J UNIX-Dateisystem

J.1 Funktionalität

- Abstraktionen für Benutzersicht:
  1. Pfade, Dateinamen
  2. Dateibaum verdeckt mehrere Platten (bzw. Partitionen)
  3. Dateien = unstrukturierte Byteströme
  4. *special files* fast wie reguläre Dateien zugreifbar
- diese Abstraktionen müssen vom Dateisystem auf konkrete Objekte abgebildet werden
- den obigen Abstraktionen entsprechen etwa folgende Objekte:
  1. / 2. Plattenpositionen, Adressen von Gerätecontrollern, etc.
  3. Platten verwalten Sektoren, Spuren und Zylinder
  4. unterschiedliche Gerätetreiber werden für E/A-Operationen auf verschiedenen Peripheriegeräten benötigt

J.2 Directories (Kataloge)

- wichtigster Bestandteil zum Aufbau eines hierarchischen Dateisystems
- Funktion: Strukturierung des Namensraums
- *Directories* enthalten Verweise auf Inodes (von Dateien oder weiteren Directories)

J.3 Inodes

- ein Inode enthält alle Informationen, die zur Verwaltung einer Datei und zum Auffinden ihres Inhalts benötigt werden
- beim Öffnen einer Datei werden die Inode-Daten von der Platte ***(disk inode)*** in die Inode-Tabelle des Systemkerns ***(in-core inode)*** gelesen

1 Umwandlung: Pfad : Inode

J.3 Inodes

- Root = Inode 2
- Inode-Nummer ist nur in dem Directory zu finden, in dem die Datei eingetragen ist
  - ➥ die Pfadkomponenten müssen einzeln bearbeitet werden
  - ➥ um den Inode der jeweils nächsten Pfadkomponente zu bestimmen, muß der Inhalt des voranstehenden Directories eingelesen werden
- Systemkern-Funktion: ***lookup( )***
- Directory Lookup Cache zur Beschleunigung
  - ◆ LRU Cache mit Einträgen
    Directory-Inode-Nummer / Datei(name) in Directory / Inode der Datei

1 Umwandlung: Pfad : Inode (2)

J.3 Inodes

- Berücksichtigt werden hierbei:
  - ◆ Symbolic Links
    - – werden beim Absteigen im Baum verfolgt
  - ◆ Mount-Punkte
    - – beim Absteigen im Baum am Mount-Punkt Wechsel zur *root* des eingehängten Dateisystems
    - – beim Aufsteigen im Baum (über "..") an der Root eines Dateisystems Wechsel auf den Mount-Punkt
  - ◆ Current Root
    - – Überschreiten beim Aufsteigen im Baum (über "..") wird verhindert

Datei öffnen

- Aufruf:

```
fd = open(path, flags, modes);
```

fd	Filedescriptor (kleiner Integer-Wert)
path	Pfadname der Datei
flags	Angabe über Zugriffsform (lesen, schreiben, lesen+schreiben), ob Datei neu erzeugt / vorher gelöscht wird
modes	Zugriffsrechte, falls die Datei neu erzeugt wird

Datei öffnen (2)

- open-Algorithmus

in-core inode zu Pfadnamen erzeugen ***(namei, lookup)*** (Inode suchen und einlesen)	
Datei existiert nicht oder keine Zugriffsrechte	
ja	nein
in-core Inode freigeben	***file table*** entry für Inode belegen ***count*** und ***offset*** initialisieren
return(Fehler)	
	user file descriptor belegen, Zeiger auf ***file table*** *entry* setzen
	falls ***truncate***, alte Blöcke freig.
	return(***user file descriptor)***

Datei öffnen (3)

- Kontrollstrukturen (früher)

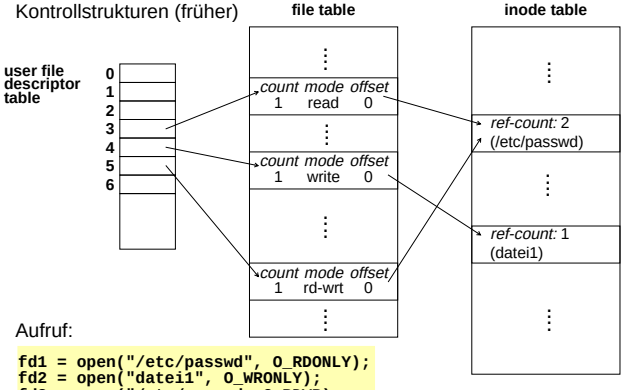

- Aufruf:

```
fd1 = open("/etc/passwd", O_RDONLY);
fd2 = open("datei1", O_WRONLY);
fd3 = open("/etc/passwd, O_RDWR);

-> fd1 == 3, fd2 == 4, fd3 == 5
```


Datei öffnen (4)

