

# Betriebssysteme

## Kapitel 7: Files

### *7.1: Konzepte*

Stand: WS 12/13 (27.11.2012)

Prof. Dr. Wolfgang Kuchlin

*Dipl.-Inform., Dr. sc. techn. (ETH)*

**Arbeitsbereich Symbolisches Rechnen  
Wilhelm-Schickard-Institut für Informatik  
Fakultät für Informations- und Kognitionswissenschaften**

**Universität Tübingen**

**Steinbeis Transferzentrum  
Objekt- und Internet-Technologien (OIT)**

[Wolfgang.Kuechlin@uni-tuebingen.de](mailto:Wolfgang.Kuechlin@uni-tuebingen.de)  
<http://www-sr.informatik.uni-tuebingen.de>



- Eine (UNIX-) **Datei** besteht aus einer linearen Folge von Bytes.
- Zugriff durch
  1. Positionieren (seek)
  2. Sequentielles read/write von Bytes
- Eine Datei ist immer auf einem nicht-flüchtigen Speicher „zuhause“, kann aber in den Hauptspeicher abgebildet (mmap) werden.
- Abstraktion „Datei“ verbirgt Eigenheiten von Platten oder Bändern (Adressierung, verstreute Speicherung in endlich großen Blöcken etc.)



# Attribute von Dateien

---

- Dateien besitzen Attribute.
- Welche Attribute vorhanden sind, hängt vom Betriebssystem ab.
  - Unterschiede zwischen DOS, UNIX, Windows NT
- Häufig vorhandene Attribute
  - Dateiname
    - Enthält oftmals eine **Extension**, die die Interpretation des Inhalts unterstützt.
  - Typ
    - wird bei Systemen gebraucht, die verschiedene Dateitypen unterstützen
      - z.B. reguläres File, symbolischer Link, Verzeichnis, Gerät, ...



# Attribute von Dateien

## (häufig vorhandene Attribute)

---

### ➤ Ort

- Ein Zeiger auf den Ort des Files auf dem physischen Speichermedium.

### ➤ Größe in Bytes

- der verbrauchte Platz ist i.a. größer, da immer ganze Blöcke alloziert werden.
- Differenz = „interner Verschnitt“

### ➤ Schutzinformation

- z.B. Information über Lese-, Schreib-, Ausführrechte

### ➤ Zeit, Datum, Benutzeridentifikation

- evtl. unterteilt in Erschaffungszeit, letzter Schreibzugriff, letzter Lesezugriff



# Operationen auf Files

---

- Anlegen: create
- Öffnen: open
- Schließen: close
- Schreiben: write
- Lesen: read
- Löschen: delete
- Abschneiden: truncate
- Positionieren in der Datei: seek (UNIX: lseek)



# Dateien und Dateikataloge / Verzeichnisse in UNIX

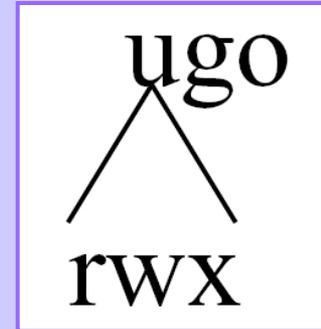
---

- Dateien sind Sequenzen von 0 oder mehr Bytes.
- Interpretation der Bytes ist Benutzersache.
- Dateinamen sind bis 255 Zeichen lang.
  
- Der Namensteil, der nach einem (dem letzten) „.“ im Dateinamen kommt, wird aber von vielen Programmen speziell interpretiert.
- Konvention:
  - \*.c C-Programme
  - \*.s Assembler
  - \*.f Fortran



# Zugriffsrechte

- *Zugriffsrechte* sind gruppiert:



- Beispiel: `chmod o+r *.c`
- Standardrechte: `via umask`
- Die Bits in der `umask` werden von den Bits der Maske `rwX.rwX.rwX` abgezogen. (Die Ziffern der `umask` werden octal interpretiert).
- Beispiel: `umask 026 → rwX.r-X.--X`



# Verzeichnisse (Directories) in UNIX

## Verzeichnis

ist selbst Datei mit Auflistung der enthaltenen Dateien.

- Beispiel: `cat -v <dir>`
- **Erzeugen**: `mkdir <name>`
- **Listen**: `ls <name>`
- **Zugriffsrechte**: Wie bisher, aber x Recht bezieht sich auf Zugriffsrecht auf bekannte Datei im Verzeichnis.
- **Verzeichnisse in Verzeichnissen**:  
/usr/bin  
/usr/include/stdio.h



