# Ein einfaches Dateisystem

Betriebssysteme
WS 2017/18

Hermann Härtig
TU Dresden

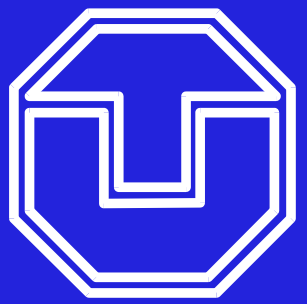

# Gegenstand

**Aufgaben eines Dateisystems**

- **Persistenz** von Daten, d. h. Daten sollen Prozess- und Systembeendigungen überstehen (auch Abstürze)
- Basismechanismen für Datenbanken
- manchmal: Schutz (separate Kapitel dieser Vorlesung)

**Zentrale Herausforderungen**

- Hardwareeigenschaften des persistenten Speichermediums
- Robustheit

→ separate Kapitel in dieser Vorlesung

**In dieser Vorlesungs-DS**

- ein ganz einfaches Dateisystem (ca Unix 1980)
- und seine Integration in Systemarchitektur

# Begriffe (nach NEHMER)

**Dateisystem**

- BS-Komponente, die Anwendungsprogrammen einen effizienten Zugriff auf persistent gespeicherte Daten ermöglicht

**Datei**

- „Behälter“ für die dauerhafte Speicherung von Informationen (gleicher oder ähnlicher Struktur) unter einem inhaltlichen Gesichtspunkt
- codiert in Bytes, durch einen „Bezeichner“ repräsentiert

**Verzeichnis**

- besondere, vom Dateisystem verwaltete Datei zur Strukturierung der auf Externspeicher abgelegten Dateien

# Datei-Operationen

| Operation | typische Parameter |
|---|---|
| • Erzeugen (Create) | Name, Attribute, Zugriffsart → Handle |
| • Entfernen (Delete, Unlink) | Name |
| • Öffnen (Open) | Name, Zugriffsart → Handle |
| • Schließen (Close) | Handle |
| • Lesen (Read) | Handle, Anzahl Zeichen, Puffer |
| • Schreiben (Write) | Handle, Anzahl Zeichen, Puffer |
| • Append | Handle, Anzahl Zeichen, Puffer |
| • Seek | Handle, Position |
| • Lesen/Setzen von Attributen | |
| • Umbenennen | |
| • „Einblenden“ | |

# Benennung (von Dateien)

**Aufgaben:**

- Benennen: symbolisch, (auch) Mensch als Benutzer
- Identifizieren: Programme, Datenbanken als Benutzer
- (schnelles) Lokalisieren
- Zugreifen

**Beispiele**

- /Users/haertig/tmp/Dateien02S.ppt
- 4, 19, 329 (I-Knoten-Nummer); 17 (Filedescriptor)
- canaletto.inf.tu-dresden.de; 141.76.20.10

# Symbolische Dateinamen

Benutzer legen Dateinamen fest ...

- innerhalb bestimmter Grenzen, je nach System
- nach Konventionen:
  - Folgen lesbarer Zeichen
  - Groß-/Kleinschreibung signifikant (oder nicht)
  - kontextabhängig (oder nicht)
  - Extensionen, z. B. komprimiertes Quell-Programm: .c.gz
  - Längenbeschränkungen
  - mit Rechnernamen, z. B. erwin:/home/hh7/tmp/x
  - Hierarchiebildung
  - mehrere Namen für ein Objekt
  - inhaltsbezogene Benennung
  - Möglichkeiten zur Abkürzung

# Datei-Attribute

**Zugriffschutz**

- Eigentümer, Besitzer, Rechte des Besitzers und anderer

**Zeiten**

- Erzeugung, letzte Modifikation, letzter Zugriff, ...

**Organisatorisches**

- aktuelle/maximale Größe
- Verwaltungsinformationen (unsichtbar)

# Datei-Typen

- in Unix-Welt:
- ➔ alle (cum grano salis) Objekte werden auch als Dateien behandelt

**Beispiele**

- normale Dateien (regular file)
- Verzeichnisse (directories)
- E/A-Geräte (special files)
- Datenströme (pipes)
- Symbolic Links

# Zugriffsstrukturen

**flach (Unix)**

- Zugriff per index in BYTE ARRAY
- Lesen/Schreiben in beliebigen Einheiten an beliebigen Stellen
- Aufprägung von Strukturen durch Anwendungen

**„Record“-Strukturen (satzstrukturierte Dateien)**

- Zugriff per “key”
- Länge der Records konstant oder variabel
- ein Datensatz (record) pro Zugriff (Lesen/Schreiben)
  - sequentiell
  - direkter Zugriff über Schlüssel
  - Kombiniert: “indexsequentiell”
- “Key-Value Stores”

# Verzeichnisse und Pfadnamen

Ziel:

- systemweite Eindeutigkeit von Dateinamen

Lösung:

- Name eindeutig in einem „Kontext“
- auch Kontexte haben Namen

Pfadname:

- Folge von Teilnamen
- Namens-Auflösung: von einem Ausgangs-Kontext ausgehend wird jeder Teilname in seinem Kontext interpretiert

Beispiel:
/Users/haertig/mail/nov/15

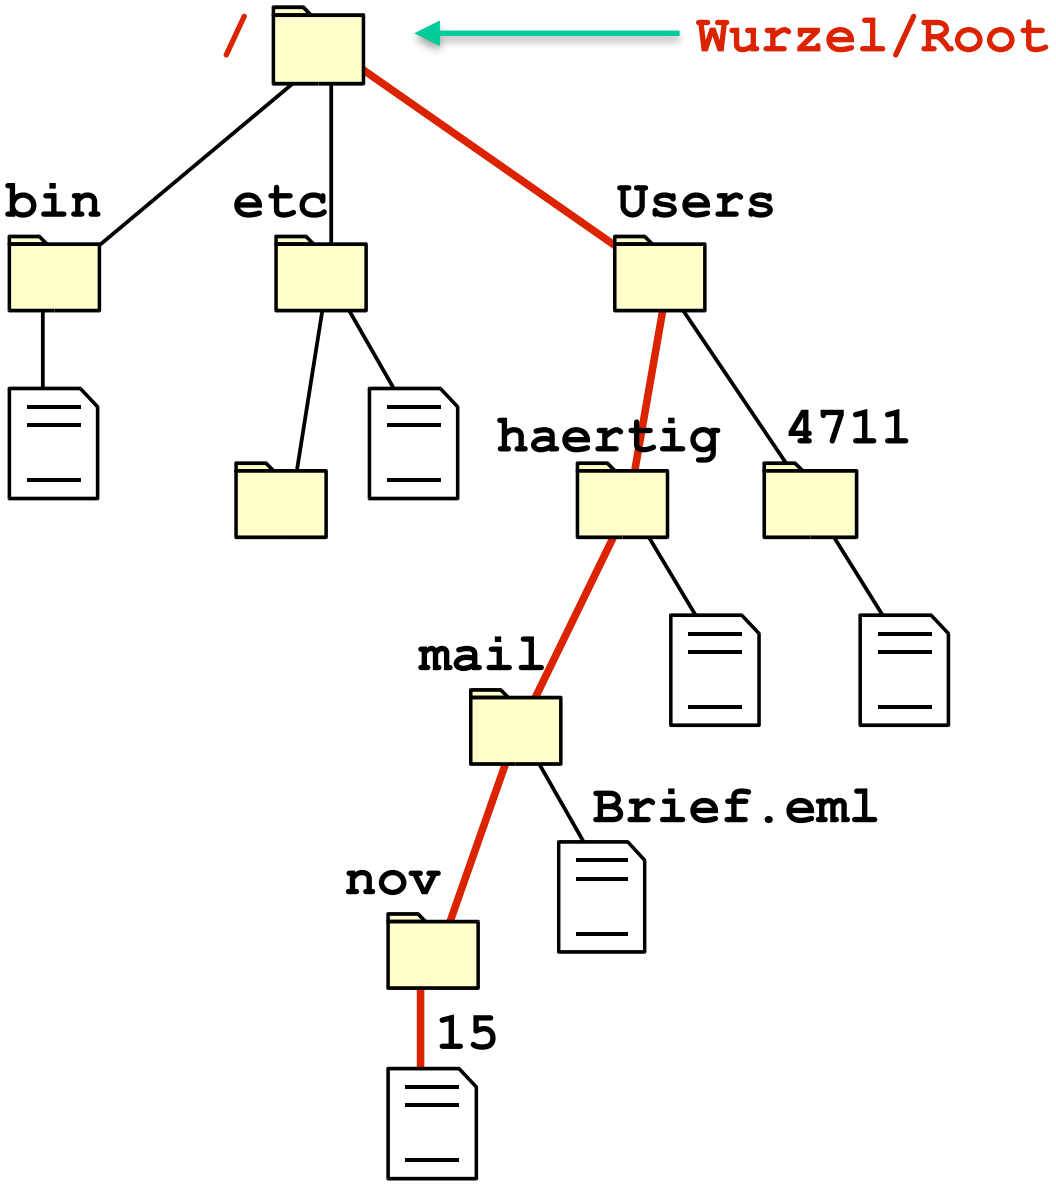

# Verzeichnis (Folder, Directory)

Abbildung von Teilnahmen auf Datei-Identifikatoren

(z.B. I-Knoten-Nummer -> kommt später):

Beispiele:

- Wurzelverzeichnis:
  bin → 5, etc → 7, Users → 567
- "Users":
  haertig → 89, 4711 → 999

# Organisation von Namensräumen

Fragestellungen:

- externe Speichermedien (SD-Karten, USB, …)
- Netzwerkdateisysteme (-> später)
- mehrfache ähnliche Nutzerumgebungen (“Container”)
- Backups
- …

Mechanismen:

- harte und symbolische “Links”
- Verbinden von Namensräumen (Mount)
- Festlegung von Kontexten

# Kontexte für Namen

Ausgangs-Kontexte durch Prozesse festgelegt, z. B. in Unix :

- Root directory: Kontext für globale Namen
- home directory: current directory bei login und durch parameterloses „cd“
- current directory: Ausgangskontext für relative Pfadnamen

Jeder Ausgangskontext kann geändert werden

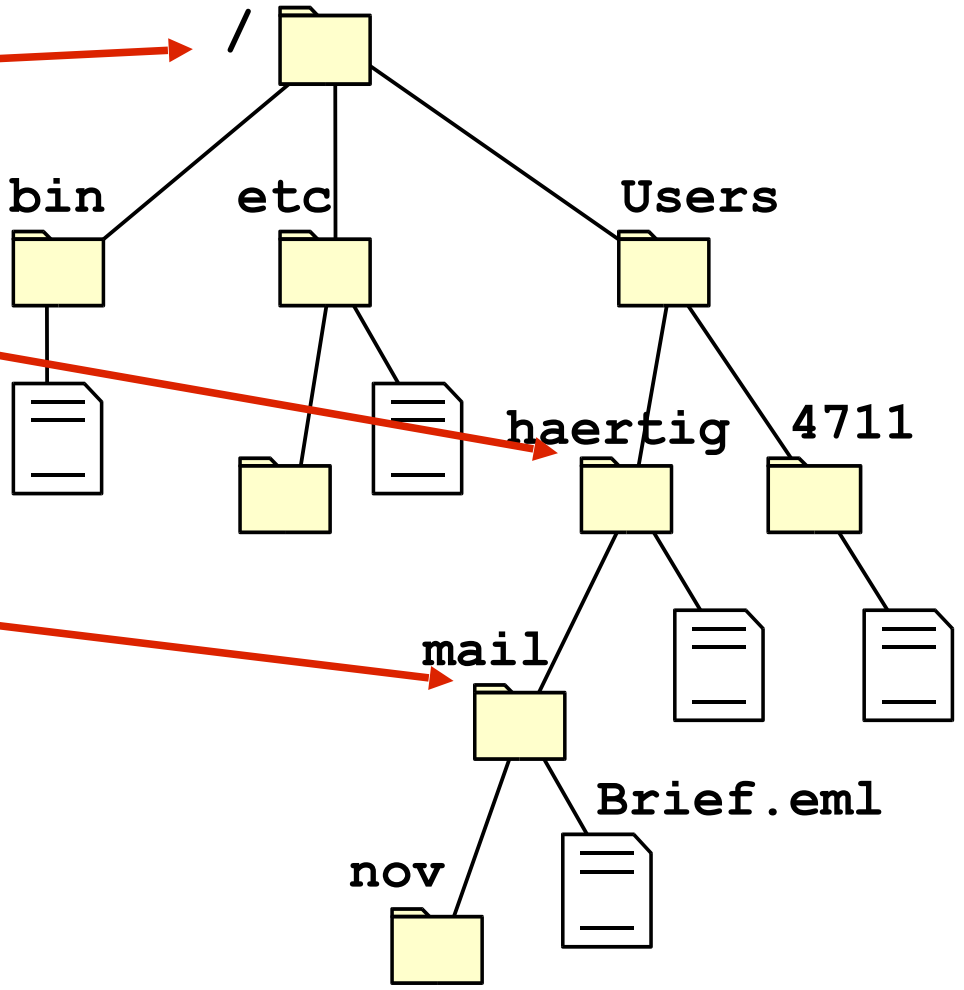

# Mehrere Namen für eine Datei: Hard Links

**„Harte Links“**

- Identifikatoren in mehreren Verzeichnissen
- Limitation:
  Gültigkeit Identifikatoren über Rechnergrenzen hinweg ?
- Zyklen !

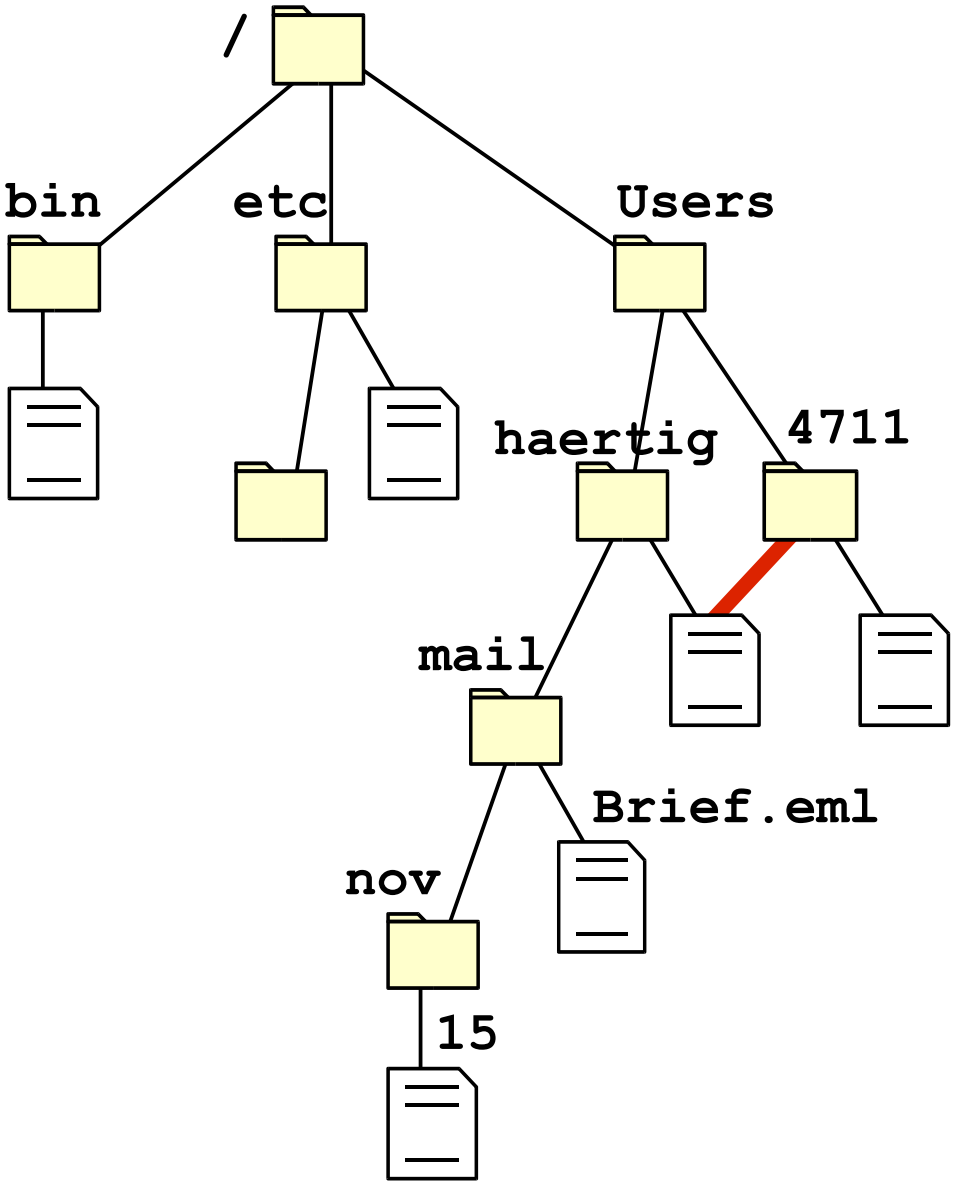

# Mehrere Namen für ein Objekt: Symb. Links

**„Symbolische Links“**

- Namen als Objekte
- Zyklen !

**Beispiel**

- x → 23
  in 23: /Users/haertig/mail/nov

→ /bin/x/15 = /Users/haertig/mail/nov/15

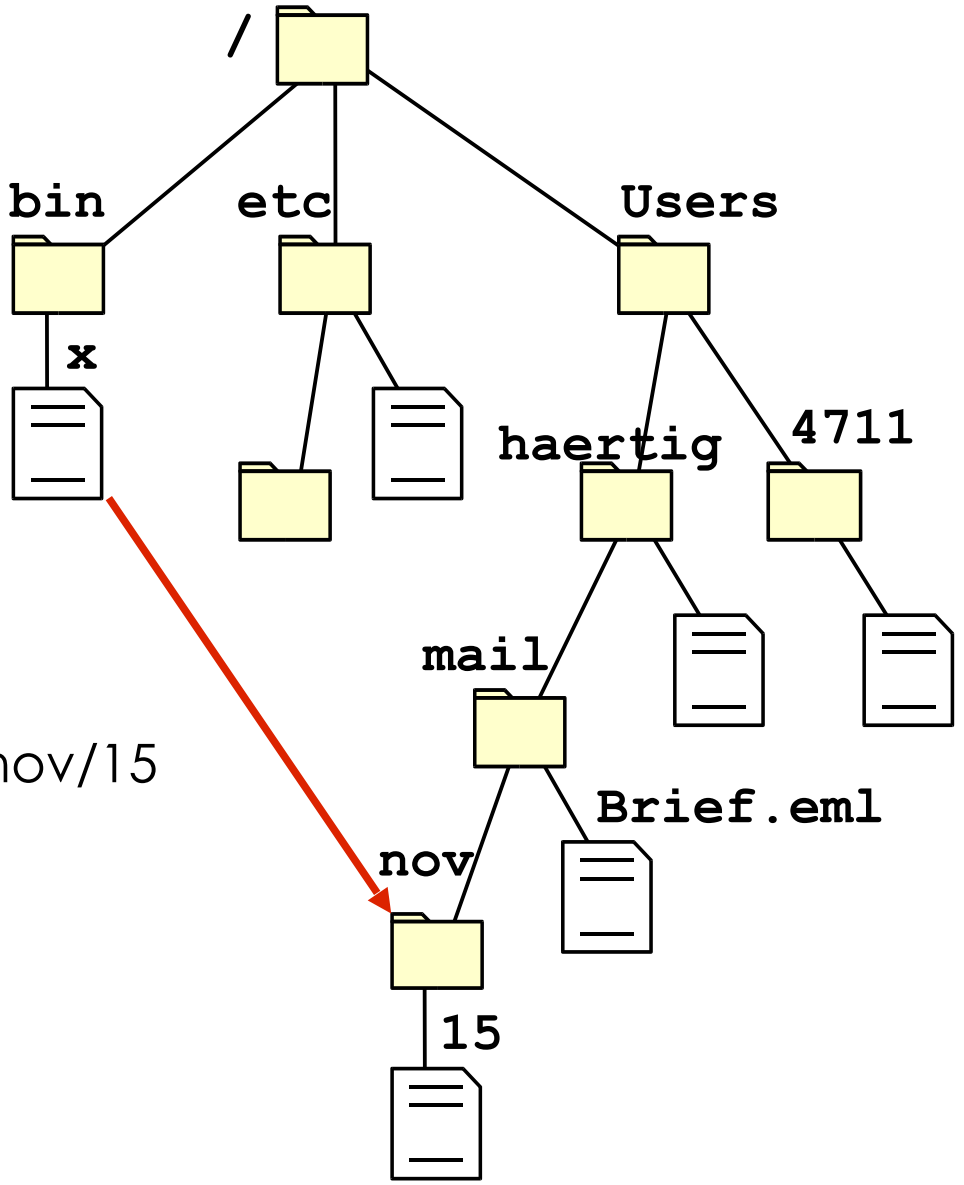

# Beispiel für Zyklen

/etc/bin/XYUtils → /bin/XYUtils
/bin/XYUtils → /usr/local/bin/XYUtils
/usr/local/bin/XYUtils → /etc/bin/XYUtils

Auflösung von /bin/XYUtils/example

- /usr/local/bin/XYUtils/example
- /etc/bin/XYUtils/example
- /bin/XYUtils/example
- /usr/local/bin/XYUtils/example
- /etc/bin/XYUtils/example