- **user file descriptor table**
  - Feld von Zeigern auf Einträge in der ***file table***
  - Teil der ***user-area*** des Prozesses
    `struct file *u_ofile[NOFILE]`
    siehe *<sys/user.h>*
  - Filedescriptor (aus ***open(2)***) ist ein Index in diese Tabelle
    - ➥ Entkopplung von Systemdatenstrukturen und Benutzerdaten
      Filedeskriptor = Capability
      (Sicherheit!)
- **file table**
  - Feld von ***file***-Strukturen (siehe *<sys/file.h>*), enthält
    - ➤ Zeiger auf Eintrag in der ***inode table***
    - ➤ Eintrag für Zugriffsmodus
    - ➤ Schreib/Lesezeiger (offset)
    - ➤ Referenzzähler

2 Datei öffnen (5)

- **inode table**
  - Feld von ***in-core inodes*** (siehe *<ufs/inode.h>*), enthält
    - Referenzzähler
    - Info über physikalisches Gerät (Platte, Partition)
    - *disk inode* Struktur
    - Informationen für ***lock***-Funktionen (***flock(2), lockf(2)***)

3 Kontrollstrukturen und Systemaufruf *dup( )*

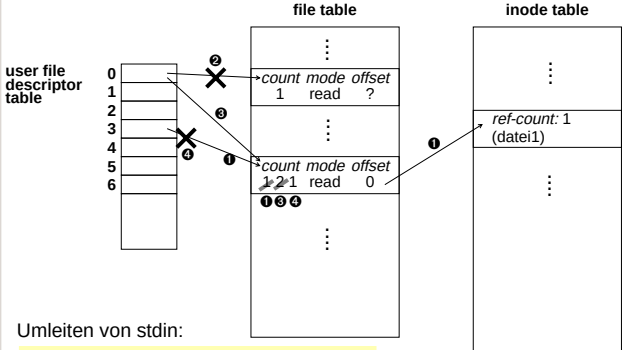

- Umleiten von stdin:

```
❶ fd1 = open("datei", O_RDONLY);
❷ close(0);
❸ dup(fd1);
❹ close(fd1);
```


4 Kontrollstrukturen und Systemaufruf *fork( )*

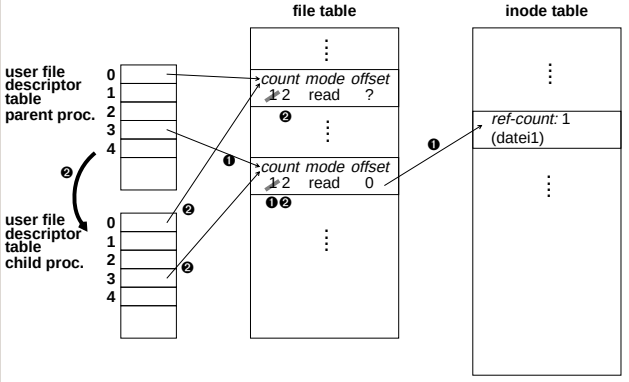


```
❶ fd1 = open("datei", O_RDONLY);
❷ fork( );
```


J.4 Vnodes

1 Motivation

- Inode = konkrete Implementierung eines Dateiverwaltungsblocks eines speziellen Dateisystems
- Problem: unterschiedliche Dateisysteme in einem UNIX-System
  - S5 – SystemV-File-System
  - UFS - UNIX-File-System
  - NFS - Network File-System
  - specFS - special File-System (Gerätedateien, FIFO-Dateien)
- ➥ unterschiedliche Implementierung (Inode, *lookup*-Funktion, …)

- Lösung: **Vnode** = abstrakte Darstellung einer Datei
  - ➥ definiert Operationen auf Dateien
    - ➤ *open, close, read/write, lookup, ...*
  - ➥ + allgemeine Zustandsinformationen
    - ➤ Dateityp (*regular file/directory*)
    - ➤ Referenzzähler
    - ➤ Verwaltungsinformationen für *locking* etc.
    - ➤ Zeiger auf konkrete Operationen und konkreten Zustand
- konkrete Darstellung einer Datei
  - ➥ Implementierung der Operationen
    - ➤ *ufs_open, ufs_close, ufs_read, ufs_lookup, ...*
  - ➥ + konkreter Zustand
    - ➤ *in-core Inode*

Aufbau eines Dateisystems auf einer Disk

1 SystemV-Dateisystem

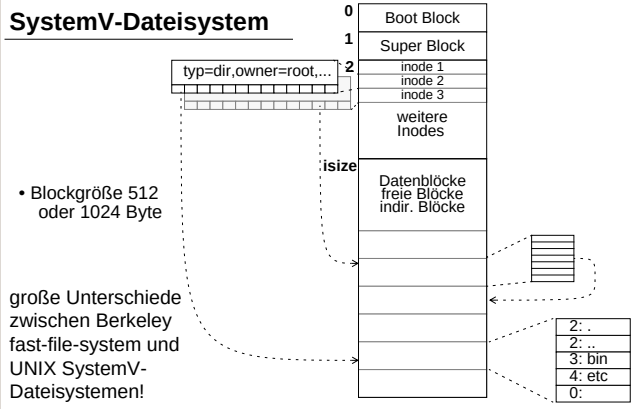

- Blockgröße 512 oder 1024 Byte

- große Unterschiede zwischen Berkeley fast-file-system und UNIX SystemV-Dateisystemen!

