C Dateisysteme

C Dateisysteme

- Einordnung

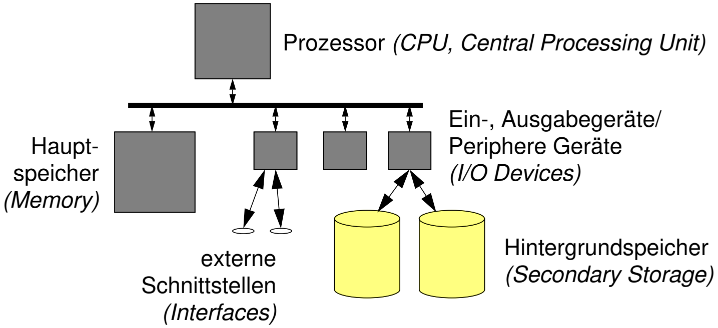

C Dateisysteme (2)

- Dateisysteme speichern Daten und Programme persistent in Dateien
  - Betriebssystemabstraktion zur Nutzung von Hintergrundspeichern (z.B. Platten, CD-ROM, Floppy Disk, Bandlaufwerke)
    - Benutzer muss sich nicht um die Ansteuerungen verschiedener Speichermedien kümmern
    - einheitliche Sicht auf den Sekundärspeicher
- Dateisysteme bestehen aus
  - Dateien *(Files)*
  - Verzeichnissen, Katalogen *(Directories)*
  - Partitionen *(Partitions)*

C Dateisysteme (3)

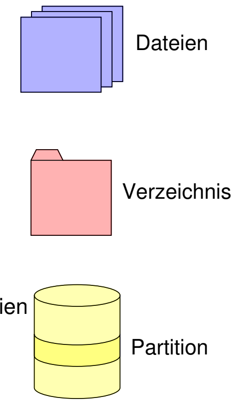

- Datei
  - speichert Daten oder Programme
- Verzeichnis
  - fasst Dateien (u. Verzeichnisse) zusammen
  - erlaubt Benennung der Dateien
  - enthält Zusatzinformationen zu Dateien
- Partitionen
  - eine Menge von Verzeichnissen und deren Dateien
  - Sie dienen zum physischen oder logischen Trennen von Dateimengen.
    - *physisch:* Festplatte, Diskette
    - *logisch:* Teilbereich auf Platte oder CD

1 Dateien

- Kleinste Einheit, in der etwas auf den Hintergrundspeicher geschrieben werden kann.

1.1 Dateiattribute

- *Name* — Symbolischer Name, vom Benutzer les- und interpretierbar
  - z.B. **`AUTOEXEC.BAT`**
- *Typ* — Für Dateisysteme, die verschiedene Dateitypen unterscheiden
  - z.B. sequenzielle Datei, zeichenorientierte Datei, satzorientierte Datei
- *Ortsinformation* — Wo werden die Daten physisch gespeichert?
  - Gerätenummer, Nummern der Plattenblocks

1.1 Dateiattribute (2)

- *Größe* — Länge der Datei in Größeneinheiten (z.B. Bytes, Blöcke, Sätze)
  - steht in engem Zusammenhang mit der Ortsinformation
  - wird zum Prüfen der Dateigrenzen z.B. beim Lesen benötigt
- *Zeitstempel* — z.B. Zeit und Datum der Erstellung, letzten Änderung
  - unterstützt Backup, Entwicklungswerkzeuge, Benutzerüberwachung etc.
- *Rechte* — Zugriffsrechte, z.B. Lese-, Schreibberechtigung
  - z.B. nur für den Eigentümer schreibbar, für alle anderen nur lesbar
- *Eigentümer* — Identifikation des Eigentümers
  - eventuell eng mit den Rechten verknüpft
  - Zuordnung beim Accounting (Abrechnung des Plattenplatzes)

1.2 Operationen auf Dateien

- Erzeugen *(Create)*
  - Nötiger Speicherplatz wird angefordert.
  - Verzeichniseintrag wird erstellt.
  - Initiale Attribute werden gespeichert.
- Schreiben *(Write)*
  - Identifikation der Datei
  - Daten werden auf Platte transferiert.
  - eventuelle Anpassung der Attribute, z.B. Länge
- Lesen *(Read)*
  - Identifikation der Datei
  - Daten werden von Platte gelesen.

1.2 Operationen auf Dateien (2)

- Positionieren des Schreib-/Lesezeigers *(Seek)*
  - Identifikation der Datei
  - In vielen Systemen wird dieser Zeiger implizit bei Schreib- und Leseoperationen positioniert.
  - Ermöglicht explizites Positionieren
- Verkürzen *(Truncate)*
  - Identifikation der Datei
  - Ab einer bestimmten Position wird der Inhalt entfernt (evtl. kann nur der Gesamtinhalt gelöscht werden).
  - Anpassung der betroffenen Attribute
- Löschen *(Delete)*
  - Identifikation der Datei
  - Entfernen der Datei aus dem Katalog und Freigabe der Plattenblocks

2 Verzeichnisse / Kataloge

- Ein Verzeichnis gruppiert Dateien und evtl. andere Verzeichnisse
- Gruppierungsalternativen:
  - Verknüpfung mit der Benennung
    - Verzeichnis enthält Namen und Verweise auf Dateien und andere Verzeichnisse, z.B. *UNIX, MS-DOS*
  - Gruppierung über Bedingung
    - Verzeichnis enthält Namen und Verweise auf Dateien, die einer bestimmten Bedingung gehorchen
      z.B. gleiche Gruppennummer in *CP/M*
      z.B. eigenschaftsorientierte und dynamische Gruppierung in *BeOS-BFS*
- Verzeichnis ermöglicht das Auffinden von Dateien
  - Vermittlung zwischen externer und interner Bezeichnung (Dateiname — Plattenblöcken)

2.1 Operationen auf Verzeichnissen

- Auslesen der Einträge *(Read, Read Directory)*
  - Daten des Verzeichnisinhalts werden gelesen und meist eintragsweise zurückgegeben
- Erzeugen und Löschen der Einträge erfolgt implizit mit der zugehörigen Dateioperation
- Erzeugen und Löschen von Verzeichnissen *(Create and Delete Directory)*

2.2 Attribute von Verzeichnissen

- Die meisten Dateiattribute treffen auch für Verzeichnisse zu
  - Name, Ortsinformationen, Größe, Zeitstempel, Rechte, Eigentümer

3 Beispiel: UNIX (Sun-UFS)

- Datei
  - einfache, unstrukturierte Folge von Bytes
  - beliebiger Inhalt; für das Betriebssystem ist der Inhalt transparent
  - dynamisch erweiterbar
  - Zugriffsrechte: lesbar, schreibbar, ausführbar
- Verzeichnis
  - baumförmig strukturiert
    - Knoten des Baums sind Verzeichnisse
    - Blätter des Baums sind Verweise auf Dateien *(Links)*
  - jedem UNIX-Prozess ist zu jeder Zeit ein aktuelles Verzeichnis *(Current Working Directory)* zugeordnet
  - Zugriffsrechte: lesbar, schreibbar, durchsuchbar, „nur" erweiterbar

3.1 Pfadnamen

- Baumstruktur

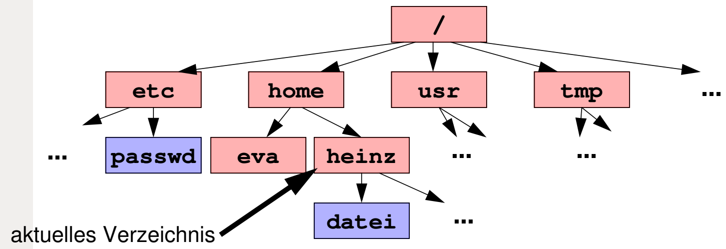

- Pfade
  - z.B. „**/home/heinz/datei**", „**/tmp**", „**datei**"
  - „**/**" ist Trennsymbol *(Slash)*; beginnender „**/**" bezeichnet Wurzelverzeichnis; sonst Beginn implizit mit dem aktuellem Verzeichnis