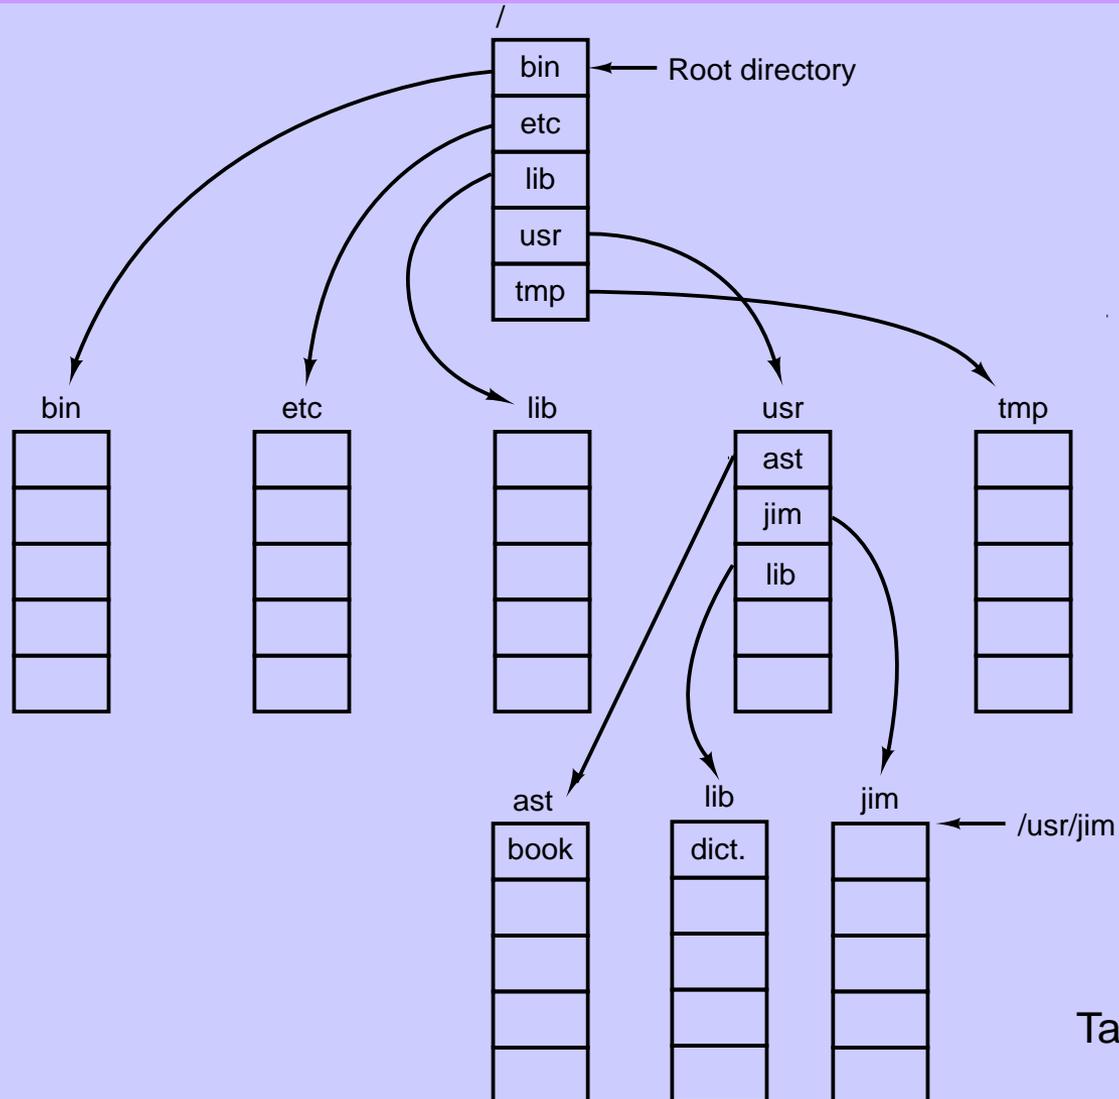
# Dateibäume in UNIX

---

- Die Dateien sind also (logisch) in einem **Dateibaum** organisiert. Zugriff über **absoluten** Pfadnamen (`/usr/ast/book`) oder **relativ** zur augenblicklichen Position (z.B. `book` bei position im Katalog `/usr/ast/`). Es können Dateien eingerichtet werden, die auf andere verweisen (**links**). Dadurch kann auf einer bestehenden Organisation eine andere logische Organisation überlagert werden.
- Durch Links wird das Dateisystem von einem Baum zu einem allgemeineren Graphen, der auch Zyklen enthalten kann.



# Dateibaum



Tanenbaum, Abb.6-10

# Beliebte Dateiverzeichnisse in UNIX

<b>/bin</b>	<b>System Binärdateien (ausführbar)</b>
<b>/dev</b>	<b>Dateien, die für Geräte stehen</b>
<b>/etc</b>	<b>Systemverwaltung</b>
<b>/home/name</b>	<b>Home-Verzeichnis für Benutzer</b>
<b>/lib</b>	<b>Bibliotheksfunktionen</b>
<b>/tmp</b>	<b>Temporäre Dateien</b>
<b>/usr</b>	<b>Benutzerdateien</b>
<b>/usr/adm</b>	<b>Systemverwaltung</b>
<b>/usr/bin</b>	<b>Weitere System-Binärdateien</b>
<b>/usr/include/</b>	<b>System Vorsann Dateien</b>
<b>/usr/lib</b>	<b>Compiler etc.</b>
<b>/usr/man</b>	<b>On-Line Manual</b>
<b>/usr/src</b>	<b>System Quellcode</b>
<b>/usr/tnp</b>	<b>Temporärdateien</b>
<b>/var/spool</b>	<b>Zwischenspeicher für Drucker etc.</b>



# Mounting

---

Unter UNIX befindet sich das **root directory** „/“ auf einer Festplatte.