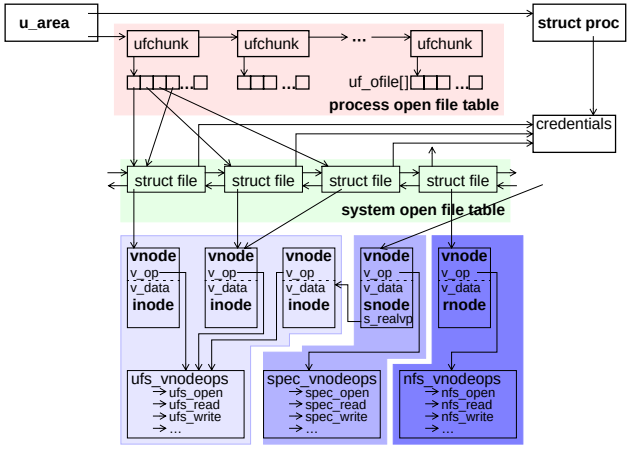

- Super-Block
  - ◆ Der *Super-Block* enthält die Verwaltungsinformationen für ein Dateisystem
    - ➤ Größe
    - ➤ Anzahl der freien Blöcke
    - ➤ Liste freier Blöcke *(free block list)*
    - ➤ Zeiger auf nächsten freien Block in der *free block list*
    - ➤ Größe der Inode-Liste
    - ➤ Anzahl freier Inodes
    - ➤ Liste freier Inodes *(free inode list)*
    - ➤ Zeiger auf ersten freien Inode
    - ➤ Lock-Felder für *free block* und *free inode list*
    - ➤ *modified flag* für Super-Block

2 Berkeley Fast File System (UNIX File System — UFS)

- für UNIX 4.2bsd entwickelt - effizienter als SystemV-Dateisysteme
- Blockgröße minimal 4k, meist 8k
  - ⇒ über zweifach indirekte Blöcke können bis zu 64 GB adressiert werden
- Directories anders aufgebaut - Dateinamen bis zu 255 Zeichen lang
- Dateisystem in ***cylinder groups*** aufgeteilt (*cylinder group* = Gruppe von aufeinanderfolgenden Zylindern auf Platte, häufig 16)
- pro *cylinder group* werden folgende Daten gehalten:
  - Backup-Kopie des Superblocks
  - Bitmap für freie Blöcke (statt *free list*)
  - Inodes
  - Datenblöcke

2 Berkeley Fast File System (2)

- Um Verschnitt gering zu halten, können Blöcke in 2, 4 oder 8 ***Fragmente*** aufgeteilt werden, die einzeln adressierbar sind
- Eine Datei wird - wenn möglich - in einer *cylinder group* gehalten

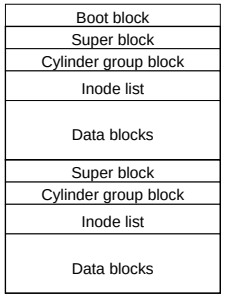

J.6 Virtuelles Dateisystem

1 Überblick

- Vnodes bilden Schnittstelle zu dateisystemunabhängigen Operationen auf Dateien
- das *Virtual File System* (**VFS**) stellt eine vergleichbare Schnittstelle für Operationen auf Dateisystemen zur Verfügung — z. B.
  - ***vfs_mount***, ***vfs_unmount***
  - ***vfs_statvfs*** Statistikdaten ermitteln
  - ***vfs_root*** root-vnode ermitteln
  - ***vfs_sync*** gepufferte Daten schreiben
- Implementierung durch VFS-switch-Tabelle
  - Dateisystemname, Initialisierungsfunktion, ***vfsops*** — Feld mit Zeigern auf die FS-Funktionen

2 Mount-Mechanismus

- über die mount-Funktion wird der root-Vnode eines Dateisystems auf einen Directory-Vnode des bestehenden Dateibaums montiert
  - Systemkern verwaltet die montierten Dateisysteme in verketteten *vfs*-Strukturen
  - über die vfs-Struktur kann ermittelt werden:
    - ➤ auf welchen Vnode das Dateisystem montiert ist
    - ➤ der root-Vnode des Dateisystems
  - Vnode des Mount-Punkts (Directory) enthält Eintrag mit Zeiger auf vfs-Datenstruktur des montierten Dateisystems