3.1 Pfadnamen (2)

- Eigentliche Baumstruktur

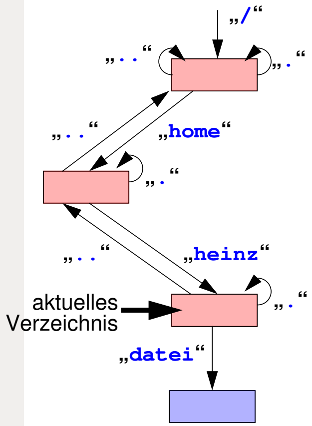

▲ benannt sind nicht Dateien und Verzeichnisse, sondern die Verbindungen zwischen ihnen

- ◆ Verzeichnisse und Dateien können auf verschiedenen Pfaden erreichbar sein
  z.B. **`../heinz/datei`** und **`/home/heinz/datei`**
- ◆ Jedes Verzeichnis enthält einen Verweis auf sich selbst („`.`“) und einen Verweis auf das darüberliegende Verzeichnis im Baum („`..`“)

3.1 Pfadnamen (3)

- Links *(Hard Links)*
  - ◆ Dateien können mehrere auf sich zeigende Verweise besitzen, sogenannte Hard-Links (nicht jedoch Verzeichnisse)

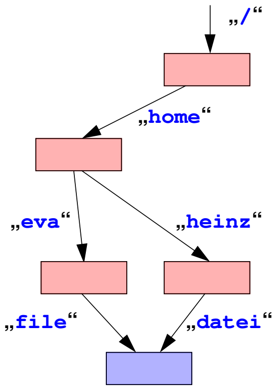

- ◆ Die Datei hat zwei Einträge in verschiedenen Verzeichnissen, die völlig gleichwertig sind:
  `/home/eva/file`
  `/home/heinz/datei`
- ◆ Datei wird erst gelöscht, wenn letzter Link gekappt wird.

3.1 Pfadnamen (4)

- Symbolische Namen *(Symbolic Links)*
  - ◆ Verweise auf einen anderen Pfadnamen (sowohl auf Dateien als auch Verzeichnisse)
  - ◆ Symbolischer Name bleibt auch bestehen, wenn Datei oder Verzeichnis nicht mehr existiert

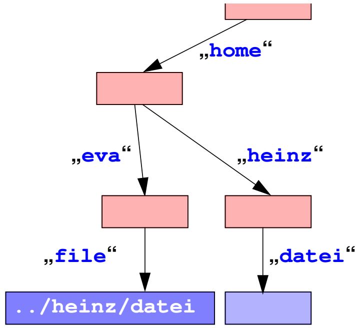

- ◆ Symbolischer Name enthält einen neuen Pfadnamen, der vom FS interpretiert wird.

3.2 Eigentümer und Rechte

- Eigentümer
  - ◆ Jeder Benutzer wird durch eindeutige Nummer (UID) repräsentiert
  - ◆ Ein Benutzer kann einer oder mehreren Benutzergruppen angehören, die durch eine eindeutige Nummer (GID) repräsentiert werden
  - ◆ Eine Datei oder ein Verzeichnis ist genau einem Benutzer und einer Gruppe zugeordnet
- Rechte auf Dateien
  - ◆ Lesen, Schreiben, Ausführen (nur vom Eigentümer veränderbar)
  - ◆ einzeln für den Eigentümer, für Angehörige der Gruppe und für alle anderen einstellbar
- Rechte auf Verzeichnissen
  - ◆ Lesen, Schreiben (Löschen u. Anlegen von Dateien etc.), Durchgangsrecht
  - ◆ Schreibrecht ist einschränkbar auf eigene Dateien („nur erweiterbarer“)

3.3 Dateien

- Basisoperationen
  - ◆ Öffnen einer Datei

```
int open( const char *path, int oflag, [mode_t mode] );
```

  - Rückgabewert ist ein Filedescriptor, mit dem alle weiteren Dateioperationen durchgeführt werden müssen.
  - Filedescriptor ist nur prozesslokal gültig.

  - ◆ Sequentielles Lesen und Schreiben

```
ssize_t read( int fd, void *buf, size_t nbytes );
```

Gibt die Anzahl gelesener Zeichen zurück

```
ssize_t write( int fd, void *buf, size_t nbytes );
```

Gibt die Anzahl geschriebener Zeichen zurück

3.3 Dateien (2)

- Basisoperationen (2)
  - ◆ Schließen der Datei

```
int close( int fd );
```

- Fehlermeldungen
  - ◆ Anzeige durch Rückgabe von `-1`
  - ◆ Variable `int errno` enthält Fehlercode
  - ◆ Funktion `perror("")` druckt Fehlermeldung bzgl. `errno` auf die Standard-Ausgabe

3.3 Dateien (2)

- Weitere Operationen
  - ◆ Lesen und Schreiben in Pufferlisten

```
int readv( int fd, const struct iovec *iov, int iovcnt );
int writev( int fd, const struct iovec *iov, int iovcnt );
```

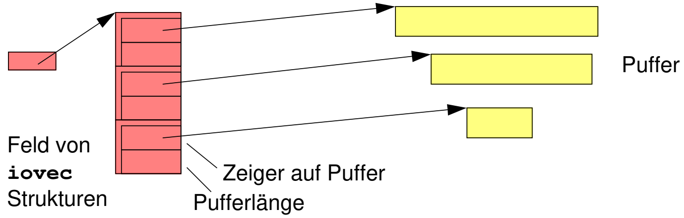

  - ◆ Positionieren des Schreib-, Lesezeigers

```
off_t lseek( int fd, off_t offset, int whence );
```


3.3 Dateien (3)

- Attribute einstellen
  - ◆ Länge

```
int truncate( const char *path, off_t length );
int ftruncate( int fd, off_t length );
```

  - ◆ Zugriffs- und Modifikationszeiten

```
int utimes( const char *path, const struct timeval *tvp );
```

  - ◆ Implizite Maskierung von Rechten

```
mode_t umask( mode_t mask );
```

  - ◆ Eigentümer und Gruppenzugehörigkeit

```
int chown( const char *path, uid_t owner, gid_t group );
int lchown( const char *path, uid_t owner, gid_t group );
int fchown( int fd, uid_t owner, gid_t group );
```

3.3 Dateien (4)

◆ Zugriffsrechte

```
int chmod( const char *path, mode_t mode );
int fchmod( int fd, mode_t mode );
```

◆ Alle Attribute abfragen

```
int stat( const char *path, struct stat *buf );
```

Alle Attribute von **path** ermitteln (folgt symbolischen Links)

```
int lstat( const char *path, sturct stat *buf );
```

Wie **stat**, folgt aber symbolischen Links nicht

```
int fstat( int fd, struct stat *buf );
```

Wie **stat**, aber auf offene Datei

3.4 Verzeichnis

■ Verzeichnisse verwalten

◆ Erzeugen

```
int mkdir( const char *path, mode_t mode );
```

◆ Löschen

```
int rmdir( const char *path );
```

◆ Hard Link erzeugen

```
int link( const char *existing, const char *new );
```

◆ Symbolischen Namen erzeugen

```
int symlink( const char *path, const char *new );
```

