Betriebssysteme (BS)

10. Eingabe und Ausgabe

https://sys.cs.tu-dortmund.de/de/lehre/ss23/bs

07.06.2023

Peter Ulbrich

peter.ulbrich@tu-dortmund.de
bs-problems@ls12.cs.tu-dortmund.de
https://sys.cs.tu-dortmund.de/de/lehre/kummerkasten

Basierend auf *Betriebssysteme* von Olaf Spinczyk, Universität Osnabrück

technische universität
dortmund

arbeitsgruppe
systemsoftware

Wiederholung: Betriebsmittel

- Das Betriebssystem hat folgende Aufgaben:
  - Verwaltung der Betriebsmittel des Rechners
  - Schaffung von Abstraktionen, die Anwendungen einen einfachen und effizienten Umgang mit Betriebsmitteln erlauben
- **Bisher:**
  - **Prozesse**
  - **Arbeitsspeicher**
- **Heute: E/A-Geräte**
  - Verwaltung von Peripheriegeräten

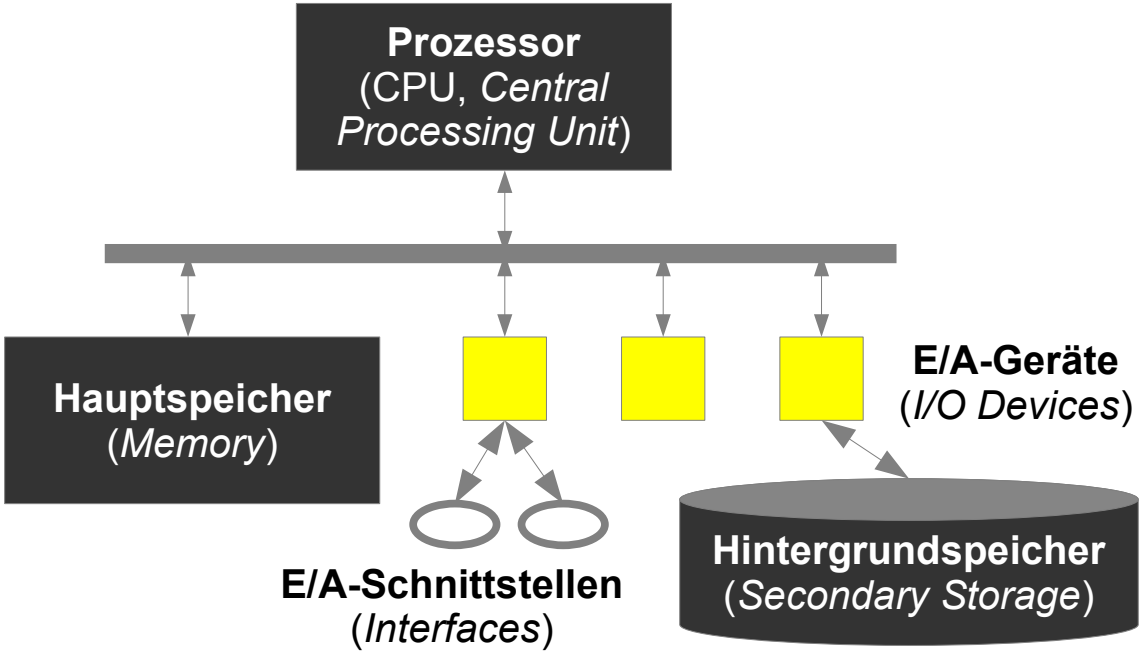

Inhalt

- Ein-/Ausgabe-Hardware
- Geräteprogrammierung
- Aufgaben des Betriebssystems
- Zusammenfassung

Tanenbaum
5: Ein-Ausgabe

Silberschatz
13: I/O-Systems

Anbindung von E/A-Geräten

Tastatur-controller

Video-controller

Platten-controller

Ethernet-controller

Bus

CPU

Haupt-speicher

Ein-/Ausgabegeräte werden über ***Controller*** an den Systembus angebunden. Die Programmierung erfolgt über **E/A-Register** auf den Controllern.

Beispiel: PC-Tastatur

- serielle zeichenweise Kommunikation
  - Tastatur ist „intelligent“ (besitzt eigenen Prozessor)

Make- und ***Break***-Codes für gedrückte Tasten

Steuercodes z.B. LEDs an/aus

Tastatur-controller

Sobald ein Zeichen abholbereit ist, löst der ***Controller*** eine **Unterbrechung** aus.

Aufgaben der Software

- Initialisierung des Controllers
- Abholen der Zeichen von der Tastatur
- Abbildung der Make- und Break-Codes auf ASCII
- Senden von Kommandos

Beispiel: CGA-Videocontroller

- Kommunikation über Videosignal
  - Umwandlung des Bildschirmspeicherinhalts in ein Bild (80x25 Z.)

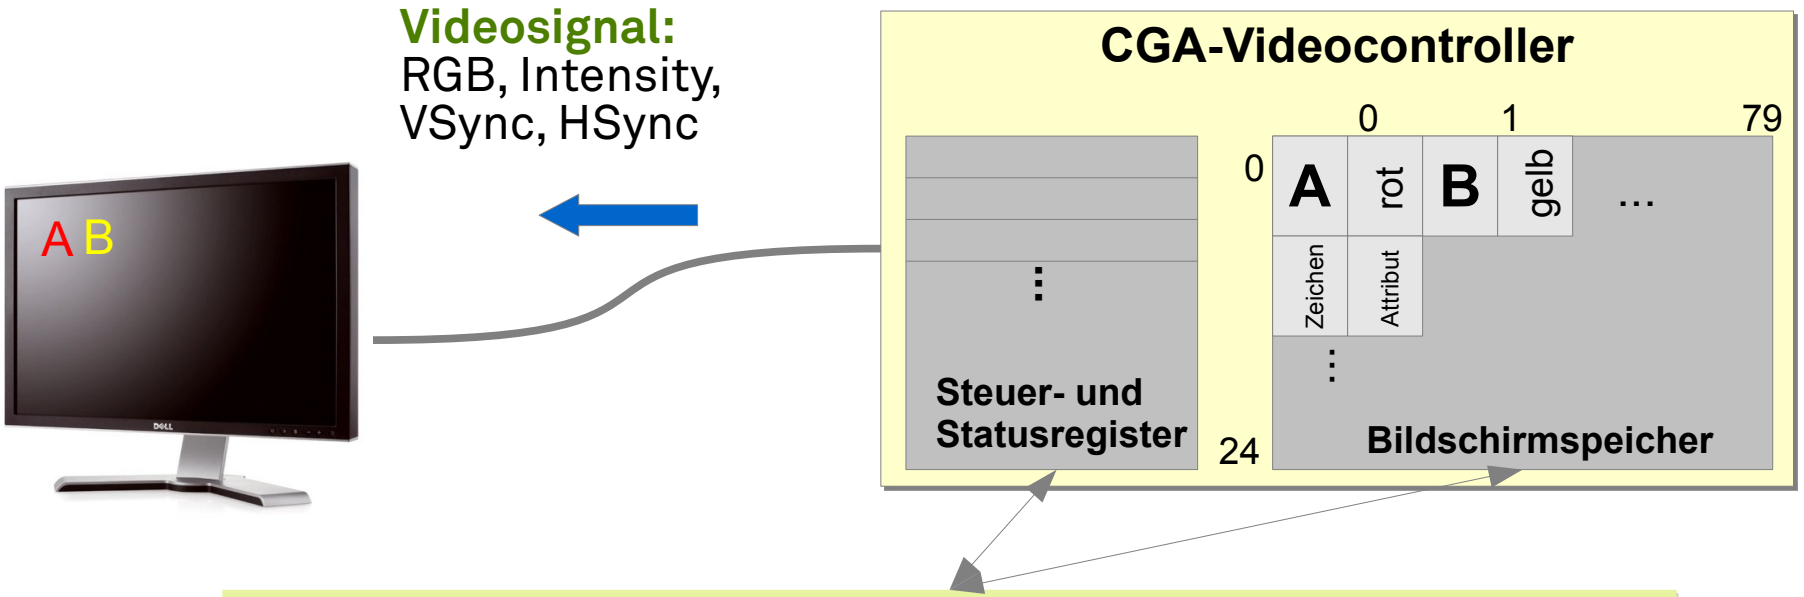

Aufgaben der Software

- Initialisierung des Controllers
- Bildschirmspeicher mit den gewünschten Zeichencodes füllen
- Steuerung der Position des Cursors
- Cursor an- und abschalten

Beispiel: IDE-Plattencontroller

- Kommunikation über AT-Befehle
  - **blockweiser wahlfreier Zugriff** auf Datenblöcke