- Kontrollstrukturen

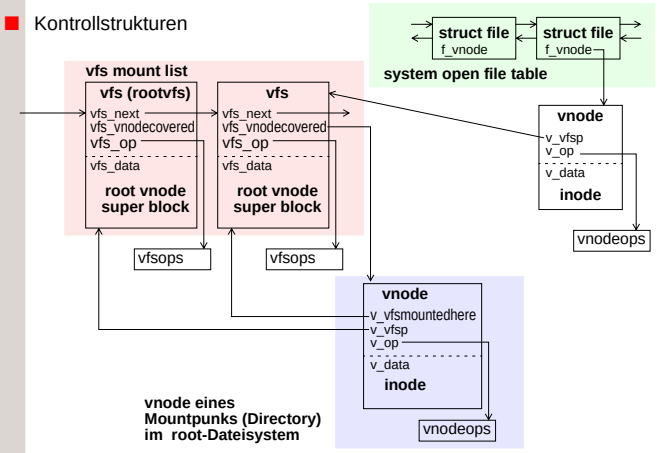

- *lookup*-Funktion des UNIX-Kerns berücksichtigt bei Pfad-Vnode-Umwandlung Mount-Punkte
  - ist in einem vnode *vfs_mountedhere* gesetzt, wird der Vnode beim Abstieg im Pfad durch den *root-vnode* des *VFS* ersetzt
  - ein *root-vnode* eines *VFS* wird bei Verfolgung von ".." durch *vfs_vnodecovered* des *VFS* ersetzt
  - an Directory-Einträgen ändert sich nichts

➥ an Mount-Punkten Diskrepanz zwischen Directory-Einträgen und Ergebnis von ***stat(2)***

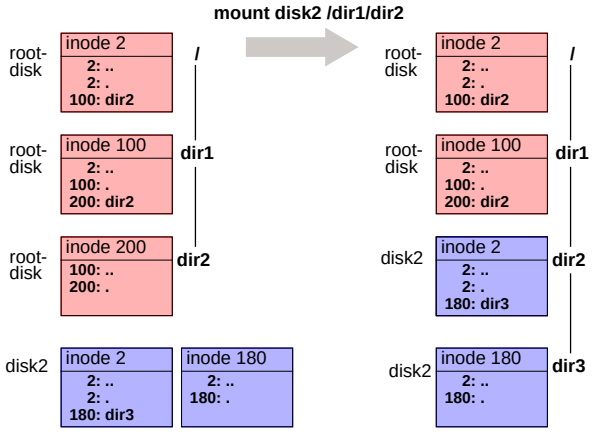

J.7 Network File System (NFS)

1 Überblick

- 1984 von Sun Microsystems Inc. entwickelt
- NFS ermöglicht, Teilbäume von Dateisystemen anderer Rechner in das lokale Dateisystem einzuhängen ***(mounten)***
- ein Teilbaum eines *Remote*-Dateisystems verhält sich dadurch genau so, wie eine Partition einer lokalen Platte, die mit einem ***mount***-Befehl in den Dateibaum eingehängt wurde
- die Dateien des *Remote*-Dateisystems können mit den gleichen Kommandos und Systemaufrufen wie lokale Dateien bearbeitet werden

1 Überblick (2)

- Abweichungen von der UNIX-Dateisemantik:
  - ***special files*** (Geräte-Dateien) sind nicht erreichbar
  - es werden nicht alle Systemdienste unterstützt (z. B. *File-locks*)
  - ***append***-Modus beim Öffnen einer Datei nicht möglich
  - wenn ein Dateisystem voll ist, wird dies nicht unmittelbar mitgeteilt
- auf der *Client*-Seite sind die NFS-Funktionen in den UNIX-Systemkern integriert **(virtuelles Dateisystem - *VFS*)**
- NFS-*Server* können, müssen aber nicht im Betriebssystem-Kern ablaufen
- Kommunikation zwischen *NFS-Client* und *-Server* erfolgt über ***SUN-RPC*** *(Remote Procedure Calls),* aufbauend auf ***UDP/IP*** oder (Solaris 2.5, 4.4bsd) ***TCP/IP***

2 Beispiel

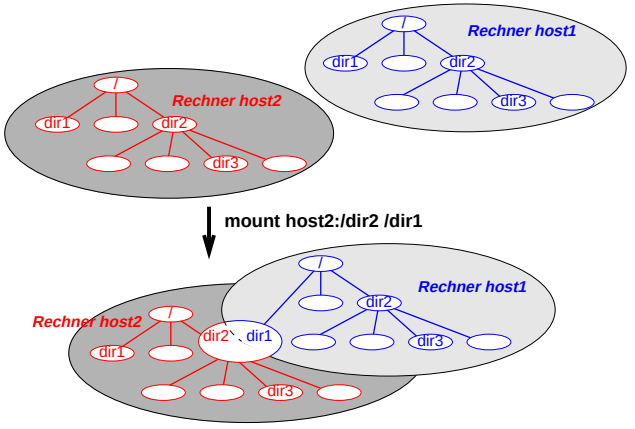

1 Überblick (3)

- *NFS-Server* sind zustandslos, d. h. sie halten keine Informationen über frühere Aufträge eines *Clients* (z. B. welche Dateien geöffnet, welche Position in einer Datei)
  → problemloser Neustart nach Systemabstürzen
- standardisierte Datendarstellung für Datenaustausch zwischen unterschiedlichen Rechnerarchitekturen:
  XDR *(e**X**ternal **D**ata **R**epresentation)*
- die Spezifikationen für NFS, XDR und RPC ist *public domain*, d. h. frei erhältlich - nicht jedoch die Implementierungen
- Programme werden immer auf dem *aufrufenden* Rechner ausgeführt
  - Betrieb von *diskless workstations* möglich
- Probleme bei unterschiedlichen Rechnertypen - unterschiedlich übersetzte Programme *(Binaries)* notwendig