◆ Verweis/Datei löschen

```
int unlink( const char *path );
```


3.4 Verzeichnisse (2)

■ Verzeichnisse auslesen

◆ Öffnen, Lesen und Schließen wie eine normale Datei

◆ Interpretation der gelesenen Zeichen ist jedoch systemabhängig, daher wurde eine systemunabhängige Schnittstelle zum Lesen definiert:

```
int getdents( int fildes, struct dirent *buf,
              size_t nbyte );
```

◆ Zum einfacheren Umgang mit Katalogen gibt es Bibliotheksfunktionen:

```
DIR *opendir( const char *path );
struct dirent *readdir( DIR *dirp );
int closedir( DIR *dirp );
long telldir( DIR *dirp );
void seekdir( DIR *dirp, long loc );
```

■ Symbolische Namen auslesen

```
int readlink( const char *path, void *buf, size_t bufsiz );
```


3.5 Inodes

■ Attribute einer Datei und Ortsinformationen über ihren Inhalt werden in sogenannten Inodes gehalten

◆ Inodes werden pro Partition nummeriert *(Inode Number)*

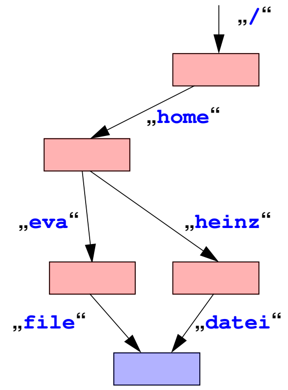

logischer Dateibaum

3.5 Inodes (2)

- Verzeichnisse enthalten lediglich Paare von Namen und Inode-Nummern

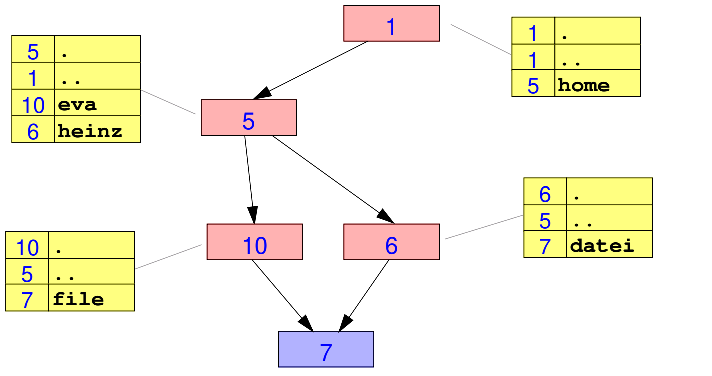

tatsächlich gespeicherter Baum

3.5 Inodes (3)

- Inhalt eines Inodes
  - Inodenummer
  - Dateityp: Verzeichnis, normale Datei, Spezialdatei (z.B. Gerät)
  - Eigentümer und Gruppe
  - Zugriffsrechte
  - Zugriffszeiten: letzte Änderung *(mtime)*, letzer Zugriff *(atime)*, letzte Änderung des Inodes *(ctime)*
  - Anzahl der Hard links auf den Inode
  - Dateigröße (in Bytes)
  - Adressen der Datenblöcke des Datei- oder Verzeichnisinhalts (zehn direkt Adressen und drei indirekte)

3.5 Inodes (4)

- Adressierung der Datenblöcke

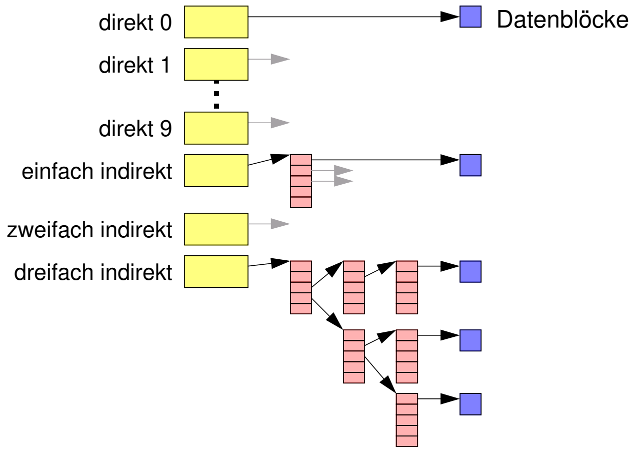

3.6 Spezialdateien

- Periphere Geräte werden als Spezialdateien repräsentiert
  - Geräte können wie Dateien mit Lese- und Schreiboperationen angesprochen werden
  - Öffnen der Spezialdateien schafft eine (evtl. exklusive) Verbindung zum Gerät, die durch einen Treiber hergestellt wird

- Blockorientierte Spezialdateien
  - Plattenlaufwerke, Bandlaufwerke, Floppy Disks, CD-ROMs

- Zeichenorientierte Spezialdateien
  - Serielle Schnittstellen, Drucker, Audiokanäle etc.
  - blockorientierte Geräte haben meist auch eine zusätzliche zeichenorientierte Repräsentation

3.7 Montieren des Dateibaums

- Der UNIX-Dateibaum kann aus mehreren Partitionen zusammenmontiert werden
  - ◆ Partition wird Dateisystem genannt *(File system)*
  - ◆ wird durch blockorientierte Spezialdatei repräsentiert (z.B. **`/dev/dsk/0s3`**)
  - ◆ Das Montieren wird *Mounten* genannt
  - ◆ Ausgezeichnetes Dateisystem ist das *Root File System*, dessen Wurzelverzeichnis gleichzeitig Wurzelverzeichnis des Gesamtsystems ist
  - ◆ Andere Dateisysteme können mit dem Befehl **`mount`** in das bestehende System hineinmontiert werden

3.7 Montieren des Dateibaums (2)

- Beispiel

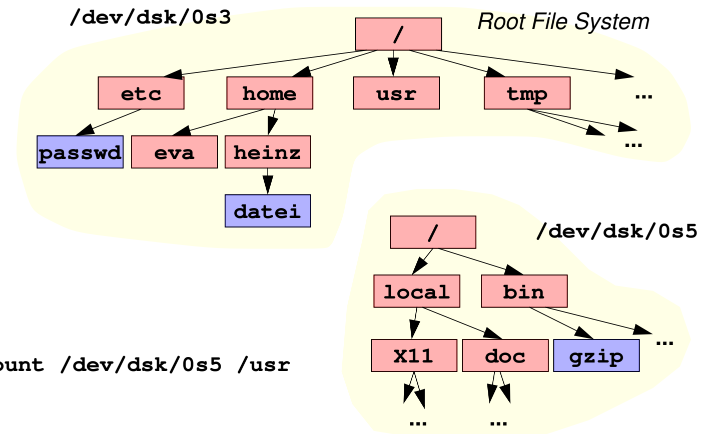

`mount /dev/dsk/0s5 /usr`

3.7 Montieren des Dateibaums (3)

- Beispiel nach Ausführung des Montierbefehls

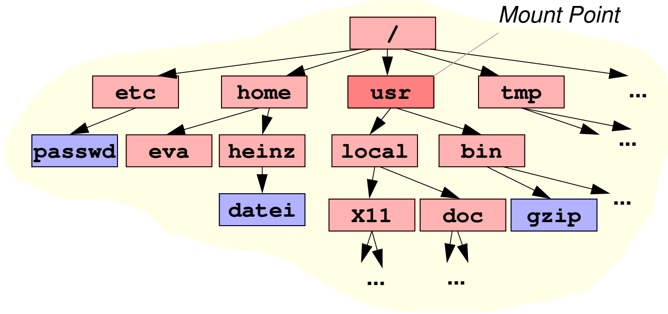

4 Beispiel: Windows 95 (VFAT, FAT32)

- VFAT = Virtual (!) File Allocation Table (oder FAT32)
  - ◆ VFAT: MS-DOS–kompatibles Dateisystem mit Erweiterungen
- Datei
  - ◆ einfache, unstrukturierte Folge von Bytes
  - ◆ beliebiger Inhalt; für das Betriebssystem ist der Inhalt transparent
  - ◆ dynamisch erweiterbar
  - ◆ Zugriffsrechte: „nur lesbar“, „schreib- und lesebar“