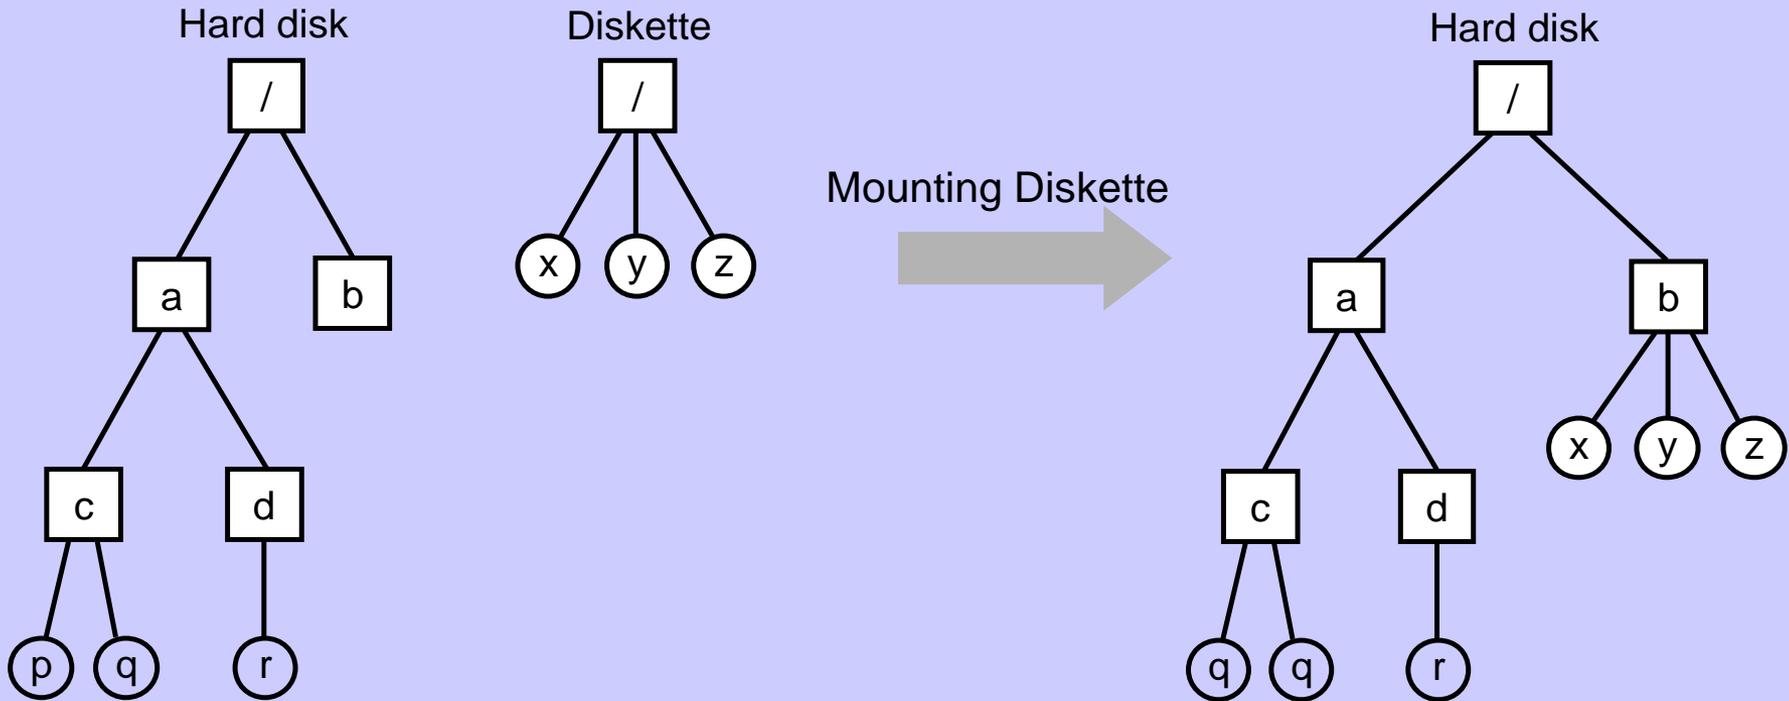
Nicht alle subdirectories müssen auf der gleichen **Partition** sein. (Partitionen sind abstrahiert spezielle „Geräte“; andere Arten von Geräten werden wir später behandeln)

Ein Dateibaum, der sich auf einem anderen Gerät befindet, kann mittels eines **mount** Befehls an eine Stelle des Dateibaums eingefügt werden, das durch ein directory gegeben ist, und wird dann als Unterbaum behandelt.

Falls das ursprüngliche directory nicht leer war, so wird dessen Inhalt durch den **mount** Befehl verdeckt (bis er nach einem evtl. **umount** wieder sichtbar wird).



