das Eintreten des Ereignisses bewirken. ➞ (kleines) Problem, wenn der andere Thread endet.
  - Bei Eintreten des Ereignisses muss der blockierte Thread geweckt werden, z. B. durch anderen Thread oder durch OS.

Erzeuger-Verbraucher-Problem

Erzeuger-Verbraucher-Problem (producer consumer problem, bounded buffer problem): zwei kooperierende Threads

- Erzeuger speichert Informationen in einem beschränkten Puffer.
- Verbraucher liest Informationen aus diesem Puffer.

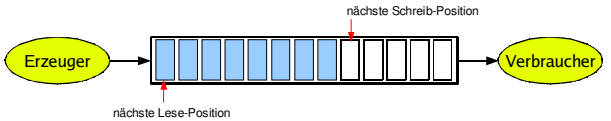

Synchronisation:

- Puffer nicht überfüllen
- Nicht aus leerem Puffer lesen

Semaphore

Semaphor: Integer- (Zähler-) Variable

- festgelegter Anfangswert N („Anzahl der verfügbaren Ressourcen“).
- Anfordern eines Semaphors (**Wait**-Operation):
  - Semaphor-Wert um 1 erniedrigen, falls er positiv ist,
  - Thread blockieren und in eine Warteschlange einreihen, wenn der Semaphor-Wert 0 ist.
- Freigabe eines Semaphors (**Signal**-Operation):
  - einen Thread aus Warteschlange wecken, falls diese nicht leer ist,
  - Semaphor-Wert um 1 erhöhen (wenn kein Thread wartet)
- Code sieht dann immer so aus:

```
wait (&sem);
/* Code, der die Ressource nutzt */
signal (&sem);
```


Mutexe

- **Mutex:** boolesche Variable (true/false), die den Zugriff auf gemein-sam genutzte Daten synchronisiert (true: erlaubt; false: verboten)
- **blockierend:** Ein Thread, der sich Zugang verschaffen will, während ein anderer Thread Zugang hat, blockiert ➡ Warteschlange
- Bei Freigabe: – Warteschlange enthält Threads ➡ einen wecken
  – Warteschlange leer ➡ Mutex auf true setzen
- **Mutex** (**mut**ual **ex**clusion) = **binärer Semaphor**, also ein Semaphor, der nur die Werte 0 / 1 annehmen kann

```
wait (mutex) {
  if (mutex==1)
    mutex=0;
    else BLOCK_CALLER;
}
```

```
signal (mutex) {
  if (P in QUEUE(mutex)) {
    wakeup (P);
    remove (P, QUEUE);
  }
  else mutex=1;
}
```

- Neue Interpretation: wait ➡ lock, signal ➡ unlock
- Mutexe für exklusiven Zugriff auf kritische Bereiche

Philosophenproblem

- Fünf Philosophen an einem Tisch (Dijkstra 1965)
  - je Philosoph ein Teller Spaghetti.
  - zwischen je zwei Tellern eine Gabel.
  - Jeder Philosoph wechselt ab zwischen Denken und Essen.
  - Zum Essen benötigt ein Philosoph die beiden Gabeln rechts und links von seinem Teller.

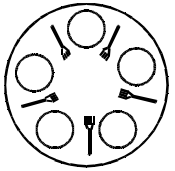

- Ziel: Philosophen nicht verhungern lassen und maximale Parallelität

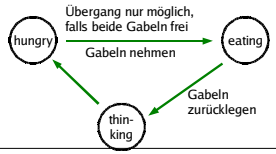

Monitore (1)

Motivation

- Arbeit mit Semaphoren und Mutexen zwingt den Programmierer, vor und nach jedem kritischen Bereich wait() und signal() aufzurufen
- Wird dies ein einziges Mal vergessen, funktioniert die Synchronisation nicht mehr
- **Monitor** kapselt die kritischen Bereiche

Monitor: Sammlung von Prozeduren, Variablen, speziellen Bedingungsvariablen und Datenstrukturen:

- Prozesse können die Prozeduren des Monitors aufrufen, können aber nicht von außerhalb des Monitors auf dessen Datenstrukturen zugreifen.
- Zu jedem Zeitpunkt kann nur ein einziger Prozess aktiv im Monitor sein (d. h.: eine Monitor-Prozedur ausführen).
- Monitor wird durch Verlassen der Monitorprozedur frei gegeben

Monitore (2)