# Verbinden von Namensräumen: “Mount”

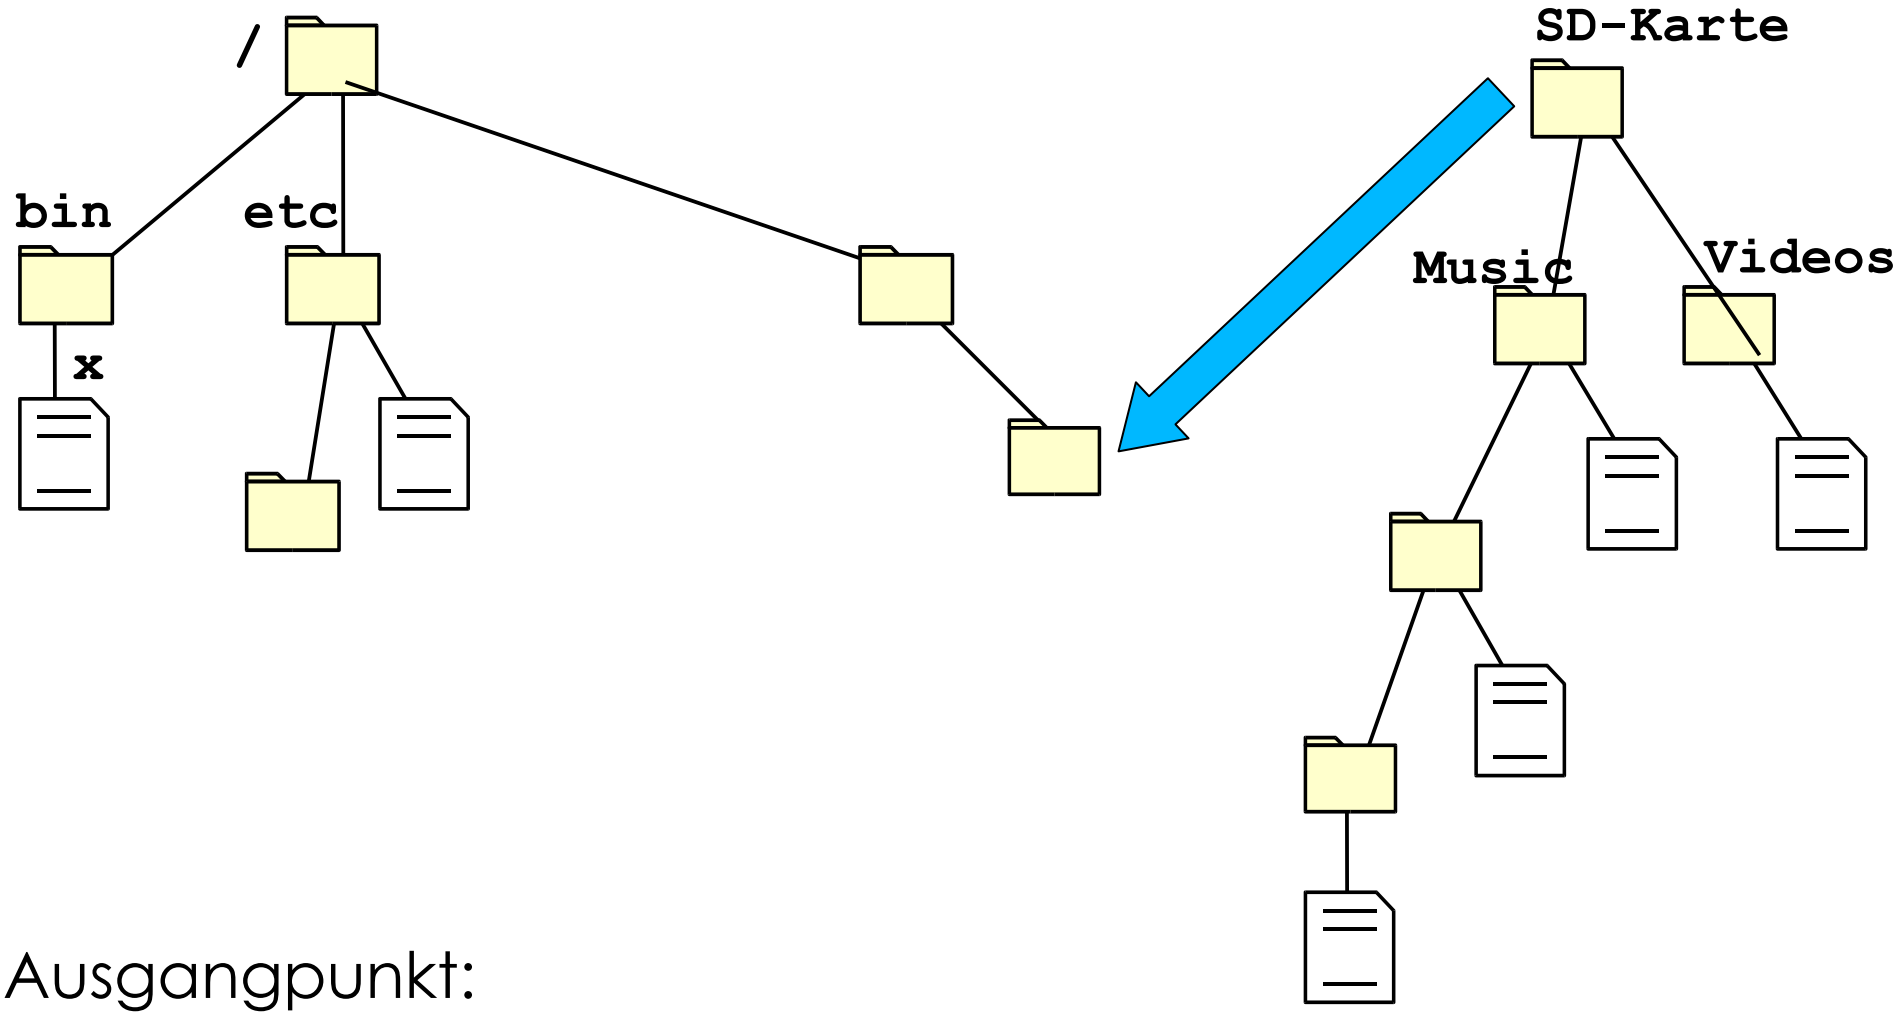


Ausgangpunkt:
2+ Dateisysteme (intern/SD-Karte)

# Verbinden von Namensräumen: “Mount”

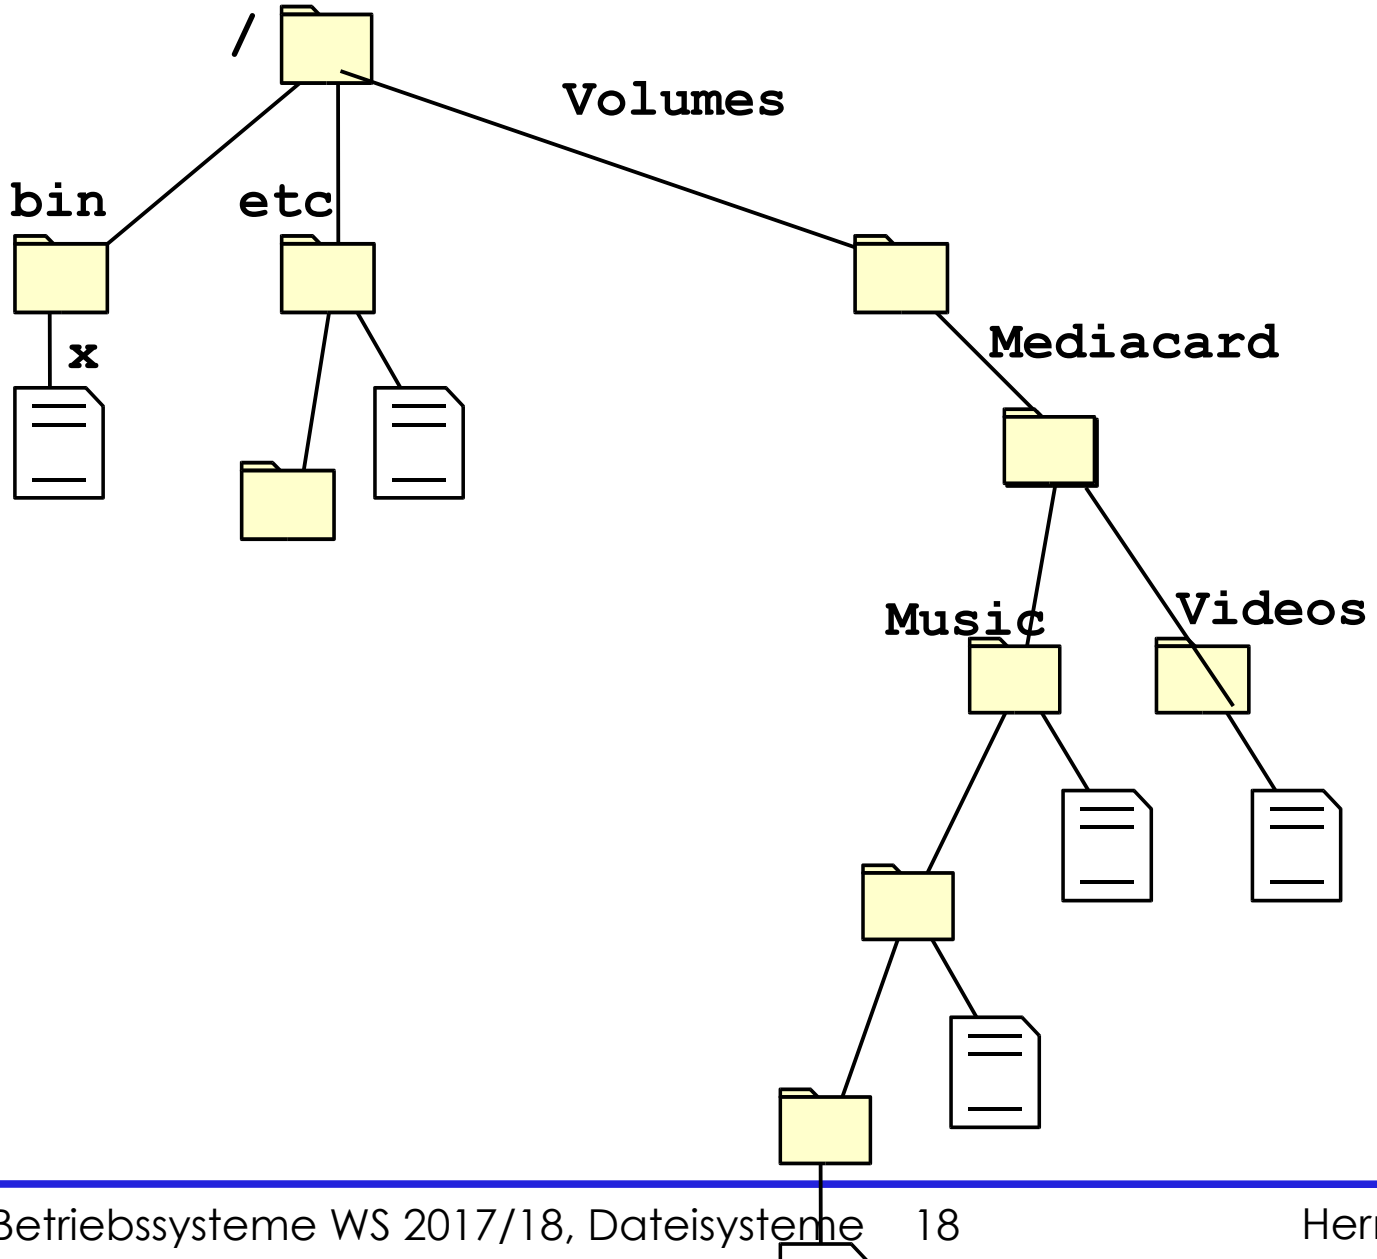

# Dazu: Symbolic Links

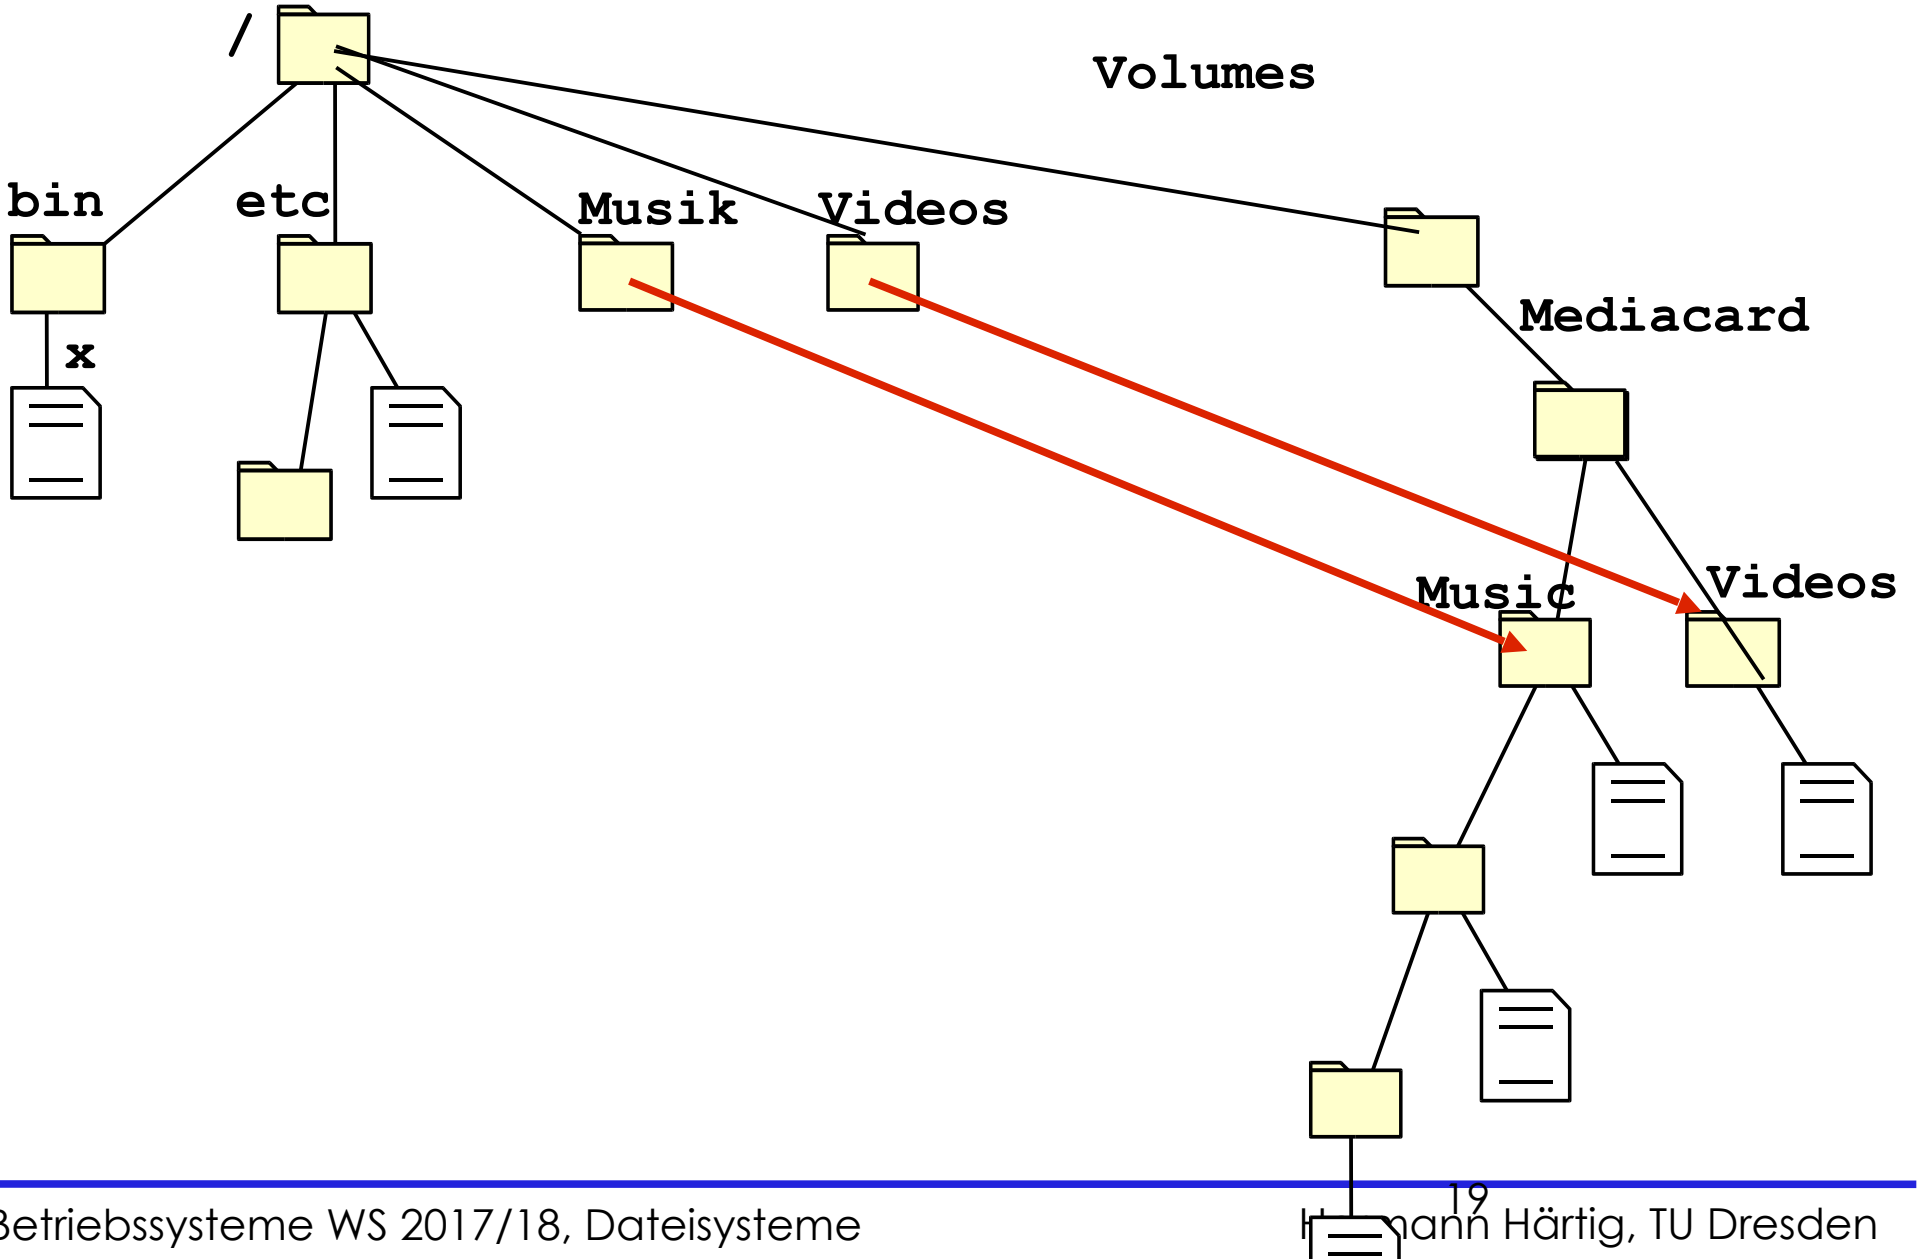

# Backup

- Alle X Stunden vollständige Kopie des Dateisystems
- Nur das Nötige Kopieren
- Mehrfache harte Links auf alles, was sich nicht änderte