# Mounting: Beispiel



Tanenbaum, Abb.10-26

# Links

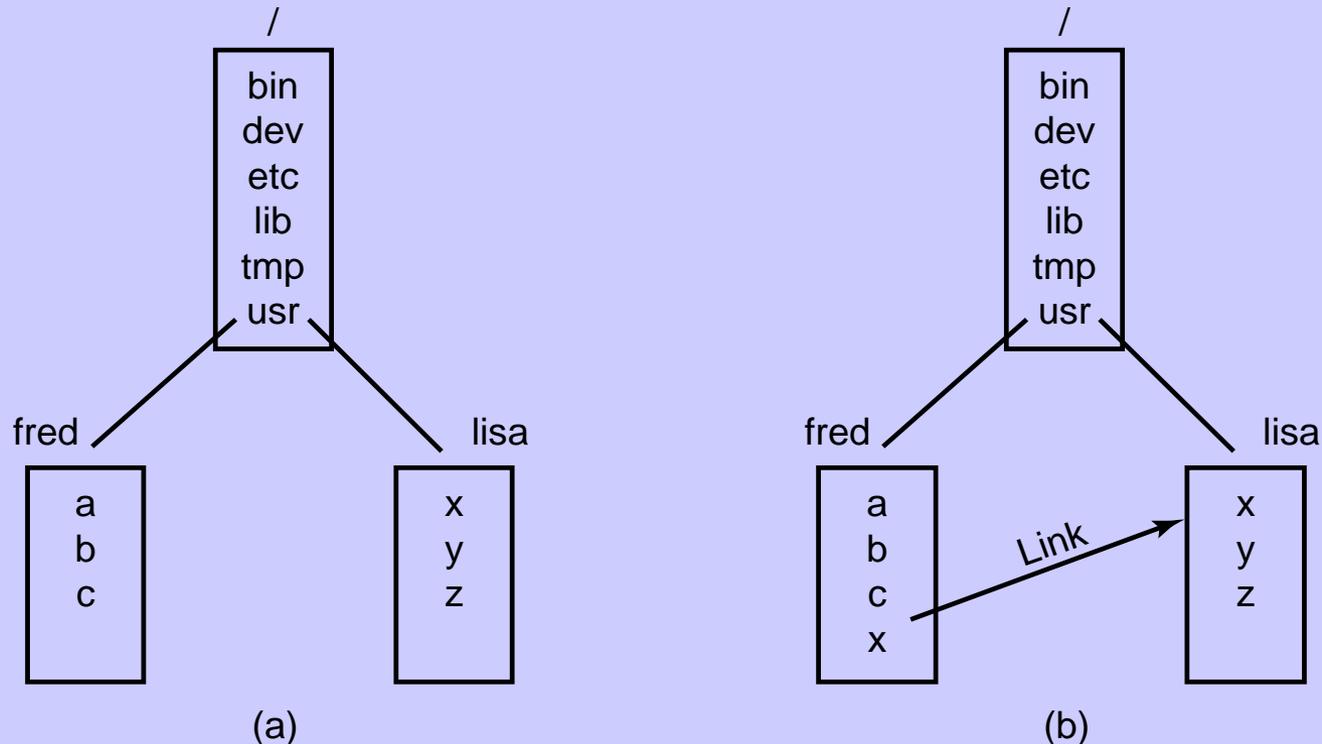
---

- In UNIX gibt es hard- und soft- (symbolic) links.
  - hard links: innerhalb eines Gerätes (i.a. Plattenpartition)
  - soft links: über Gerätegrenzen hinweg
    - Beispiel: `ln -s /usr/ast/book OS_book`
- Es ist möglich, einen Dateibaum von einem Gerät in den Dateibaum eines anderen Geräts einzutragen (mounting) und somit logisch einzugliedern. Der Benutzer merkt das Überschreiten der Gerätegrenzen dann nicht und arbeitet logisch mit einem einzigen Dateibaum.



# Beispiel: Links

Tanenbaum,  
Abb. 10-25



F. und L. arbeiten gemeinsam an Datei `x` im Verzeichnis `/usr/lisa`.

(a) F. kann relativ (`./lisa/x`) oder absolut (`/usr/lisa/x`) auf `x` zugreifen.

(b) F. kann einen Link auf `x` erzeugen und somit wie auf eine lokale Datei zugreifen (`x`).

# Sticky Bit, setuid-Bit, setgid-Bit

---

- Neben den Bits für r, w, x für jeweils u, g oder o gibt es im Feld der Zugriffsrechte noch einige weitere bits, die gesetzt werden können.
- Mit dem **sticky bit** können Directories mit einem Lock versehen werden, das das Löschen von Files durch group Mitglieder verhindert (die rwx Rechte auf dem Directory haben, um z.B. neue Files anlegen zu können oder bestehende ändern dürfen sollen.)



# Sticky Bit, setuid-Bit, setgid-Bit

---

- Das setuid-Bit kann sinnvollerweise nur bei ausführbaren Dateien gesetzt sein (solche, die also x Permission für ugo besitzen). Ist das setuid-Bit gesetzt, wird normalerweise ein s statt ein x angezeigt.
- Ein Programm, dessen setuid-Bit gesetzt ist, wird unter der User-id ausgeführt, der das File gehört, und nicht unter der User-id des Aufrufers, wie dies im Normalfall geschieht. Hierdurch kann einem normalen Benutzer auf kontrollierte Art Zugriff auf privilegierte Ressourcen gewährt werden.



# Der setuid Mechanismus

---

- Beispiel: Ein Benutzer soll in der `/etc/passwd`-Datei sein eigenes Password ändern dürfen, das dort in DES- verschlüsselter Form steht, aber keine anderen Änderungen vornehmen dürfen. Das File `/etc/passwd` gehört `root`, und normale Benutzer haben keinen Schreibzugriff:

```
-rw-r--r-- 1 root sys 524 Apr 30 13:54 /etc/passwd
```

- Beim Programmfile `/usr/bin/passwd`, das `root` gehört, ist das setuid-Bit gesetzt.



# Der setuid Mechanismus

---

```
-r-sr-sr-x 3 root sys 15688 Oct 25 1995 /usr/bin/passwd
```

- Wenn das Programmfile `/usr/bin/passwd` von einem normalen Benutzer aufgerufen wird, läuft es unter der UserId von `root` ab, und kann daher das file `/etc/passwd` ändern. Es ist Aufgabe des Programms `/usr/bin/passwd` zu gewährleisten, daß nur solche Änderungen in `/etc/passwd` vorgenommen werden, die dem Benutzer erlaubt sind.
- Der setuid-Mechanismus stellt ein größeres Sicherheitsproblem in UNIX dar und wird in neueren UNIX-Varianten eingeschränkt. Z.B. dürfen keine shell-scripts mit dem setuid-Bit versehen werden.