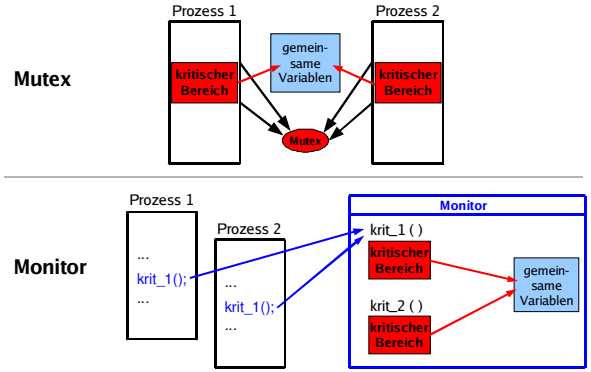

Monitore (3)

- Monitor-Konzept erinnert an Klassen oder Module
- Kapselung der Prozeduren und Variablen (außer über als public deklarierte Prozeduren kein Zugriff auf Monitor)
- Einfaches und übersichtliches Verfahren, um kritische Bereiche zu schützen, aber:
- Busy waiting ➡ Schlafen/Wecken wäre besser

Zustandsvariablen (condition variables)

Für jede Zustandsvariable Wait- und Signal-Funktionen:

- m_wait (var): aufrufenden Prozess sperren (er gibt den Monitor frei)
- m_signal (var): gesperrten Prozess entsperren (weckt einen Prozess, der den Monitor mit m_wait() verlassen hat); erfolgt unmittelbar vor Verlassen des Monitors

Monitore (4)

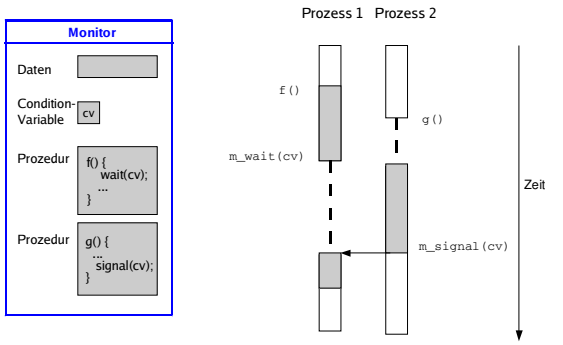

Locking

Locking erweitert die Funktionalität von Mutexen, indem es verschiedene Lock-Modi (Zugriffsarten) unterscheidet, und deren „Verträglichkeit“ miteinander festlegt:

- Concurrent Read: Lesezugriff, andere Schreiber erlaubt.
- Concurrent Write: Schreibzugriff, andere Schreiber erlaubt.
- Protected Read: Lesezugriff, andere Leser erlaubt, aber keine Schreiber (share lock)
- Protected Write: Schreibzugriff, andere Leser erlaubt, aber kein weiterer Schreiber (update lock)
- Exclusive: Schreibzugriff, keine anderen Zugriffe erlaubt

Synchronisation im Linux-Kernel

- **Spin Locks / Reader-Writer Spin Locks**
- **Semaphore / Reader-Writer-Semaphore**

Spin Locks (1)

- Lock mit Mutex-Funktion: Gegenseitiger Ausschluss
- Code, der ein Spin Lock anfordert und nicht erhält, läuft in Schleife weiter, bis das Lock verfügbar wird („spinning“)
- Typ: *spinlock_t*

```
spinlock_t xy_lock = SPIN_LOCK_UNLOCKED

spin_lock (&xy_lock);
/* kritischer Abschnitt */
spin_unlock (&xy_lock);
```

- Da Spin Locks nicht schlafen, kann man sie in Interrupt-Handlern verwenden

Spin Locks (2)

- Ggf. zusätzlich Interrupts sperren:

```
unsigned long flags;
spin_lock_irqsave (&xy_lock, flags);
/* kritischer Abschnitt */
spin_unlock_irqrestore (&xy_lock, flags);
```

(Interrupts sichern, dann sperren; urspr. Zustand wiederherstellen)

- Wenn zu Beginn alle Interrupts aktiviert sind, geht es auch einfacher:

```
spin_lock_irq (&xy_lock);
/* kritischer Abschnitt */
spin_unlock_irq (&xy_lock);
```

- Spin Locks sind nicht „rekursiv“, d.h.: es ist nicht möglich, das gleiche Spin Lock zweimal nacheinander anzufordern, etwa beim rekursiven Aufruf einer Funktion
- Alternative zu Spin Locks: Reader Writer Locks