# Backup mit Hard Links

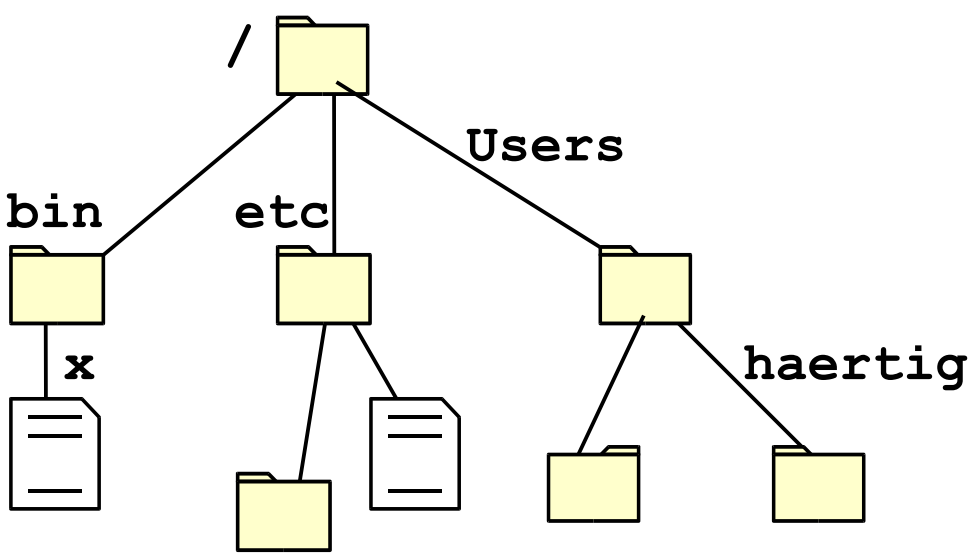


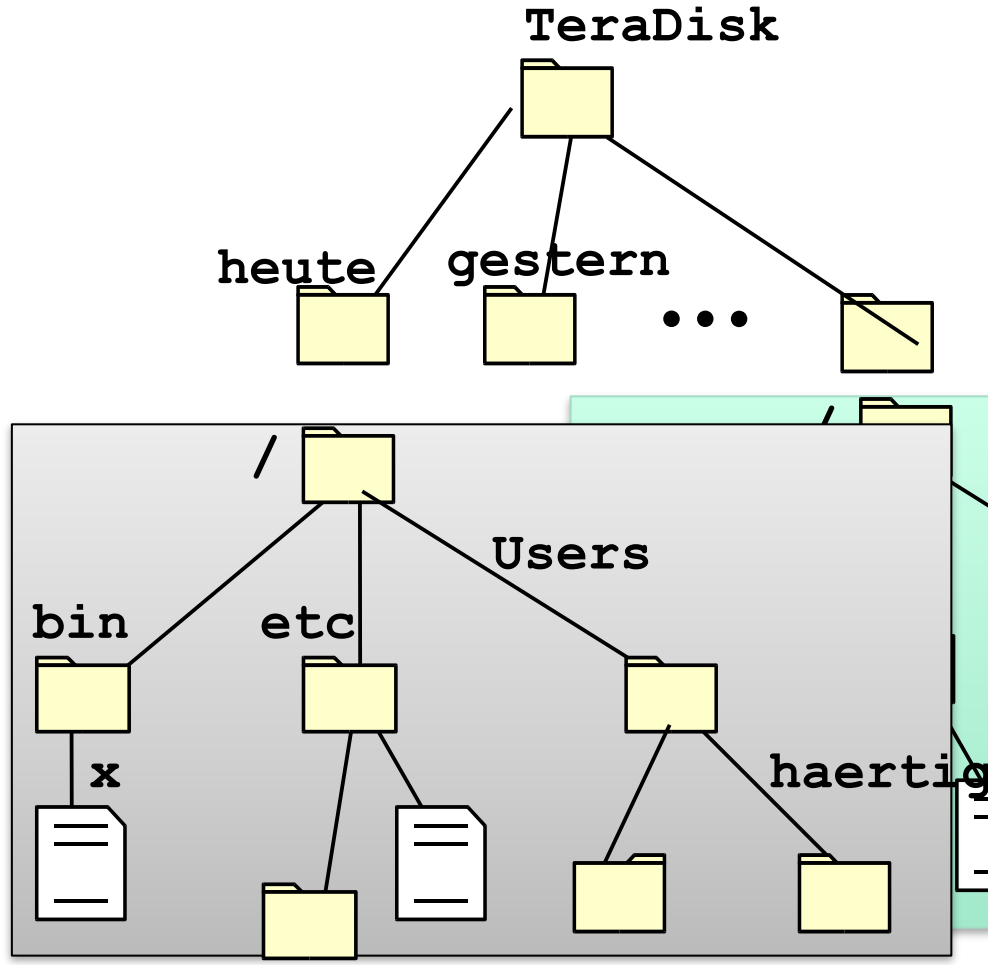

# Backup mit Hard Links

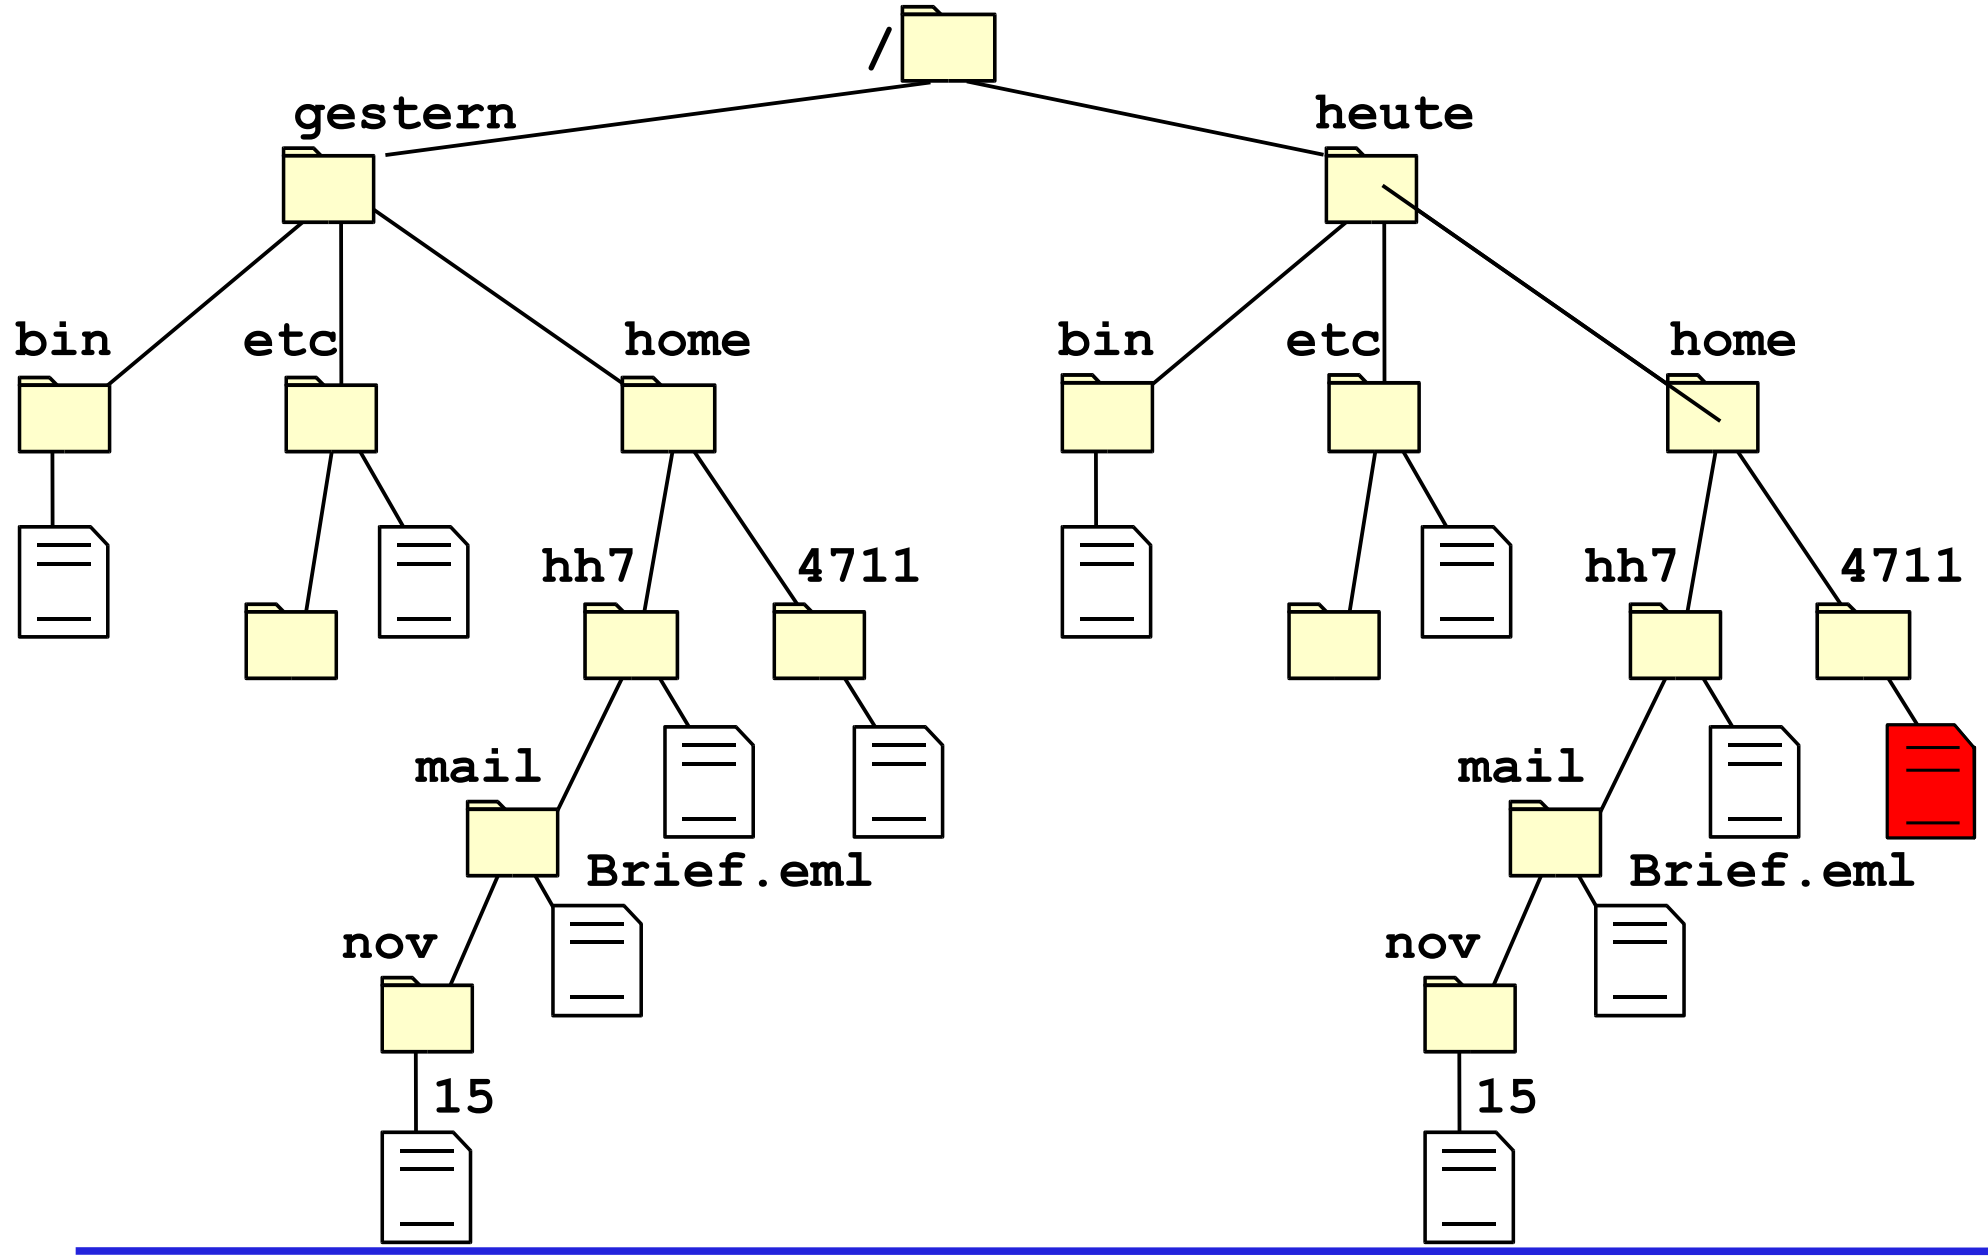

# Beispiel: Backup

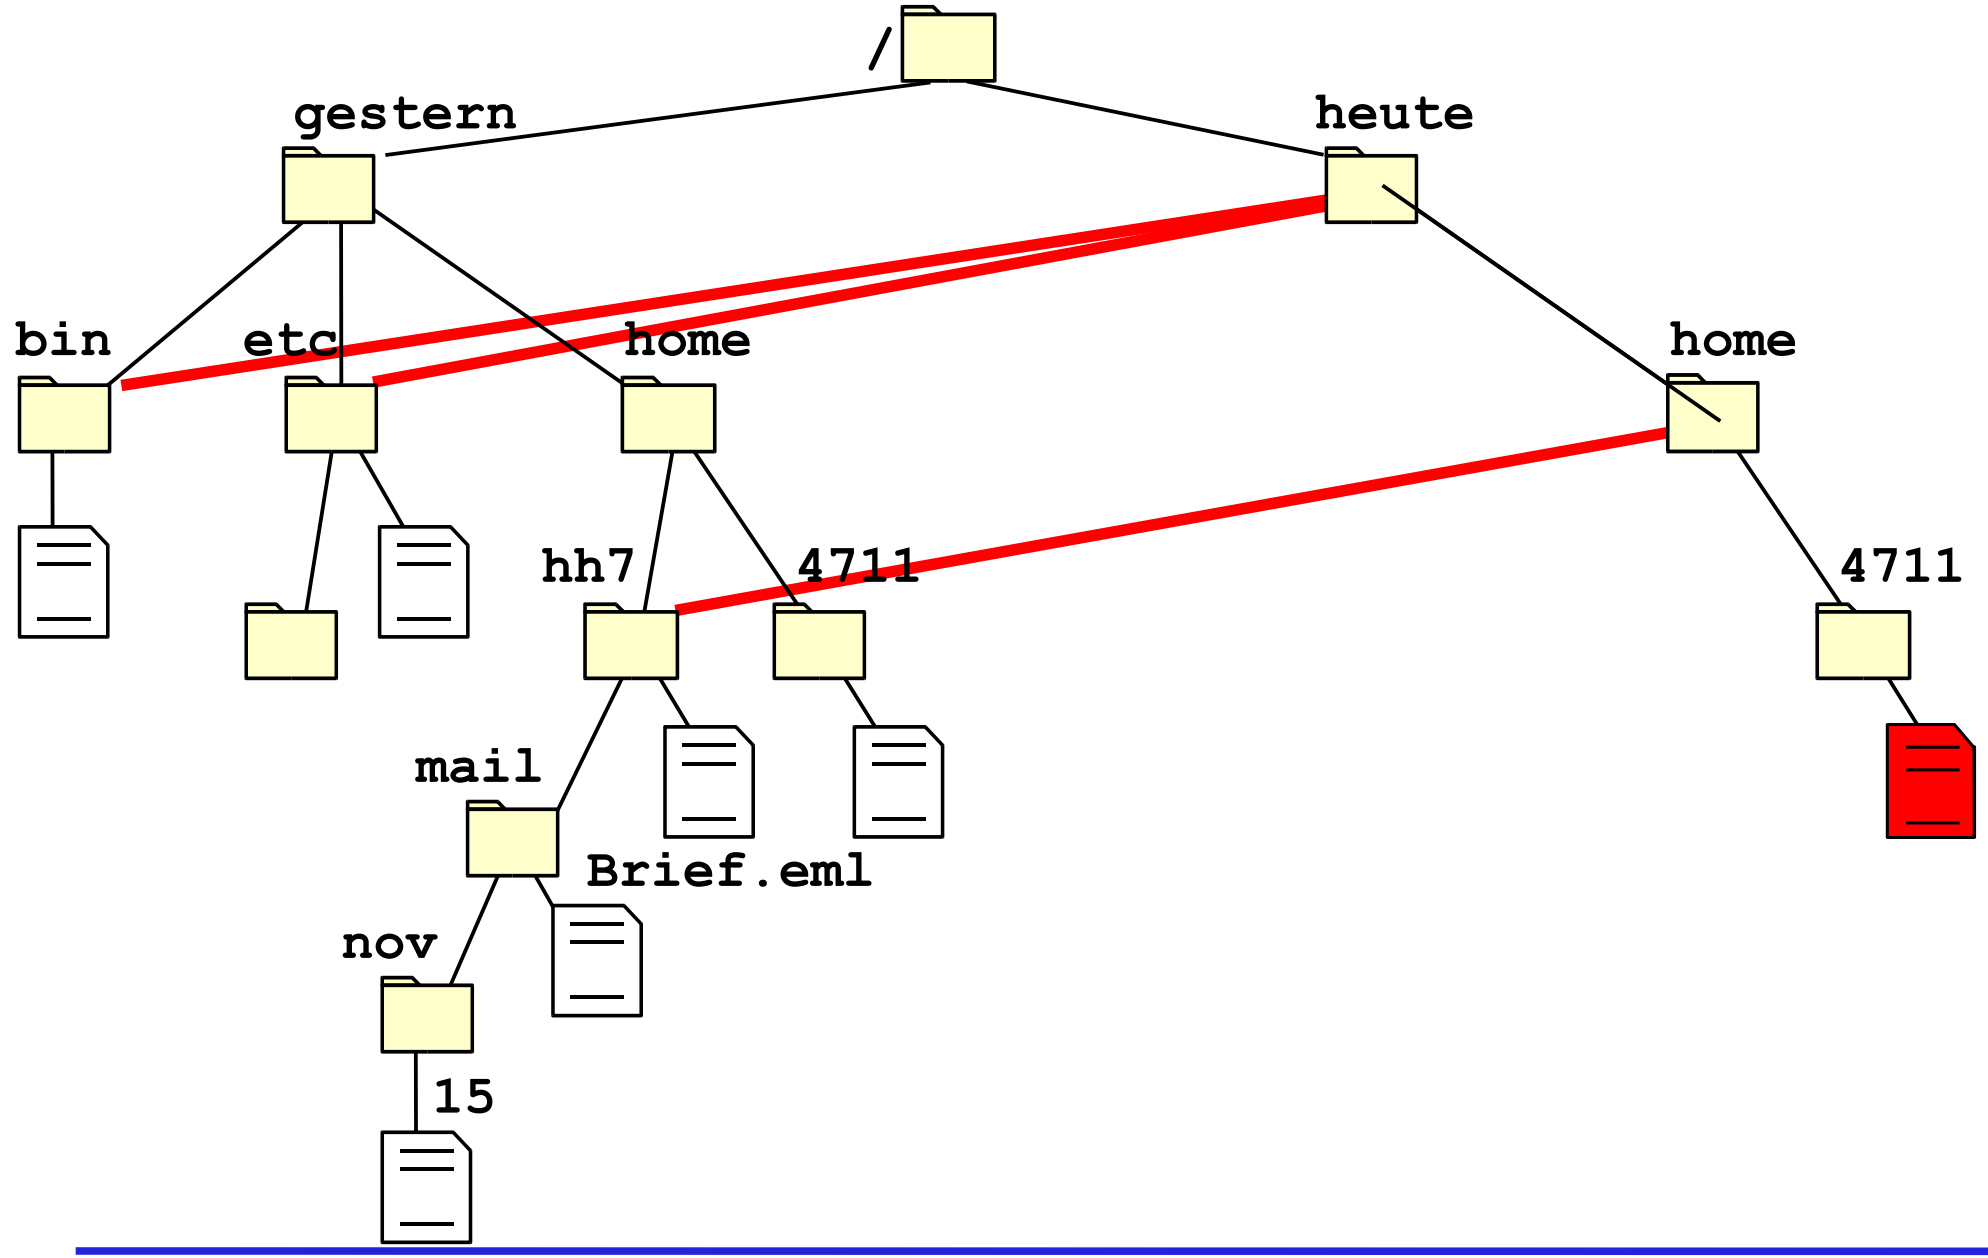

# Kontexte für Namen

Ausgangs-Kontexte durch Prozesse festgelegt, z. B. in Unix :

- Root directory: Kontext für globale Namen
- home directory: current directory bei login und durch parameterloses „cd“
- current directory: Ausgangskontext für relative Pfadnamen

Jeder Ausgangskontext kann geändert werden

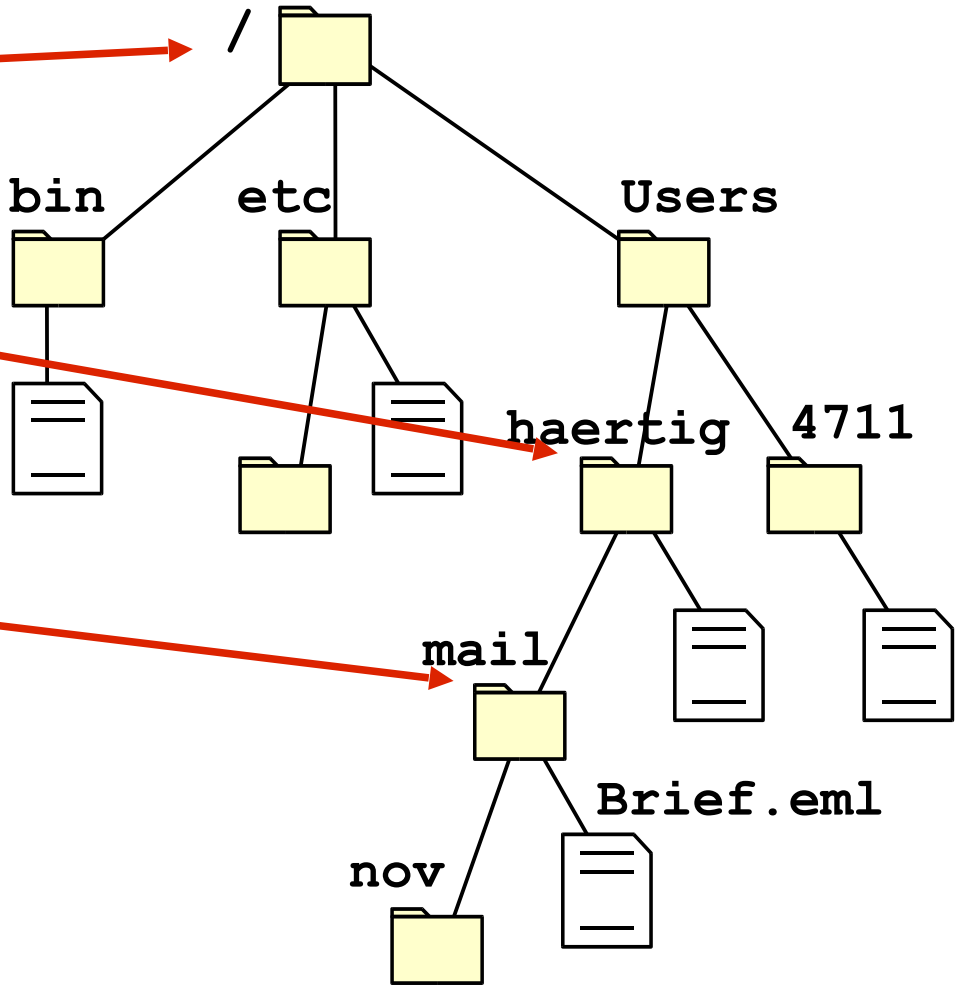

# Einfache Form von Virtualisierung

Unix:
CHROOT

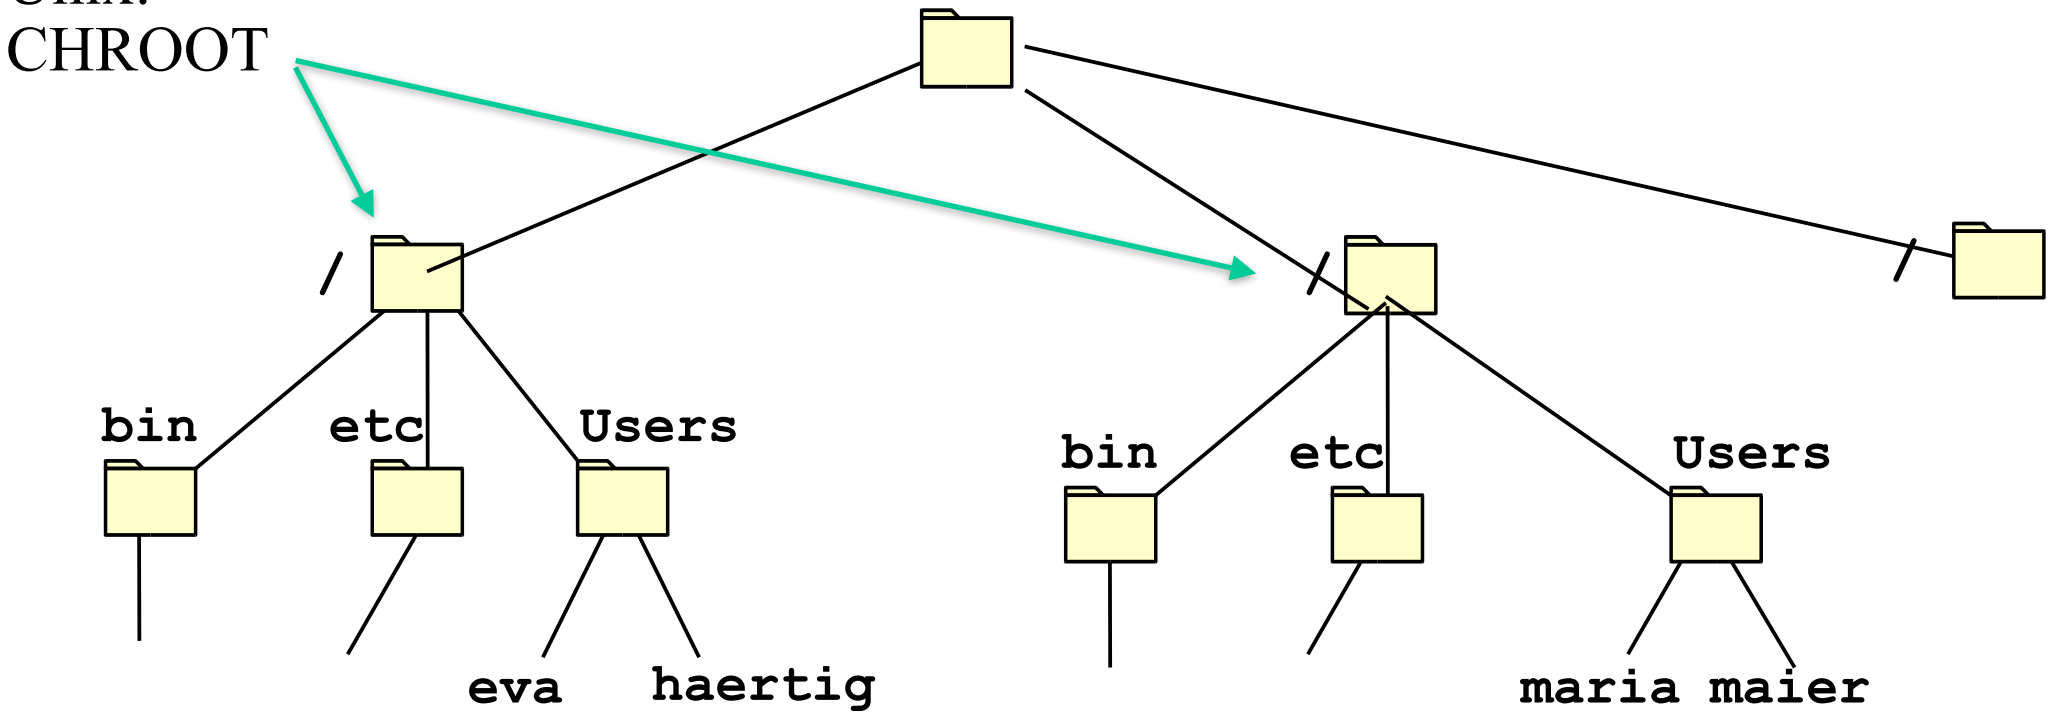


Rudimentäre Form von "Container"

# Verzeichnisse

Implementierung und Zugriff analog normale Datei mit:

- interner Struktur
- speziellen Operationen
  - opendir / closedir
  - readdir
  - lookup
  - rename

