Betriebssystem-Entwicklung mit Literate Programming

Foliensatz 11: Dateisysteme

Wintersemester 2014/15

Hans-Georg Eßer

h.g.esser@cs.fau.de
http://ohm.hgesser.de/

v1.1, 16.12.2014

Dateisysteme (1)

- Frühe Betriebssysteme (CP/M, MS-DOS etc.):
  - ein einziges (logisches) Dateisystem, z. B. FAT
  - Support für wenige Gerätekategorien (z. B. nur Floppy-Laufwerke)
  - Code für Hardware-Zugriff und logische Behandlung des Dateisystems vermischt
- Moderne Betriebssysteme (Linux, Windows etc.):
  - virtuelles Dateisystem
  - getrennter Code für Hardware / Dateisysteme

Dateisysteme (2)

- Ulix setzt Methoden moderner BS ein
  - unterste Ebene: Hardware, einzelne Sektoren lesen, Funktionen `readsector_hd()`, `writesector_hd()`, `readsector_fd()`, `writesector_fd()`
  - oberste Ebene: virtuelles Dateisystem, Dateien und Verzeichnisse manipulieren, Funktionen `u_open()`, `u_read()`, `u_write()`, `u_lseek()` etc.
  - Verbindungsstücke: Dateisystem-spezifische Funktionen, z. B. für Minix- oder FAT-Dateisystem

Dateisysteme (3)

- Ulix – So setzen sich die Komponenten zusammen:
  - Geräte über Geräte-IDs unterscheidbar (DEV_HDA, DEV_HDB, DEV_FD0, DEV_FD1), prinzipiell erweiterbar
  - File-Deskriptoren (für offene Dateien)
    - global (für BS und alle Prozesse)
    - verwaltet jedes Dateisystem selbst
    - getrennte Gruppen je Gerät

Ulix: VFS-Funktionen (1)

```
int u_open (char *path, int oflag) {
  /* Variablen-Deklarationen ausgelassen */

  // check relative/absolute path
  if (*path != '/') relpath_to_abspath (path, abspath);
  else              strncpy (abspath, path, 256);

  get_dev_and_path (abspath,
    &device, &fs, &localpath);

  switch (fs) {
    case FS_MINIX:
      fd = mx_open (device, localpath, oflag);
      if (fd == -1) return -1;   // error
      else          return (fs << 8) + fd;

    case FS_FAT:   return -1;  // not implemented
    case FS_ERROR: return -1;  // error
  }
}
```

VFS-Pfad

Pfad auf Gerät

Ulix: VFS-Funktionen (2)

```
relpath_to_abspath (path, abspath);

z. B.:  $PWD:       /home/ulix/
        path:       Documents/beispiel.txt

        abspath:    /home/ulix/Documents/beispiel.txt

get_dev_and_path (abspath, &device, &fs, &localpath);

z. B.:  Mount:      2. Floppy (FD1) auf /mnt gemountet,
                    Typ minix
        abspath:    /mnt/tmp/beispiel.txt

        device:     DEV_FD1 (2. Floppy)
        fs:         FS_MINIX
        localpath:  /tmp/beispiel.txt

mx_open (device, localpath, oflag);
```

Ulix: VFS-Funktionen (3)

- Die generische Funktion `u_open` weiß also nichts über den Aufbau von Minix-, FAT- oder sonstigen Dateisystemen
- Aber: kann rausfinden, welches Gerät und welches Dateisystem verwendet wird, und dann die richtige spezifische `open`-Funktion (z. B. `mx_open`) aufrufen

Ulix: VFS-Funktionen (4)

- Jedes Subsystem (Minix, FAT etc.) verwaltet eigene File Descriptors (0, 1, 2, …)
- Auf VFS-Ebene werden diese zusammengesetzt, global eindeutig, z. B.
  - Minix: FS_MINIX = 1,
  - Minix-lokaler FD globaler FD

    0 1<<8 + 0 = 256 + 0 = 256

    1 1<<8 + 1 = 256 + 1 = 257

    2 1<<8 + 2 = 256 + 2 = 258 …

Ulix: VFS-Funktionen (5)

- Neben `u_open` zum Öffnen einer Datei sind weitere Standardfunktionen verfügbar, etwa
- `u_read`: aus Datei lesen
- `u_write`: in Datei schreiben
- `u_lseek`: an Position in Datei springen
- `u_close`: Datei schließen
- `u_unlink`: Datei löschen
- `u_mkdir`: Verzeichnis erzeugen etc.