Kernel-Semaphore

- Kernel-Semaphore: „schlafende“ Locks, mit Warteschlange
- Geeignet für Sperren, die über einen längeren Zeitraum gehalten werden: keine Verschwendung von Rechenzeit
- Semaphore sind nur im Prozess-Kontext einsetzbar, nicht in Interrupt-Handlern (Interrupt-Handler dürfen nicht schlafen)
- Code, der einen Semaphor verwenden will, darf nicht bereits ein normales Spin Lock besitzen (Semaphor-Zugriff kann dazu führen, dass der Thread sich schlafen legt.)
- Verwendung mit *up()* und *down()*

```
down (&sem);
/* kritischer Abschnitt */
up (&sem);
```

- Varianten von *down()*
  - *down (&sem);*
  - *down_interruptible (&sem);*
  - *down_trylock (&sem);*

Deadlocks: kleinstes Beispiel

Prozess P

```
lock (A);
lock (B);
/* krit. Ber. */
unlock (A);
unlock (B);
```

Prozess Q

```
lock (B);
lock (A);
/* krit. Ber. */
unlock (B);
unlock (A);
```

Problematische Reihenfolge:

P: lock(A)
Q: lock(B)
P: lock(B) <- blockiert
Q: lock(A) <- blockiert

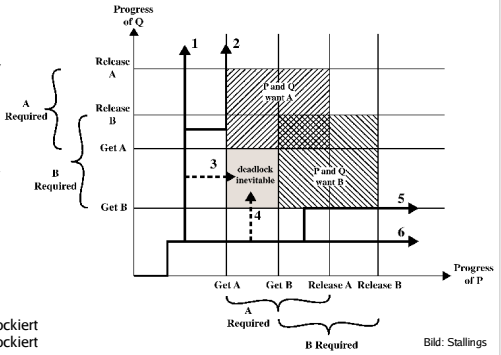

Bild: Stallings

4 Deadlock-Bedingungen

1. **Gegenseitiger Ausschluss (mutual exclusion)**
2. **Hold and Wait (besitzen und warten)**
   Ein Prozess ist bereits im Besitz einer oder mehrerer Ressourcen, und er kann noch weitere anfordern
1. **Ununterbrechbarkeit der Ressourcen**
   Ressource kann nicht durch das Betriebssystem entzogen werden
4. **Zyklisches Warten**
   Man kann die Prozesse in einem Kreis anordnen, in dem jeder Prozess eine Ressource benötigt, die der folgende Prozess belegt hat

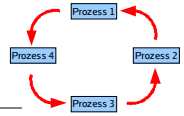

- (1) bis (4) sind **notwendige und hinreichende** Bedingungen für einen Deadlock (Äquivalenz)
- (4) ist der erfolgversprechendste Ansatzpunkt, um Deadlocks aus dem Weg zu gehen

Ressourcen-Zuordnungs-Graph (1)

- Belegung und (noch unerfüllte) Anforderung grafisch darstellen:

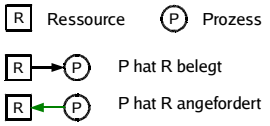

- P, Q aus Minimalbeispiel

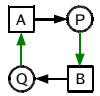

- Deadlock = Kreis im Graph

- Variante für Ressourcen, die mehrfach vorkommen können

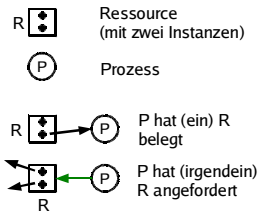

  - Kreis nur notwendig für Deadlock

Deadlock-Erkennung (1)

- Idee: Deadlocks zunächst zulassen
- System regelmäßig auf Vorhandensein von Deadlocks überprüfen
- Beispiel:

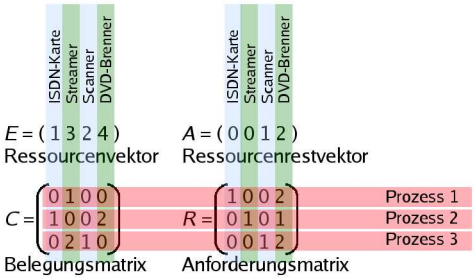

Deadlock-Erkennung (2)

Algorithmus

1. Suche einen unmarkierten Prozess P_i, dessen verbleibende Anforderungen vollständig erfüllbar sind, also $R_{ij} \leq A_j$ für alle j
2. Gibt es keinen solchen Prozess, beende den Algorithmus
3. Ein solcher Prozess könnte erfolgreich abgearbeitet werden. Simuliere die Rückgabe aller belegten Ressourcen: $A := A+C_i$ (i-te Zeile von C)
   Markiere den Prozess – er ist nicht Teil eines Deadlocks
4. Weiter mit Schritt 1