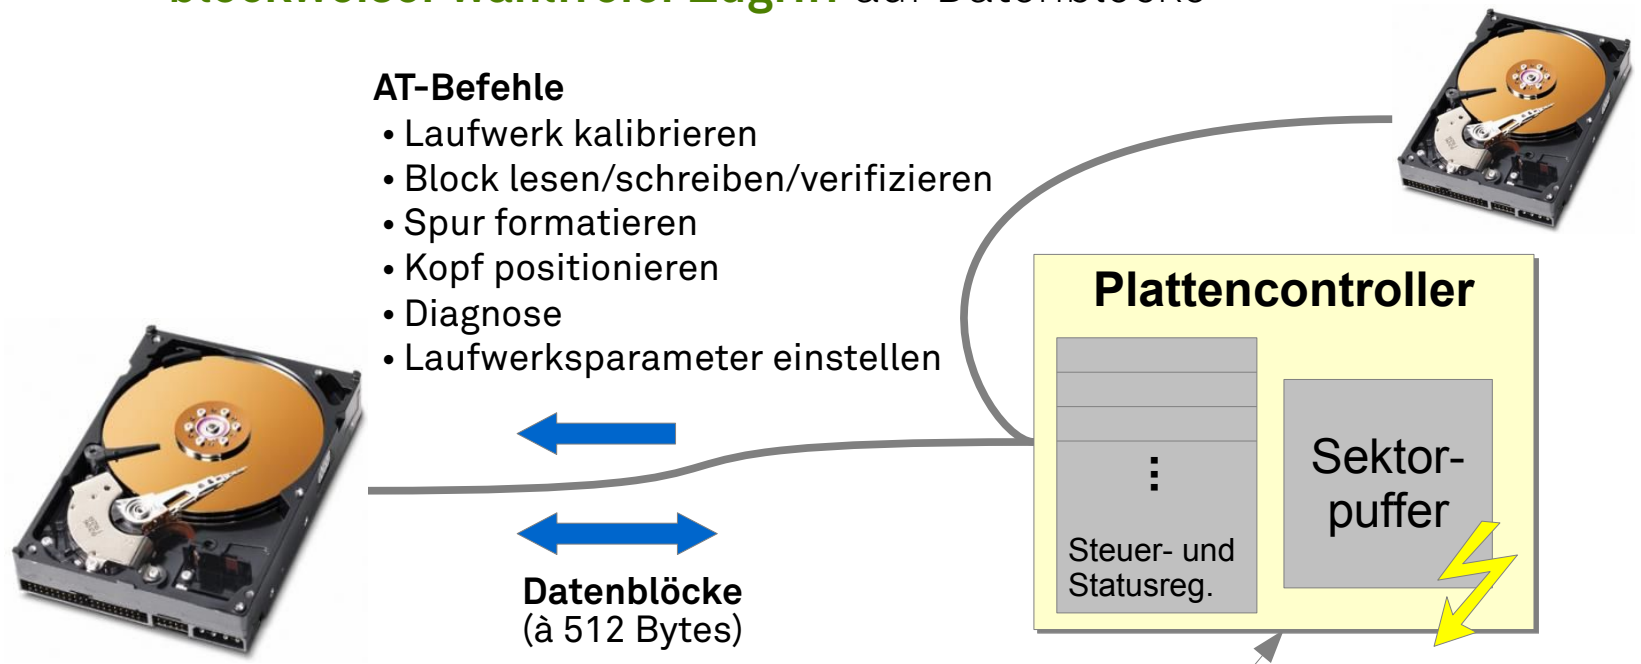

Aufgaben der Software:
- AT-Befehle in Register schreiben
- Sektorpuffer füllen/leeren
- Auf die Unterbrechungen reagieren
- Fehlerbehandlung

Sobald der Sektorpuffer ausgelesen bzw. voll-geschrieben wurde, löst der Controller eine **Unterbrechung** aus.

Beispiel: Ethernet-Controller

- serielle paketbasierte Buskommunikation
  - Pakete haben eine variable Größe und enthalten Adressen

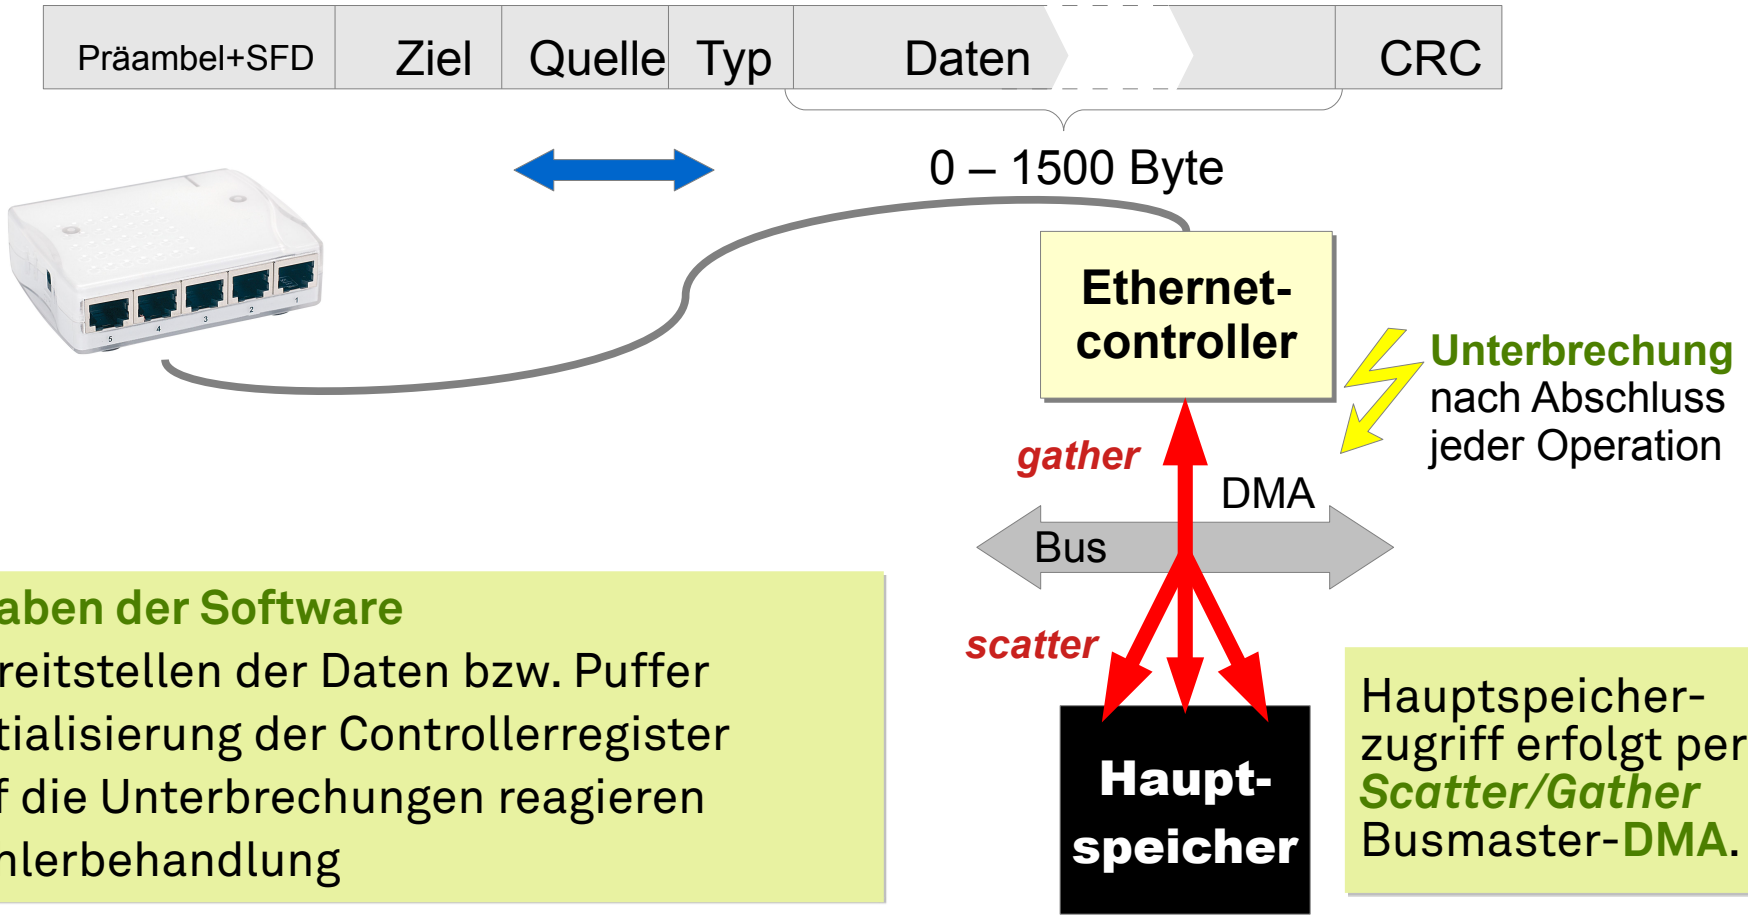

Aufgaben der Software

- Bereitstellen der Daten bzw. Puffer
- Initialisierung der Controllerregister
- auf die Unterbrechungen reagieren
- Fehlerbehandlung

Hauptspeicher-zugriff erfolgt per *Scatter/Gather* Busmaster-DMA.

Geräteklassen

- **zeichenorientierte Geräte**
  - Tastatur, Drucker, Modem, Maus, ...
  - meist rein **sequentieller Zugriff**, selten wahlfreie Positionierung
- **blockorientierte Geräte**
  - Festplatte, Diskette, CD-ROM, DVD, Bandlaufwerke, ...
  - meist **wahlfreier blockweiser Zugriff** (random access)

- Andere Geräte passen weniger gut in dieses Schema:
  - Grafikkarten (insbesondere 3D-Beschleunigung)
  - Netzwerkkarten (Protokolle, Adressierung, Broadcast/Multicast, Nachrichtenfilterung, ...)
  - Zeitgeberbaustein (einmalige oder periodische Unterbrechungen)
  - ...

Unterbrechungen ...