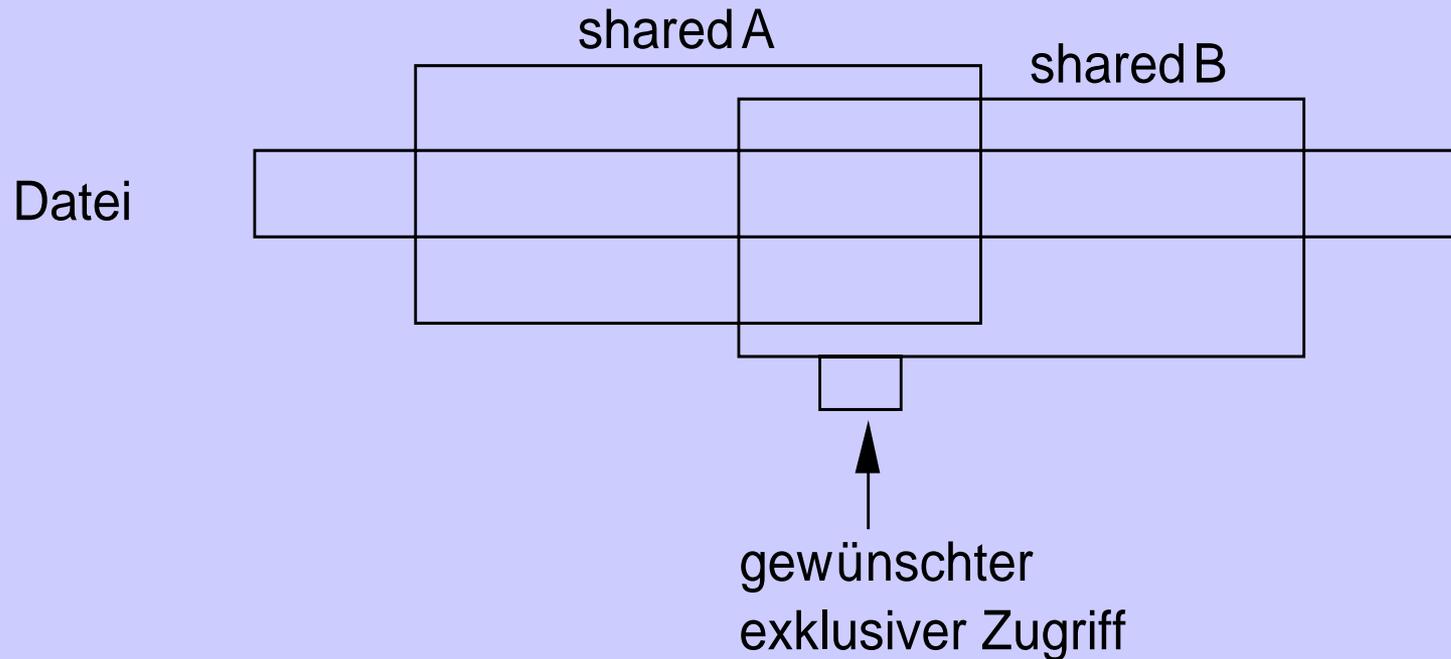
# Locking

---

- Locking: Dateien können für Exklusivzugriffe reserviert werden (POSIX).
  - Wichtig für Synchronisation paralleler Dateizugriffe.
- 2 Arten von *locks*:
  - **shared** - Reservierung für Lesezugriff (vgl. readers/writers locks)
  - **exclusive** - Reservierung für Schreibzugriff
- Es kann jede zusammenhängende Bytesequenz reserviert werden
- *shared locks* können sich überlappen.
- Exklusivzugriff nur möglich, nachdem alle anderen Reservierungen aufgehoben wurden.



# Datei locking nach POSIX



# Probleme ohne locking

- Ohne Reservierungen sind bei Parallelzugriff Inkonsistenzen und andere semantische Fehler möglich.
- Fehlertyp: Ausfall  
Gegeben Datei  $D$  und zwei Prozesse  $P_1$  und  $P_2$ :

(1)	$P_1$	liest Byte	$B = C.$
(2)	$P_2$	liest Byte	$B = C.$
(3)	$P_1$	schreibt	$B = C_1.$
(4)	$P_2$	schreibt	$B = C_2.$

- 2 Probleme:
  - Die Aktion von  $P_1$  "fällt unter den Tisch".
  - Falls (3) und (4) vertauscht ausgeführt werden, fällt Aktion von  $P_2$  weg.