# i-nodes (I-Knoten)

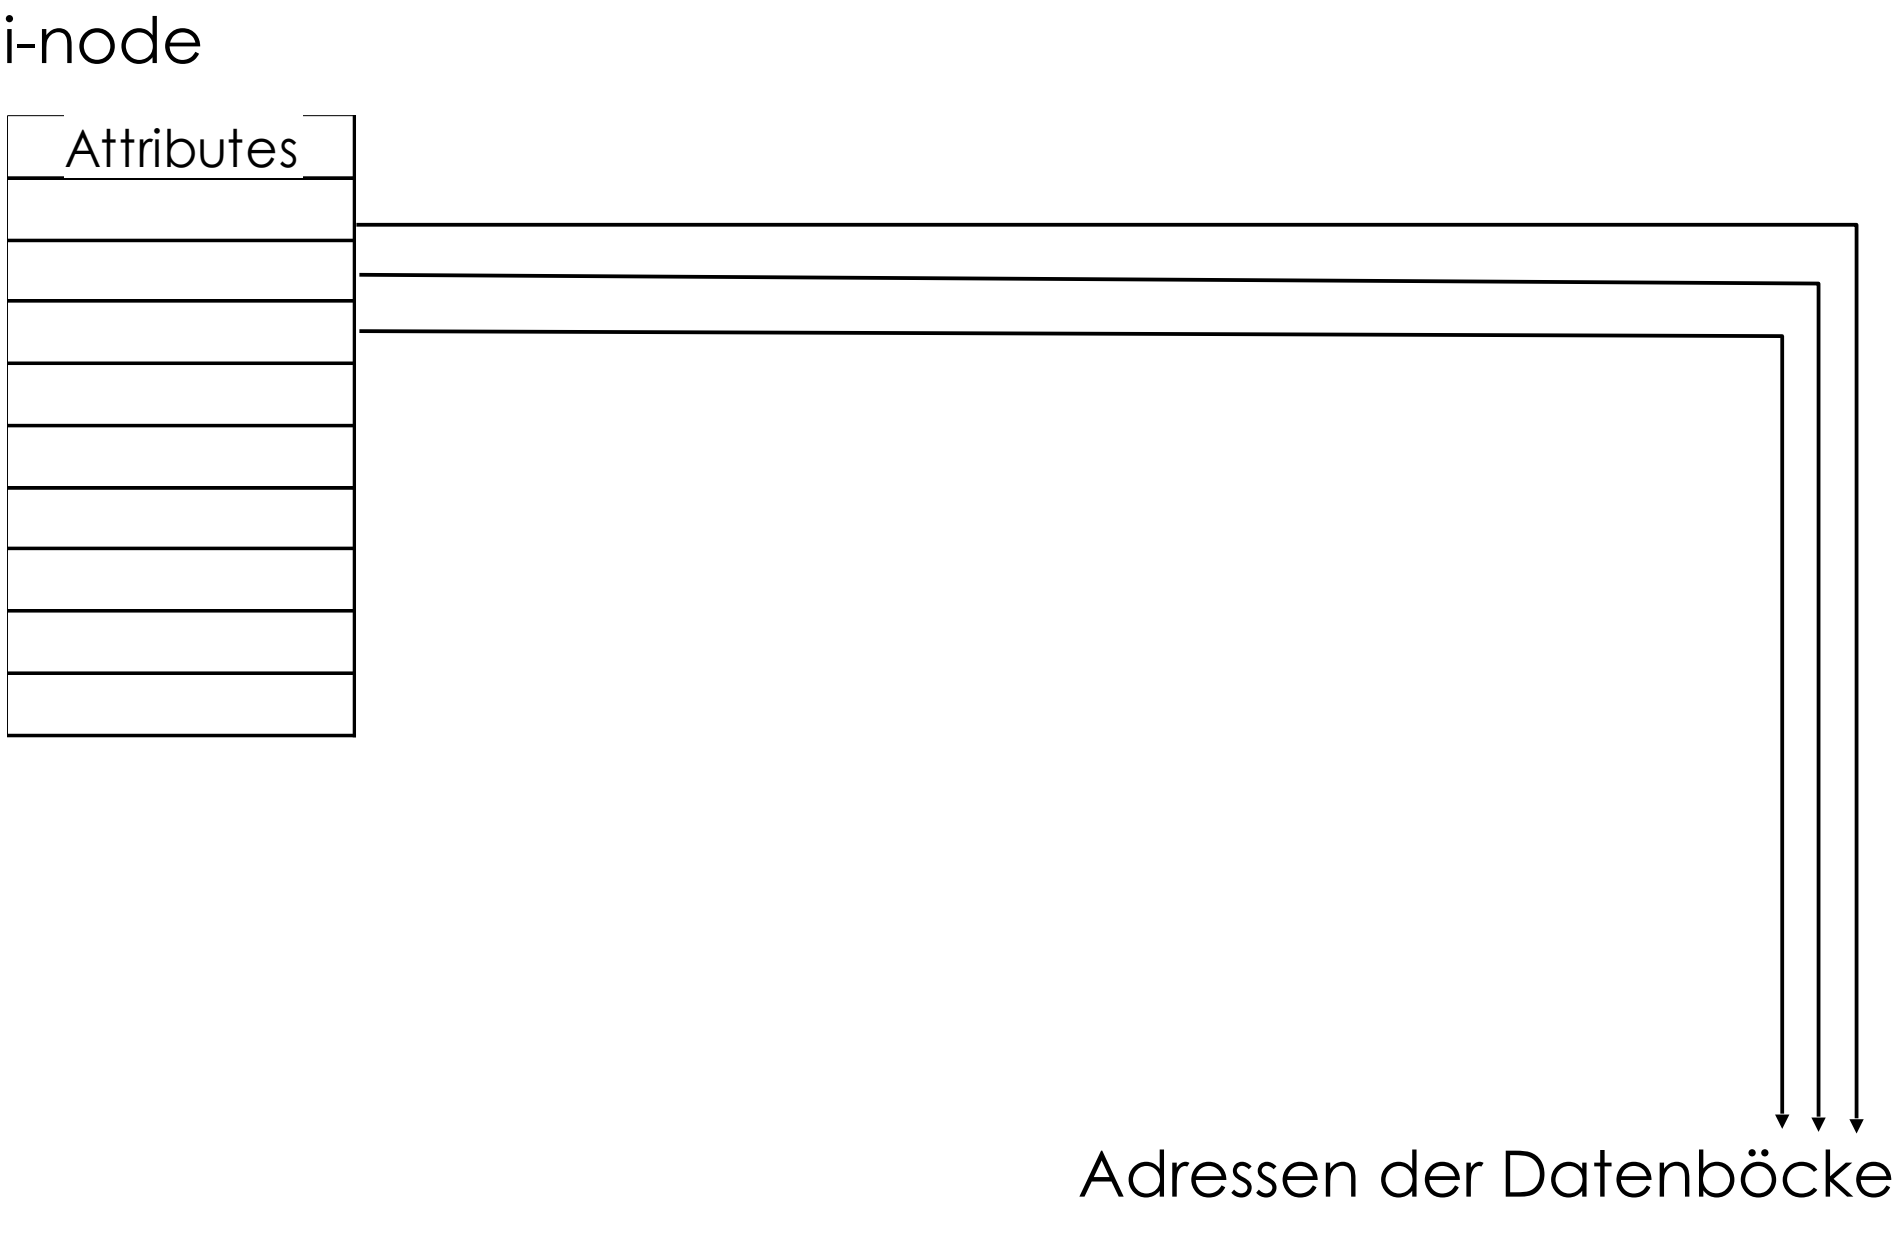

# i-nodes (I-Knoten)

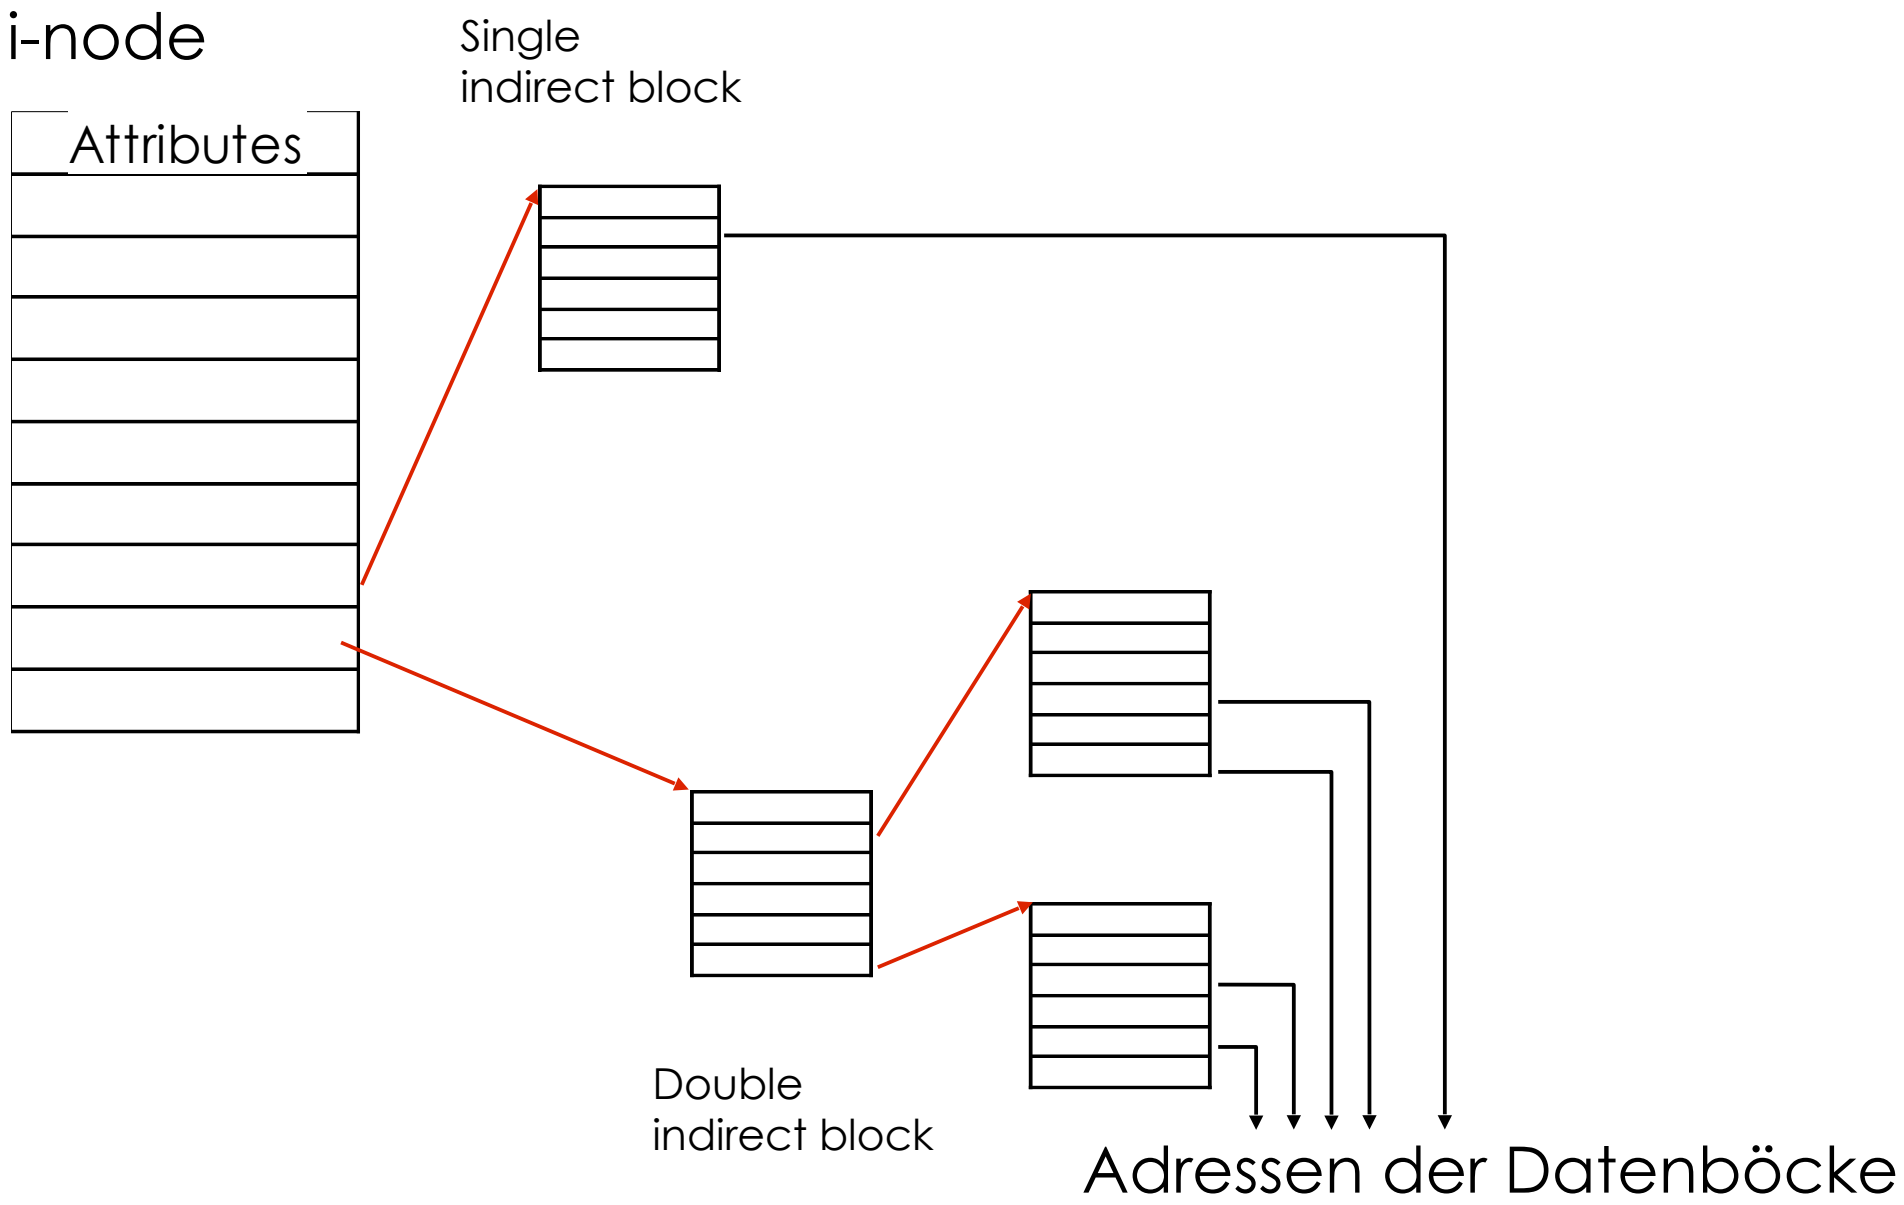

# i-nodes (I-Knoten)

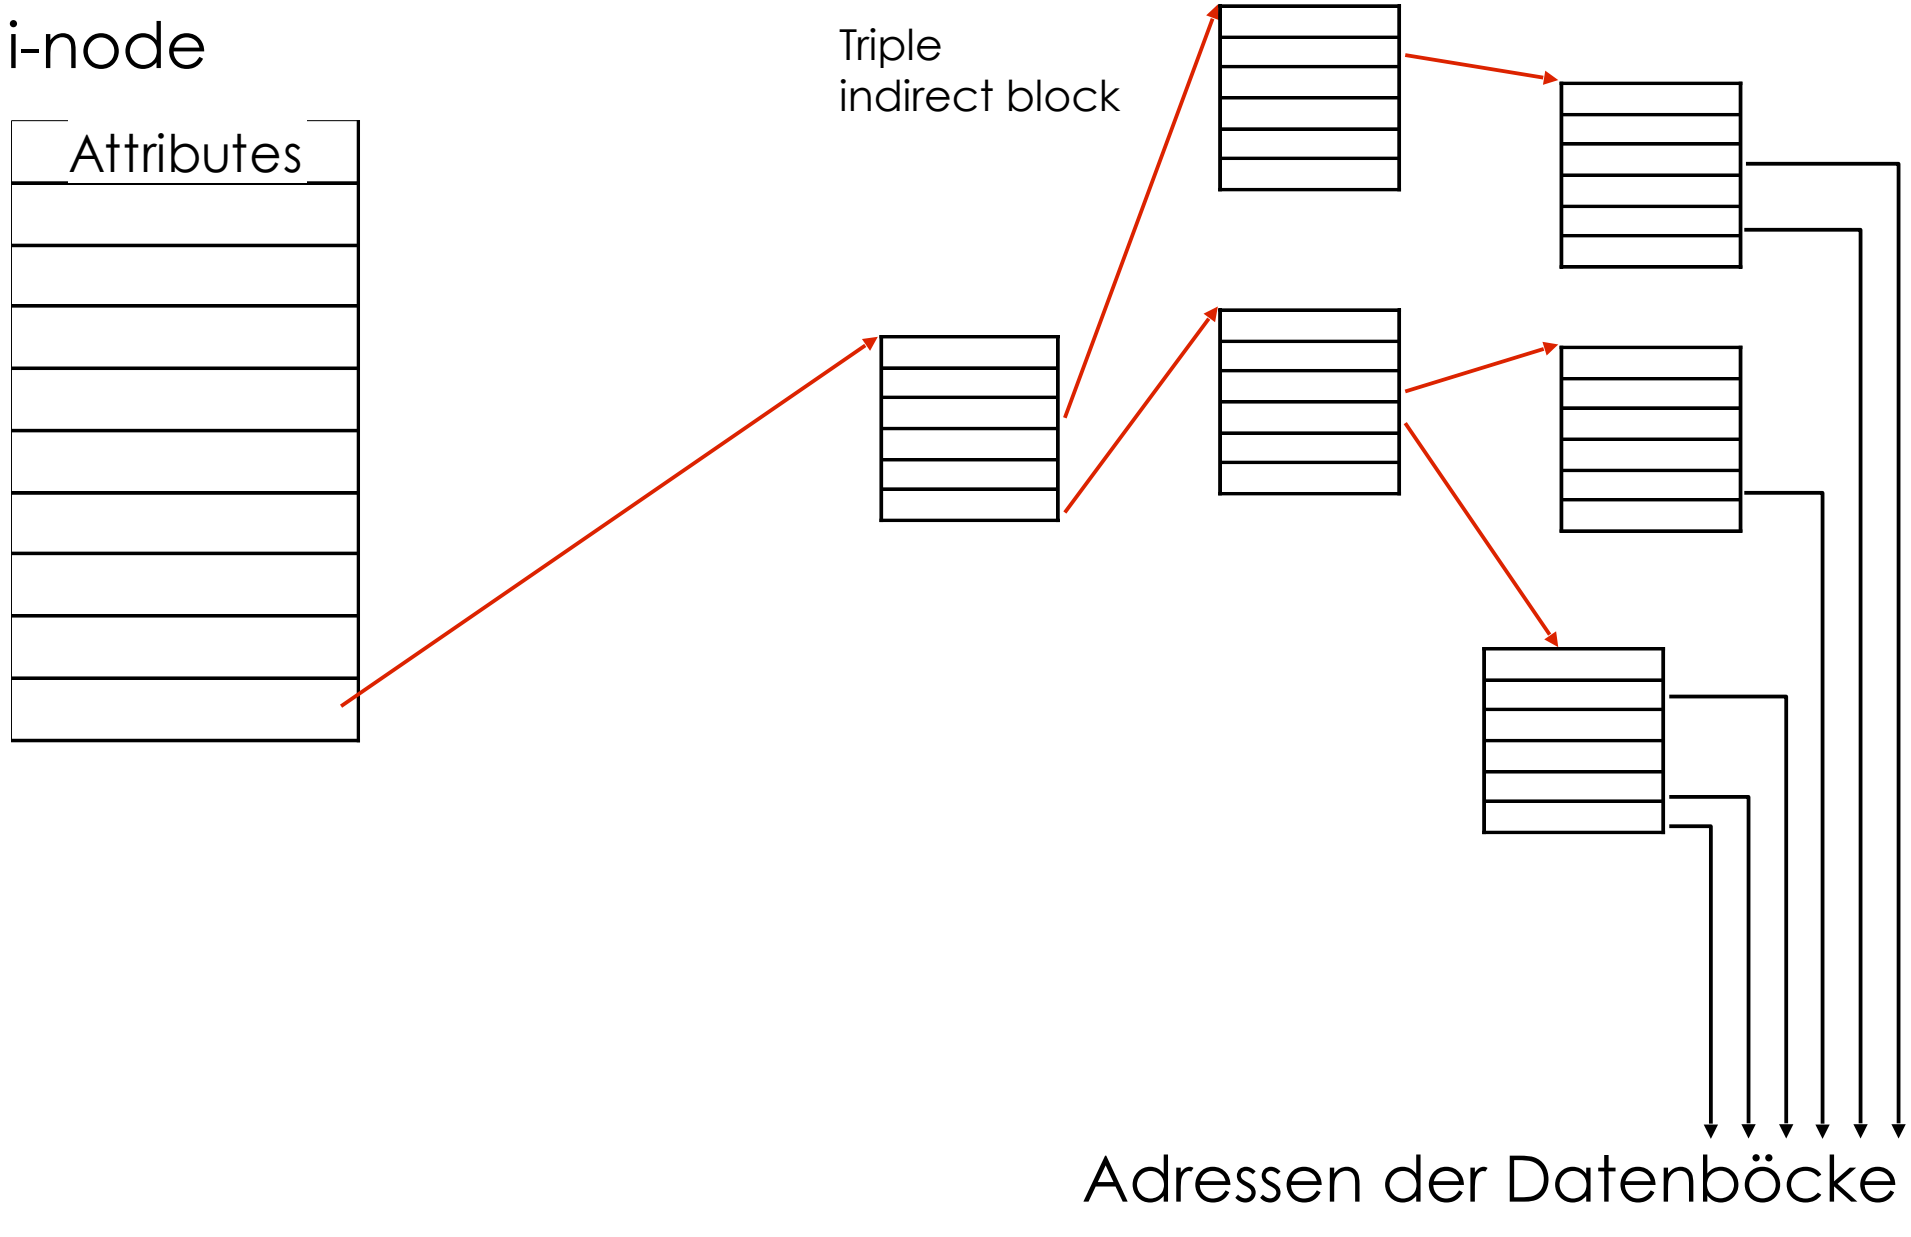

# Verwaltung des freien Plattenspeichers

## Verwendung von Listen

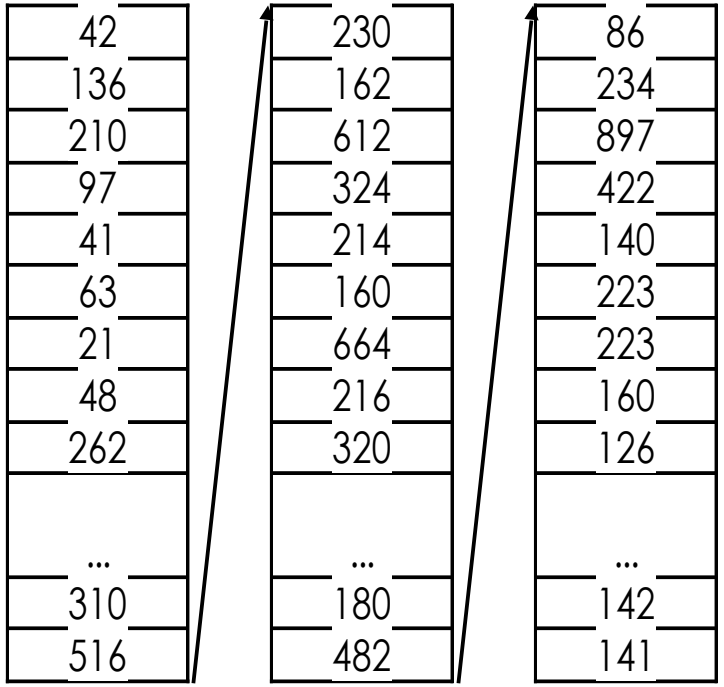


## Verwendung von Bitmaps

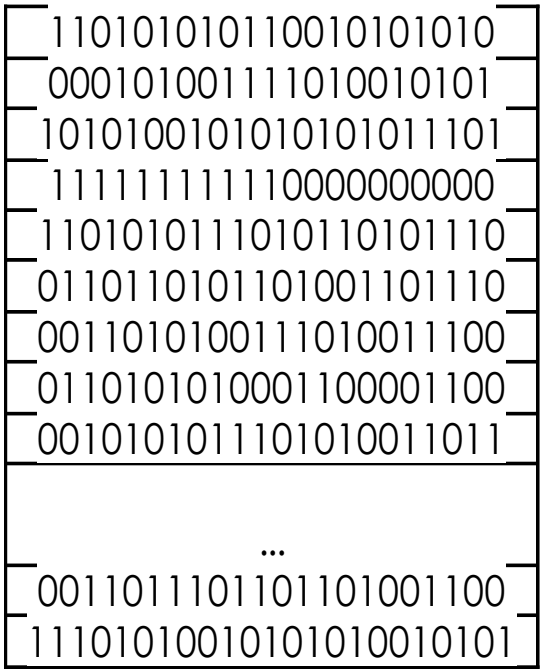

# Ablauf eines Dateizugriffs

Namensdienste:
symbolische Namen → Identifikatoren

Zugriffe auf (Daten in) Dateien:

- häufig: **`open`** (Zugriff)* **`close`**
- Zugriff über
  - Kopieren aus Datei in Adressraum und zurück:
    **`read/write`** (Datei, Position in Datei, Länge, Adresse im Adressraum)
    keine Ausrichtung der Adressen notwendig
    **`seek`**-Operation ersetzt „Position in Datei“ als Parameter
  - Einblenden in Adressraum:
    **`map`** (Datei, Adresse in Adressraum, Offset, Länge)
    dann Zugriff über normale Maschinen-Instruktionen
    Offset und Adresse müssen an Seitengrenzen ausgerichtet sein

Zugriffe auf Dateiattribute ...