- signalisieren, dass die Software aktiv werden muss

Software kann IRQ-Behandlung unterdrücken. x86:
sti → erlauben
cli → unterdrücken

Ablauf einer Unterbrechungsbehandlung auf der Hardwareebene

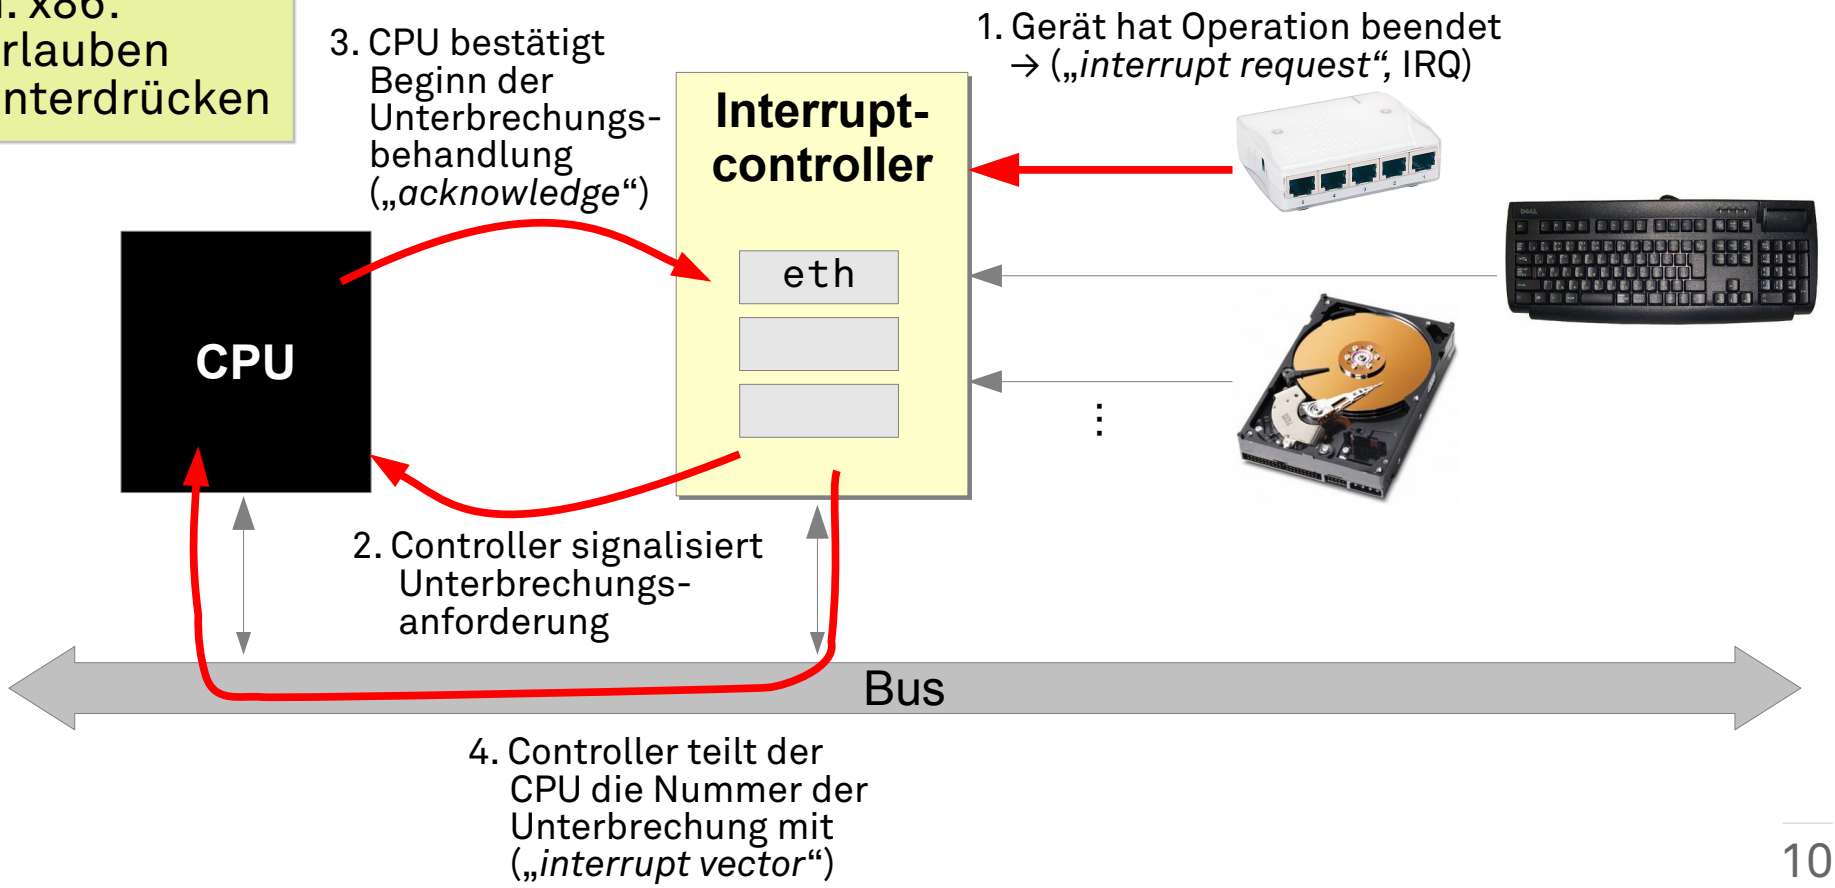

Direct Memory Access (DMA) ...

- ... wird von komplexen Controllern benutzt, um Daten unabhängig von der CPU in den bzw. aus dem Hauptspeicher zu transferieren.

Durchführung eines DMA-Transfers

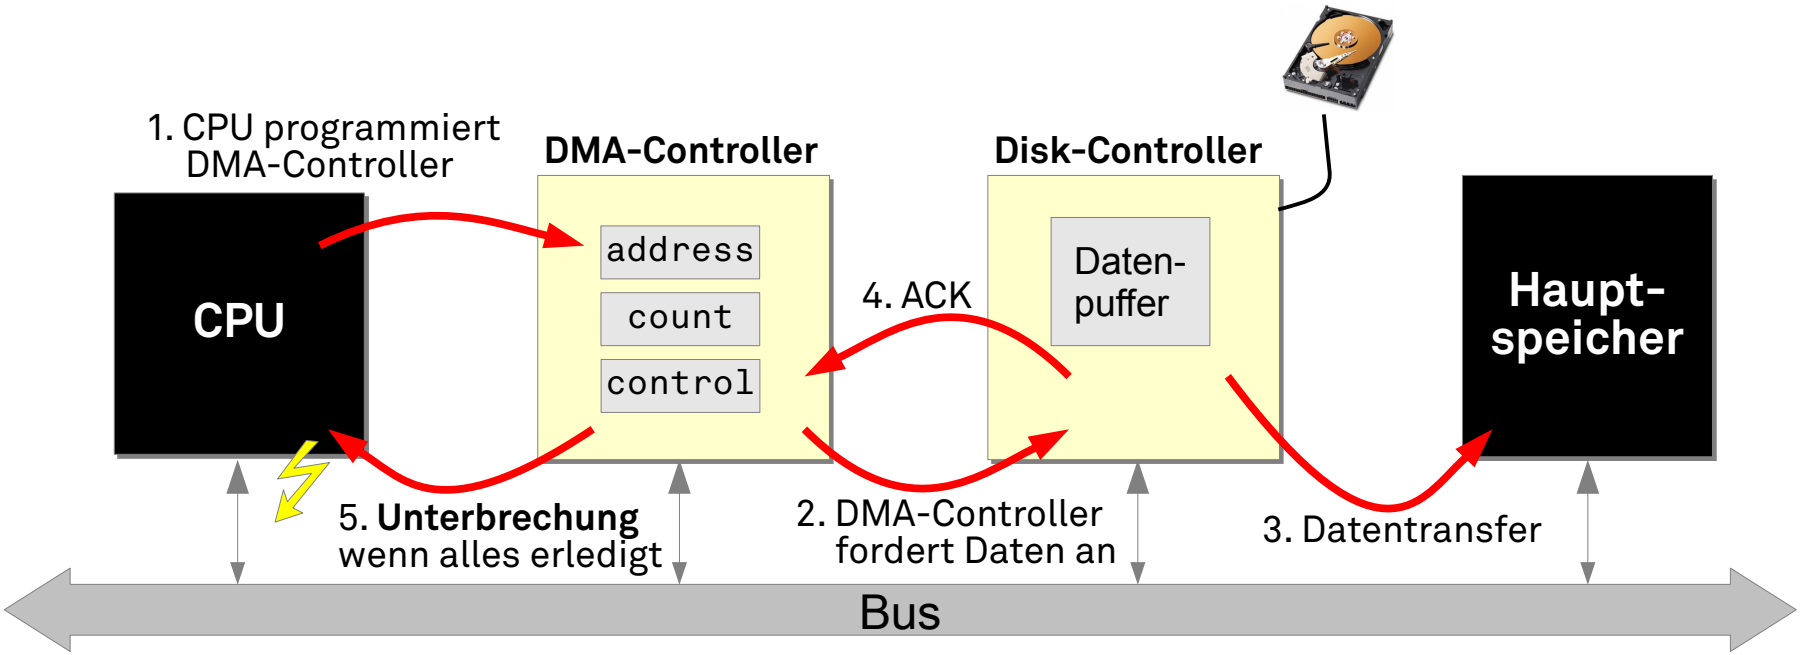

2., 3. und 4. wird in Abhängigkeit von **count** wiederholt durchgeführt

Inhalt

- Ein-/Ausgabe-Hardware
- Geräteprogrammierung
- Aufgaben des Betriebssystems
- Zusammenfassung

Ein-/Ausgabeadressraum

- Zugriff auf *Controller*-Register und *Controller*-Speicher erfolgt je nach Systemarchitektur ...