Ulix: VFS-Funktionen (6)

- Viele VFS-Funktionen haben einfachen Aufbau

```
int u_read (int fd, void *buf, int nbyte) {
  if (fd < 0) return -1;   // file not open
  int fs      = fd >> 8;
  int localfd = fd & 0xff;

  switch (fs) {
    case FS_MINIX: return mx_read (localfd, buf, nbyte);
    case FS_FAT:   return -1;  // not implemented
    case FS_ERROR: return -1;  // error
  }
}
```

Minix-Dateisystem (1)

Klassisches Unix-Dateisystem

- **Superblock:** enthält Verwaltungsinformationen über Datenträger
- **Inode:** Metadaten einer Datei (Größe, Datenblöcke, Zugriffsrechte etc.)
- **Inode-Bitmap:** speichert, welche Inodes verwendet / frei sind
- **Block-Bitmap:** speichert, welche Datenblöcke verwendet / frei sind

Minix-Dateisystem (2)

- Inodes enthalten *keinen* Dateinamen
- **Verzeichnisse:** spezielle Dateien, die Zuordnungen der Form

  Dateiname → Inode-Nummer

  enthalten

Minix-Dateisystem (3)

- Aufbau eines Minix-Dateisystems

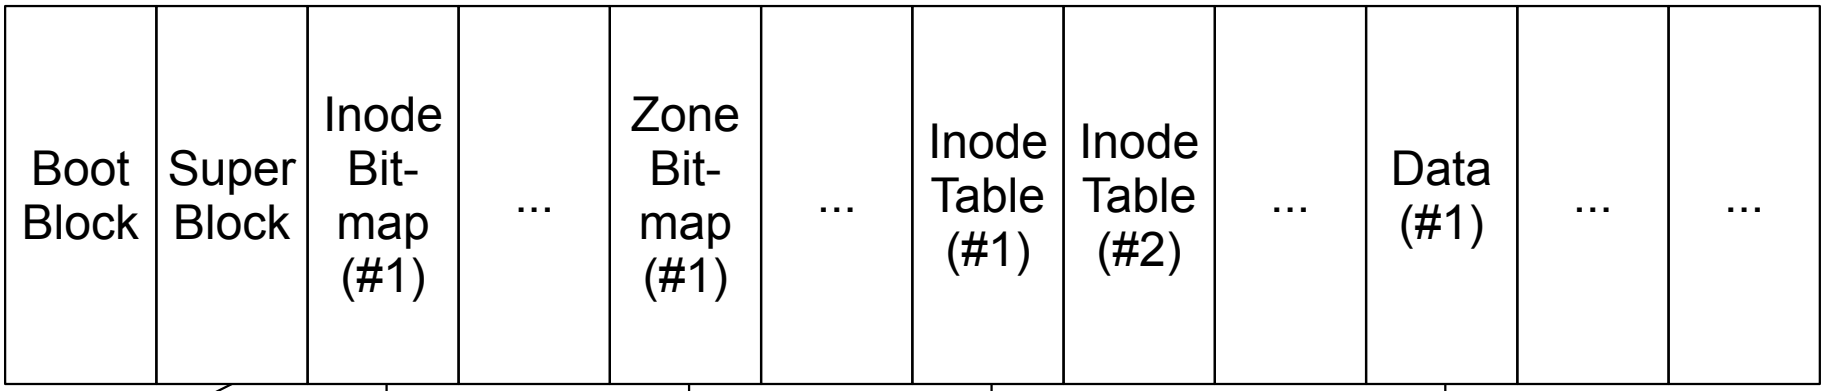

enthält u.a.:

Inodes
Datenblöcke
Größe I-Map
Größe Z-Map
Minix-FS-Version

direkt hinter Super Block; #Blöcke steht im Superblock

#Blöcke steht im Superblock

Block-Nr. ergibt sich aus Größe von I-Map und Z-Map

Block-Nr. steht im Superblock

Minix-Dateisystem (4)