4 Beispiel: Windows 95 (FAT16, FAT32) (2)

- Partitionen heißen Laufwerke
  - Sie werden durch einen Buchstaben dargestellt (z.B. `C:`)
- Verzeichnis
  - baumförmig strukturiert
    - Knoten des Baums sind Verzeichnisse
    - Blätter des Baums sind Dateien
  - jedem Windows-Programm ist zu jeder Zeit ein aktuelles Laufwerk und ein aktuelles Verzeichnis pro Laufwerk zugeordnet
  - Zugriffsrechte: „nur lesbar“, „schreib- und lesbar“

4.1 Pfadnamen

- Baumstruktur

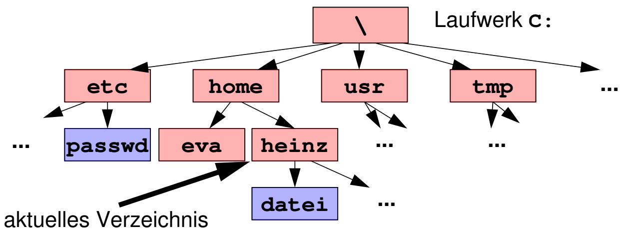

- Pfade
  - z.B. „`C:\home\heinz\datei`“, „`\tmp`“, „`C:datei`“
  - „`\`“ ist Trennsymbol *(Backslash)*; beginnender „`\`“ bezeichnet Wurzelverzeichnis; sonst Beginn implizit mit dem aktuellen Verzeichnis
  - beginnt der Pfad ohne Laufwerksbuchstabe wird das aktuelle Laufwerk verwendet

4.1 Pfadnamen (2)

- Namenskonvention
  - Kompatibilitätsmodus: 8 Zeichen Name, 3 Zeichen Erweiterung (z.B. **`AUTOEXEC.BAT`**)
  - Sonst: 255 Zeichen inklusive Sonderzeichen (z.B. „**`Eigene Programme`**“)
- Verzeichnisse
  - Jedes Verzeichnis enthält einen Verweis auf sich selbst („`.`“) und einen Verweis auf das darüberliegende Verzeichnis im Baum („`..`“) (Ausnahme Wurzelverzeichnis)
  - keine Hard-Links oder symbolischen Namen

4.2 Rechte

- Rechte pro Datei und Verzeichnis
  - schreib- und lesbar — nur lesbar *(read only)*
- Keine Benutzeridentifikation
  - Rechte garantieren keinen Schutz, da von jedermann veränderbar

4.3 Dateien

- Attribute
  - Name, Dateilänge
  - Attribute: versteckt *(Hidden)*, archiviert *(Archive)*, Systemdatei *(System)*
  - Rechte
  - Ortsinformation: Nummer des ersten Plattenblocks
  - Zeitstempel: Erzeugung, letzter Schreib- und Lesezugriff

D Prozesse und Nebenläufigkeit

D Prozesse und Nebenläufigkeit

- Einordnung

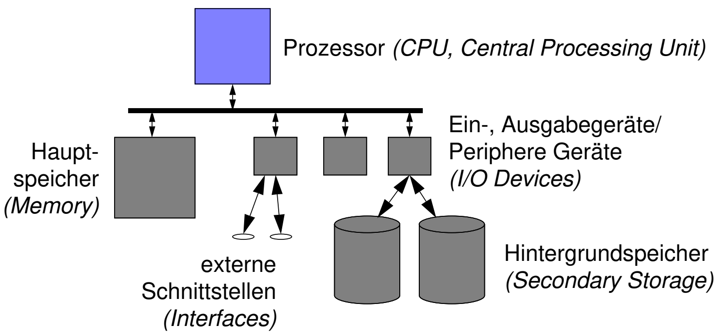

1 Prozessor

- Register
  - Prozessor besitzt Steuer- und Vielzweckregister
  - Steuerregister:
    - Programmzähler *(Instruction Pointer)*
    - Stapelregister *(Stack Pointer)*
    - Statusregister
    - etc.
- Programmzähler enthält Speicherstelle der nächsten Instruktion
  - Instruktion wird geladen und
  - ausgeführt
  - Programmzähler wird inkrementiert
  - dieser Vorgang wird ständig wiederholt

1 Prozessor (2)

- Beispiel für Instruktionen

```
...
0010 5510000000   movl DS:$10, %ebx
0015 5614000000   movl DS:$14, %eax
001a 8a           addl %eax, %ebx
001b 5a18000000   movl %ebx, DS:$18
...
```

- Prozessor arbeitet in einem bestimmten Modus
  - Benutzermodus: eingeschränkter Befehlssatz
  - privilegierter Modus: erlaubt Ausführung privilegierter Befehle
    - Konfigurationsänderungen des Prozessors
    - Moduswechsel
    - spezielle Ein-, Ausgabebefehle

1 Prozessor (3)

- Unterbrechungen *(Interrupts)*

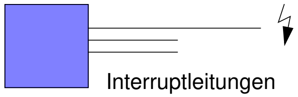

Signalisieren der Unterbrechung
(Interrupt Request; IRQ)

- ◆ Prozessor unterbricht laufende Bearbeitung und führt eine definierte Befehlsfolge aus (vom privilegierten Modus aus konfigurierbar)
- ◆ vorher werden alle Register einschließlich Programmzähler gesichert (z.B. auf dem Stack)
- ◆ nach einer Unterbrechung kann der ursprüngliche Zustand wiederhergestellt werden
- ◆ Unterbrechungen werden im privilegierten Modus bearbeitet

1 Prozessor (4)

- Systemaufrufe *(Traps; User Interrupts)*
  - ◆ Wie kommt man kontrolliert vom Benutzermodus in den privilegierten Modus?
  - ◆ spezielle Befehle zum Eintritt in den privilegierten Modus
  - ◆ Prozessor schaltet in privilegierten Modus und führt definierte Befehlsfolge aus (vom privilegierten Modus aus konfigurierbar)
  - ◆ solche Befehle werden dazu genutzt die Betriebssystemschnittstelle zu implementieren *(Supervisor Calls)*
  - ◆ Parameter werden nach einer Konvention übergeben (z.B. auf dem Stack)

2 Prozesse

- Stapelsysteme *(Batch Systems)*
  - ◆ ein Programm läuft auf dem Prozessor von Anfang bis Ende
- Heutige Systeme *(Time Sharing Systems)*
  - ◆ mehrere Programme laufen gleichzeitig
  - ◆ Prozessorzeit muss den Programmen zugeteilt werden
  - ◆ Programme laufen nebenläufig
- Terminologie
  - ◆ **Programm:** Folge von Anweisungen
    (hinterlegt beispielsweise als Datei auf dem Hintergrundspeicher)
  - ◆ **Prozess:** Programm, das sich in Ausführung befindet, und seine Daten
    (*Beachte*: ein Programm kann sich mehrfach in Ausführung befinden)

2.1 Prozesszustände

- Ein Prozess befindet sich in einem der folgenden Zustände:
  - ◆ **Erzeugt** *(New)*
    Prozess wurde erzeugt, besitzt aber noch nicht alle nötigen Betriebsmittel
  - ◆ **Bereit** *(Ready)*
    Prozess besitzt alle nötigen Betriebsmittel und ist bereit zum Laufen
  - ◆ **Laufend** *(Running)*
    Prozess wird vom realen Prozessor ausgeführt
  - ◆ **Blockiert** *(Blocked/Waiting)*
    Prozess wartet auf ein Ereignis (z.B. Fertigstellung einer Ein- oder Ausgabeoperation, Zuteilung eines Betriebsmittels, Empfang einer Nachricht); zum Warten wird er blockiert
  - ◆ **Beendet** *(Terminated)*
    Prozess ist beendet; einige Betriebsmittel sind jedoch noch nicht freigegeben oder Prozess muss aus anderen Gründen im System verbleiben