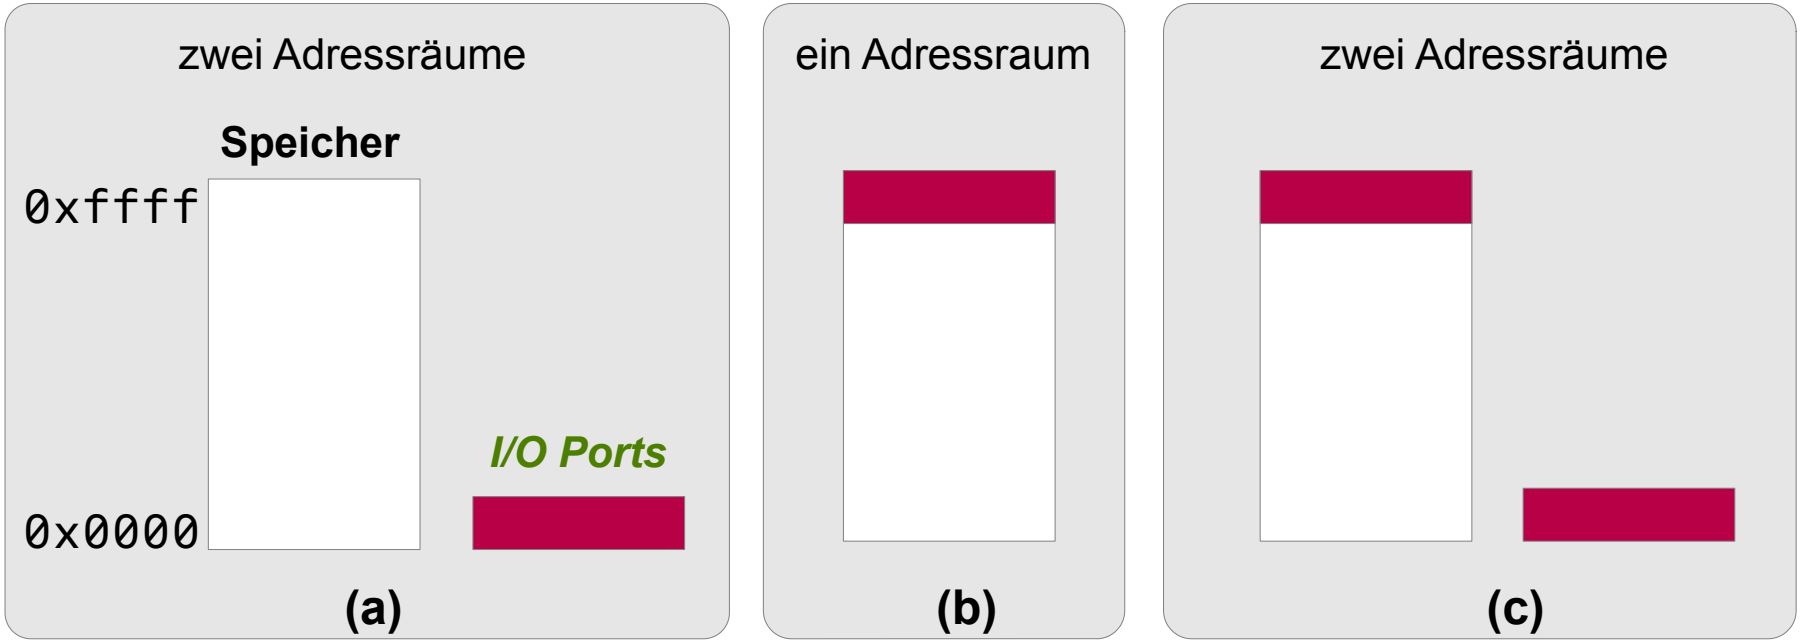

(a) separater E/A-Adressraum
- anzusprechen über spezielle Maschineninstruktionen

(b) gemeinsamer Adressraum (*Memory-Mapped I/O*)

(c) hybride Architektur

Arbeitsweise von Gerätetreibern

- Je nach Fähigkeiten des Geräts erfolgt E/A mittels …
  - ***Polling*** (oder „Programmierte E/A“),
  - **Unterbrechungen** oder
  - **DMA**
- **Beispiel:** Drucken einer Textzeile

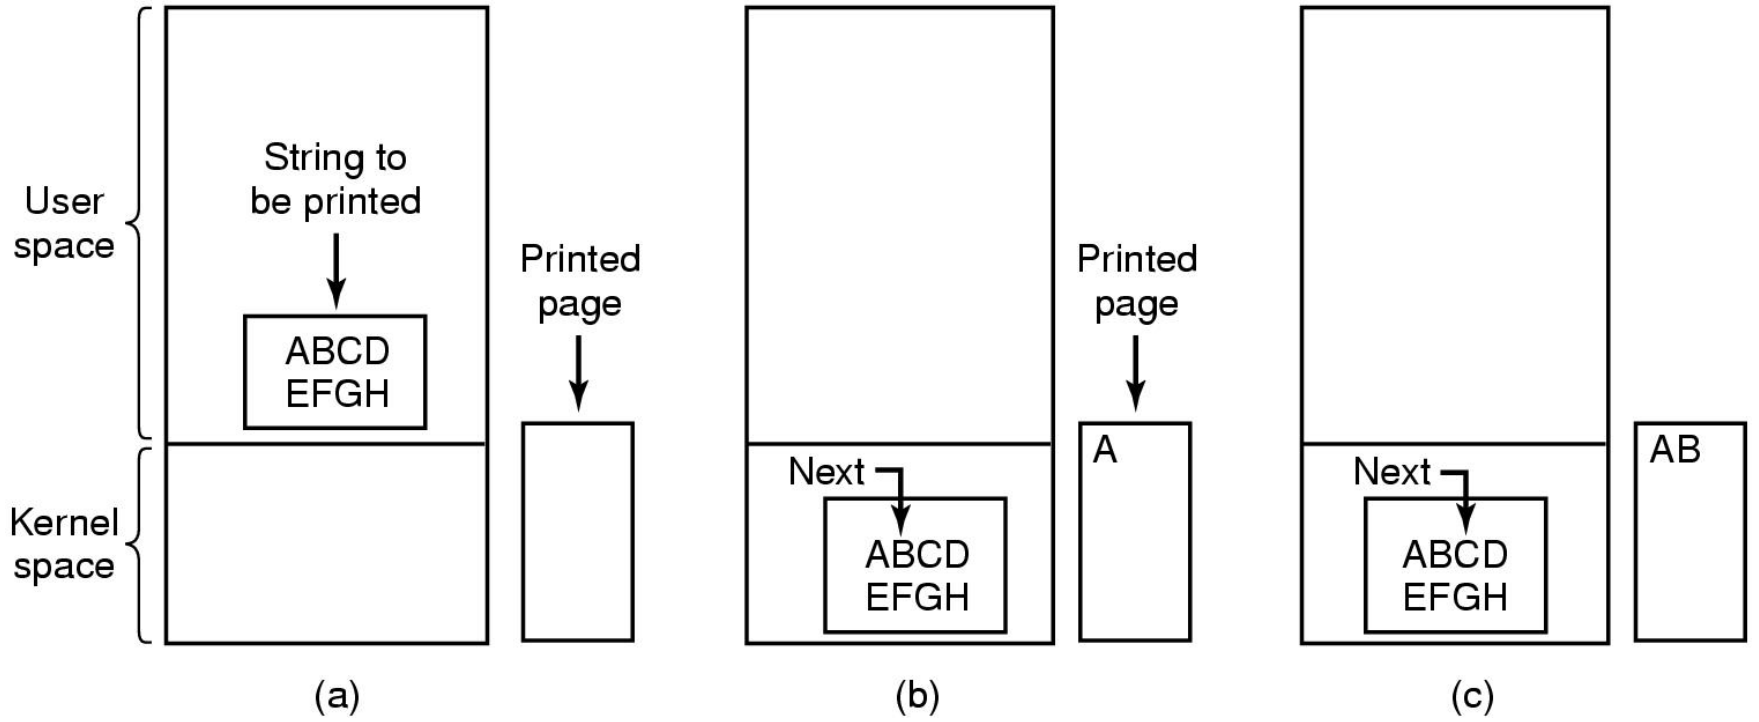

Quelle: Tanenbaum, „Modern Operating Systems“

Polling (oder „Programmierte E/A“)

... bedeutet **aktives Warten** auf ein Ein-/Ausgabegerät.

```
/* Zeichen in Kern-Puffer p kopieren */
copy_from_user (buffer, p, count);

/* Schleife über alle Zeichen */
for (i = 0; i < count; i++) {

  /* Warte “aktiv” bis Drucker bereit */
  while (*printer_status_reg != READY)
    ;

  /* Ein Zeichen ausgeben */
  *printer_data_reg = p[i];
}

return_to_user ();
```

Pseudo-Code einer Betriebssystem-funktion zum Drucken von Text im ***Polling*-Betrieb**

Unterbrechungsgetriebene E/A

... bedeutet, dass die CPU während der Wartezeit einem anderen Prozess zugeteilt werden kann.

Code, der die E/A-Operation initiiert

```
copy_from_user (buffer, p, count);

/* Druckerunterbrechungen erlauben */
enable_interrupts ();

/* Warte bis Drucker bereit */
while (*printer_status_reg != READY);

/* Erstes Zeichen ausgeben */
*printer_data_reg = p[i++];

scheduler ();
return_to_user ();
```

Unterbrechungsbehandlungsroutine

```
if (count > 0) {
  *printer_data_reg = p[i];
  count--;
  i++;
}
else
  unblock_user ();

acknowledge_interrupt ();
return_from_interrupt ();
```

DMA-getriebene E/A

... bedeutet, dass die Software nicht mehr für den Datentransfer zwischen Controller und Hauptspeicher zuständig ist.