# Probleme ohne locking

## ➤ Fehlertyp: Inkonsistenz

Gegeben Wort  $W = B_1B_0 = C_{11}C_{10}$

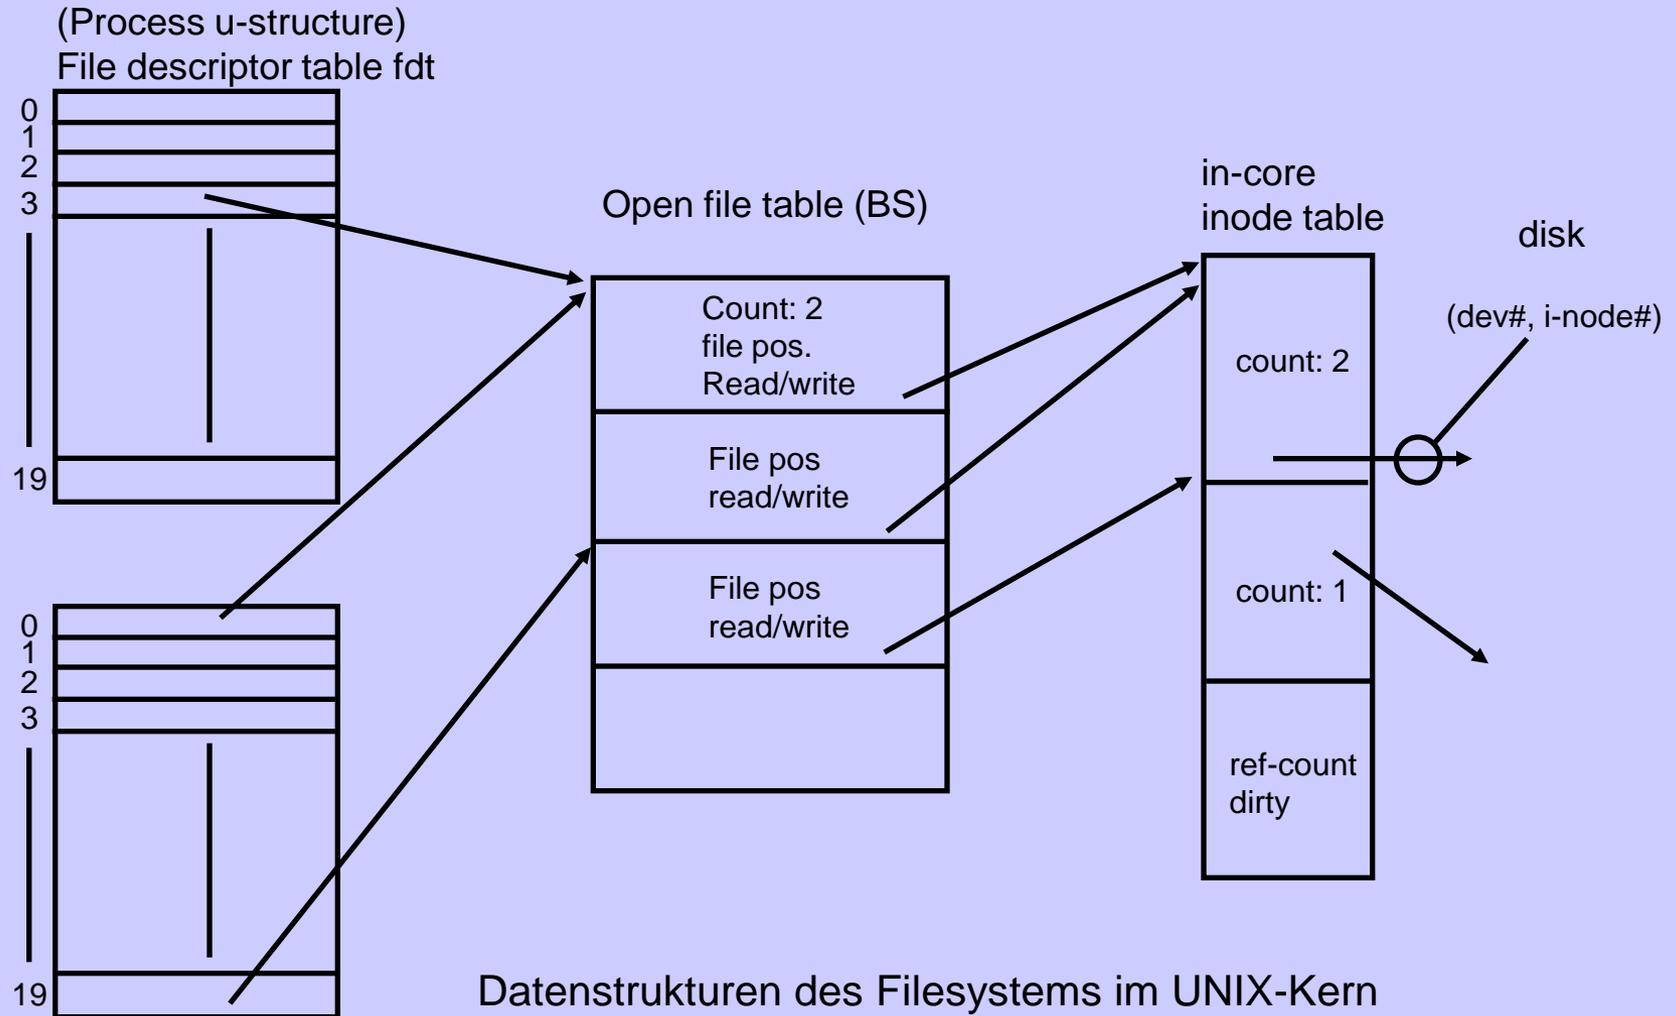
(1)	$P_1$	liest Byte	$B_0 = C_{10}$
(2)	$P_2$	schreibt	$B_0 = C_{20}$
(3)	$P_2$	schreibt	$B_1 = C_{21}$
(4)	$P_1$	liest	$B_1 = C_{21}$

## ➤ Problem:

- $P_1$  liest inkonsistentes Datum  $C_{21}C_{10}$  statt entweder  $C_{11}C_{10}$  oder  $C_{21}C_{20}$

## ➤ Grundregel: Bei Parallelverarbeitung müssen für Schreibzugriff gemeinsame Daten *immer* reserviert werden.

# Files: Zugriffs-Datenstrukturen im Kern



# Files: Zugriffs-Datenstrukturen im Kern

---

- Es gibt (mindestens) 3 Zugriffsschichten im Kern
  1. (File-)Deskriptor-Tabelle in der u.-structure jedes Prozesses
    - zur Umsetzung eines Kernel-internen (geheimen) pointers auf einen extern sichtbaren und nutzbaren Index in die Descriptor-Tabelle
  2. Open File Table global für jeden geöffneten File-Zugang
    - zum Speichern der File-Position und des Zugriffs-Modus (r/w)
    - verwandte Prozesse können sich einen File-Zugriff teilen
  3. In-Core I-node Table mit Kopie des I-nodes für jedes File, das geöffnet wurde
    - zum schnellen Zugriff auf die Verwaltungs-Info für das File selbst (Ersparnis eines Plattenzugriffs)
- Evtl. gibt es zusätzlich eine Virtualisierungsschicht
  - für den uniformen Zugriff auf unterschiedliche Dateisysteme / I-nodes



# Files und Prozesse: Deskriptoren

---

- Die Prozesse selbst greifen auf Dateien über Deskriptoren (file descriptor) zu.
- Ein Deskriptor ist ein Index in die private File-Deskriptor-Tabelle des Prozesses, die in der `u.-structure` angelegt ist. Dort stehen Verweise auf die Einträge in der globalen Tabelle aller offenen Files (open file table **ft**).
- Die ersten drei Einträge sind per default
  - **stdin** (`==0`)
  - **stdout** (`==1`)
  - **stderr** (`==2`)



# Öffnen einer Datei

---

- Vor der ersten Benutzung muss eine Datei **geöffnet** werden. Dadurch werden die Zugriffsstrukturen angelegt.
- OO-Interpretation: Das neue Objekt der Klasse Datei muss initialisiert werden.
- System-Aufruf:

```
fd = open(pathname, flags, modes)
```

`pathname` Dateiname als String.

`flags` Art des Öffnens, z.B. zum Lesen oder Schreiben.

`modes` Zugriffsrechte, falls die Datei neu geschaffen (kreiert) wird.

`fd` **File-Deskriptor**. `fd == -1` zeigt einen Fehler an.