# Integration in Systemarchitektur

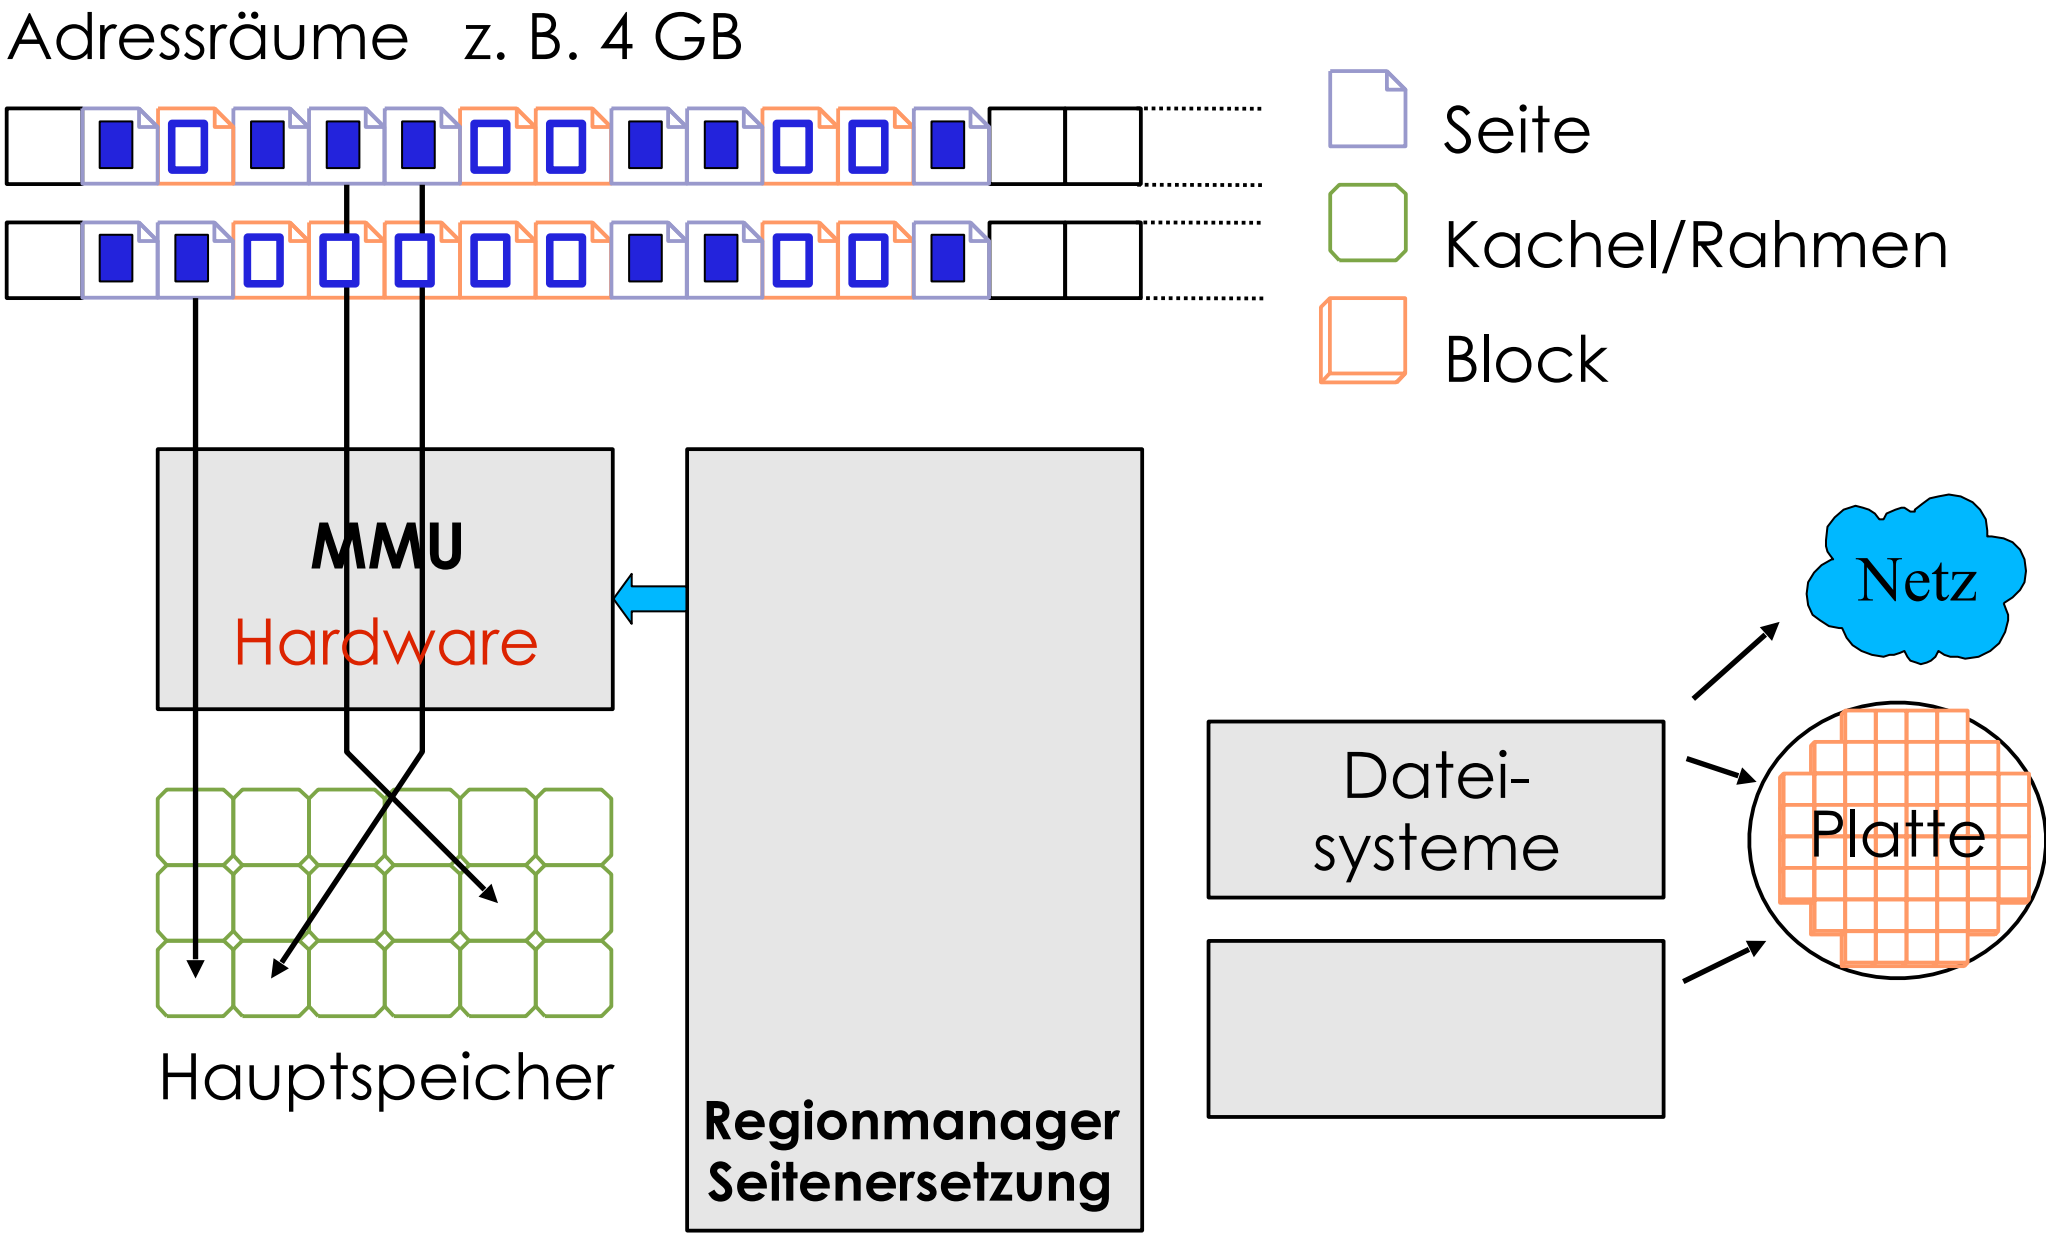

# Das Zusammenspiel

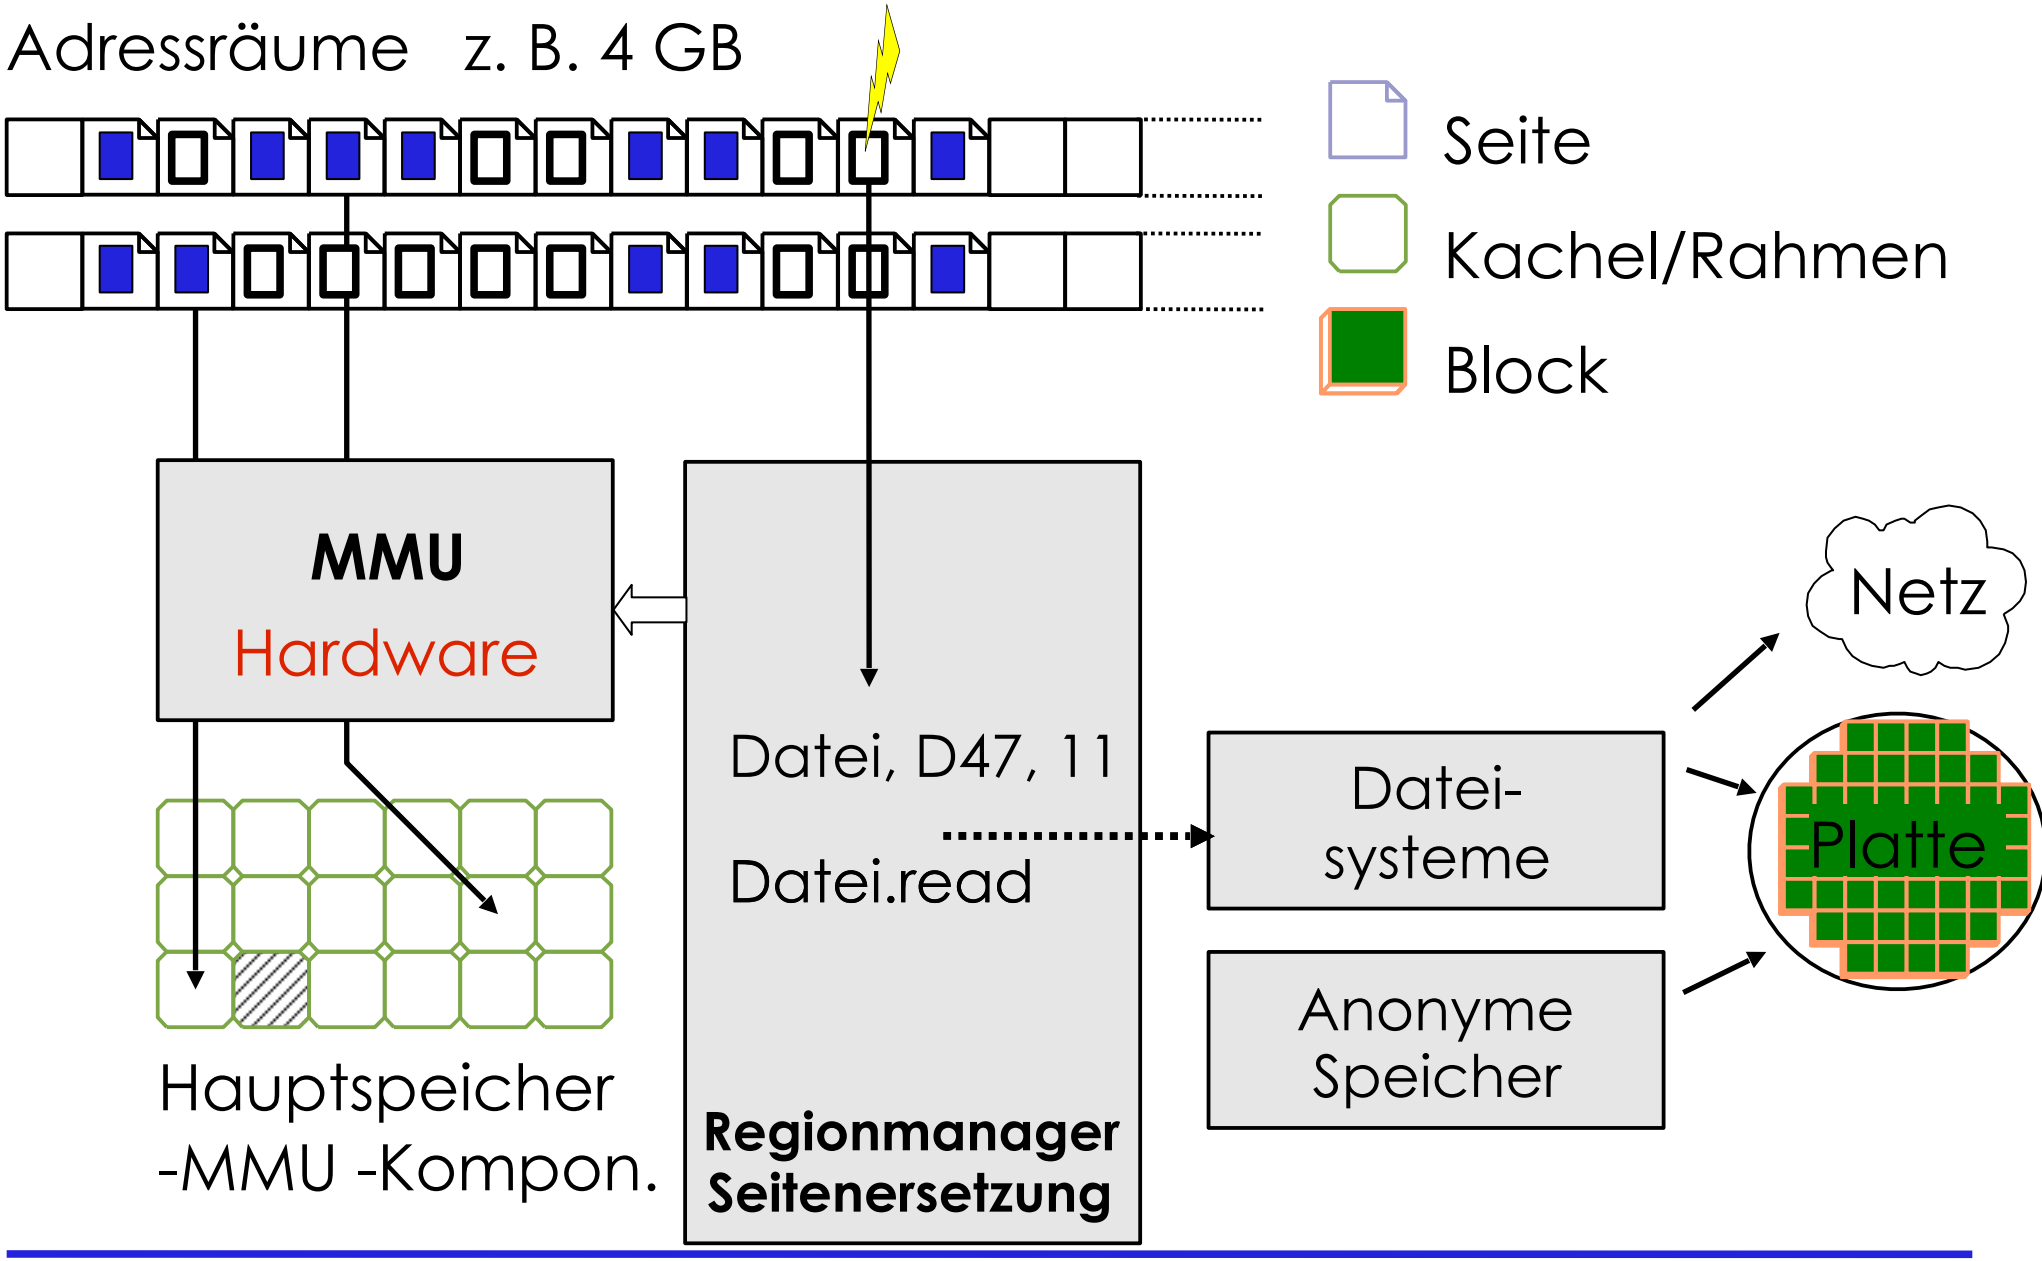

# Das Zusammenspiel

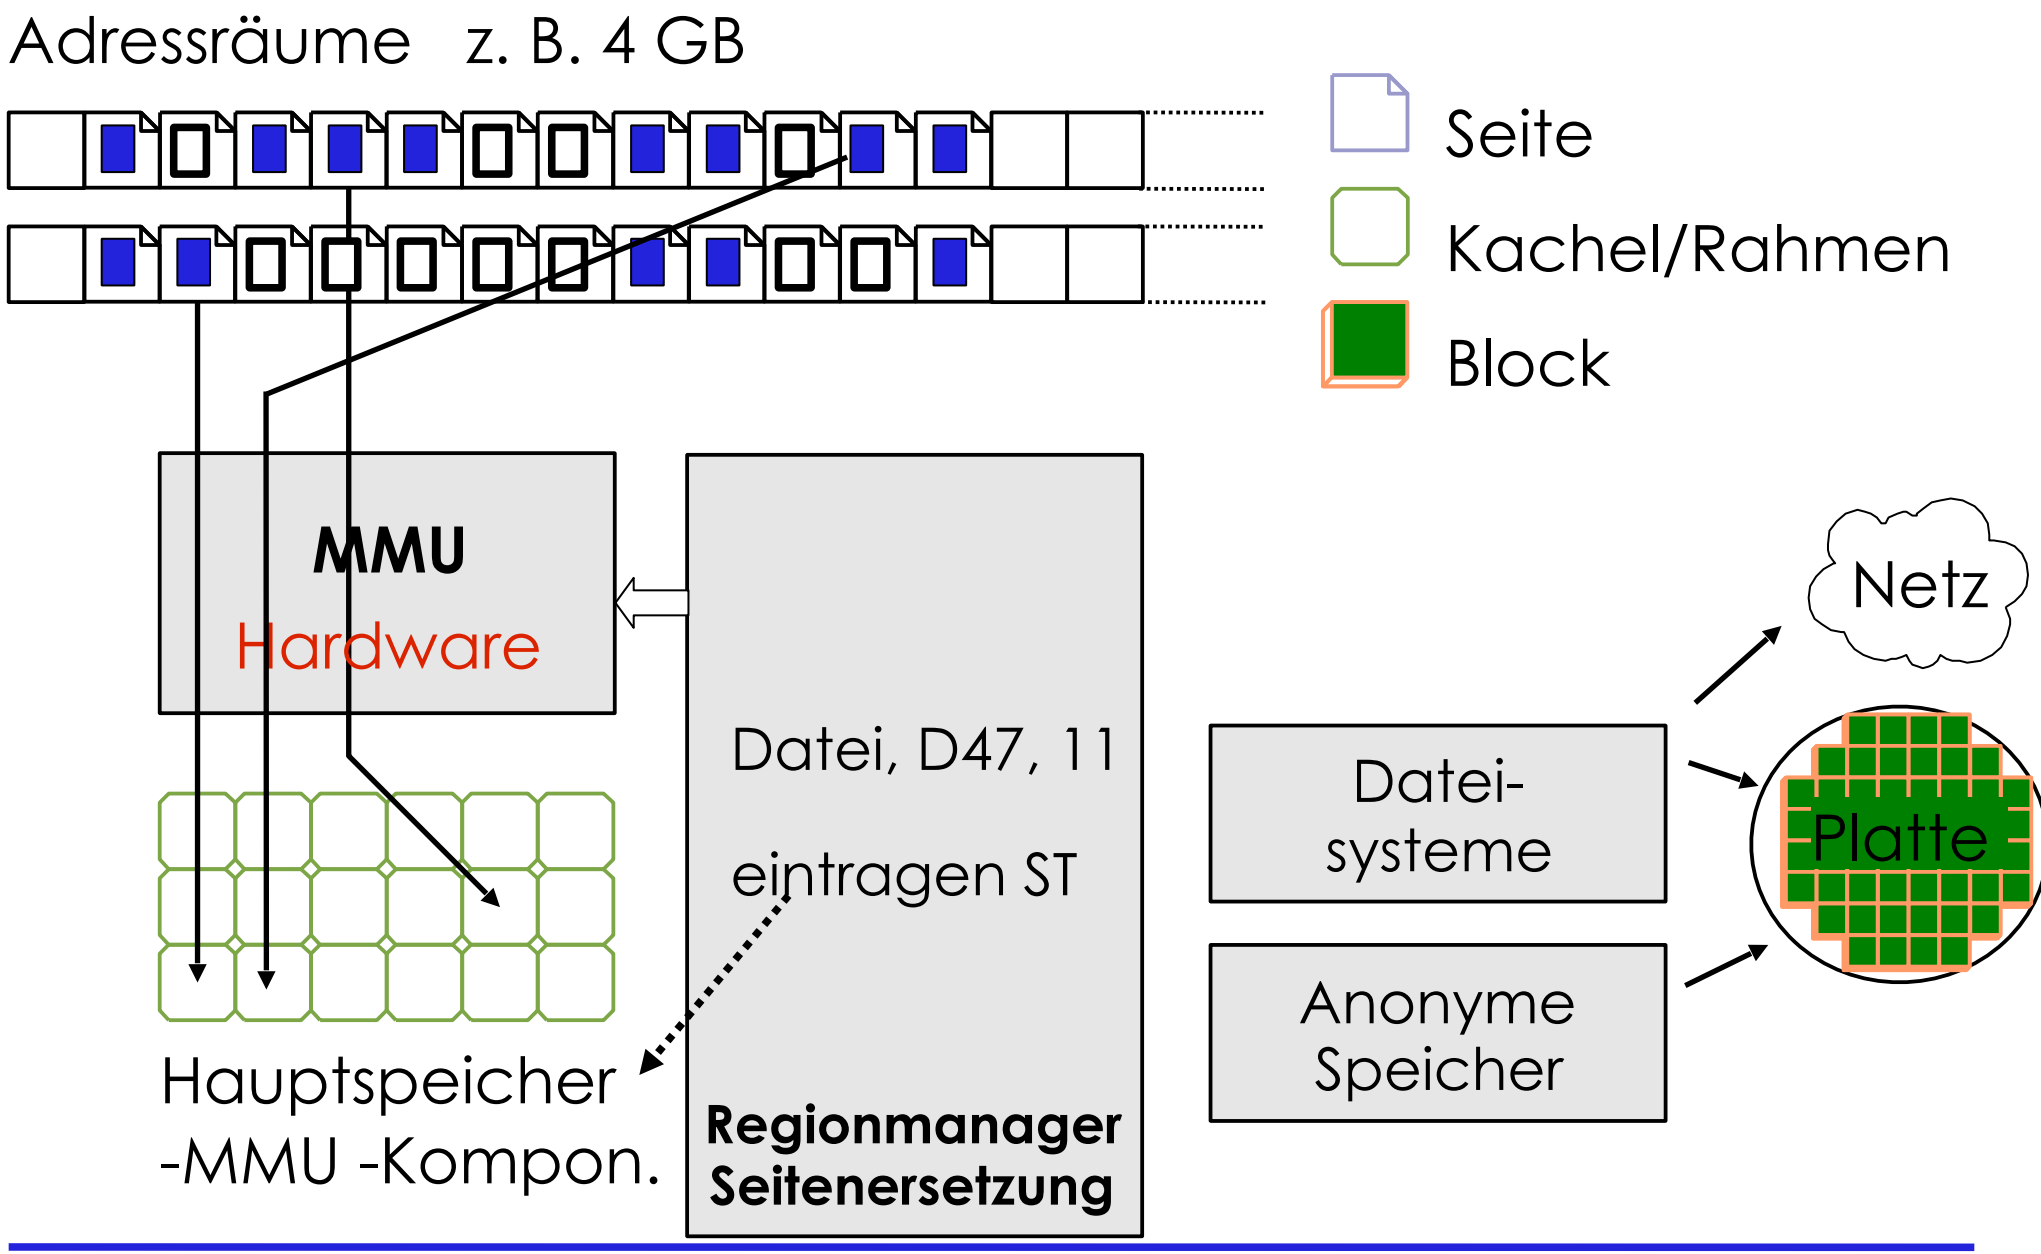

# Zugriff mittels Einblendung

**`mmap (Datei, Adresse, Länge, Offset)`**

- bei Seitenfehler:
  - Zugriff auf Datei über Seitenfehlerbehandlung
  - dann Zugriff über normale HW-Instruktionen
- „Pager“ muss Struktur der Dateiimplementierung kennen!