3 Sicherheitsaspekte

- Dateisysteme müssen explizit exportiert werden um von anderen Rechnern *gemountet* werden zu können
  - der Systemverwalter des exportierenden Rechners kann festlegen, welche Rechner welches Dateisystem von ihm importieren dürfen
  - bei ***secure NFS*** kann darüber hinaus auch spezifiziert werden, welche Benutzer des anderen Rechners zugreifen dürfen
- die Benutzerabbildung erfolgt in UNIX über die *User-Id*
  - Beispiel: der Benutzer mit der *User-Id* 129 auf Rechner *host1* hat in einem Dateisystem, das von Rechner *host2* importiert ist, genau die Rechte, die der Benutzer mit *User-Id* 129 auf dem Rechner *host2* hat
- Der *Super-User* (*User-Id* 0) wird auf den Benutzer *nobody* abgebildet (die *Super-User*-Abbildung kann pro exportiertes Dateisystem/ Zielrechner auch explizit festgelegt werden)

4 Implementierung

- NFS-Server erzeugen beim ***nfs_open()*** ein **file-handle** (Kombination aus Filesystem/Device-Id und Inode) und übergeben dies dem NFS-Client
  - es werden auf Server-Seite keine Informationen gehalten!
  - bei jedem Lese-/Schreib-Zugriff wird die Datei auf Basis der file-handle-Informationen neu geöffnet
- NFS-Client benutzt file-handle für alle weiteren Zugriffe auf die geöffnete Datei (Block lesen/schreiben)
  - file-handle wird im **rnode**-Teil des vnode gespeichert
  - Offset-Informationen sind in der file-Struktur vorhanden
  - vfs-Struktur enthält die Adresse des NFS-Servers

4 Implementierung (2)

- Besonderheiten:
  - wird eine Datei auf Client-Seite gelöscht, obwohl noch Prozesse gültige Dateideskriptoren darauf halten:
    - ➤ wird sie auf der Serverseite nur umbenannt (nfs_...)
    - ➤ wird sie erst endgültig gelöscht, wenn die letzte Referenz auf den vnode auf der Client-Seite geschlossen wird

J.8 Block-Puffer Cache

1 Verwaltungsstrategien

- Pufferverwaltungssystem mit Verwaltungsalgorithmen, ähnlich denen in einem Paging System (nicht demand paging!) mit folgenden Eigenschaften:
  - **read ahead**
    wird ein Block gelesen, so werden auch der Transfer des folgenden Blocks angestoßen (wenn sequentiell gelesen wird)
  - **write after**
    wird ein Block geschrieben, bedeutet dies nicht den sofortigen physikalischen Transfer auf die Platte
  - **geschrieben** wird u. a. bei folgenden Ereignissen:
    - ➤ Datei wird geschlossen
    - ➤ keine freien Puffer mehr vorhanden
    - ➤ vom System *(clock)* wird ein ***update*** angestoßen
    - ➤ Systemaufruf ***sync(2)*** oder ***fsync(2)*** (BSD)

1 Verwaltungsstrategien (2)

- werden ausgelagerte Blöcke, deren Puffer noch nicht anderweitig benutzt wurde, erneut angesprochen, so werden sie reaktiviert ***(reclaim)***
- wenn zur Gewinnung von freien Blöcken eine Auslagerung angestoßen wird, werden die Kandidaten für die Freiliste nach dem LRU-Algorithmus ausgewählt

2 Integration von Buffer Cache und Speicherverwaltung

- Ab SystemV R4 werden die Puffer des Dateisystems mit dem normalen Paging-System verwaltet
  - Dateiblöcke werden in virt. Adreßraum des Kerns abgebildet
  - Daten werden dann einfach aus Kern in User-level Adreßraum kopiert
    - ➤ Page-fault bewirkt Einlagerung der Seite aus der Datei (über vnode-Operationen des jeweiligen Dateisystems)