# Öffnen und Schließen einer Datei

- System call: `fd = open(pathname, flags, modes)`
- Man muss vom Datei-Namen (`pathname`) zu einem Datei-Deskriptor kommen.
  1. Prüfe, ob der I-node der Datei bereits im in-core inode table vorhanden ist
    - Nachschlagen in der Hashtabelle aller `<Name, inode>` Paare
  2. Falls nein, finde den I-node auf der Platte (secondary storage)
    - bei absolutem Pfadnamen suche beginnend mit dem root directory
    - bei relativem Pfadnamen suche beginnend mit dem current working directory (`cwd`).
  3. Prüfe Zugriffsrechte und trage I-node in den in-core table ein.
  4. Lege Eintrag in der Open File Table an
  5. Lege Eintrag an der ersten freien Stelle in der File Descriptor Table an. Das Ergebnis `fd` ist der Index dieses Eintrags.



# Öffnen einer Datei

---

- Ist der gefundene I-node noch nicht im Kern, so wird er von der Platte in die I-node-Tabelle des Kerns geladen (incore Inode table).
- Nach Prüfen der Zugriffsrechte wird ein Eintrag in der File-Table angelegt und die Lese/Schreib-position (**offset**) initialisiert.
  - im normalen Lese/Schreibmodus: offset = Dateianfang 0
  - im Schreibanhangmodus **write-append**: offset = Größe der Datei
- Danach wird ein Verweis auf diesen File-Table-Eintrag im privaten file-descriptor table des Prozesses eingetragen und zwar an der ersten freien Stelle. Das Ergebnis fd ist dann der Index dieses letzten Eintrags.
- Es ist durchaus möglich, eine Datei zweimal zu öffnen, z.B. einmal zum Lesen und einmal zum Schreiben.



# Öffnen einer Datei

---

- `open` muss zunächst zum Dateinamen (Pfadnamen) den zugehörigen I-node finden. Hierzu werden Kataloge (*directories*) durchsucht.
  - Ein Katalog ist eine Datei mit einer Tabelle aus (Name, I-node-index) Einträgen (Abbildungsfunktion).
- Um Datei zu finden, wird die Tabelle durchsucht und der I-node Index extrahiert, dann können via I-node die Blöcke gefunden werden.
- Bei Angabe eines absoluten Pfads `/usr/ast/book` beginnt die Suche in I-node #2, dem `root` Katalog.



# Open File Table

---

- Die Zwei-Schichten-Struktur aus fdt und ft erlaubt es verschiedenen Prozessen, sich einen Zugang zu einer Datei mit einer gemeinsamen Lese/Schreib-Position zu teilen.
- Man könnte in der fdt direkt den I-node Index eintragen, tut dies aber aus folgendem Grund nicht:
  - Grundverschiedene Prozesse sollen verschiedene Dateipositionen halten können.
  - Verwandte Prozesse (z.B. shell mit 2 Kindern) sollen sich eine Dateiposition teilen können. (shell kann z.B. positionieren und Kind kann dann von dort aus lesen.)
  - Dazu dient die Beschreibungstabelle offener Dateien (**open file descriptor table** - ofdt oder auch **file table** - ft). )



# Open File Table

---

- Zwei verschiedene Prozesse können somit dieselbe Datei an verschiedenen Stellen bearbeiten.
- Da bei `fork()` mit der u-structure auch der Prozess fdt kopiert wird, haben Vater und Kind zunächst gleiche fdt-Einträge.
- Wenn der Vater die Lese/Schreibposition in der Datei verändert, sieht auch das Kind diese Veränderung (und umgekehrt). Dadurch können z.B. 2 Prozesse fortlaufende Einträge in einer Auftragsdatei abwechselnd lesen (und verarbeiten).