- Die CPU wird weiter entlastet.

```
copy_from_user (buffer, p, count);
set_up_DMA_controller (p, count);
scheduler ();
return_to_user ();
```

Code, der die E/A-Operation initiiert

```
acknowledge_interrupt ();
unblock_user ();
return_from_interrupt ();
```

Unterbrechungsbehandlungsroutine

Diskussion: Unterbrechungen

- **Kontextsicherung**
  - Wird teilweise von der CPU selbst erledigt.
    - z.B. Statusregister und Rücksprungadresse, aber nur das Minimum.
  - **Alle veränderten Register** müssen gesichert und am Ende der Behandlung wiederhergestellt werden.
- Behandlungsroutine **möglichst kurz**
  - Während der Unterbrechungsbehandlung werden i.d.R. weitere Unterbrechungen unterdrückt.
    - Es droht der **Verlust von Unterbrechungen**
  - Möglichst nur den Prozess wecken, der auf E/A-Beendigung wartet.

Diskussion: Unterbrechungen (2)

- Unterbrechungen sind die Quelle der Asynchronität
  - Ursache für Race Conditions im Betriebssystemkern
- Unterbrechungssynchronisation:
  - einfachste Möglichkeit: **Unterbrechungsbehandlung** durch die CPU zeitweise *hart* **verbieten**, während kritische Abschnitte durchlaufen werden.
    - x86: sti, cli
    - wieder Gefahr des Unterbrechungsverlusts
  - BS gängig: **mehrstufige Behandlungen**, durch die das harte Sperren von Unterbrechungen minimiert wird
    - Abstrakt: **Prolog** (asynchron) und **Epilog** (synchron zum BS)
    - UNIX: *Top Half, Bottom Half*
    - Linux: *Tasklets*
    - Windows: *Deferred Procedures*

Diskussion: *Direct Memory Access*

- **Caches**
  - Heutige Prozessoren arbeiten mit Daten-Caches;
    DMA läuft am Cache vorbei!
  - Vor dem Aufsetzen eines DMA-Vorgangs muss der Cache-Inhalt in den Hauptspeicher zurückgeschrieben und invalidiert werden bzw.
    der Cache darf für die entsprechende Speicherregion nicht eingesetzt werden.
- **Speicherschutz**
  - Heutige Prozessoren verwenden eine MMU zur Isolation von Prozessen und zum Schutz des Betriebssystems;
    DMA läuft am Speicherschutz vorbei!
  - Fehler beim Aufsetzen von DMA-Vorgängen sind extrem kritisch.
  - Anwendungsprozesse dürfen DMA-Controller nie direkt programmieren!

Inhalt

- Ein-/Ausgabe-Hardware
- Geräteprogrammierung
- Aufgaben des Betriebssystems
- Zusammenfassung

Aufgaben des Betriebssystems

- **Geräteabstraktionen** schaffen
  - einheitlich, einfach, aber vielseitig
- **Ein-/Ausgabenprimitiven** bereitstellen
  - synchron und/oder asynchron
- **Pufferung**
  - falls das Gerät bzw. der Empfängerprozess noch nicht bereit ist
- **Geräteansteuerung**
  - möglichst effizient unter Beachtung mechanischer Eigenschaften
- **Ressourcenzuordnung** verwalten
  - bei **teilbaren** Geräten: Welcher Prozess darf wo lesen/schreiben?
  - bei **unteilbaren** Geräten: zeitweise Reservierungen
- **Stromsparzustände** verwalten
- **Plug&Play** unterstützen
- ...

Aufgaben des Betriebssystems

- **Geräteabstraktionen** schaffen
  - einheitlich, einfach, aber vielseitig
- **Ein-/Ausgabenprimitiven** bereitstellen
  - synchron und/oder asynchron
- **Pufferung**
  - falls das Gerät bzw. der Empfängerprozess noch nicht bereit ist
- **Geräteansteuerung**
  - möglichst effizient unter Beachtung mechanischer Eigenschaften
- **Ressourcenzuordnung** verwalten
  - bei **teilbaren** Geräten: Welcher Prozess darf wo lesen/schreiben?
  - bei **unteilbaren** Geräten: zeitweise Reservierungen
- **Stromsparzustände** verwalten
- **Plug&Play** unterstützen
- ...

Schichten des E/A-Subsystems

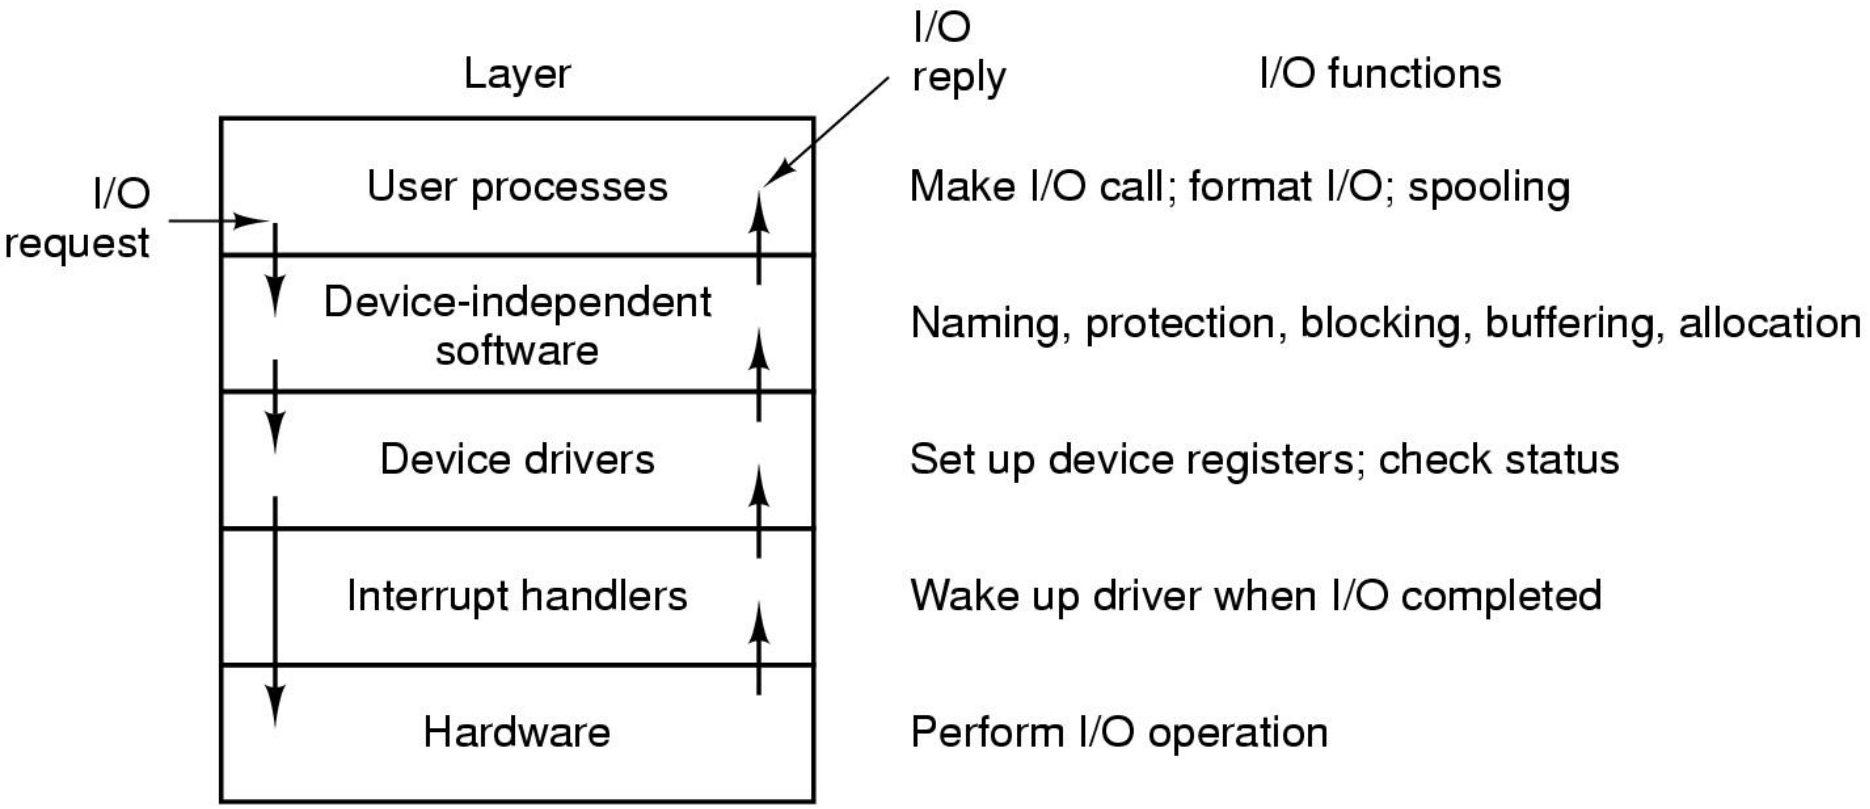

Quelle: Tanenbaum, „Modern Operating Systems“

UNIX: Geräteabstraktionen

- Periphere Geräte werden als **Spezialdateien** repräsentiert:
  - Geräte können **wie Dateien** mit Lese- und Schreiboperationen angesprochen werden.
  - Öffnen der Spezialdateien schafft eine Verbindung zum Gerät, die durch einen Treiber hergestellt wird.
  - direkter Durchgriff vom Anwender auf den Treiber
- **blockorientierte Spezialdateien** (block devices)
  - Plattenlaufwerke, Bandlaufwerke, Floppy Disks, CD-ROMs
- **zeichenorientierte Spezialdateien** (character devices)
  - serielle Schnittstellen, Drucker, Audiokanäle etc.