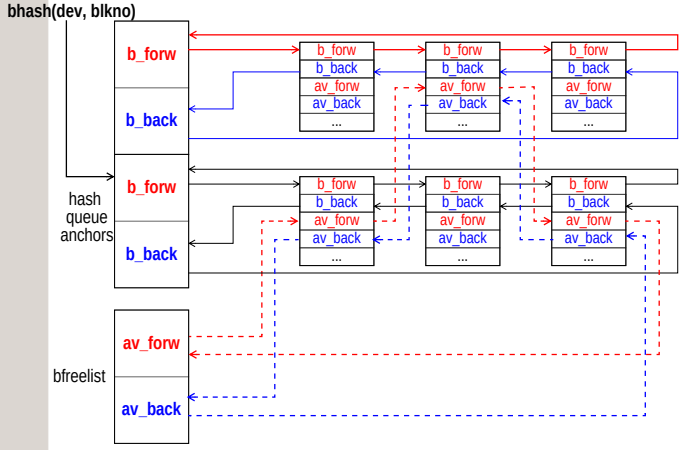

1 Kontrollfluß

```
sysent-table
  read(u.u_ap)      (u_ap = fd, buf, count)
    buf, count -> uio
    rwuio(uio, READ)
      fp = GETF(fd)        (Zeiger of open file table besorgen)
      uio = { fp->f_mode, fp->offset }
      fops-switch ──────► sockets
      vnodes
        vno_rw(fp, rw, uio)
          vp = fp->f_data      (vnode-Struktur aufbauen)
          iomode = 0 | APPEND | SYNC
          vnode-switch ──────► NFS
                       ──────► specFS
          UFS
            ufs_rw(vp, uio, rw, iomode, ...)
              ip = VTOI(vp)      (inode-pointer aus vnode besorgen)
              rwip(ip, uio, rw, iomode)
                lblock = uio->offset/bsize    (logische Blocknr.)
                pblock = bmap(lblock)         (phys. Blocknr.)
                bread(vp, pblock, bsize)
                  :
                uiomove( ... )
                  gelesenen Block in Benutzeradreßraum
                  kopieren
              ja  weiterer Block zu lesen?
```


- in BSD4.4 sind die Puffer zusätzlich an den *vnodes* verankert
- Buffer-Header (struct buf, siehe *<sys/buf.h>)*

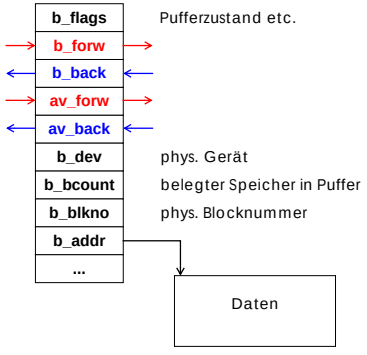

J.10 Treiber

1 Überblick

- Jede Gerätedatei entspricht einem physischen oder virtuellen Gerät
- bei den physischen Geräten werden zwei Ein-Ausgabesysteme unterschieden:
  - zeichenorientierte E/A (Terminals, Drucker)
  - blockorientierte E/A (vor allem Platten)
- für jedes Ein-Ausgabesystem existiert ein:
  - Puffersystem
  - Treiberfunktionsvektor, *cdevsw* und *bdevsw*

1 Überblick (2)

- Für jeden Gerätetyp ist in mindestens einem dieser Vektoren eine Zeile mit den gerätespezifischen Operationen reserviert
- Jedes Gerät ist mit dem Tripel (E/A-Typ, *major number*, *minor number*) eindeutig beschrieben
  - E/A-Typ wählt Funktionsvektor aus
  - *major number* wählt die zugehörige Zeile im Funktionsvektor aus
  - *minor number* dient im gerätespezifischen Kontrollblock des Treibers als Index zur Identifikation des Geräts

2 Treiber-Funktionsvektoren

- *block-device-switch*:

```
struct bdevsw {
        int         (*d_open)();
        int         (*d_close)();
        int         (*d_strategy)();
        int         (*d_dump)();
        int         (*d_psize)();
        int         d_flags;
};
```

  - *read*- und *write*-Aufrufe werden über den Block-Puffer abgewickelt
  - die *strategy*-Funktion regelt die E/A-Operation zwischen Block-Puffer und Gerät
  - *major*- und *minor number* werden im Inode gespeichert

2 Treiber-Funktionsvektoren (2)

- *character -device-switch*:

```
struct cdevsw {
        int     (*d_open)();
        int     (*d_close)();
        int     (*d_read)();
        int     (*d_write)();
        int     (*d_ioctl)();
        int     (*d_reset)();
        int     (*d_select)();
        int     (*d_mmap)();
        struct  streamtab *d_str;
};
```

  - im Falle von *Streams*-Treibern sind alle Komponenten leer - nur die *streamtab*-Komponente enthält einen Verweis auf die Struktur der *Streams*-Verwaltung
- Block-orientierte Geräte (z. B. Platten) haben in der Regel einen zweiten Eintrag als zeichen-orientiertes Gerät um direkte Zugriffe unter Umgehung der Block-Puffer zu ermöglichen

2 Treiber-Funktionsvektoren (3)

- der Systemaufruf *mknod* legt im Dateisystem Knoten für die Gerätedateien an
- Beispiel aus /dev

```
% ls -l /dev
crw--w--w-  1 root      0,   0 Feb  5 12:38 console
crw-r-----  1 root      3,   1 Dec  2 11:48 kmem
crw-rw-rw-  1 root     13,   0 Sep 15  1988 mouse
crwx-w----  1 eckert   20,   5 Feb  5 12:07 ttyp5
crw-rw-rw-  1 root     21,   5 Feb  5 12:06 ptyp5
brw-r-----  1 root      7,   1 Sep 15  1988 sd0b
crw-r-----  1 root     17,   1 Sep 15  1988 rsd0b
brw-r-----  1 root      3,   0 Dec  2  1988 xy0a
crw-r-----  1 root      9,   0 Jan 10 10:34 rxy0a
crw--w--w-  1 root     12,   0 Feb  5 12:11 ttya
crw--w--w-  1 root     12,   1 Jan 11 09:58 ttyb
```