Deadlock-Behebung

Entziehen einer Ressource?
In den Fällen, die wir betrachten, unmöglich (ununterbrechbare Ressourcen)

Abbruch eines Prozesses, der am Deadlock beteiligt ist

Rücksetzen eines Prozesses in einen früheren Prozesszustand, zu dem die Ressource noch nicht gehalten wurde (erfordert regelmäßiges Sichern der Prozesszustände)

Deadlock-Vermeidung (1)

Deadlock Avoidance (Vermeidung)

- **Idee:** BS erfüllt Ressourcenanforderung nur dann, wenn dadurch auf keinen Fall ein Deadlock entstehen kann
- Das funktioniert nur, wenn man die **Maximalforderungen aller Prozesse** kennt
  - Prozesse registrieren **beim Start** für alle denkbaren Ressourcen ihren Maximalbedarf
  - für die Praxis i. d. R. irrelevant, nur in wenigen Spezialfällen nützlich

Sichere vs. unsichere Zustände

- Ein Zustand heißt **sicher**, wenn es eine Ausführreihenfolge der Prozesse gibt, die auch dann keinen Deadlock verursacht, wenn alle Prozesse sofort ihre maximalen Ressourcen-forderungen stellen.
- Ein Zustand heißt **unsicher**, wenn er nicht sicher ist.
- Unsicher bedeutet nicht zwangsläufig Deadlock!

Deadlock-Vermeidung (2)

Banker-Algorithmus

- Datenstrukturen wie bei Deadlock-Erkennung:
  - n Prozesse P_1 ... P_n, m Ressourcentypen R_1 ... R_m mit je E_i Ressourcen-Instanzen (i=1,...,m) → **Ressourcenvektor** $E = (E_1 \ldots E_m)$
  - **Ressourcenrestvektor** A (wie viele sind noch frei?)
  - **Belegungsmatrix** C
    C_{ij} = Anzahl Ressourcen vom Typ j, die Prozess i belegt
  - **Maximalbelegung** Max:
    Max_{ij} = max. Bedarf, den Prozess i an Ressource j hat
  - **Maximale zukünftige Anforderungen:** $R = Max - C$,
    R_{ij} = # Ress. vom Typ j, die Prozess i noch maximal anfordern kann

Feststellen, ob ein Zustand sicher ist = Annehmen, dass alle Prozesse sofort ihre Maximalforderungen stellen, und dies auf Deadlocks überprüfen

Deadlock-Verhinderung (1)

Deadlock-Verhinderung (prevention):
Vorbeugendes Verhindern

- mache mindestens eine der vier Deadlock-Bedingungen unerfüllbar, dann sind keine Deadlocks mehr möglich (denn die vier Bedingungen sind notwendig)

1. Gegenseitiger Ausschluss

- Ressourcen nur exklusiv zuteilen, wenn es keine Alternative gibt
- Beispiel: Statt mehrerer konkurrierender Prozesse, die einen gemeinsamen Drucker verwenden wollen, einen Drucker-Spooler einführen
  - keine Konflikte mehr bei Zugriff auf Drucker
  - aber: Problem evtl. nur verschoben (Größe des Spool-Bereichs bei vielen Druckjobs begrenzt?)

Deadlock-Verhinderung (2)

2. Hold and Wait

- Alle Prozesse müssen die benötigten Ressourcen gleich beim Prozessstart anfordern (und blockieren)
- hat verschiedene Nachteile:
  - Ressourcen-Bedarf entsteht oft dynamisch (ist also beim Start des Prozesses nicht bekannt)
  - verschlechtert Parallelität (Prozess hält Ressourcen über einen längeren Zeitraum)

3. Ununterbrechbarkeit der Ressourcen

- Ressourcen entziehen?
- siehe Deadlock-Behebung (Abbruch / Rücksetzen)

Deadlock-Verhinderung (3)

4. Zyklisches Warten (1)

- Ressourcen durchnumerieren
  - *ord*: $\mathbf{R} = \{R_1, ..., R_n\} \rightarrow \mathbb{N}$, $ord(R_i) \neq ord(R_j)$ für $i \neq j$
- Prozess darf Ressourcen nur in der durch *ord* vorgegebenen Reihenfolge anfordern
- Das macht Deadlocks unmöglich. (Widerspruchsbeweis)