2.1 Prozesszustände (2)

- Zustandsdiagramm

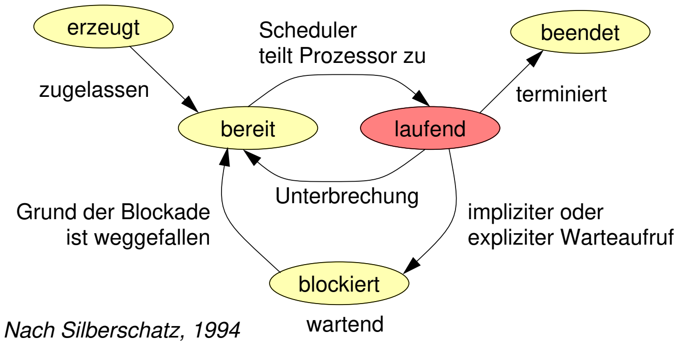

Nach Silberschatz, 1994

◆ Scheduler ist der Teil des Betriebssystems, der die Zuteilung des realen Prozessors vornimmt.

2.2 Prozesswechsel (2)

- Umschaltung

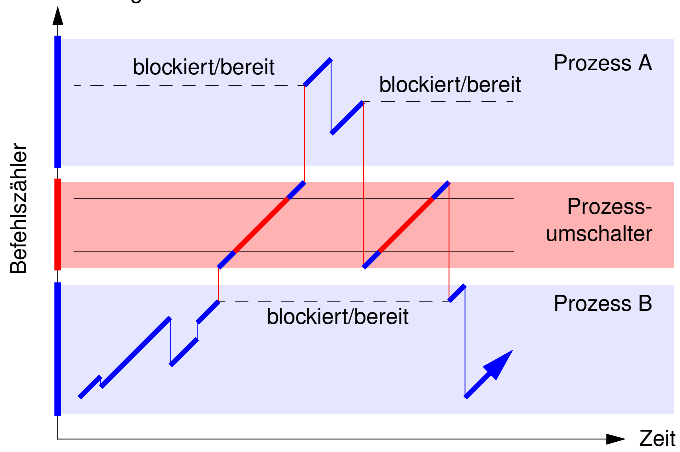

2.2 Prozesswechsel

- Konzeptionelles Modell

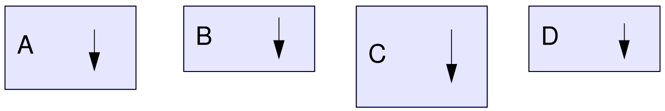

vier Prozesse mit eigenständigen Befehlszählern

- Umschaltung *(Context Switch)*

◆ Sichern der Register des laufenden Prozesses inkl. Programmzähler (Kontext),

◆ Auswahl des neuen Prozesses,

◆ Ablaufumgebung des neuen Prozesses herstellen (z.B. Speicherabbildung, etc.),

◆ gesicherte Register laden und

◆ Prozessor aufsetzen.

2.2 Prozesswechsel (3)

- Prozesskontrollblock *(Process Control Block; PCB)*

◆ Datenstruktur, die alle nötigen Daten für einen Prozess hält. Beispielsweise in UNIX:

  - Prozessnummer *(PID)*
  - verbrauchte Rechenzeit
  - Erzeugungszeitpunkt
  - Kontext (Register etc.)
  - Speicherabbildung
  - Eigentümer *(UID, GID)*
  - Wurzelkatalog, aktueller Katalog
  - offene Dateien
  - ...

2.2 Prozesswechsel (4)

- Prozesswechsel unter Kontrolle des Betriebssystems
  - ◆ Mögliche Eingriffspunkte:
    - Systemaufrufe
    - Unterbrechungen
  - ◆ Wechsel nach/in Systemaufrufen
    - Warten auf Ereignisse
      (z.B. Zeitpunkt, Nachricht, Lesen eines Plattenblock)
    - Terminieren des Prozesses
  - ◆ Wechsel nach Unterbrechungen
    - Ablauf einer Zeitscheibe
    - bevorzugter Prozess wurde laufbereit
- Auswahlstrategie zur Wahl des nächsten Prozesses
  - ◆ *Scheduler*-Komponente

2.3 Prozesserzeugung (UNIX)

- Erzeugen eines neuen UNIX-Prozesses
  - ◆ Duplizieren des gerade laufenden Prozesses

`pid_t fork( void );`

Vater

```
pid_t p;
...
p= fork();
if( p == (pid_t)0 ) {
    /* child */
    ...
} else if( p!=(pid_t)-1 ) {
    /* parent */
    ...
} else {
    /* error */
    ...
}
```

Kind

```
pid_t p;
...
p= fork();
if( p == (pid_t)0 ) {
    /* child */
    ...
} else if( p!=(pid_t)-1 ) {
    /* parent */
    ...
} else {
    /* error */
    ...
}
```


2.3 Prozesserzeugung (UNIX)

- Erzeugen eines neuen UNIX-Prozesses
  - ◆ Duplizieren des gerade laufenden Prozesses

`pid_t fork( void );`

Vater

```
pid_t p;
...
p= fork();
if( p == (pid_t)0 ) {
    /* child */
    ...
} else if( p!=(pid_t)-1 ) {
    /* parent */
    ...
} else {
    /* error */
    ...
}
```


2.3 Prozesserzeugung (2)

- ◆ Der Kind-Prozess ist eine perfekte Kopie des Vaters
  - Gleiches Programm
  - Gleiche Daten (gleiche Werte in Variablen)
  - Gleicher Programmzähler (nach der Kopie)
  - Gleicher Eigentümer
  - Gleiches aktuelles Verzeichnis
  - Gleiche Dateien geöffnet (selbst Schreib-, Lesezeiger ist gemeinsam)
  - ...
- ◆ Unterschiede:
  - Verschiedene PIDs
  - **fork()** liefert verschiedene Werte als Ergebnis für Vater und Kind

2.4 Speicheraufbau eines Prozesses (UNIX)

- Aufteilung des Hauptspeichers eines Prozesses in Segmente

```
int a= 3, b, c= 0;
const int f= 42;
const char *s= "Hello World\n";

int main( ... ) {
    int g= 5;
}
```

	0xffffffff
Stacksegment (lokale Daten)	g: 5
	Stapel (Stack) frei Halde (Heap)
BSS (Block Storage Segment)	c: 0 b: 0
Datensegment (initialisierte Daten)	s: Zeiger a: 3
Textsegment (Codesegment)	??: "Hello World\n" f: 42 main: Instruktionen
	0x0

2.4 Speicheraufbau eines Prozesses (UNIX)

- Aufteilung des Hauptspeichers eines Prozesses in Segmente

```
int a= 3, b, c= 0;
const int f= 42;
const char *s= "Hello World\n";

int main( ... ) {
    int g= 5;
}
```

```
s[1]= 'a';          /* cc error */
f= 2;               /* cc error */
```

	0xffffffff
Stacksegment (lokale Daten)	g: 5
	Stapel (Stack) frei Halde (Heap)
BSS (Block Storage Segment)	c: 0 b: 0
Datensegment (initialisierte Daten)	s: Zeiger a: 3
Textsegment (Codesegment)	??: "Hello World\n" f: 42 main: Instruktionen
	0x0