2 Treiber-Funktionsvektoren (4)

- Auszug aus der Konfigurationsdatei des Systemkerns

```
struct bdevsw   bdevsw[] =
{
  { nodev,    nodev,    nodev,      nodev,     /*0*/
    0,        0},                     /* was ip */
  { tmopen,   tmclose,  tmstrategy, tmdump,    /*1*/
    0,        B_TAPE },
  { nodev,    nodev,    nodev,      nodev,     /*2*/
    0,        B_TAPE},                /* was ar */
  { xyopen,   nulldev,  xystrategy, xydump,    /*3*/
    xysize,   0 },
  ...
  { sdopen,   nulldev,  sdstrategy, sddump,    /*7*/
    sdsize,   0 },
  ...
}
```


J.11 Hintergrundspeicher

1 Organisation einer Disk - Laufwerk

- typische Winchester-Festplatten bestehen aus mehreren, übereinander angeordneten Magnetplatten und einem Schreib-/Lese-Kopf pro Plattenoberfläche

- Begriffe:

Spur *(Track)*	Umlaufbahn auf einer Diskoberfläche
Sektor	Teil einer Spur
Zylinder	Menge der Spuren mit gleichem Radius über alle Oberflächen

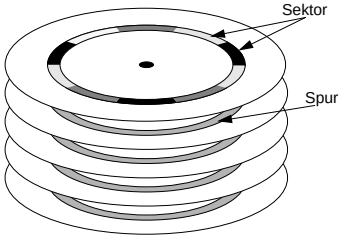

1 Organisation einer Disk - Laufwerk (2)

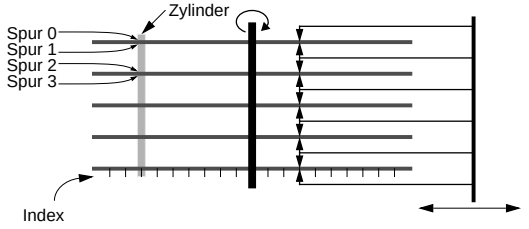

1 Organisation einer Disk - Laufwerk (3)

- Beispiele realer Disks:

	Fujitsu			*Seagate*	
	M2344K	*M2652*	*Elite9*	*Elite47*	*Cheetah18*
	1987	1990	1994	1998	1998
	9"	9"	5,25"	5,25"	3,5"
Bussystem:	SMD	IPI	SCSI-2	Ultra SCSI	Fibre
Kapazität:	690 MB	2,0GB	10,8GB	47 GB	18GB
Zylinder:	624	1893	4925	9996	6962
Spuren/Zyl.:	27	20	27	28	24
Bytes/Spur:	40960	52864	variabel		
Sektoren/Spur:	1 - 128 (konfigurierbar)				
Positionierzeit:					
(Spur-Spur)	4 ms	2 ms		1,1 ms	0,6 ms
(mittel)	16 ms	11 ms	11 ms	13 ms	5,7 ms
(max)	33 ms	22 ms		28 ms	12 ms
Transfer MB/s:	2,458	4,75	6 - 7	40	200
Umdr./Min.:	3600	5400	5400	5357	10025

➥ was bedeutet das konkret (z.B. bei Elite9)?
- eine Umdrehung = 11 ms
- bei DEC Alpha (300 MHz, 2 Instr./Takt = 600 Mio/Sek.) ca. 6,6 Mio. Befehle ausführbar

2 Organisation einer Disk (SCSI)

- Platte = Sequenz von Datenblöcken (perfect media)
- lokaler Pufferspeicher (z. B. 1-4 MB) für Optimierungsstrategien (da Bus schneller als Medium-Transfer)

3 Organisation einer Disk — Betriebssystem

- UNIX kann eine Disk in **Partitionen** unterteilen
  - ➥ auf jeder Partition kann ein UNIX-Dateisystem angelegt werden
- jedes UNIX-Dateisystem enthält eigene, von anderen Partitionen unabhängige Inodes
- aus diesen Inodes wird auf jedem UNIX-Dateisystem über Directories ein eigener, hierarchisch aufgebauter Dateibaum erzeugt
- mehrere solche Bäume können durch ***mounten*** zu einem Dateibaum zusammengefaßt werden

3 Organisation einer Disk — BS (2)

- die Position der einzelnen Partitionen wird festgelegt:
  - in älteren UNIX-Systemen statisch im Kern
  - in neueren UNIX-Systemen in Tabelle (*VTOC - Volume Table of Contents*) am Anfang der Platte (z. B. Zyl. 0, Spur 0, Sekt. 0)
- Partitionierung am Beispiel Solaris

```
Current partition table (original):
Total disk cylinders available: 2733 + 2 (reserved cylinders)

Part      Tag  Flag     Cylinders     Size          Blocks
 0        root  wm       0 -  101    75.70MB  (102/0/0)   155040
 1        swap  wu     102 -  446   256.05MB  (345/0/0)   524400
 2      backup  wm       0 - 2732     1.98GB  (2733/0/0) 4154160
 3  unassigned  wm       0            0       (0/0/0)          0
 4  unassigned  wm       0            0       (0/0/0)          0
 5  unassigned  wm       0            0       (0/0/0)          0
 6         usr  wm     447 - 2732     1.66GB  (2286/0/0) 3474720
 7  unassigned  wm       0            0       (0/0/0)          0
```