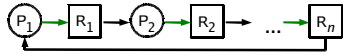

- Problem: Gibt es eine feste Reihenfolge der Ressourcenbelegung, die für alle Prozesse geeignet ist?
- reduziert Parallelität (Ressourcen zu früh belegt)

Allgemeine Konzepte (1/2)

- Zusammenhängende vs. nicht zusammenhängende Allokation
  - Partitionen fester / einheitlicher Größe
  - Part. fester / verschiedener Größe
  - Part. mit dynamischer Größe
- Fragmentierung: intern / extern
- Verwaltung freier Bereiche
  - Bit Maps / Linked Lists

Allgemeine Konzepte (2/2)

- Zuteilung freien Speichers
  - First-Fit, Best-Fit, Worst-Fit, Quick-Fit
  - Buddy System, mit Baum-Repräsentation
- Besonderes beim Speicher:
  - Code-Verschiebung
  - Speicherschutz

Virtuelle Speicherverwaltung (Paging)

- Aufteilung des Adressraums in Seiten (pages) fester Größe und des Hauptspeichers in Seitenrahmen (page frames) gleicher Größe.
- Der lineare, zusammenhängende Adressraum eines Prozesses („virtueller" Adressraum) wird auf beliebige, nicht zusammenhängende Seitenrahmen abgebildet.
- Eine einzige Liste freier Seitenrahmen verwalten
- Berechnung der physikalischen Speicheradresse aus der vom Programm angegebenen virtuellen Adresse
  - zur Laufzeit des Programms, transparent für das Programm,
  - muss von der Hardware unterstützt werden.
- Vorteile der virtuellen Speicherverwaltung:
  - Einfache Zuteilung von Hauptspeicher.
  - Keine externe Fragmentierung, geringe interne Fragmentierung.
  - Kein Aufwand für den Programmierer.

Virtueller Adressraum

- Beim Paging wird der Zusammenhang zwischen Programmadresse und physikalischer Hauptspeicheradresse erst zur Laufzeit mit Hilfe der Seitentabellen hergestellt.

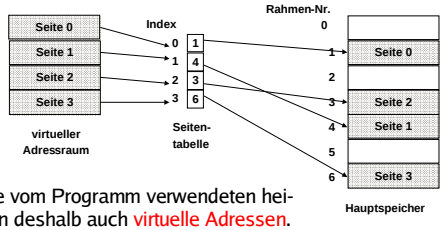

- Die vom Programm verwendeten hei-ßen deshalb auch virtuelle Adressen.
- Der virtuelle Adressraum eines Programms ist der lineare, zusammenhängende Adressraum, der dem Programm zur Verfügung steht.

Adressübersetzung beim Paging (1)

- Programmadresse in zwei Teile aufteilen:
  Seitennummer + relative Adresse (Offset) in der Seite
  Beispiel: 32-bit-Adresse bei einer Seitengröße von 4 KB, also 4096 (=2^12) Byte:

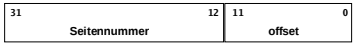

- Für jeden Prozess gibt es eine Seitentabelle (page table). Diese enthält für jede Prozess-Seite
  - eine Angabe, ob die Seite im Speicher ist,
  - die Nummer des Seitenrahmens im Hauptspeicher, der die Seite enthält.
- Ein spezielles Register enthält die Anfangsadresse der Seitentabelle für den aktuellen Prozess.
- Seitennummer als Index in die Seitentabelle verwenden.

Adressübersetzung beim Paging (2)

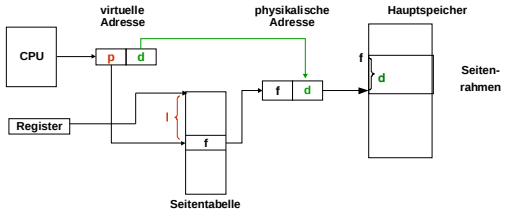

- Für jeden Hauptspeicherzugriff wird ein zusätzlicher Hauptspeicherzugriff auf die Seitentabelle benötigt. Dies muss durch Caches in der Hardware beschleunigt werden!
- Seite nicht im Speicher -> page fault (Seitenfehler) auslösen.

Aufgabenbeispiel

Paging mit folgenden Parametern:
- 32-Bit-Adressbus
- 32 KB Seitengröße
- 64 MB RAM

Zu berechnen:
a) maximale Anzahl der adressierbaren virtuellen Seiten
b) Größe der erforderlichen Seitentabelle (in MB)

a) 32 KB (Seitengröße) = 2^5 x 2^{10} Byte = 2^{15} Byte
d.h.: Offset ist 15 Bit lang

Also gibt es 2^{17} virtuelle Seiten

b) Zur Seitentabelle:
In 64 MB RAM passen 64 M / 32 K = 2 K = 2048 (2^{11}) Seitenrahmen
Ein Eintrag in der Seitentabelle benötigt darum 11 Bit, in der Praxis 2 Byte.