2.4 Speicheraufbau eines Prozesses (UNIX)

- Aufteilung des Hauptspeichers eines Prozesses in Segmente

```
int a= 3, b, c= 0;
const int f= 42;
const char *s= "Hello World\n";

int main( ... ) {
    int g= 5;
}
```

```
s[1]= 'a';
f= 2;
```

	0xffffffff
Stacksegment (lokale Daten)	g: 5
	Stapel (Stack) frei Halde (Heap)
BSS (Block Storage Segment)	c: 0 b: 0
Datensegment (initialisierte Daten)	s: Zeiger a: 3
Textsegment (Codesegment)	??: "Hello World\n" f: 42 main: Instruktionen
	0x0

2.4 Speicheraufbau eines Prozesses (UNIX)

- Aufteilung des Hauptspeichers eines Prozesses in Segmente

```
int a= 3, b, c= 0;
const int f= 42;
const char *s= "Hello World\n";

int main( ... ) {
    int g= 5;
}
```

```
((char*)s)[1]= 'a';
*((int *)&f)= 2;
```

	0xffffffff
Stacksegment (lokale Daten)	g: 5
	Stapel (Stack) frei Halde (Heap)
BSS (Block Storage Segment)	c: 0 b: 0
Datensegment (initialisierte Daten)	s: Zeiger a: 3
Textsegment (Codesegment)	??: "Hello World\n" f: 42 main: Instruktionen
	0x0

2.4 Speicheraufbau eines Prozesses (UNIX)

- Aufteilung des Hauptspeichers eines Prozesses in Segmente

```
int a= 3, b, c= 0;
const int f= 42;
const char *s= "Hello World\n";

int main( ... ) {
    int g= 5;
}
```

```
((char*)s)[1]= 'a';  /* SIGSEGV */
*((int *)&f)= 2;     /* SIGSEGV */
```

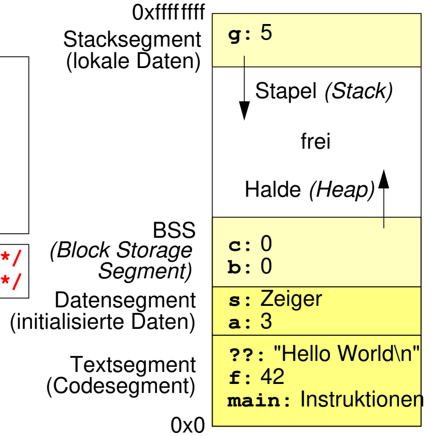

2.5 Ausführen eines Programms (UNIX)

- Prozess führt ein neues Programm aus

```
int execve( const char *path, char *const argv[],
            char *const envp[] );
```

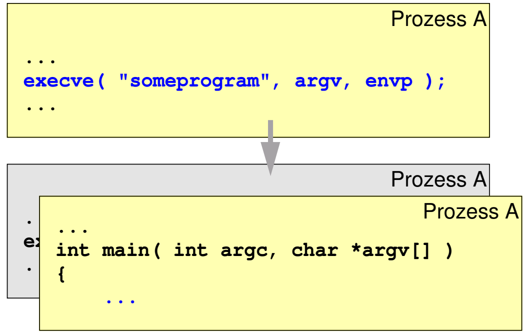

Altes ausgeführtes Programm ist endgültig beendet.

2.5 Ausführen eines Programms (UNIX)

- Prozess führt ein neues Programm aus

```
int execve( const char *path, char *const argv[],
            char *const envp[] );
```

Prozess A

```
...
execve( "someprogram", argv, envp );
...
```


2.6 Operationen auf Prozessen (UNIX)

- Prozess beenden

```
void _exit( int status );
[ void exit( int status ); ]
```

- Prozessidentifikator

```
pid_t getpid( void );      /* eigene PID */
pid_t getppid( void );     /* PID des Vaterprozesses */
```

- Warten auf Beendigung eines Kindprozesses

```
pid_t wait( int *statusp );
```

2.7 Prozesshierarchie (Solaris)

- Hierarchie wird durch Vater-Kind–Beziehung erzeugt

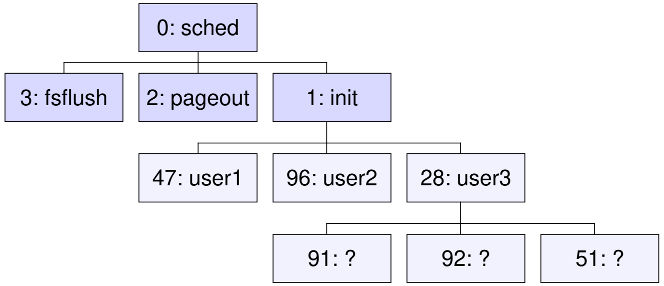

Frei nach Silberschatz 1994

- ◆ Nur der Vater kann auf das Kind warten
- ◆ Init-Prozess adoptiert verwaiste Kinder

3 Auswahlstrategien

- Strategien zur Auswahl des nächsten Prozesses *(Scheduling Strategies)*
  - ◆ Mögliche Stellen zum Treffen von Scheduling-Entscheidungen
    1. Prozess wechselt vom Zustand „laufend“ zum Zustand „blockiert“ (z.B. Ein-, Ausgabeoperation)
    2. Prozess wechselt von „laufend“ nach „bereit“ (z.B. bei einer Unterbrechung des Prozessors)
    3. Prozess wechselt von „blockiert“ nach „bereit“
    4. Prozess terminiert
  - ◆ Keine Wahl bei 1. und 4.
  - ◆ Wahl bei 2. und 3.

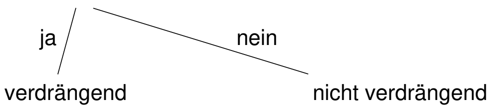

3 Auswahlstrategien (2)

- CPU Auslastung
  - ◆ CPU soll möglichst vollständig ausgelastet sein

★ CPU-Nutzung in Prozent, abhängig von der Anzahl der Prozesse und deren prozentualer Wartezeit

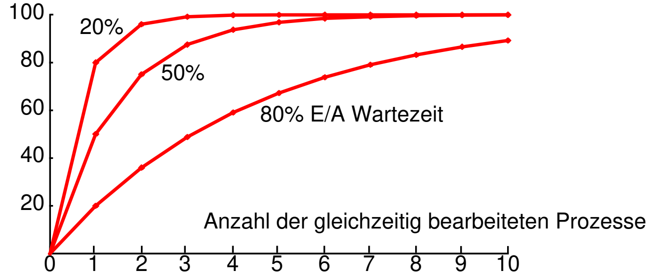

Nach Tanenbaum, 1995

3 Auswahlstrategien (3)

- Durchsatz
  - ◆ Möglichst hohe Anzahl bearbeiteter Prozesse pro Zeiteinheit
- Verweilzeit
  - ◆ Gesamtzeit des Prozesses in der Rechenanlage soll so gering wie möglich sein
- Wartezeit
  - ◆ Möglichst kurze Gesamtzeit, in der der Prozess im Zustand „bereit“ ist
- Antwortzeit
  - ◆ Möglichst kurze Reaktionszeit des Prozesses im interaktiven Betrieb

3.1 First Come, First Served

- Der erste Prozess wird zuerst bearbeitet *(FCFS)*
  - „Wer zuerst kommt ...“
  - Nicht-verdrängend
- Warteschlange zum Zustand „bereit“
  - Prozesse werden hinten eingereiht
  - Prozesse werden vorne entnommen

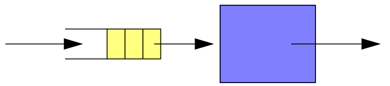

- Bewertung
  - fair (?)
  - Wartezeiten nicht minimal
  - nicht für Time-Sharing-Betrieb geeignet