3 Organisation einer Disk — BS (3)

- den einzelnen Partitionen sind jeweils *block special files* **(/dev/dsk)** und *character special files* **(/dev/rdsk)** zugeordnet
  - ➥ über diese Dateien sind *major-number* (=Disk-Typ) und *minor-number* (=Partition) zur Interaktion mit dem Treiber feststellbar
  - ➥ die *block special files* sind in *mount*-Kommandos verwendbar
  - ➥ über die *character special files* ist ungepufferter Zugriff auf eine Partition möglich (z. B. für file system check)
  - ➥ Beispiel Solaris:

```
% ls -lL /dev/dsk
brw-r-----   1 root      32,   0 Oct 23 17:21 c0t0d0s0
brw-r-----   1 root      32,   1 Oct 23 17:21 c0t0d0s1
brw-r-----   1 root      32,   2 Oct 23 17:21 c0t0d0s2
...
brw-r-----   1 root      32,   6 Oct 23 17:21 c0t0d0s6
brw-r-----   1 root      32,   7 Oct 23 17:21 c0t0d0s7

% fsck /dev/rdsk/c0t0d0s6
% mount /dev/dsk/c0t0d0s6 /usr
```


4 Disk-Zugriffsstrategien

- die Verwaltungsstrategien des *Buffer Cache* haben u. a. zwei Auswirkungen auf den Platten-Treiber
  - ◆ weniger Plattenzugriffe bei häufigen Operationen auf einer Datei
  - ◆ Anforderungen an den Plattentreiber kommen nicht einzeln, sondern immer in Gruppen (z. B. wenn Auslagerung angestoßen wurde)
- der Plattendurchsatz kann gesteigert werden, wenn die Anforderungen geeignet sortiert werden
- Problem bei modernen Disks:
  - ➤ Disk hat internen Pufferspeicher und fährt eine eigene Strategie für Zugriffe auf das Medium

4 Disk-Zugriffsstrategien (2)

- mögliche Strategien:
  - **FIFO**
    - \+ Aufträge werden fair behandelt
    - – Plattenzugriffe nicht optimal, da viele Positionierungen erforderlich
  - **SATF** *(shortest access time first)*
    - \+ optimiert die Positionierungen des Plattenarms
    - – bei vielen Aufträgen für einen begrenzten Bereich können aber Aufträge für entferntere Positionen ausgehungert werden
  - **SCAN**
    - \+ Aufträge werden nach Zylinderpositionen sortiert, so daß der Plattenarm der Reihe nach über alle Positionen bewegt wird
    - – viele Aufträge für einen kleinen Bereich benachteiligen entfernte Aufträge
  - gemischte Strategien
    z. B. SATF über die ersten 8 Aufträge → Mischung aus SATF und FIFO

J.12 Disk-Treiber: Datenstrukturen und Kontrollfluß

1 Überblick

- Jedem Gerät (Platte) ist eine Warteschlange für Puffer des Buffer-Caches zugeordnet
- Puffer für Aufträge an den Disktreiber werden in die Warteschlange des zugehörigen Geräts einsortiert (*disksort( )*)
- Disktreiber entnimmt für freie Geräte Aufträge und startet den Controller
- bearbeitete Aufträge werden durch Interrupt gemeldet
  - ➥ Interrupt-Bearbeitung
    - – eigener Aktivitätsträger
    - – unabhängig von den beauftragenden Prozessen!
      - • weckt wartende Prozesse
      - • startet nächsten Auftrag aus Warteschlange

2 Datenstrukturen

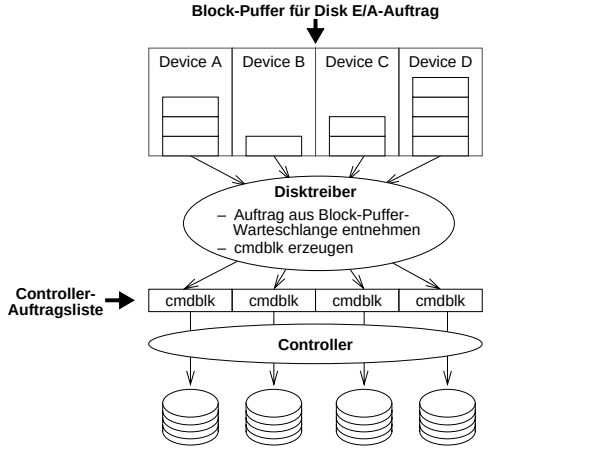

3 Kontrollfluß