- Minix-spezifische Funktionen (`mx_*`) verstehen den logischen Aufbau des Minix-FS
- Auf unterster Ebene werden schließlich einzelne 1-KB-Blöcke vom Datenträger angefordert:
- Aufruf von `readblock (device,block,buf)`
- `readblock` kann dann passende Geräte-spezifische Funktion aufrufen, z. B. `readblock_hd` oder `readblock_fd`

Blöcke lesen

- Beispiel `readblock`:
- Drei Geräte-Klassen (HD, FD, „Serial Disk“)

```
void readblock (int device, int blockno, char* buffer) {
  unsigned char major = device >> 8;      // obere  8 Bits
  unsigned char minor = device & 0xFF;    // untere 8 Bits
  switch (major) {
    case MAJOR_HD:     readblock_hd (minor/64, blockno, buffer);
                       break;
    case MAJOR_FD:     readblock_fd (minor,    blockno, buffer);
                       break;
    case MAJOR_RAM:    break;   // not implemented
    case MAJOR_SERIAL: readblock_serial (      blockno, buffer);
                       break;
    default: break;
  }
}
```

DEV_HDA = 0x**3**00 → major = **3**, minor = 0
DEV_HDB = 0x**3**40 → major = **3**, minor = 0x40
DEV_FD0 = 0x**2**00 → major = **2**, minor = 0
DEV_FD1 = 0x**2**01 → major = **2**, minor = 1

Datentransfers

- Zugriff auf Datenträger immer nach gleichem Muster, Beispiel Lese-Operation:
  - gewünschte Blocknummer, Datenpuffer und Transferrichtung geeignet kodieren
  - Kommando mit `outport`-Befehlen an Controller schicken
  - schlafen legen (nach Abschluss kommt Interrupt)
  - *falls DMA*: alles schon fertig
  - *falls nicht DMA*: Daten aus Controller-Speicher kopieren (`inport`)

Beispiel: Auf Platte schreiben

„controller magic“

```
void writesector_hd (int hd, int sector, char* buffer) {
  hd_direction = HD_OP_WRITE;

  outportb (IO_IDE_DISKSEL,   0xe0 | (hd<<4));   // select disk
  outportb (IO_IDE_DEVCTRL,   0);                // generate interrupt
  outportb (IO_IDE_SEC_COUNT, 1);                // one sector
  outportb (IO_IDE_SECTOR,     sector         & 0xff);
  outportb (IO_IDE_SECTOR+1,  (sector >> 8)   & 0xff);
  outportb (IO_IDE_SECTOR+2,  (sector >> 16)  & 0xff);
  outportb (IO_IDE_SECTOR+3, ((sector >> 24) & 0x0f) | ((0xe + hd) << 4));
  outportb (IO_IDE_COMMAND, IDE_CMD_WRITE);

  inportb          (IO_IDE_STATUS);              // read status, ack irq
  repeat_outportsl (IO_IDE_DATA, buffer, HD_SECSIZE / 4);
  inportb          (IO_IDE_STATUS);              // read status, ack irq
  while (hd_direction == HD_OP_WRITE) {};        // wait for completion
  hd_direction = HD_OP_NONE;
}
```

(stark vereinfacht, ohne Prozesse)

Interrupt-Handler

- Controller (HD oder FD) erzeugt einen Interrupt, wenn der Transfer abgeschlossen ist
  - **DMA:** Bei DMA ist der Interrupt das Signal dafür, dass der Transfer in den PC-Hauptspeicher abgeschlossen ist
  - **non-DMA:** Ansonsten liegen die Daten im internen Speicher des Controllers und müssen noch ausgelesen werden

Interrupt-Handler (ohne DMA)

```
void ide_handler (context_t *r) {
  switch (hd_direction) {
    case HD_OP_READ:  <disable interrupts>
                      // Daten vom Controller ins RAM kopieren
                      repeat_inportsl (IO_IDE_DATA, hd_buf,
                                       HD_SECSIZE / 4);
                      hd_direction = HD_OP_NONE;
                      break;
    case HD_OP_WRITE: <disable interrupts>
                      hd_direction = HD_OP_NONE;
                      break;

  // wartenden Prozess aufwecken
  <enable interrupts>
}
```