# Schließen einer Datei

---

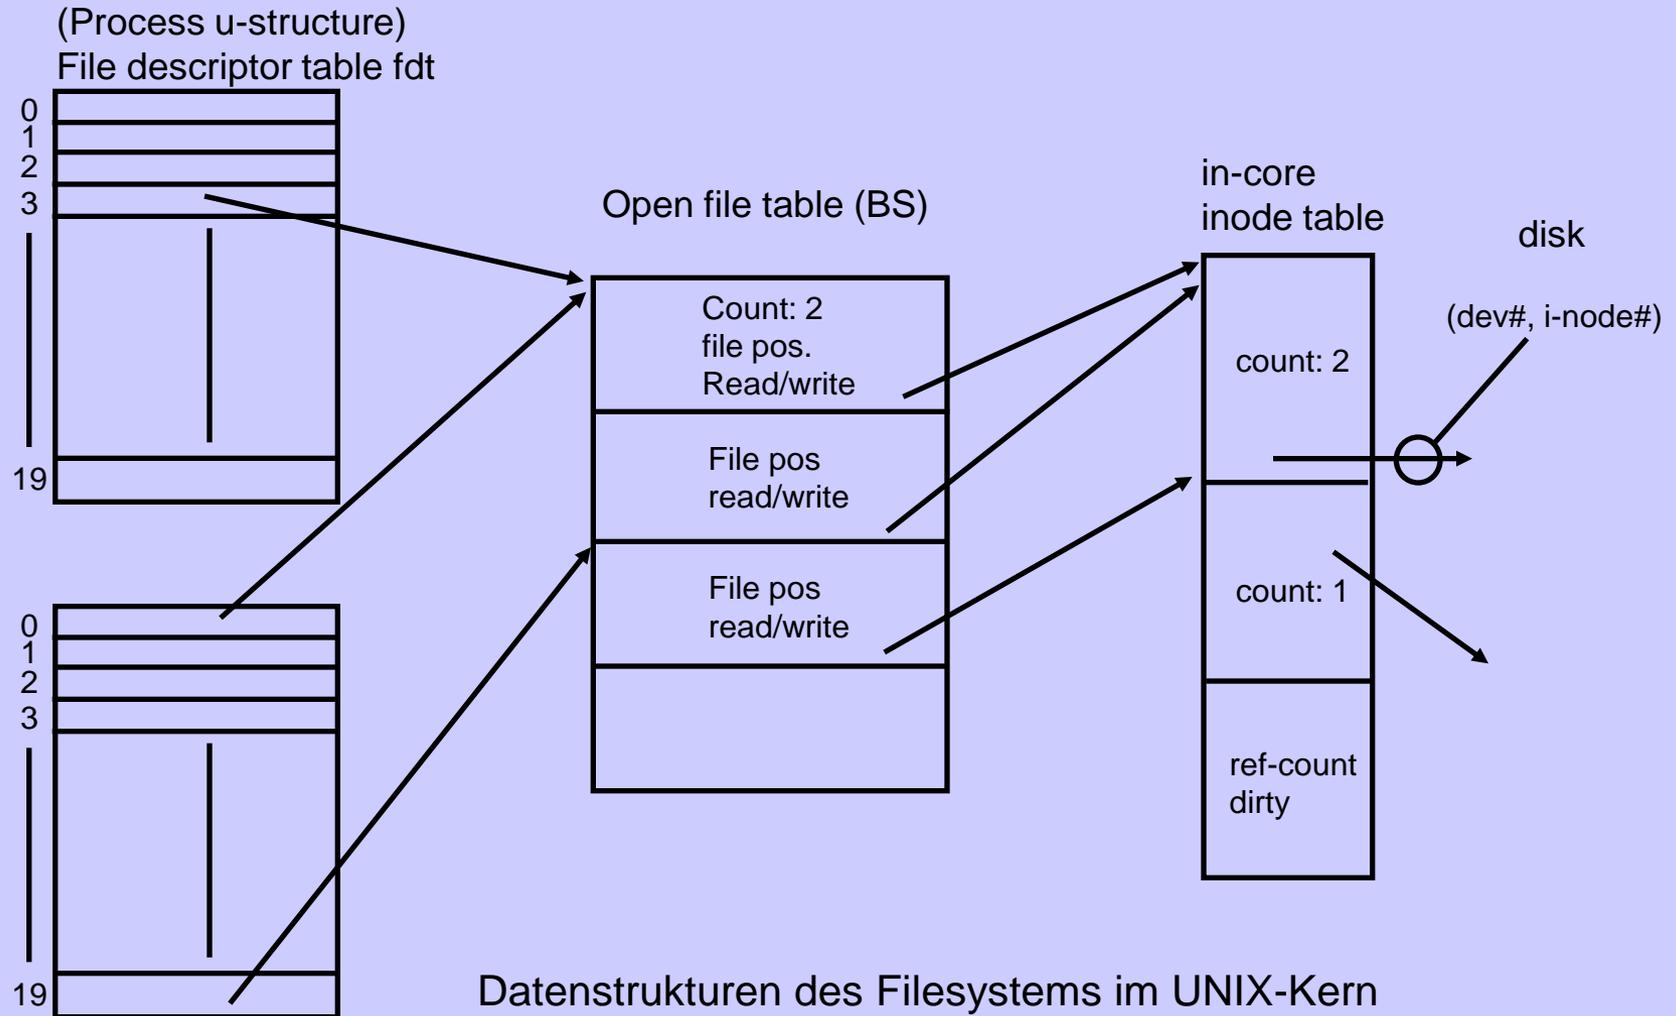
- System-Aufruf zum Schließen einer Datei mit Deskriptor `fd`:

```
close(fd)
```

- `close(fd)` löscht den Eintrag mit Index `fd` in der `fdt` und schafft so einen freien Eintrag.
- `close` ist implizit bei Programmende.
- `close` dekrementiert Referenzzähler **count** im
  - entsprechenden `ft`-Eintrag
  - im in-core `inode`
- `close` gibt Datenstrukturen frei, wenn **count** = 0 wird.



# Files und Prozesse



# Lesen von einer Datei

- Systemaufruf für das Lesen einer Datei:

```
read(fd, buffer, nbytes)
```

- Man muss von fd zum I-node kommen, von dort zum richtigen Block und darin zur richtigen Byte-Folge
  1. Ausgehend vom Eintrag an Stelle fd der Deskriptor-Tabelle finde die File-Position fpos und den I-node
  2. Finde den Block mit dem ersten Byte durch die Rechnung  $\{\text{block} = (\text{fpos} \text{ div } \text{blocksize});\}$  Hier ist div die Ganzzahldivision (der erste Block ist Block Nr. 0)
  3. Finde den offset des ersten zu lesenden Byte im Block durch die Rechnung  $\{\text{offset} = \text{fpos} \text{ mod } \text{blocksize};\}$ . Hier ist mod die modulo-Operation.
- Falls  $(\text{nbytes} + \text{offset}) > \text{blocksize}$  muss mindestens ein weiterer Block gelesen werden



# Verschieben der Position des File-Pointers

- Files sind normalerweise auf Platte realisiert und bestehen aus Blöcken. Repositionierung des FilePointers ist deshalb oftmals effizienter möglich, als dies das rein sequentielle File Modell impliziert.
- In UNIX gibt es hierzu den System-Call **lseek**.

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

- Der File-Pointer kommt an die Position `offset`, die in Abhängigkeit des `whence` Flags vom File-Anfang, der jetzigen Position oder dem File-Ende aus gerechnet wird.
  - `off_t` wird in `sys/types.h` als `long` definiert.



# Duplizieren eines Deskriptors

---

- Man kann `stdin` und `stdout` durch andere Files ersetzen (redirecting standard input / output)
- Hierzu schließt man `stdin` (bzw. `stdout`) und schafft so einen freien Eintrag in der Deskriptortabelle
- Danach dupliziert man den Deskriptor des gewünschten Files:

```
newfd = dup(fd)
```

- Eine Kopie des Eintrags mit Index `fd` wird im ersten freien Platz der Deskriptorstelle untergebracht, sein Index in `newfd` übergeben.
- Beispiel:  
`close(stdin); newfd = dup(3);`  
→ File # 3 nimmt den Platz von `stdin` ein.