UNIX: Geräteabstraktionen (2)

- Eindeutige Beschreibung der Geräte durch ein 3-Tupel: (Gerätetyp, *Major Number*, *Minor Number*)
- **Gerätetyp**: *Block Device*, *Character Device*
- ***Major Number***:
  Auswahlnummer für einen Treiber
- ***Minor Number***:
  Auswahl eines Gerätes innerhalb eines Treibers

UNIX: Geräteabstraktionen (3)

- Auszug aus dem *Listing* des **/dev**-Verzeichnisses

```
brw-rw---- ulbr disk 3,  0 2008-06-15 14:14 /dev/hda
brw-rw---- ulbr disk 3, 64 2008-06-15 14:14 /dev/hdb
brw-r----- root disk 8,  0 2008-06-15 14:13 /dev/sda
brw-r----- root disk 8,  1 2008-06-15 14:13 /dev/sda1
crw-rw---- root uucp 4, 64 2006-05-02 08:45 /dev/ttyS0
crw-rw---- root lp   6,  0 2008-06-15 14:13 /dev/lp0
crw-rw-rw- root root 1,  3 2006-05-02 08:45 /dev/null
lrwxrwxrwx root root     3 2008-06-15 14:14 /dev/cdrecorder -> hdb
lrwxrwxrwx root root     3 2008-06-15 14:14 /dev/cdrom -> hda
```

Zugriffs-rechte

Eigen-tümer

Major und *Minor No.*

Erstellungs-zeitpunkt der Spezialdatei

Name der Spezialdatei

c: *character device*
b: *block device*
l: *link*

UNIX: Zugriffsprimitiven

Das Wichtigste in Kürze ... (siehe man 2 ...)

- `int open(const char *devname, int flags)`
  - *Öffnen* eines Geräts. Liefert Dateideskriptor als Rückgabewert.
- `off_t lseek(int fd, off_t offset, int whence)`
  - Positioniert den Schreib-/Lesezeiger
  - nur bei Geräten mit wahlfreiem Zugriff
- `ssize_t read(int fd, void *buf, size_t count)`
  - Einlesen von max. **`count`** Bytes in Puffer **`buf`** von Deskriptor **`fd`**
- `ssize_t write(int fd, const void *buf, size_t count)`
  - Schreiben von **`count`** Bytes aus Puffer **`buf`** auf Deskriptor **`fd`**
- `int close(int fd)`
  - *Schließen* eines Geräts: Dateideskriptor **`fd`** kann danach nicht mehr benutzt werden.

UNIX: Gerätespezifische Funktionen

- Spezielle Geräteeigenschaften werden über **ioctl** angesprochen:

```
IOCTL(2)          Linux Programmer's Manual          IOCTL(2)

NAME
       ioctl - control device

SYNOPSIS
       #include <sys/ioctl.h>

       int ioctl(int d, int request, ...);
```

- Schnittstelle generisch, Semantik gerätespezifisch:

```
CONFORMING TO
       No single standard. Arguments, returns, and semantics of
       ioctl(2) vary according to the device driver in question
       (the call is used as a catch-all for operations that
       don't cleanly fit the Unix stream I/O model). The ioctl
       function call appeared in Version 7 AT&T Unix.
```

UNIX: Warten auf mehrere Geräte

- bisher: **Lese- oder Schreibaufrufe blockieren**
  - Was tun beim Lesen von mehreren Quellen?

- **Alternative 1**: nichtblockierende Ein-/Ausgabe
  - `O_NDELAY` beim `open()`
  - **Polling-Betrieb**: Prozess muss immer wieder `read()` aufrufen
  - unbefriedigend, da Verschwendung von CPU-Zeit bis etwas vorliegt

UNIX: Warten auf mehrere Geräte (2)

- **Alternative 2**: Blockieren an mehreren Dateideskriptoren
  - Systemaufruf:

```
int select (int nfds, fd_set *readfds, fd_set *writefds,
            fd_set *errorfds, struct timeval *timeout);
```

  - `nfds` legt fest, bis zu welchem Dateideskriptor `select` wirken soll.
  - …`fd`s sind Dateideskriptoren, auf die gewartet werden soll:
    - `readfds` — bis etwas zum Lesen vorhanden ist
    - `writefds` — bis man schreiben kann
    - `errorfds` — bis ein Fehler aufgetreten ist
  - *Timeout* legt fest, wann der Aufruf spätestens deblockiert.
  - Makros zum Erzeugen der Dateideskriptormengen
  - **Ergebnis:** In den Dateideskriptormengen sind nur noch die Dateideskriptoren vorhanden, die zur Deblockade führten.

Pufferung bei E/A-Operationen

- **Probleme** ohne Datenpuffer im Betriebssystem:
  - Daten, die eintreffen, bevor `read` ausgeführt wurde (z.B. von der Tastatur), müssten verloren gehen.
  - Wenn ein Ausgabegerät beschäftigt ist, müsste `write` scheitern oder den Prozess blockieren, bis das Gerät wieder bereit ist.
  - Ein Prozess, der eine E/A-Operation durchführt, kann nicht ausgelagert werden.

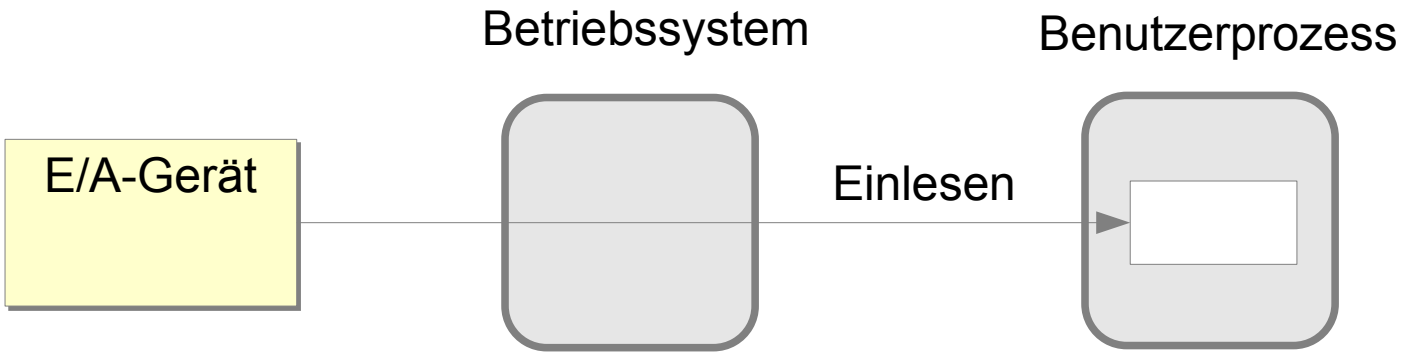

(a) Leseoperation ohne Puffer

E/A-Einzelpuffer

- **Einlesen**:
  - Daten können vom System entgegengenommen werden, auch wenn der Leserprozess noch nicht `read` aufgerufen hat.
  - Bei Blockgeräten kann der nächste Block vorausschauend gelesen werden, während der vorherige verarbeitet wird.
  - Prozess kann problemlos ausgelagert werden. DMA erfolgt in Puffer.
- **Schreiben**:
  - Daten werden kopiert. Aufrufer blockiert nicht. Datenpuffer im Benutzeradressraum kann sofort wiederverwendet werden.

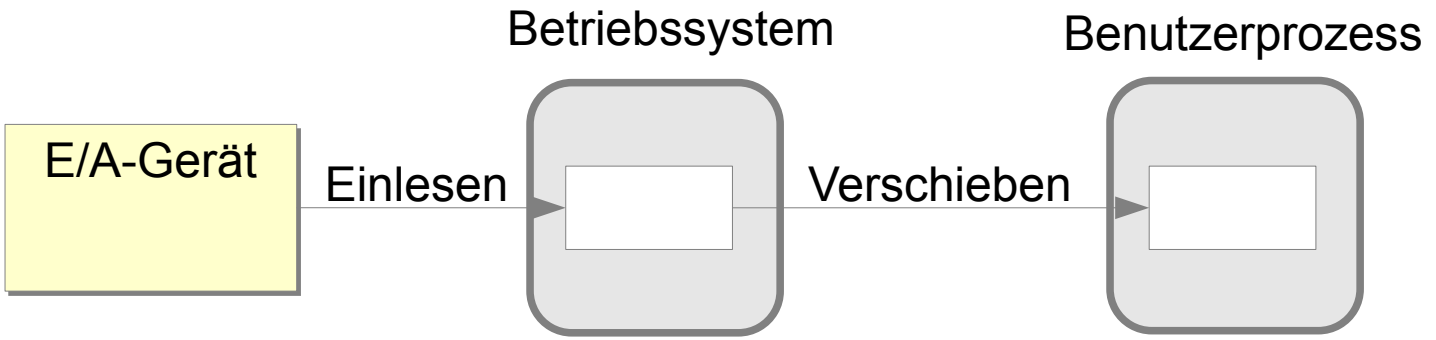

(b) Leseoperation mit Einzelpuffer

E/A-Einzelpuffer

Leistungsabschätzung

Eine einfache Rechnung zeigt den Leistungsgewinn beim wiederholten blockweisen Lesen mit anschließender Verarbeitung:

T: Dauer der Leseoperation
C: Rechenzeit für die Verarbeitung
M: Dauer des Kopiervorgang (Systempuffer→Benutzerprozess)

G: Gesamtdauer für Lesen und Verarbeiten eines Blocks

ohne Puffer: $G_0 = T + C$

mit Puffer: $G_E = \max(T, C) + M$

Mit $T \approx C$ und $M \approx 0$ wäre $G_0 \approx 2 \cdot G_E$. Leider ist $M > 0$.