=> Platzbedarf:
#(virt. Seiten) x Größe(Eintrag)
= 2^{17} x 2 Byte = 2^{18} Byte = 256 KB = ¼ MB

Virtueller Speicher allgemein (1)

- Mehr Prozesse können effektiv im Speicher gehalten werden
  ➞ bessere Systemauslastung
- Ein Prozess kann viel mehr Speicher anfordern als physikalisch verfügbar
- allgemeiner Vorgang:
  - Nur Teile des Prozesses befinden sich im physikalischen Speicher
  - falls Zugriff auf eine Adresse, die ausgelagert ist:
    - BS setzt den Prozess auf blockiert
    - BS setzt eine Disk-I/O-Leseanfrage ab
    - Nach Laden des fehlenden Stücks (Seite oder Segment) wird ein I/O-Interrupt abgesetzt
    - BS setzt Prozess zuletzt wieder in den Bereit-Zustand

Virtueller Speicher allgemein (2)

- „*thrashing*“ (siehe später): Prozessor verbringt die meiste Zeit mit Ein- und Auslagern von Prozessteilen statt mit der Ausführung von Prozessanweisungen

- Lokalitätsprinzip:
  - Zugriffe auf Daten und Programmcode häufig lokal gruppiert;
    ➞ Annahme gerechtfertigt, dass nur wenige Prozess-stücke während einer kurzen zeitlichen Periode gleichzeitig vorgehalten werden müssen

Translation Look-Aside Buffer

- Translation Lookaside Buffer (TLB): schneller Hardware-Cache, mit den zuletzt benutzten Seitentabelleneinträgen
- Treffer im TLB ➞ Speicherzugriff auf Seitentabelle unnötig
- Fehltreffer ➞ Zugriff auf die Seitentabelle (Alten Eintrag im TLB durch neuen ersetzen)
- Trefferquote (hit ratio) beeinflusst die durch-schnittliche Zeit einer Adressübersetzung.
- Lokalitätsprinzip ➞ auch bei kleinen TLBs hohe Trefferquoten
- Inhalt des TLB ist prozessspezifisch! Zwei Möglichkeiten:
  - Jeder Eintrag im TLB hat „valid bit". Bei Prozesswechsel (Context Switch) gesamten TLB invalidieren.
  - Jeder Eintrag im TLB enthält Prozessidentifikation (PID), die mit der PID des zugreifenden Prozesses verglichen wird.

Invertierte Seitentabellen

- Bei großem virtuellen Speicher sehr viele Einträge in der Seitentabelle nötig, z.B. 2^{32} Byte Adressraum, 4 Kbyte/Seite
  ➞ über 1 Mio. Seiteneinträge, also Tabelle >4 MByte (je Prozess)
- Platz sparen durch invertierte Seitentabellen:
  - normal: ein Eintrag pro (virtueller) Seite mit Verweis auf den Seitenrahmen (im Hauptspeicher)
  - invertiert: ein Eintrag pro Seiten*rahmen* mit Verweis auf Tupel (Prozess-ID, virtuelle Seite)
- Problem: Suche zu Prozess *p* und seiner Seite *n* nach dem Eintrag (*p*,*n*) in der invertierten Tabelle ➞ langwierig
- Auch hier TLB einsetzen, um auf „meist genutzte" Seiten schnell zugreifen zu können
- Bei TLB-Miss hilft aber nichts: Suchen...
- Andere Lösung für Problem der großen Seitentabellen: Mehrstufiges Paging

Mehrstufiges Paging (1)

- Zweistufiges Paging:
  - Seitennummer noch einmal unterteilen, z. B.:

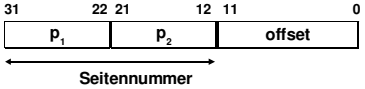

  - p_1: Index in äußere Seitentabelle, deren Einträge jeweils auf eine innere Seitentabelle zeigen
  - p_2: Index in eine der inneren Seitentabellen, deren Einträge auf Seitenrahmen im Speicher zeigen
  - Die inneren Seitentabellen müssen nicht alle speicherresident sein
- Analog dreistufiges Paging etc. implementieren

Mehrstufiges Paging (2)