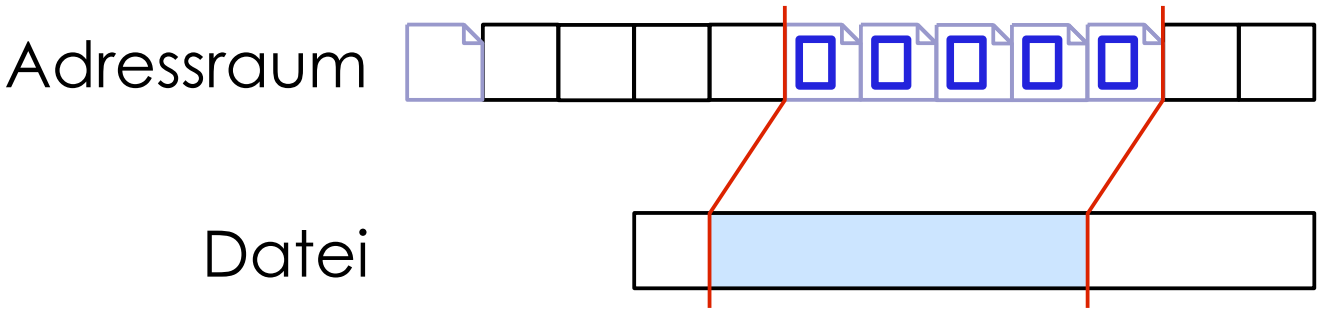

# Zugriff mittels Einblendung

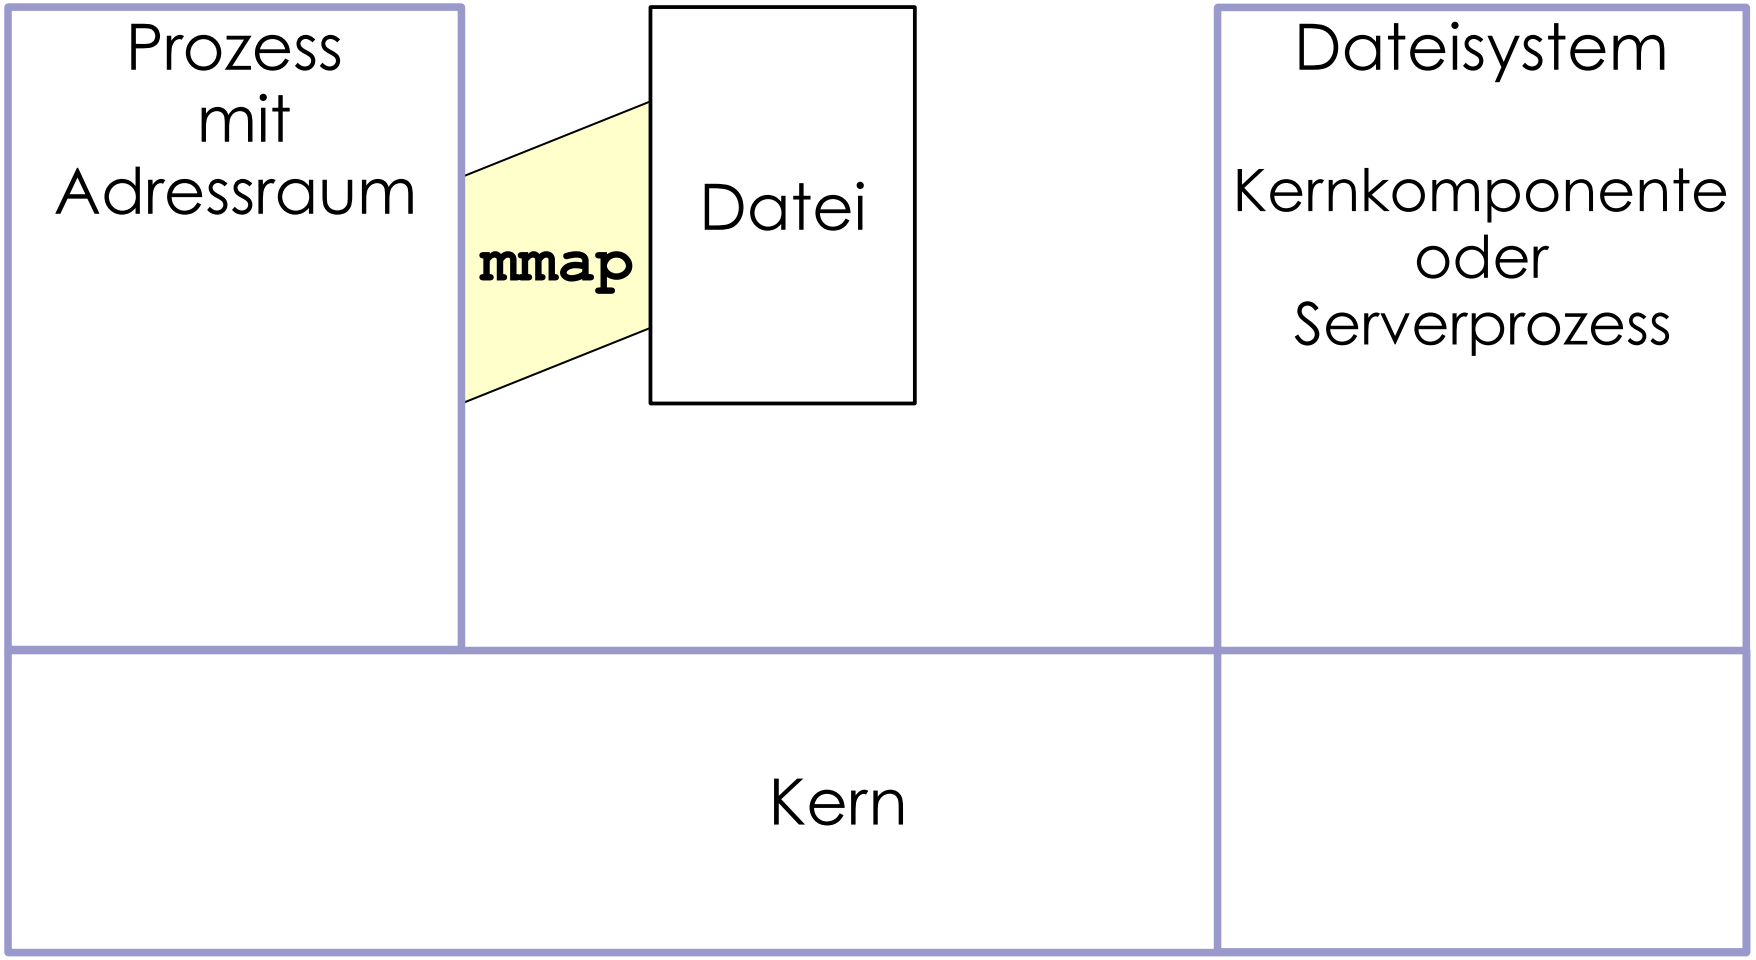

# Zugriff mittels Einblendung

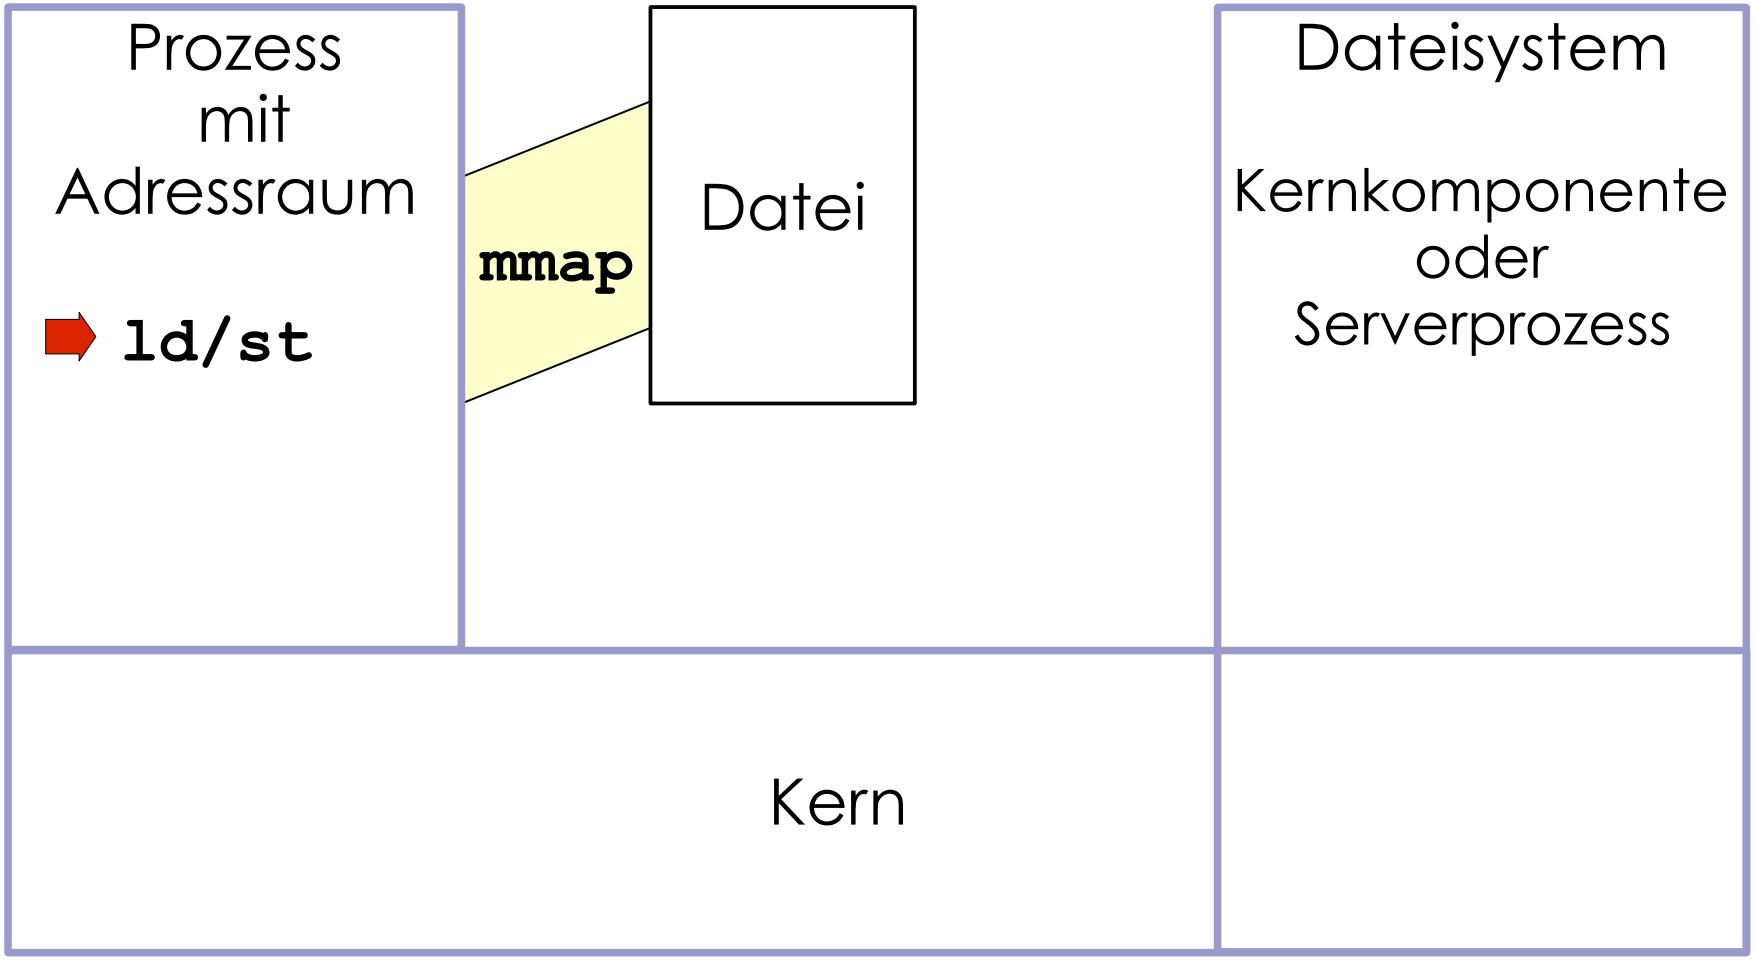

# Zugriff mittels Einblendung

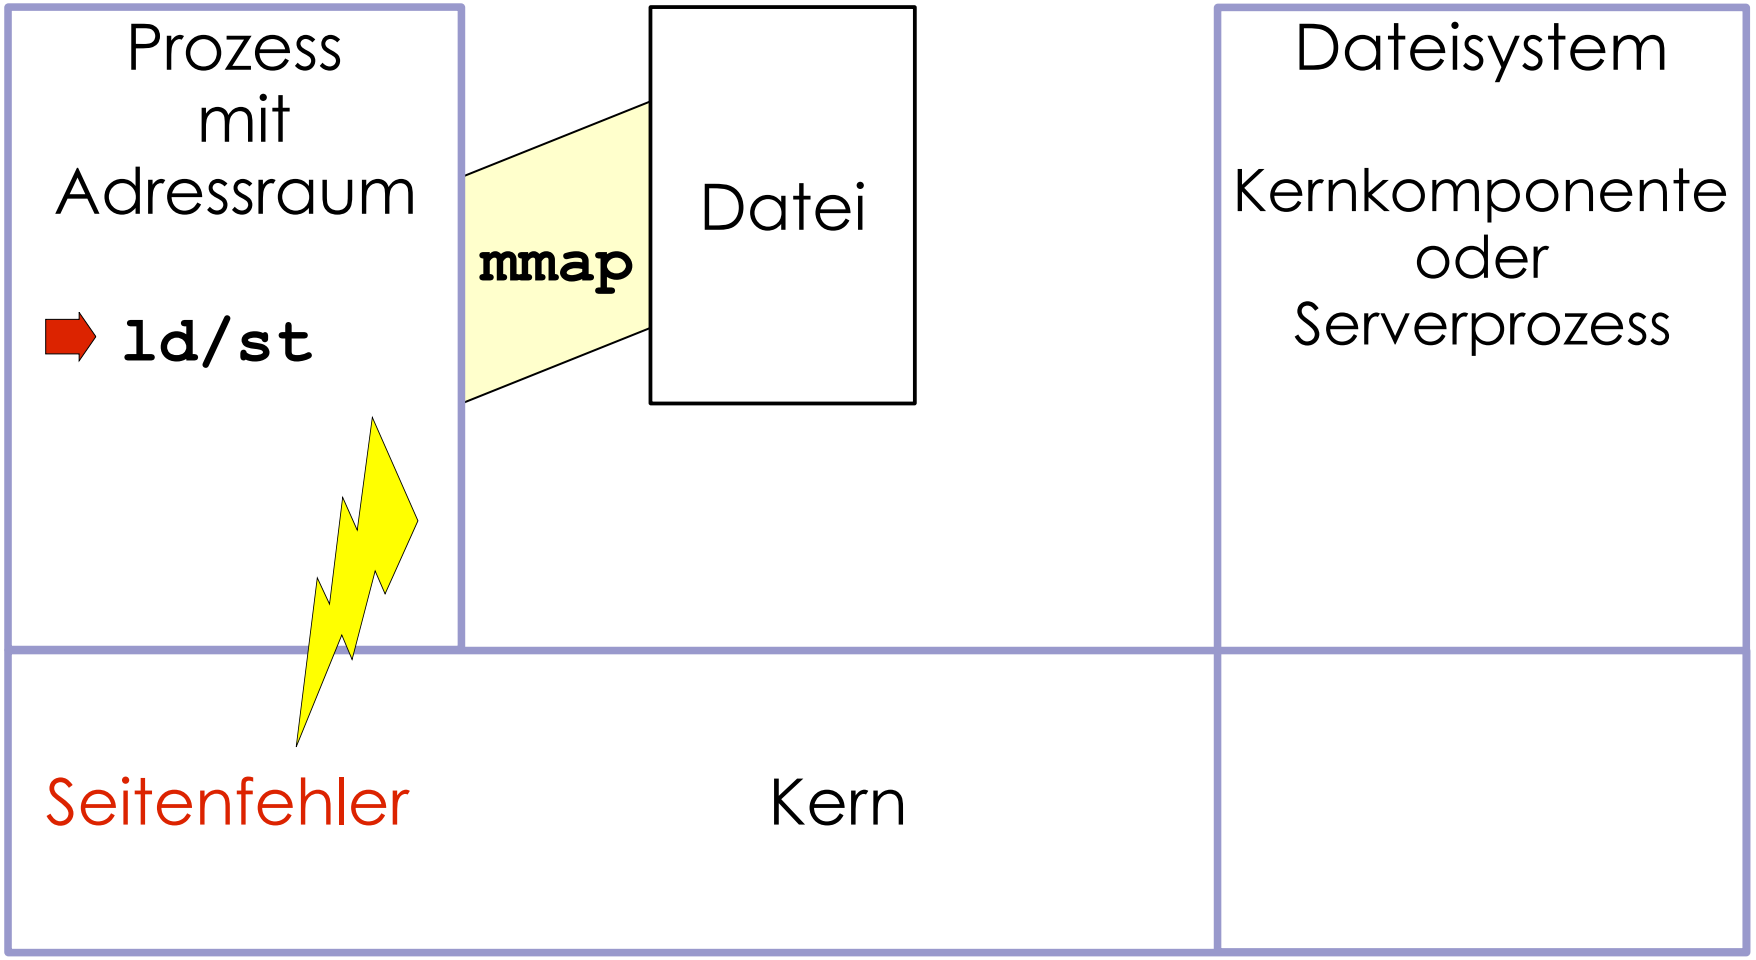

# Zugriff mittels Einblendung

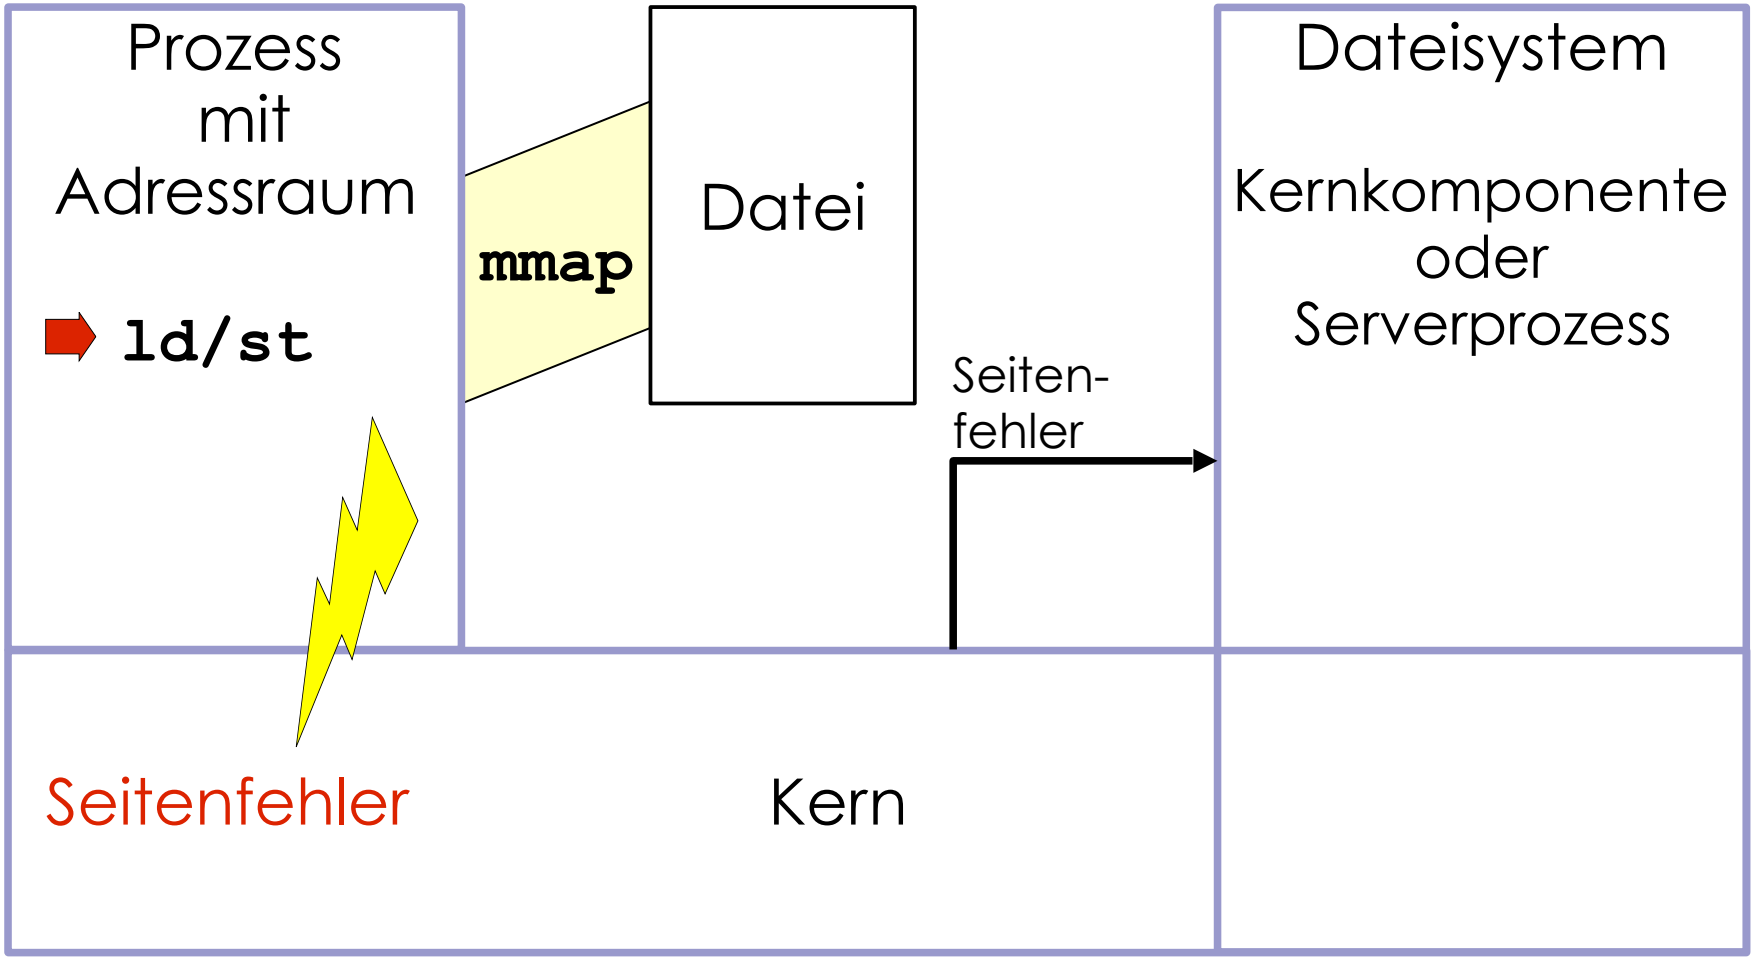

# Zugriff mittels Einblendung

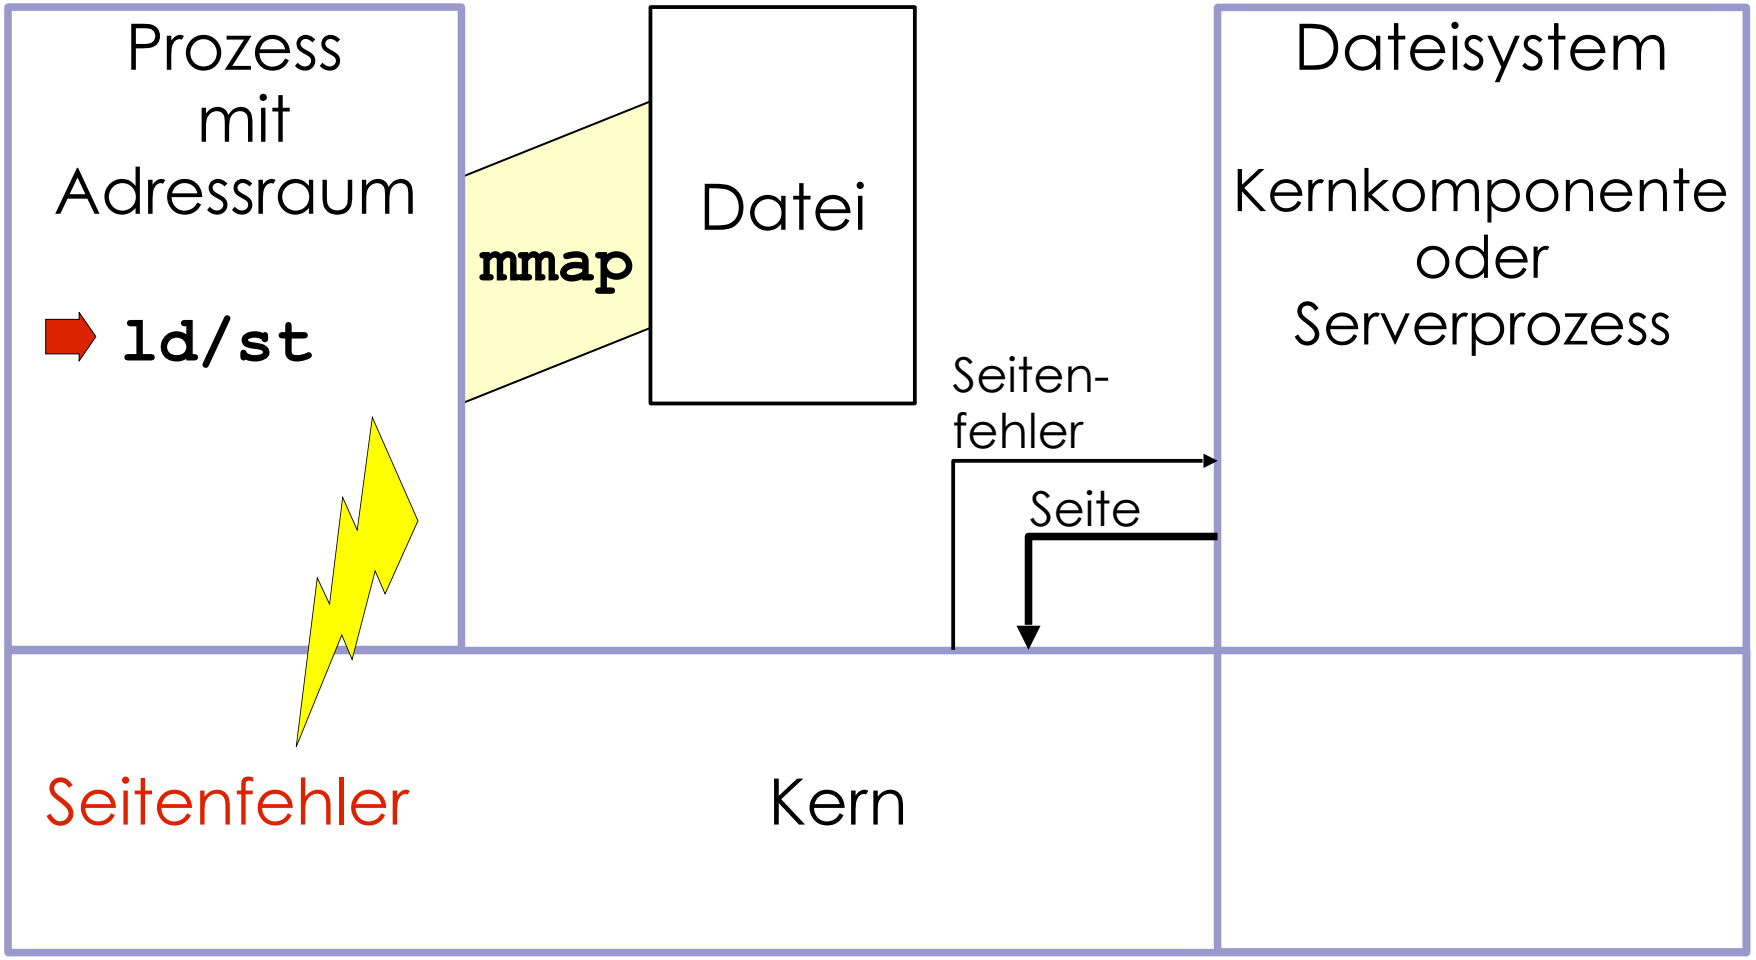

# Zugriff mittels Einblendung

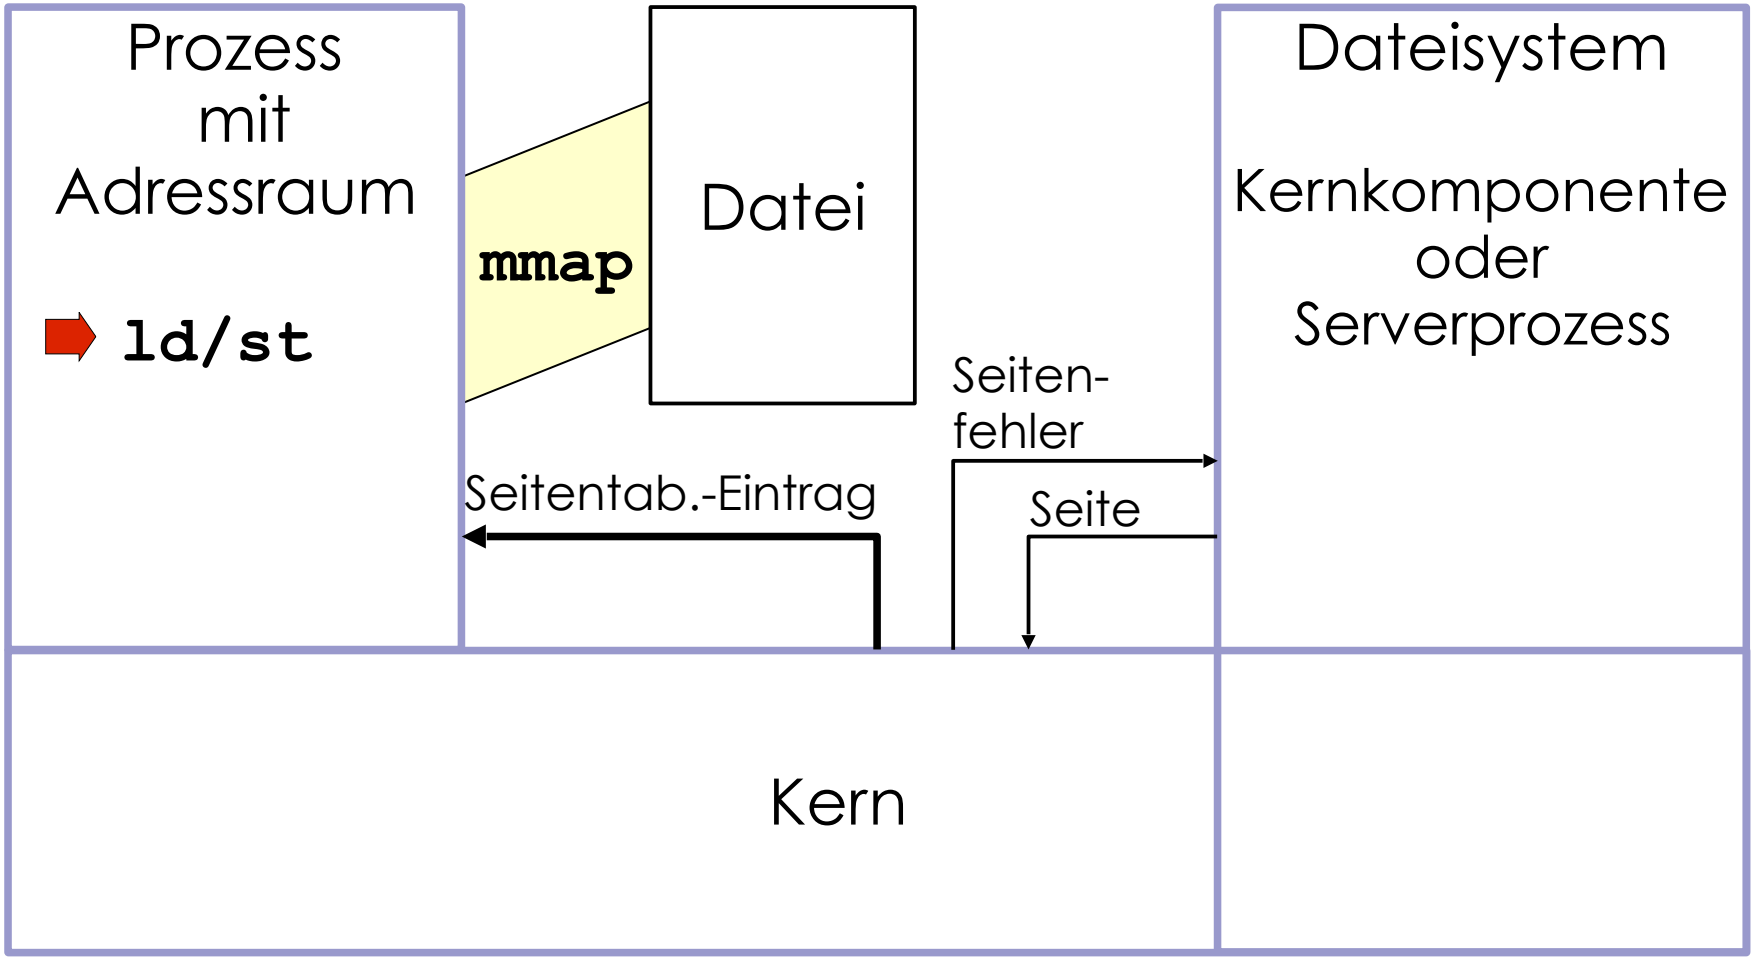

# Zugriff mittels Kopieren (read/write)

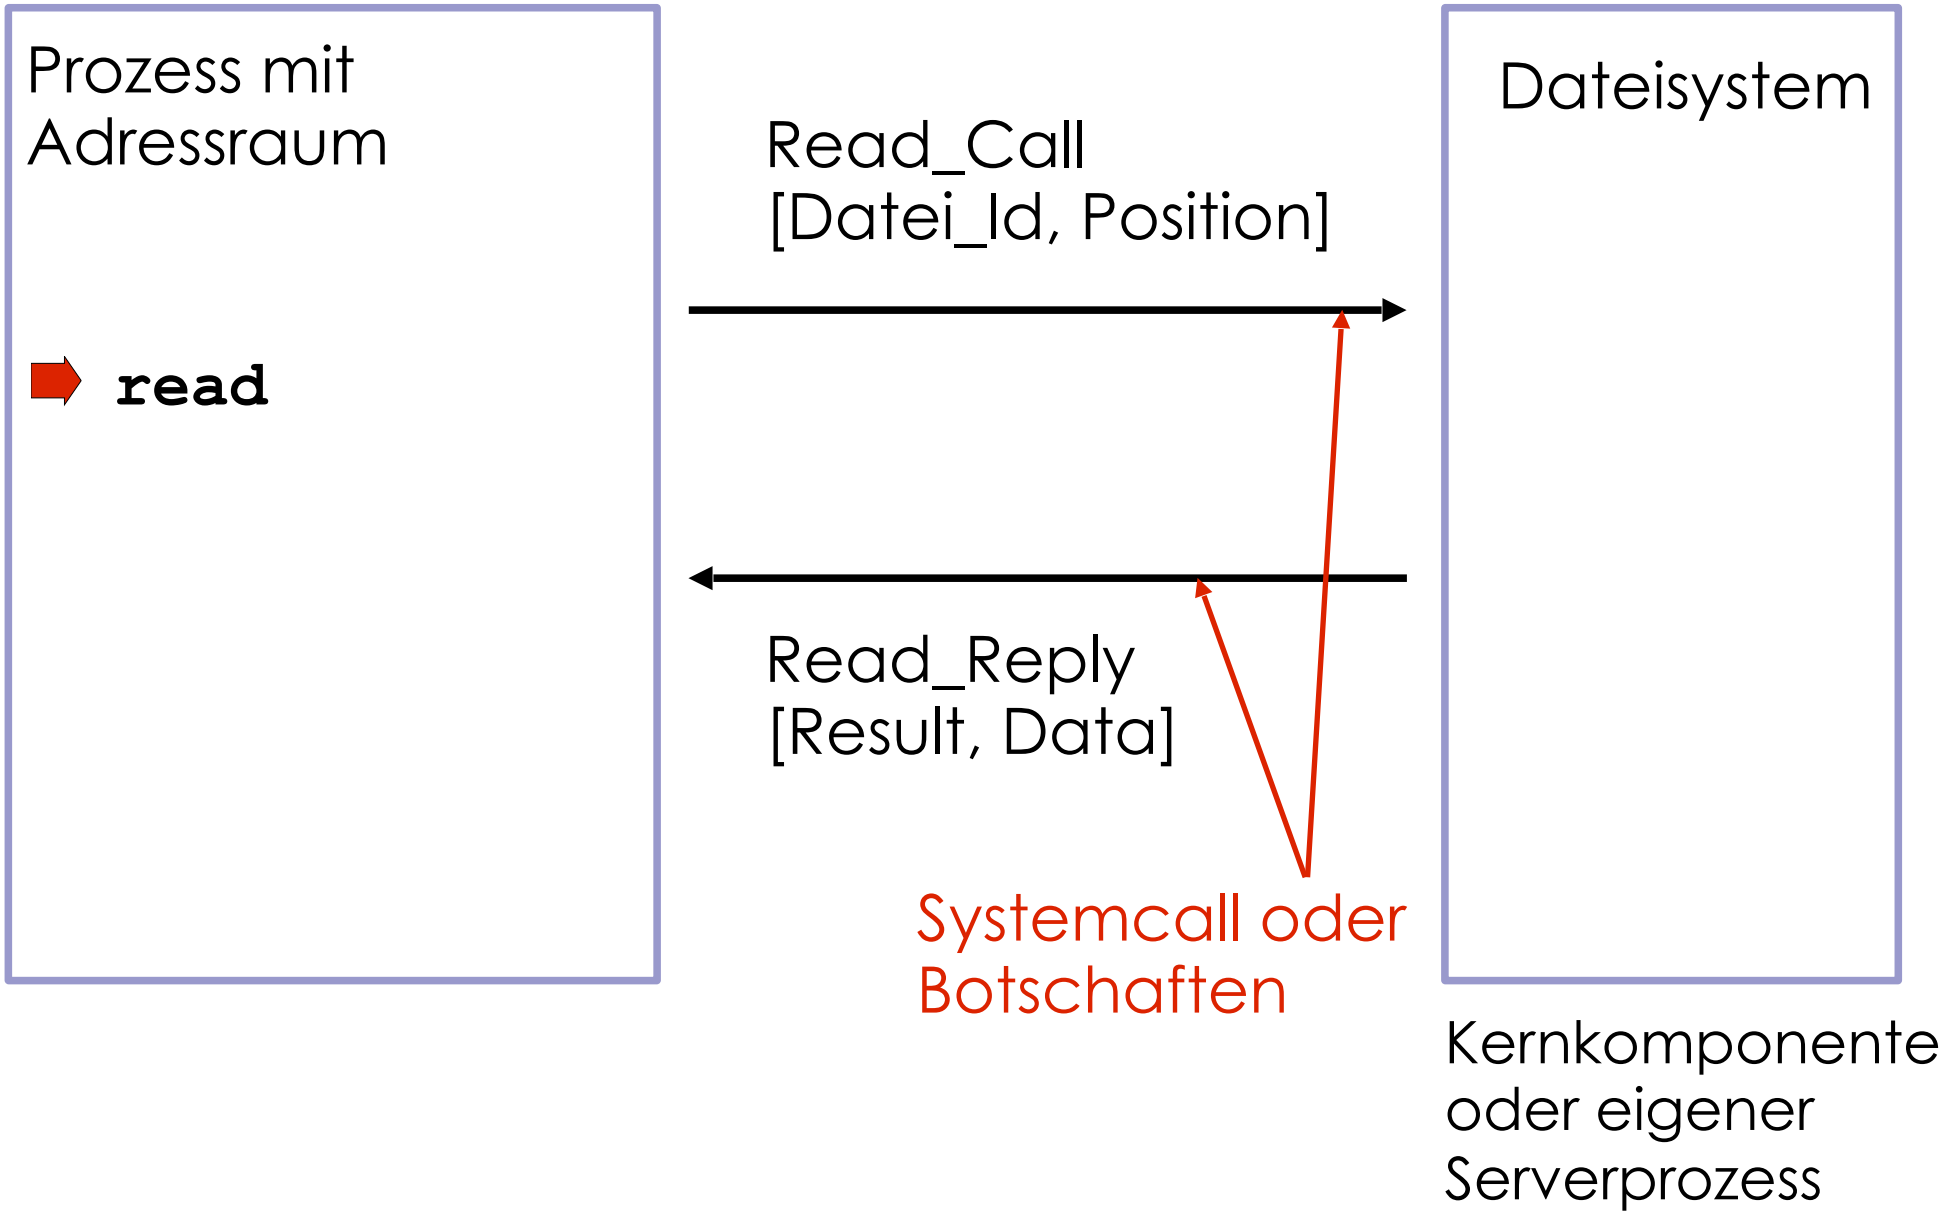

# Ablauf eines „write“ Dateizugriffs (Unix)

**`fd = open(„drops/papers/xy.tex“, RW, ...)`**

Pfadname → i-node number (Namensauflösung)

i-node number → fd

**`seek (fd, position)`**

**`write (fd,address, length)`**

**Im folgenden**

- beteiligte Datenstrukturen
- Ablauf

**vereinfacht:** ignoriert werden

- Fehlerbehandlung
- Attribute, Rechte
- Vorhandensein mehrerer Dateisysteme pro Rechner
- Plattentreiberdetails

# Beteiligte Datenstrukturen (des Dateisystems)

- Prozesssteuerblock:  current directory, Filedescriptor fd
- Verzeichnisse
- Tabelle geöffneter Dateien, pro Datei:
  - file pointer  (gegenwärtige Schreib-/Leseposition), ...
  - i-node number
- Dateitabelle auf Platte (Tabelle der I-Knoten)
  - Index in dieser Tabelle (i-node number) identifiziert Datei
- für alle (auch nicht geöffnete) Dateien: i-node
  - Allokation (Zuordnung von Dateiblöcken zu Plattenblöcken)
  - Attribute
- Puffer-Verwaltung