E/A-Wechselpuffer

- **Einlesen**:
  - Während Daten vom E/A-Gerät in den einen Puffer transferiert werden, kann der andere Pufferinhalt in den Empfängeradressraum kopiert werden.
- **Schreiben**:
  - Während Daten aus einem Puffer zum E/A-Gerät transferiert werden, kann der andere Puffer bereits mit neuen Daten aus dem Senderadressraum gefüllt werden.

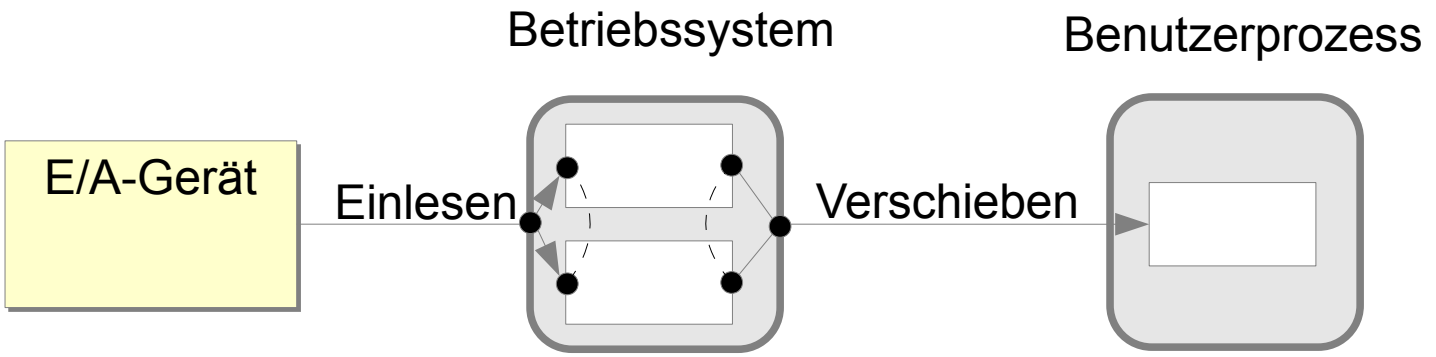

(c) Leseoperation mit Wechselpuffer

E/A-Wechselpuffer

- **Einlesen**:

Leistungsabschätzung

Mit einem Wechselpuffer kann ein Leseoperation parallel zur Kopieroperation und Verarbeitung erfolgen.

ohne Puffer: $G_0 = T + C$

mit Puffer: $G_E = \max(T, C) + M$

mit Wechselpuffer: $G_W = \max(T, C + M)$

Mit $C + M \leq T$ könnte das Gerät zu 100% ausgelastet werden.

E/A-Ringpuffer

- **Einlesen**:
  - Viele Daten können gepuffert werden, auch wenn der Leserprozess nicht schnell genug `read`-Aufrufe tätigt.
- **Schreiben**:
  - Ein Schreiberprozess kann mehrfach `write`-Aufrufe tätigen, ohne blockiert werden zu müssen.

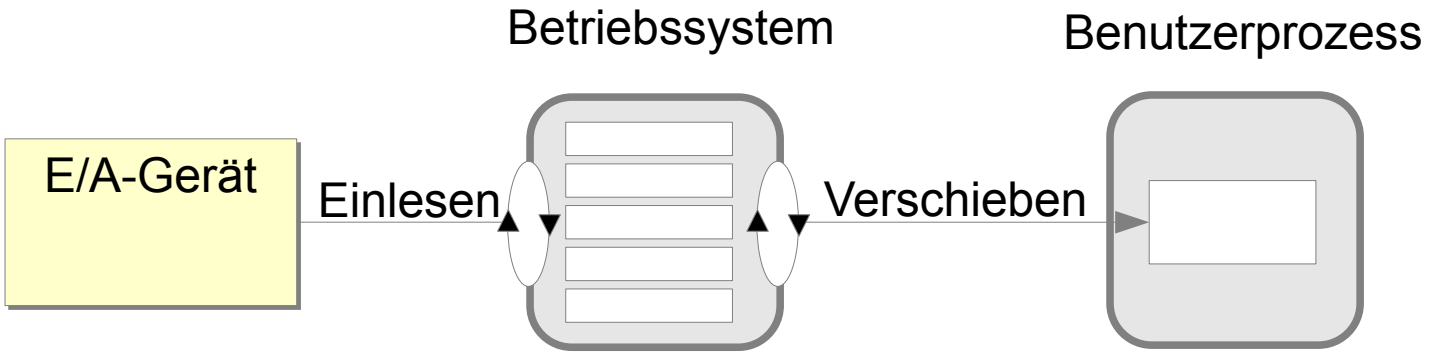

(d) Leseoperation mit Ringpuffer

Diskussion: E/A-Puffer

- **E/A-Puffer entkoppeln** die E/A-Operationen der Nutzerprozesse vom Gerätetreiber
  - **Kurzfristig** lässt sich eine erhöhte Ankunftsrate an E/A-Aufträgen bewältigen.
  - **Langfristig** bleibt auch bei noch so vielen Puffern ein Blockieren von Prozessen (oder Verlust von Daten) nicht aus.
- Puffer haben ihren Preis:
  - Verwaltung der Pufferstruktur
  - Speicherplatz
  - Zeit für das Kopieren
- In komplexen Systemen wird teilweise mehrfach gepuffert.
  - **Beispiel**: Schichten von Netzwerkprotokollen
  - Nach Möglichkeit vermeiden!

Geräteansteuerung: Beispiel Festplatte

- Treiber muss **mechanische Eigenschaften** beachten!
- Plattentreiber hat in der Regel mehrere Aufträge in Warteschlange
  - Eine bestimmte Ordnung der Ausführung kann Effizienz steigern.
  - Zusammensetzung der Bearbeitungszeit eines Auftrags:
    - **Positionierungszeit**: abhängig von akt. Stellung des Plattenarms
    - **Rotationsverzögerung**: Zeit bis der Magnetkopf den Sektor bestreicht
    - **Übertragungszeit**: Zeit zur Übertragung der eigentlichen Daten
- Ansatzpunkt: *Positionierungszeit*

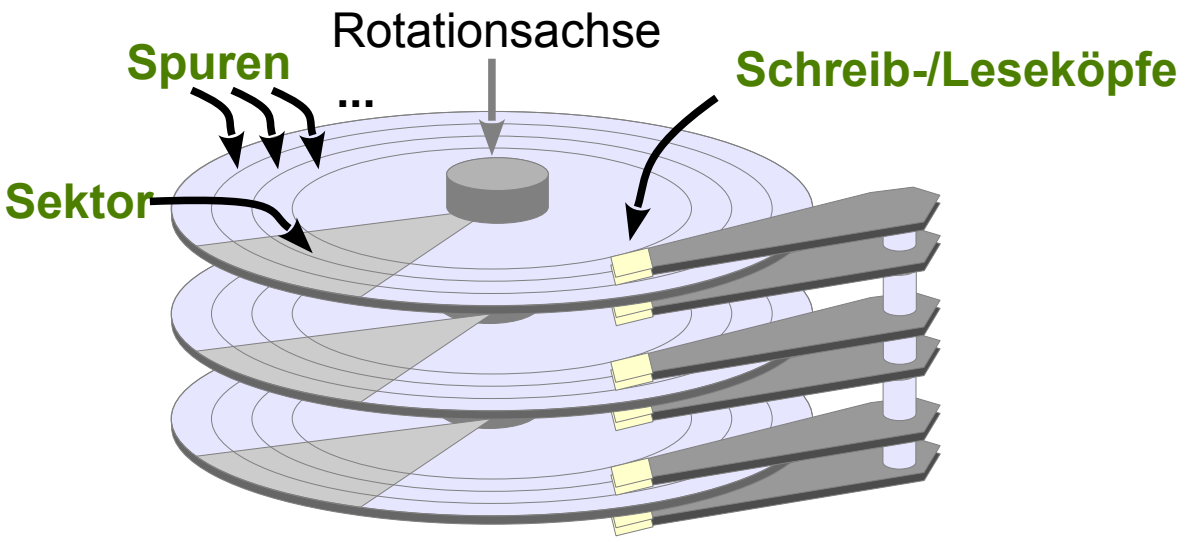

E/A-*Scheduling*: FIFO

- Bearbeitung gemäß Ankunft des Auftrags (***First In First Out***)
  - Referenzfolge (Folge von Spurnummern): 98, 183, 37, 122, 14, 124, 65, 67
  - Aktuelle Spur: 53