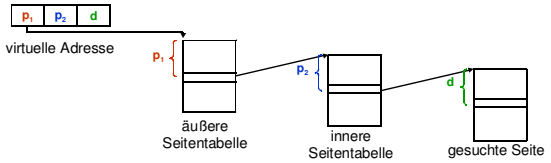

- Größe der Seitentabellen:
  Beispiel:

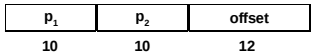

  - Äußere Tabelle: 1024 (2^{10}) Einträge, die auf (bis zu) 1024 innere Tabellen zeigen, die wieder je 1024 Einträge haben.
  - 4 Byte pro Tabelleneintrag ➞ Größe der Tabelle = 1 Seite
  - nur so viele innere Seitentabellen verwenden, wie nötig.

Demand Paging

- Der Adressbereich eines Prozesses muss nicht vollständig im Hauptspeicher sein.
  - **Lokalitätsprinzip:** Prozess spricht in einer Zeitspanne nur relativ wenige, nahe beieinanderliegende Adressen an.
  - Teile des Programms werden bei einem bestimmten Ablauf evtl. nicht benötigt (Spezialfälle, Fehlerbehandlung etc.).
- Demand Paging bedeutet
  - dass eine Seite nur dann in den Speicher geladen wird, wenn der Prozess sie anspricht,
  - Seite kann auch wieder aus dem Speicher entfernt werden
- Vorteile von Demand Paging:
  - Der Adressbereich eines Prozesses kann größer sein als der physikalische Hauptspeicher.
  - Prozesse belegen weniger Platz im Hauptspeicher, somit können mehr Prozesse gleichzeitig aktiv sein.

Seitenersetzung

- Wenn bei einem Page Fault kein freier Seitenrahmen zur Verfügung steht, muss das Betriebssystem einen frei machen.
- Algorithmus wählt nach einer Strategie diesen Rahmen aus.
- Falls die zu ersetzende Seite, seit sie zuletzt (aus dem Swap) in den Speicher geholt wurde, verändert wurde, muss ihr aktueller Inhalt gesichert werden:
  - Ein modify bit (dirty bit) vermerkt, ob Seite verändert wurde.
  - veränderte Seite auf Platte sichern (Page-/Swap-Bereich).
- Eine unveränderte Seite kann später - bei Bedarf - wieder von der alten Stelle auf der Platte geladen werden.
- Im Seitentabelleneintrag für die ersetzte Seite valid bit löschen und merken, von wo die Seite wieder geladen werden kann.
- Seitenersetzungsstrategien: So wenig page faults wie möglich
- Lokale vs. globale Ersetzung

Optimale Strategie / FIFO

Optimale Strategie: Diejenige Seite ersetzen, auf die in Zukunft am längsten nicht zugegriffen wird.

- Vorteil: Diese Strategie verursacht die kleinste Zahl an Page Faults.
- Nachteil: Diese Strategie ist nicht implementierbar.

Die optimale Strategie kann modellhaft zur Bewertung anderer Strategien benutzt werden.

First In, First Out (FIFO): Die Seite ersetzen, die schon am längsten im Speicher ist.

- Vorteil: Sehr einfach zu implementieren:
- Nachteil: Die ersetzte Seite kann in dauernder Benutzung sein und gleich wieder angefordert werden.

Least Recently Used (LRU)

Die Seite ersetzen, die am längsten nicht benutzt worden ist.

- Vorteil: In der Regel weniger Page Faults als FIFO.
- Nachteil: Aufwändige Implementierung.

Zwei mögliche Implementierungen: mit Zähler oder verketteter Liste

Referenz-Bits

- Jeder Seitentabelleneintrag kann ein Referenz-Bit enthalten
  - das bei einem Zugriff auf die Seite gesetzt wird (Hardware),
  - das nach bestimmten Kriterien gelöscht wird (Software).
- Ein Referenz-Bit
  - liefert die Information, ob auf eine Seite seit dem letzten Löschen des Bits zugegriffen wurde,
  - sagt nichts über den Zeitpunkt des Zugriffs auf eine Seite aus,
  - sagt nichts über die Reihenfolge der Zugriffe auf mehrere Seiten aus.
- Mit Referenz-Bits kann man weitere Seitenersetzungsstrategien implementieren, z. B.
  - Modifikation von LRU, die weniger aufwändig ist: binärer Zähler mit Aging
  - **Second-Chance-Algorithmus**, eine Verbesserung der FIFO-Strategie.