3.1 First Come, First Served (2)

- Beispiel zur Betrachtung der Wartezeiten

Prozess 1: 24
Prozess 2: 3
Prozess 3: 3
} Zeiteinheiten

- Reihenfolge: P1, P2, P3

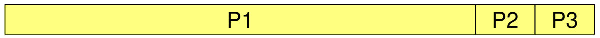

mittlere Wartezeit: (0+24+27)/3 = 17

- Reihenfolge: P2, P3, P1

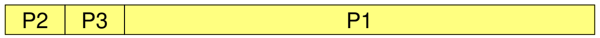

mittlere Wartezeit: (6+0+3)/3 = 3

3.2 Shortest Job First

- Kürzester Job wird ausgewählt *(SJF)*
  - Länge bezieht sich auf die nächste Rechenphase bis zur nächsten Warteoperation (z.B. Ein-, Ausgabe)
- „bereit“-Warteschlange wird nach Länge der nächsten Rechenphase sortiert
  - Vorhersage der Länge durch Protokollieren der Länge bisheriger Rechenphasen (Mittelwert, exponentielle Glättung)
  - ... Protokollierung der Länge der vorherigen Rechenphase
- SJF optimiert die mittlere Wartezeit
  - Da Länge der Rechenphase in der Regel nicht genau vorhersagbar, nicht ganz optimal.
- Varianten: verdrängend *(PSJF)* und nicht-verdrängend

3.3 Prioritäten

- Prozess mit höchster Priorität wird ausgewählt
  - dynamisch — statisch
    (z.B. SJF: dynamische Vergabe von Prioritäten gemäß Länge der nächsten Rechenphase)
    (z.B. statische Prioritäten in Echtzeitsystemen; Vorhersagbarkeit von Reaktionszeiten)
  - verdrängend — nicht-verdrängend
- Probleme
  - Aushungerung
    Ein Prozess kommt nie zum Zuge, da immer andere mit höherer Priorität vorhanden sind.
  - Prioritätenumkehr *(Priority Inversion)*

3.3 Prioritäten (2)

- Prioritätenumkehr
  - ◆ hochpriorer Prozess wartet auf ein Betriebsmittel, das ein niedrigpriorer Prozess besitzt; dieser wiederum wird durch einen mittelprioren Prozess verdrängt und kann daher das Betriebsmittel gar nicht freigeben

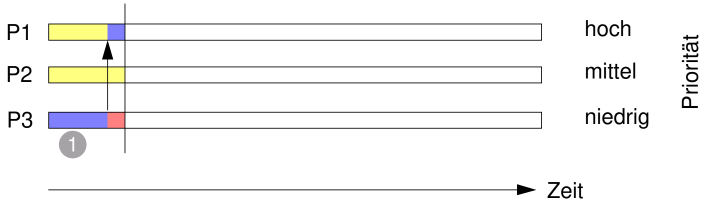

laufend
bereit
blockiert

1. P3 belegt ein Betriebsmittel

3.3 Prioritäten (2)

- Prioritätenumkehr
  - ◆ hochpriorer Prozess wartet auf ein Betriebsmittel, das ein niedrigpriorer Prozess besitzt; dieser wiederum wird durch einen mittelprioren Prozess verdrängt und kann daher das Betriebsmittel gar nicht freigeben

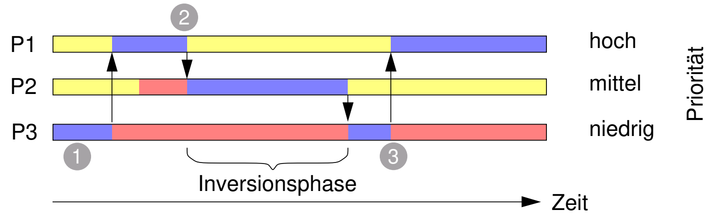

laufend
bereit
blockiert

1. P3 fordert Betriebsmittel an
2. P1 wartet auf das gleiche Betriebsmittel
3. P3 gibt Betriebsmittel frei

3.3 Prioritäten (2)

- Prioritätenumkehr
  - ◆ hochpriorer Prozess wartet auf ein Betriebsmittel, das ein niedrigpriorer Prozess besitzt; dieser wiederum wird durch einen mittelprioren Prozess verdrängt und kann daher das Betriebsmittel gar nicht freigeben

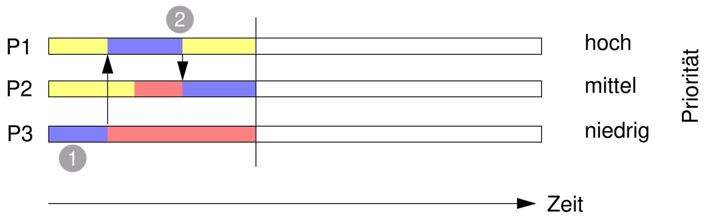

laufend
bereit
blockiert

1. P3 belegt ein Betriebsmittel
2. P1 wartet auf das gleiche Betriebsmittel

3.3 Prioritäten (3)

★ Lösungen
  - ◆ zur Prioritätenumkehr:
    dynamische Anhebung der Priorität für kritische Prozesse
  - ◆ zur Aushungerung:
    dynamische Anhebung der Priorität für lange wartende Prozesse (Alterung, *Aging*)

3.4 Round-Robin Scheduling

- Zuteilung und Auswahl erfolgt reihum
  - ähnlich FCFS aber mit Verdrängung
  - Zeitquant *(Time Quantum)* oder Zeitscheibe *(Time Slice)* wird zugeteilt
  - geeignet für *Time-Sharing*-Betrieb

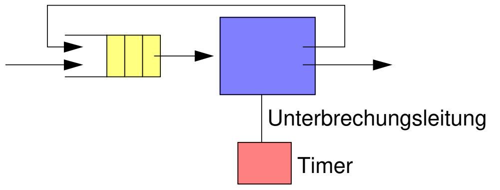

  - Wartezeit ist jedoch eventuell relativ lang

3.4 Round-Robin Scheduling (2)

- Beispiel zur Betrachtung der Wartezeiten

Prozess 1:	24	Zeiteinheiten
Prozess 2:	3	
Prozess 3:	3	

  - Zeitquant ist 4 Zeiteinheiten
  - Reihenfolge in der „bereit“-Warteschlange: P1, P2, P3

P1	P2	P3	P1	P1	P1	P1	P1
0–4	4–7	7–10	10–14	14–18	18–22	22–26	26–30

mittlere Wartezeit: (6+4+7)/3 = 5.7

3.4 Round-Robin Scheduling (3)

- Effizienz hängt von der Größe der Zeitscheibe ab
  - kurze Zeitscheiben: Zeit zum Kontextwechsel wird dominant
  - lange Zeitscheiben: Round Robin nähert sich FCFS an
- Verweilzeit und Wartezeit hängt ebenfalls von der Zeitscheibengröße ab
  - Beispiel: 3 Prozesse mit je 10 Zeiteinheiten Rechenbedarf
    - Zeitscheibengröße 1
    - Zeitscheibengröße 10

3.4 Round-Robin Scheduling (4)

- Zeitscheibengröße 1:

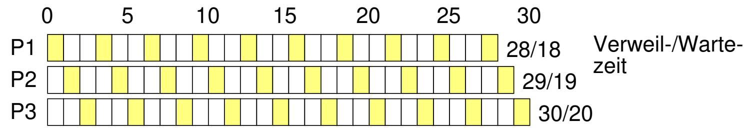

durchschnittliche Verweilzeit: 29 Zeiteinheiten = (28+29+30)/3
durchschnittliche Wartezeit: 19 Zeiteinheiten = (18+19+20)/3

3.4 Round-Robin Scheduling (4)

◆ Zeitscheibengröße 1:

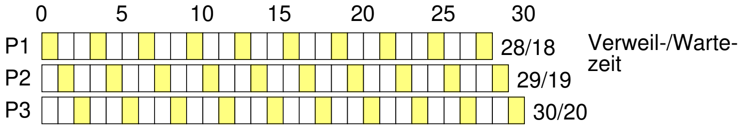

durchschnittliche Verweilzeit: 29 Zeiteinheiten = (28+29+30)/3
durchschnittliche Wartezeit: 19 Zeiteinheiten = (18+19+20)/3

◆ Zeitscheibengröße 10:

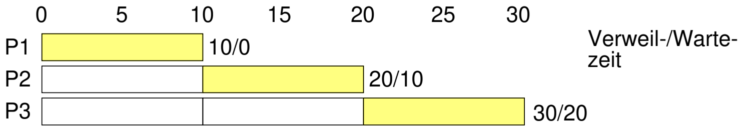

durchschnittliche Verweilzeit: 20 Zeiteinheiten = (10+20+30)/3
durchschnittliche Wartezeit: 10 Zeiteinheiten = (0+10+20)/3

3.5 Multilevel-Queue Scheduling

■ Verschiedene Schedulingklassen

◆ z.B. Hintergrundprozesse (Batch) und Vordergrundprozesse (interaktive Prozesse)

◆ jede Klasse besitzt ihre eigenen Warteschlangen und verwaltet diese nach einem eigenen Algorithmus

◆ zwischen den Klassen gibt es ebenfalls ein Schedulingalgorithmus z.B. feste Prioritäten (Vordergrundprozesse immer vor Hintergrundprozessen)

■ Beispiel: Solaris

◆ Schedulingklassen

- Systemprozesse
- Real-Time Prozesse
- Time-Sharing Prozesse
- interaktive Prozesse

3.5 Multilevel-Queue Scheduling (2)

◆ Scheduling zwischen den Klassen mit fester Priorität (z.B. Real-Time-Prozesse vor Time-Sharing-Prozessen)

◆ In jeder Klasse wird ein eigener Algorithmus benutzt:

- Systemprozesse: FCFS
- Real-Time Prozesse: statische Prioritäten
- Time-Sharing und interaktive Prozesse: ausgefeiltes Verfahren zur Sicherung von:
  - kurzen Reaktionszeiten
  - fairer Zeitaufteilung zwischen rechenintensiven und I/O-intensiven Prozessen
  - gewisser Benutzersteuerung

★ Multilevel Feedback Queue Scheduling

3.6 Multilevel-Feedback-Queue Scheduling

■ Mehrere Warteschlangen *(MLFB)*

◆ jede Warteschlange mit eigener Behandlung

◆ Prozesse können von einer zur anderen Warteschlange transferiert werden

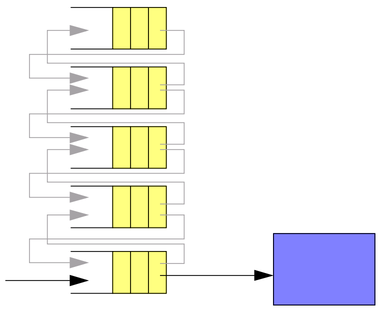

3.6 Multilevel Feedback Queue Scheduling (2)

- Beispiel:
  - ◆ mehrere Warteschlangen mit Prioritäten (wie bei Multilevel Queue)
  - ◆ Prozesse, die lange rechnen, wandern langsam in Warteschlangen mit niedrigerer Priorität (bevorzugt interaktive Prozesse)
  - ◆ Prozesse, die lange warten müssen, wandern langsam wieder in höherpriore Warteschlangen *(Aging)*

3.7 Beispiel: Time Sharing Scheduling in Solaris

- 60 Warteschlangen, Tabellensteuerung

Level	ts_quantum	ts_tqexp	ts_maxwait	ts_lwait	ts_slpret
0	200	0	0	50	50
1	200	0	0	50	50
2	200	0	0	50	50
3	200	0	0	50	50
4	200	0	0	50	50
5	200	0	0	50	50
...					
44	40	34	0	55	55
45	40	35	0	56	56
46	40	36	0	57	57
47	40	37	0	58	58
48	40	38	0	58	58
49	40	39	0	59	58
50	40	40	0	59	58
51	40	41	0	59	58
52	40	42	0	59	58
53	40	43	0	59	58
54	40	44	0	59	58
55	40	45	0	59	58
56	40	46	0	59	58
57	40	47	0	59	58
58	40	48	0	59	58
59	20	49	32000	59	59

3.7 Beispiel: TS Scheduling in Solaris (2)

- Tabelleninhalt
  - ◆ kann ausgelesen und gesetzt werden (Auslesen: `dispadmin -c TS -g`)
  - ◆ `Level:` Nummer der Warteschlange
    Hohe Nummer = hohe Priorität
  - ◆ `ts_quantum:` maximale Zeitscheibe für den Prozess (in Millisek.)
  - ◆ `ts_tqexp:` Warteschlangennummer, falls der Prozess die Zeitscheibe aufbraucht
  - ◆ `ts_maxwait:` maximale Zeit für den Prozess in der Warteschlange ohne Bedienung (in Sekunden; Minimum ist eine Sekunde)
  - ◆ `ts_lwait:` Warteschlangennummer, falls Prozess zulange in dieser Schlange
  - ◆ `ts_slpret:` Warteschlangenummer für das Wiedereinreihen nach einer blockierenden Aktion

3.7 Beispiel: TS Scheduling in Solaris (3)

- Beispielprozess:
  - ◆ 1000ms Rechnen am Stück
  - ◆ 5 E/A Operationen mit jeweils Rechenzeiten von 1ms dazwischen

#	Warteschlange	Rechenzeit	Prozesswechsel weil ...
1	59	20	Zeitquant abgelaufen
2	49	40	Zeitquant abgelaufen
3	39	80	Zeitquant abgelaufen
4	29	120	Zeitquant abgelaufen
5	19	160	Zeitquant abgelaufen
6	9	200	Zeitquant abgelaufen
7	0	200	Zeitquant abgelaufen
8	0	180	E/A Operation
9	50	1	E/A Operation
10	58	1	E/A Operation
11	58	1	E/A Operation
12	58	1	E/A Operation

3.7 Beispiel: TS Scheduling in Solaris (4)

- Tabelle gilt nur unter der folgenden Bedingung:
  - ◆ Prozess läuft fast alleine, andernfalls
    - könnte er durch höherpriore Prozesse verdrängt und/oder ausgebremst werden,
    - wird er bei langem Warten in der Priorität wieder angehoben.
- Beispiel:

#	Warteschlange	Rechenzeit	Prozesswechsel weil ...
...			
6	9	200	Zeitquant abgelaufen
7	0	20	Wartezeit von 1s abgelaufen
8	50	40	Zeitquant abgelaufen
9	40	40	Zeitquant abgelaufen
10	30	80	Zeitquant abgelaufen
11	20	120	Zeitquant abgelaufen
...			

3.7 Beispiel: TS Scheduling in Solaris (5)

- Weitere Einflussmöglichkeiten
  - ◆ Anwender und Administratoren können Prioritätenoffsets vergeben
  - ◆ Die Offsets werden auf die Tabellenwerte addiert und ergeben die wirklich verwendete Warteschlange
  - ◆ positive Offsets: Prozess wird bevorzugt
  - ◆ negative Offsets: Prozess wird benachteiligt
  - ◆ Außerdem können obere Schranken angegeben werden
- Systemaufruf
  - ◆ Verändern der eigenen Prozesspriorität

```
int nice( int incr );
```

(positives Inkrement: niedrigere Priorität;
negatives Inkrement: höhere Priorität)