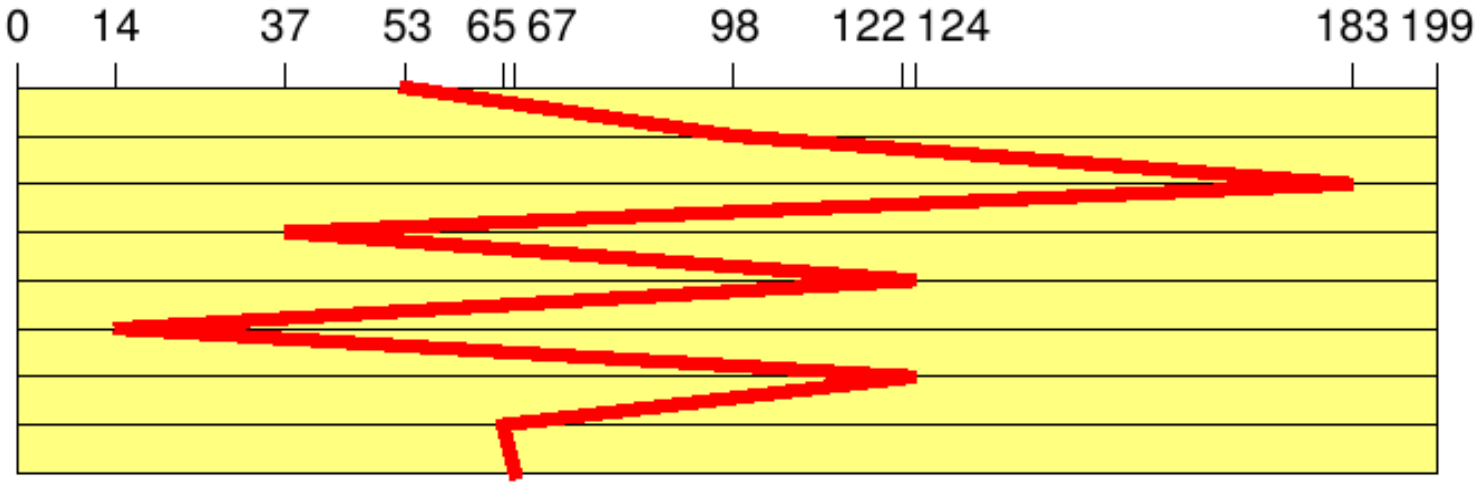

  - Gesamtzahl der **Spurwechsel: 640**
  - Weite Bewegungen des Schwenkarms: mittlere Bearbeitungsdauer lang!

E/A-*Scheduling*: SSTF

- Es wird der Auftrag mit der kürzesten Positionierzeit vorgezogen (***Shortest Seek Time First***)
  - dieselbe Referenzfolge: 98, 183, 37, 122, 14, 124, 65, 67
  - (Annahme: Positionierungszeit proportional zum Spurabstand)

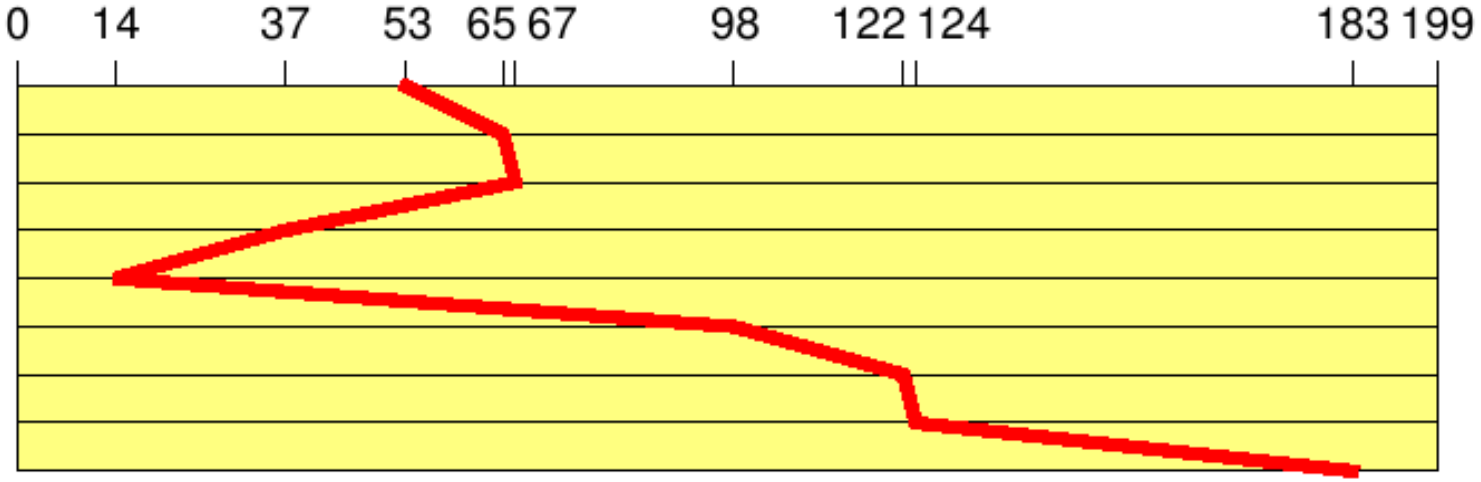

  - Gesamtzahl der **Spurwechsel: 236**
  - ähnlich wie SJF kann auch SSTF zur **Aushungerung** führen!
  - noch nicht optimal

E/A-*Scheduling*: *Elevator*

- Bewegung des Plattenarms in eine Richtung bis keine Aufträge mehr vorhanden sind (**Fahrstuhlstrategie**)
  - Gleiche Referenzfolge (Annahme: bisherige Kopfbewegung Richtung 0)

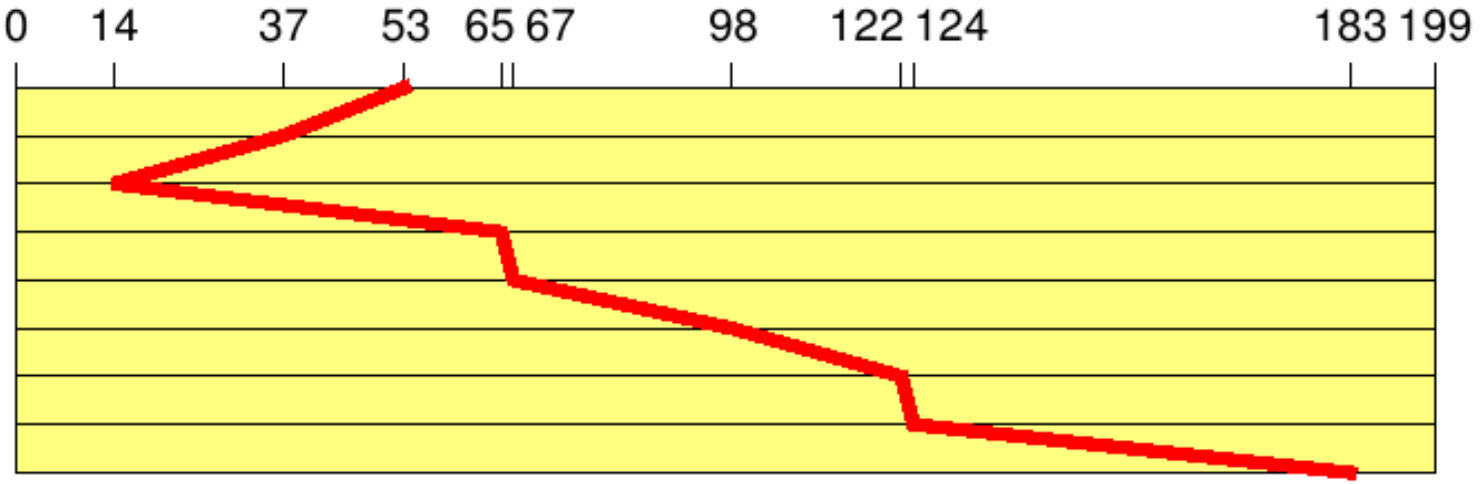

  - Gesamtzahl der **Spurwechsel: 208**
  - Neue Aufträge werden miterledigt ohne zusätzliche Positionierungszeit
  - **Keine Aushungerung**, lange Wartezeiten aber nicht ausgeschlossen

Diskussion: E/A-*Scheduling* heute

- Platten sind intelligente Geräte
  - Physikalische Eigenschaften werden verborgen (Logische Blöcke)
  - Platten weisen riesige Caches auf
  - *Solid State Disks* enthalten keine Mechanik mehr

→ E/A-*Scheduling* verliert langsam an Bedeutung

→ Erfolg einer Strategie ist schwerer vorherzusagen

- Trotzdem ist E/A-*Scheduling* noch immer sehr wichtig:
  - CPUs werden immer schneller, Platten kaum
  - **Linux** implementiert zur Zeit zwei verschiedene Varianten der **Fahrstuhlstrategie** (+ FIFO für „Platten“ ohne Positionierungszeit):
    - **DEADLINE**: Bevorzugung von Leseanforderungen (kürzere Deadlines)
    - **COMPLETELY FAIR**: Prozesse erhalten gleichen Anteil an E/A-Bandbreite

Inhalt

- Ein-/Ausgabe-Hardware
- Geräteprogrammierung
- Aufgaben des Betriebssystems
- Zusammenfassung

Zusammenfassung

- E/A-Hardware ist sehr unterschiedlich
  - teilweise auch „hässlich“ zu programmieren
- Die Kunst des Betriebssystembaus besteht darin, …
  - trotzdem **einheitliche und einfache Schnittstellen** zu definieren
  - **effizient** mit der Hardware umzugehen
  - CPU und E/A-**Geräteauslastung zu maximieren**.
- Gerätetreibervielfalt ist für den Erfolg eines Betriebssystems extrem wichtig.
  - Bei Systemen wie Linux und Windows sind die Gerätetreiber das weitaus größte Subsystem.