Dateisysteme

Beispiele

- **CP/M:** flache Hierarchie, 16 Datenblockadressen in Dateisystemeintrag
- **FAT (MS-DOS):** Verzeichnisse, Verweis auf Index-Block (der enthält Datenblockadressen)
- **Ext2:** Verzeichnisse, Index-Allokation mit bis zu dreifach indirekter Adressierung

Inodes und Blockadressen: Indirektion

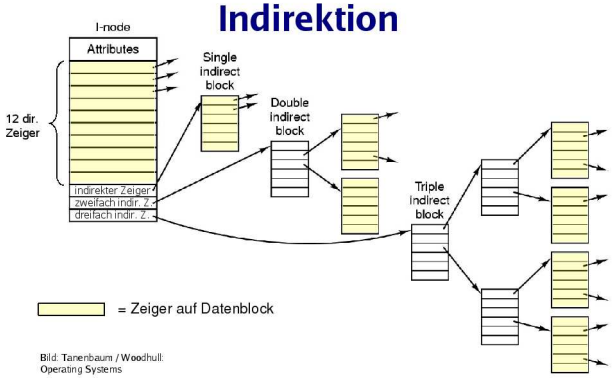

Bild: Tanenbaum / Woodhull: Operating Systems

Indirektion und Dateigrößen

- Beim Erstellen des Dateisystems unterschiedliche Blockgrößen möglich:
  - 1024-Byte-Blöcke -> max. Größe 16 GByte
  - x 2 / x 16
  - 2048-Byte-Blöcke -> max. Größe 256 GByte
  - x 2 / x 16
  - 4096-Byte-Blöcke -> max. Größe 4096 GByte (4 TB)
- Bei großen Dateien: Speichern der Blocknummern in Indirektionsblöcken (bis zu 3 Stufen): Verdoppeln der Blockgröße = Ver-16-fachen (2^4) der Blocknummern: Faktor 2^3 aus Indirektion, Faktor 2 aus Blockgröße

Aufgabenbeispiel

Dateisystem mit folgenden Parametern:
- Dateisystemgröße: **16 GB**
- Blockgröße: **32 KB**
- I-Node enthält:
  - **9 direkte** Verweise
  - **4 1-fach indirekte** Verweise
  - **2 2-fach indirekte** Verweise
  - **1 3-fach indirekter** Verweis

Zu berechnen:
a) Größe der Blockadresse
b) # Adressen pro Block
c) Maximale Dateigröße, die ein Inode zulässt

a) Dateisystem: 16 GB, Block: 32 KB
-> Es gibt 16 G / 32 K = 0,5 M = 512 K = 2^{19} Blöcke

Blockadressen sind also mind. 19 Bit lang, in der Praxis: 4 Byte
(kleinste 2er Potenz, in die 19 Bit passen)

b) Blockgröße / Adressgröße = 32 KB / 4 Byte = 8 K = 8192 = 2^{13}

c) # (adressierb. Blöcke) x Blockgröße =
(9 +
4 x 8192 +
2 x 8192^2 +
1 x 8192^3) x 32 KB
= 17.596.482.060.576 KB ≈ 16.781.313 GB
≈16.388 Terabyte (sehr groß)

Virtual Filesystem (VFS)

- zusätzliche Abstraktionsschicht
- virtuelles Dateisystem verbirgt Sicht auf konkrete Dateisysteme (NTFS, FAT, Ext2, ISO 9660, ...) auf konkreten Dateiträgern (Platte, DVD, Diskette, ...) und vereinheitlicht Zugriff für Anwendungen
- Linux: Inodes, Dateien, Verzeichnisse

Datei-Attribute unter Linux/Ext2

Dreierlei Attribut-Arten:

- Standard-UNIX-Attribute: `chmod` (rwx für user, group, others)
  - symbolische und numerische Schreibweise
  - `umask`
- Zusatzattribute: `chattr` (append-only, immutable etc.)
- erweiterte Attribute: `setfattr`, `getfattr`, `attr` (Name-/Wert-Paare, z. B. ACLs)

Und das war's auch schon...

- Wir sehen uns zur Prüfung (24.07.)
  ... und vielleicht bei der Klausureinsicht
- Viel Erfolg beim Lernen!
- Ergebnisse der Evaluation: http://hm.hgesser.de/

- **Nicht vergessen:**
  Fragen bis zum Klausurtermin jederzeit
  - per Mail: hans-georg.esser@hm.edu
  - Antworten kommen per Mail
  - ... und landen im Prüfungs-Blog: http://hm.hgesser.de/blog