# Dateideskriptoren

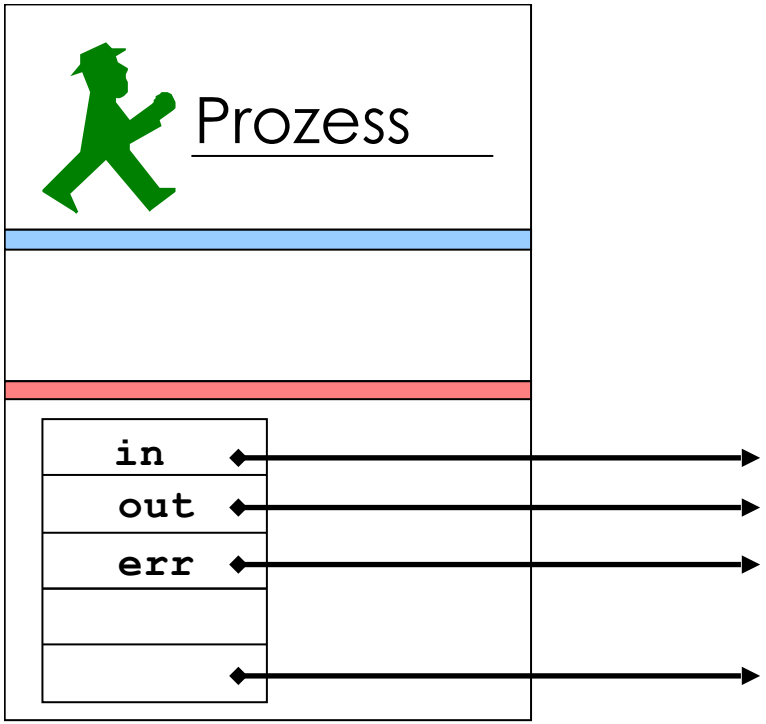

# Tabelle geöffneter Dateien

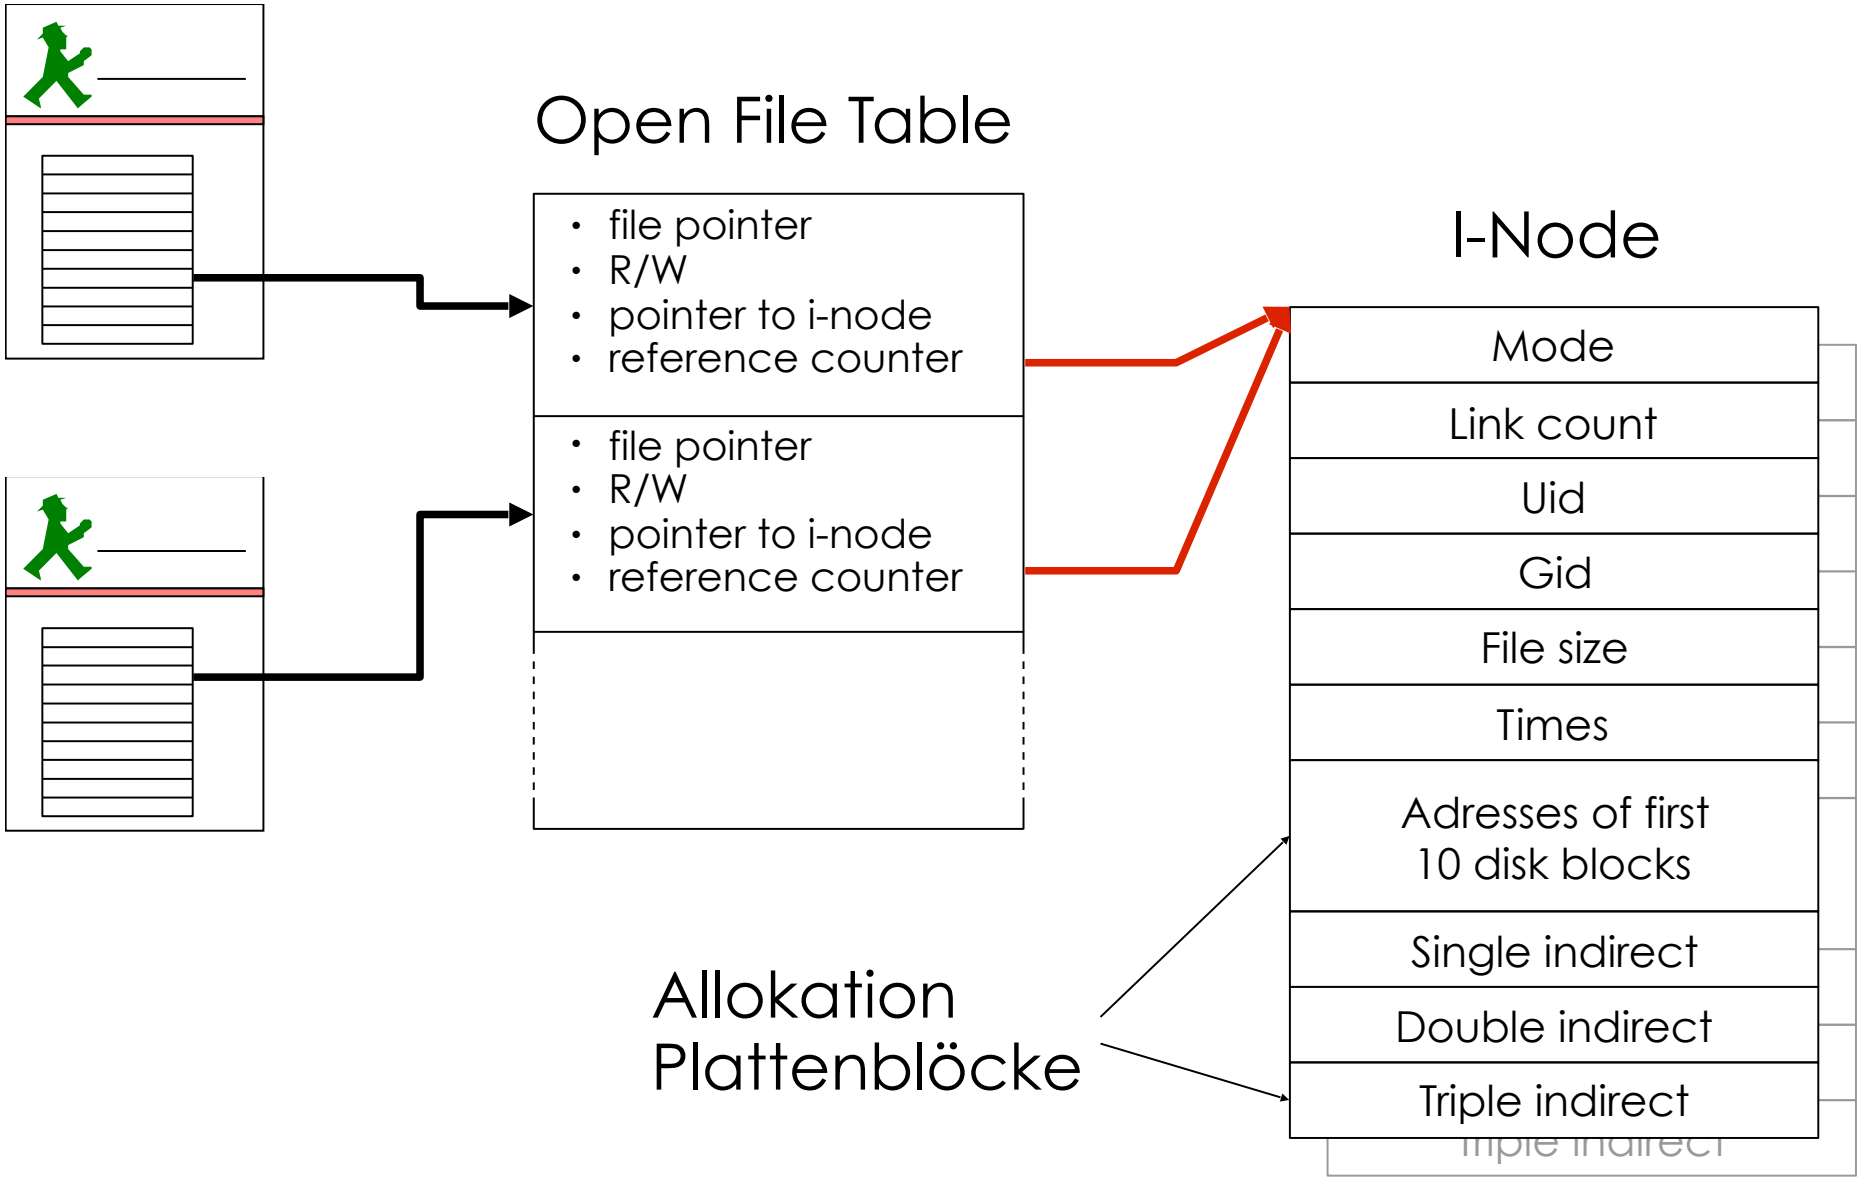

# i-node (I-Knoten)

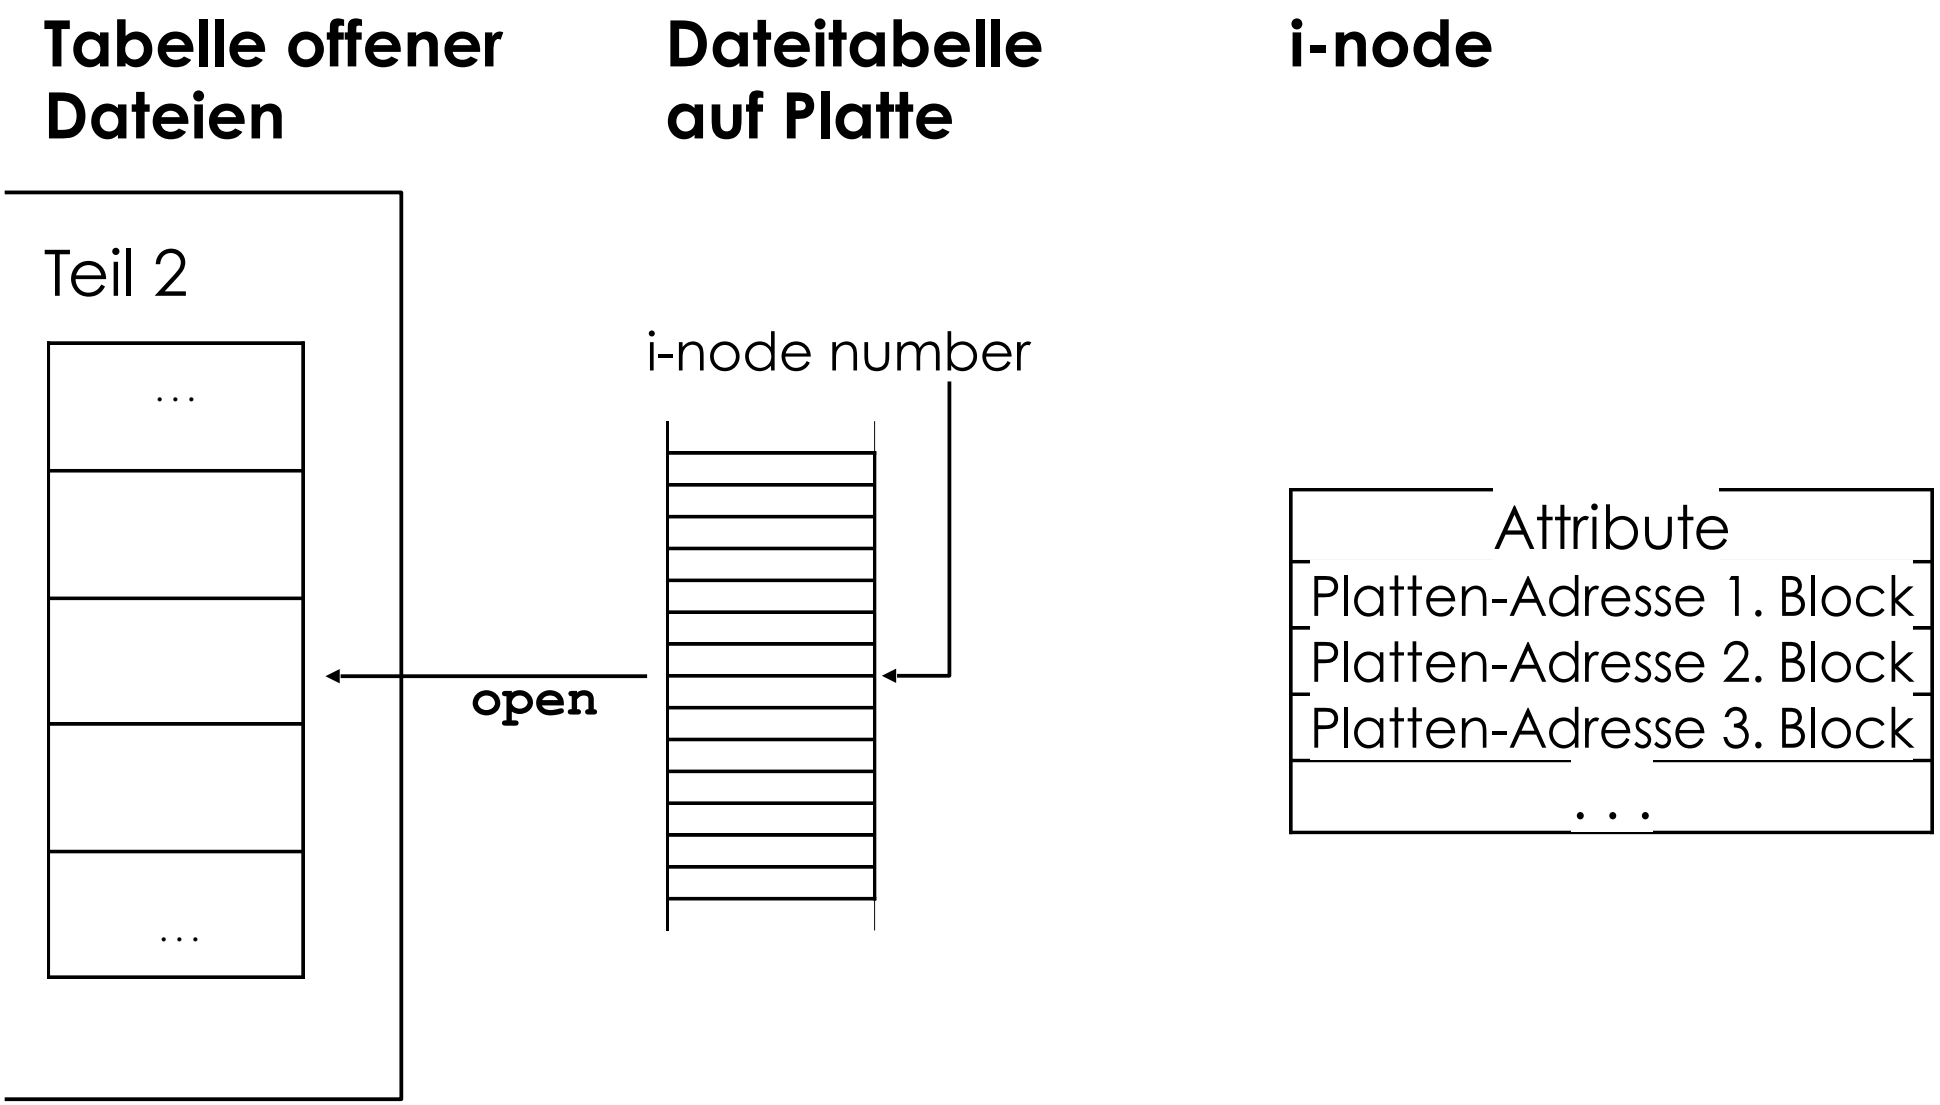

# Pufferverwaltung und Ablauf read/write

**Block-Kachel-Tabelle**
(„Buffer Cache“)

- Struktur im Kernadressraum
- Zuordnung:
  Plattenadresse ↔ Puffer
- Puffer allokieren/laden
  (resident im Hauptspeicher)

**Ablauf (read/write)**

- fd → file pointer, i-node
  → Plattenadresse
- Puffer
  - evtl. Puffer besorgen
  - evtl. Laden von Platte
- Kopieren in Adressraum

# Ablauf write

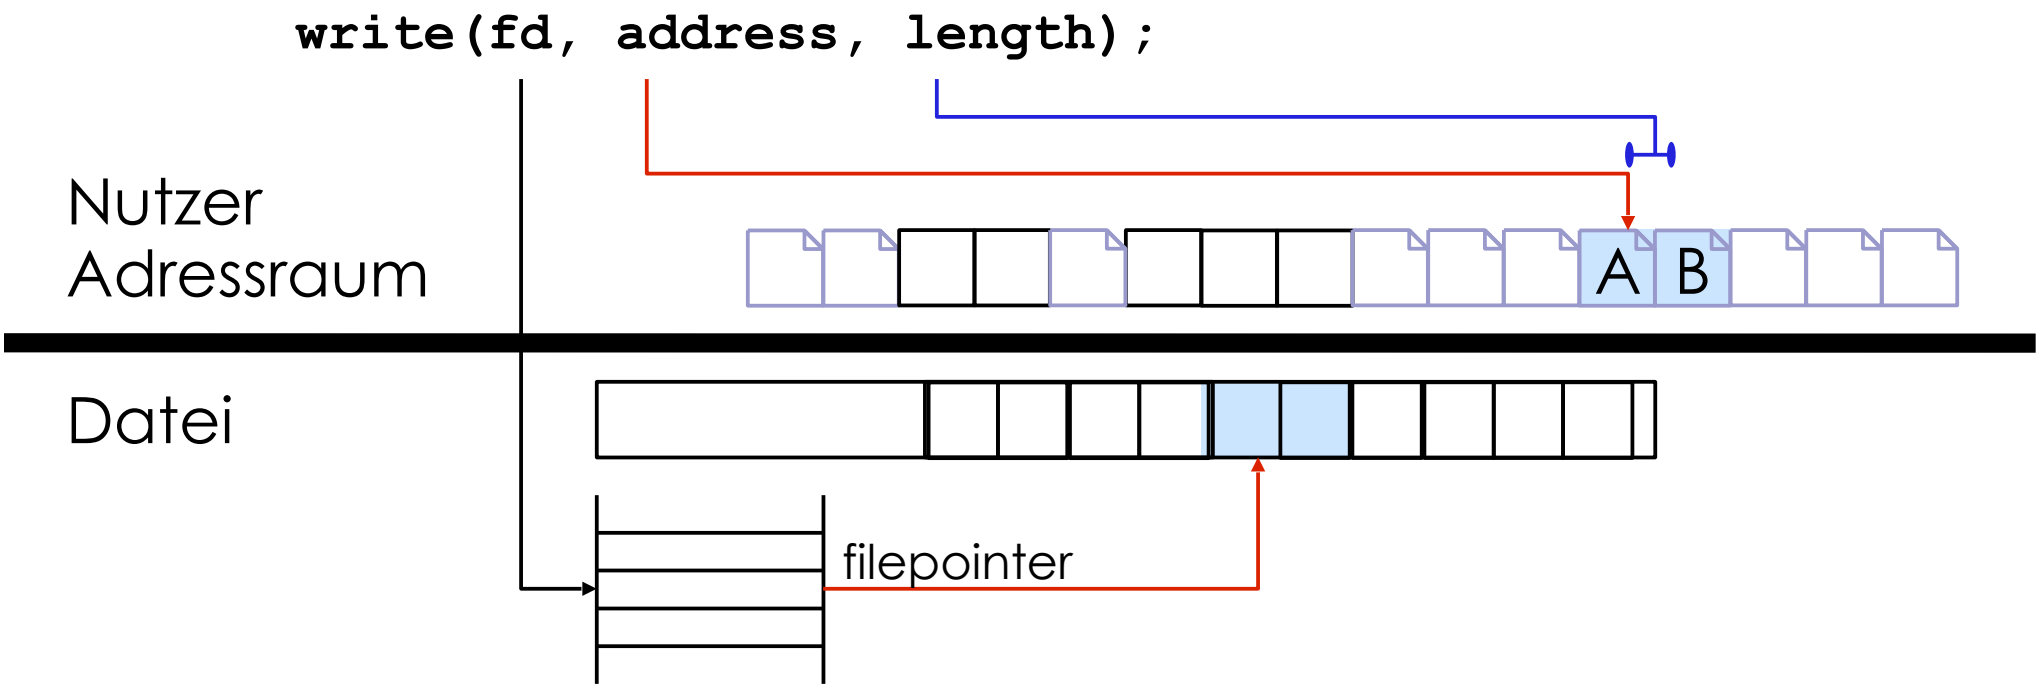


nächste Folie: vergrößerter Ausschnitt

# Ablauf write

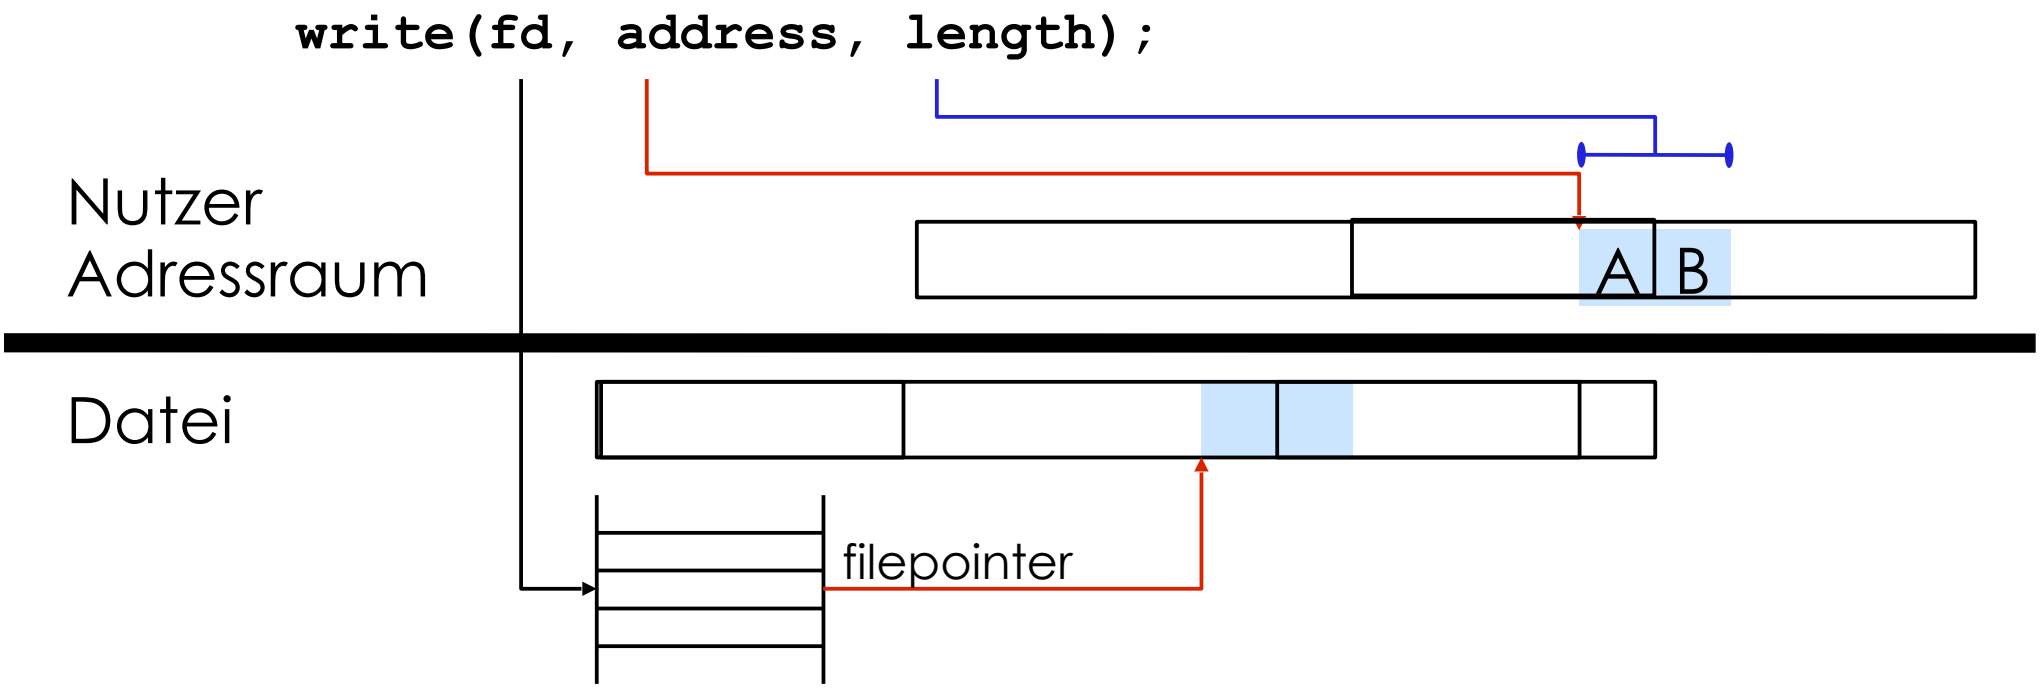

# Ablauf write: Puffern in Buffercache

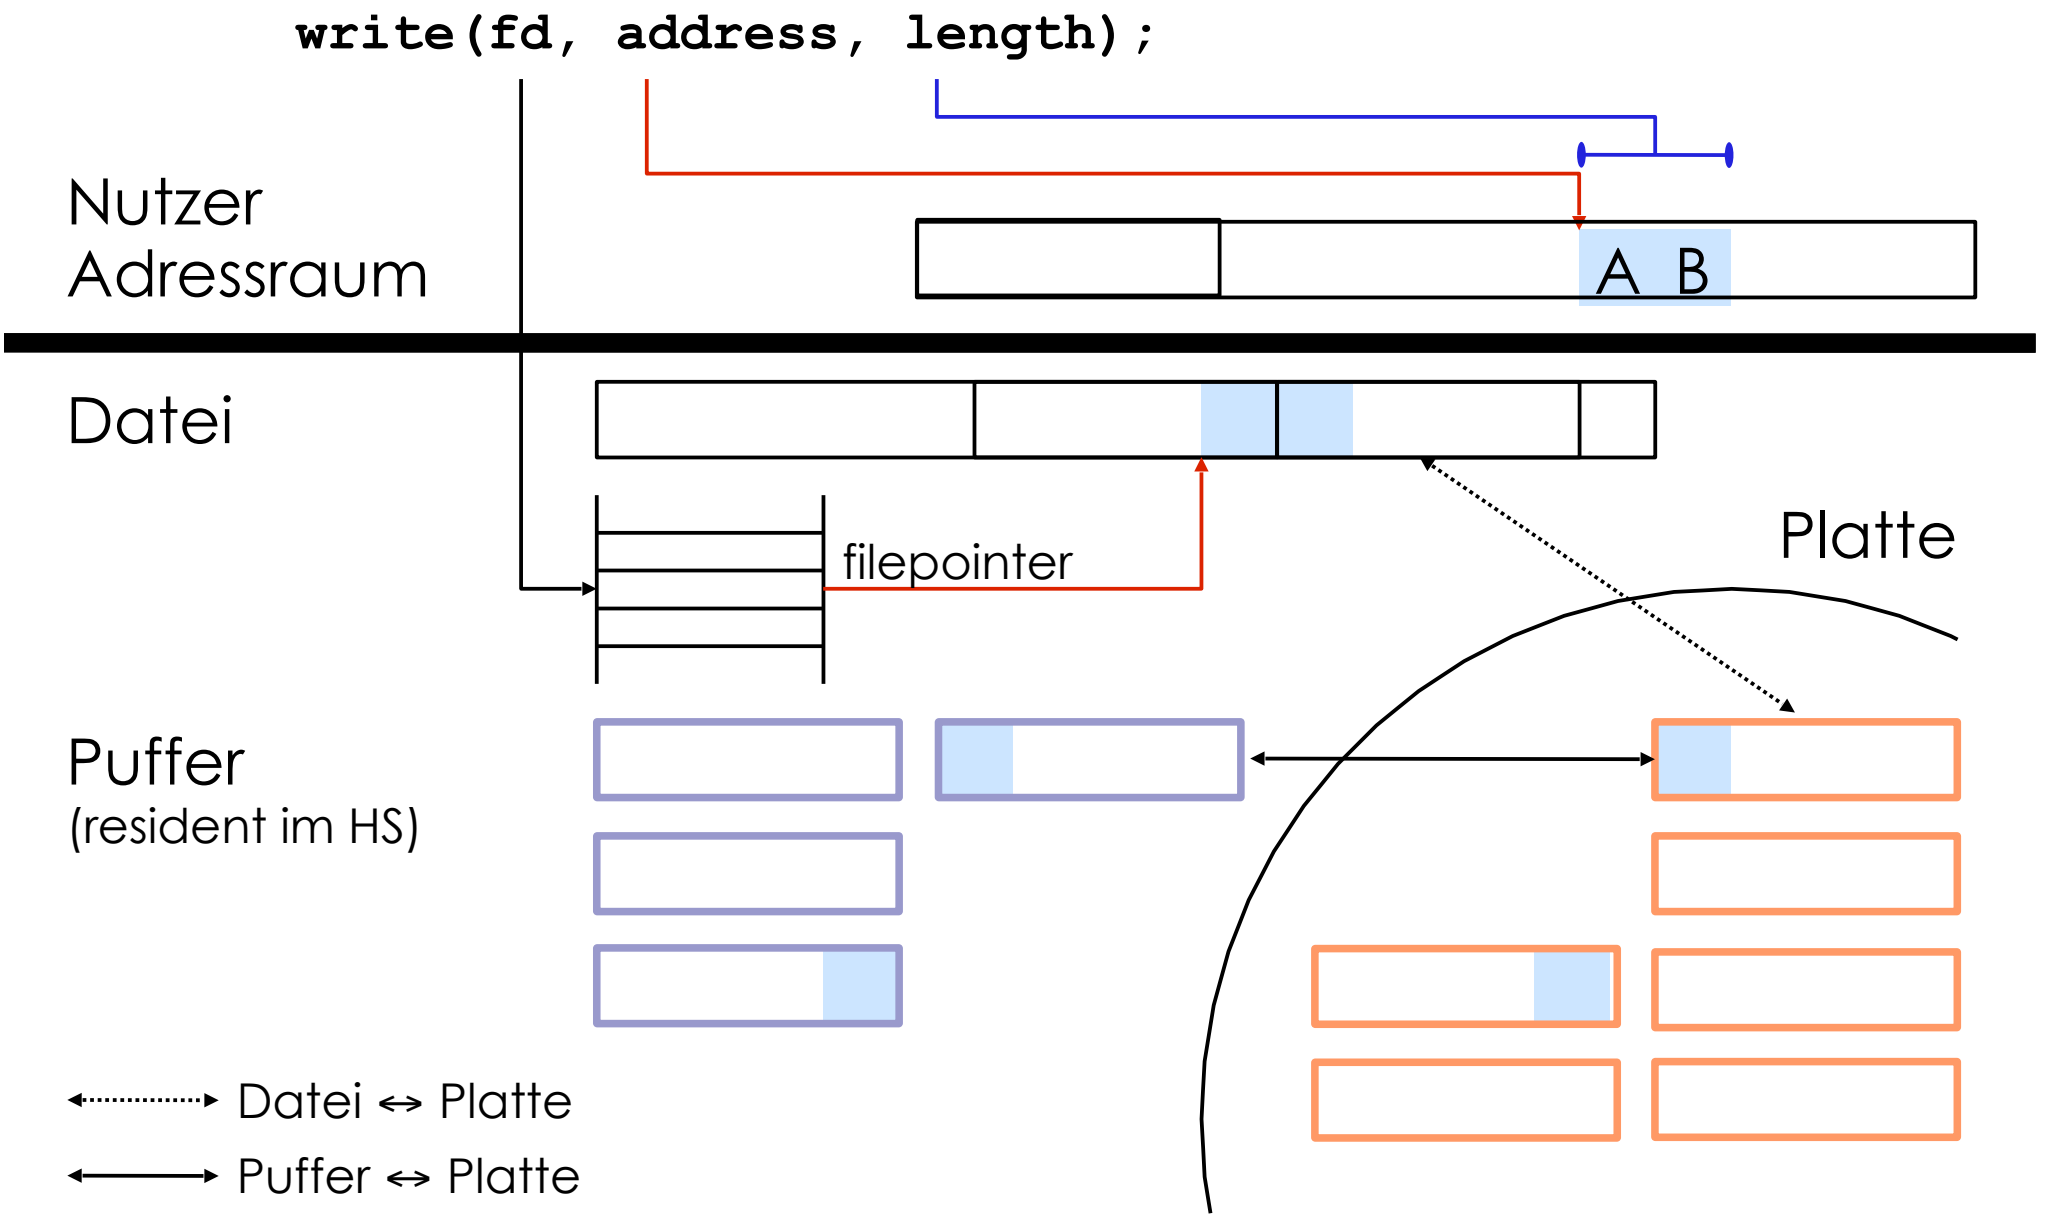

# Ablauf write

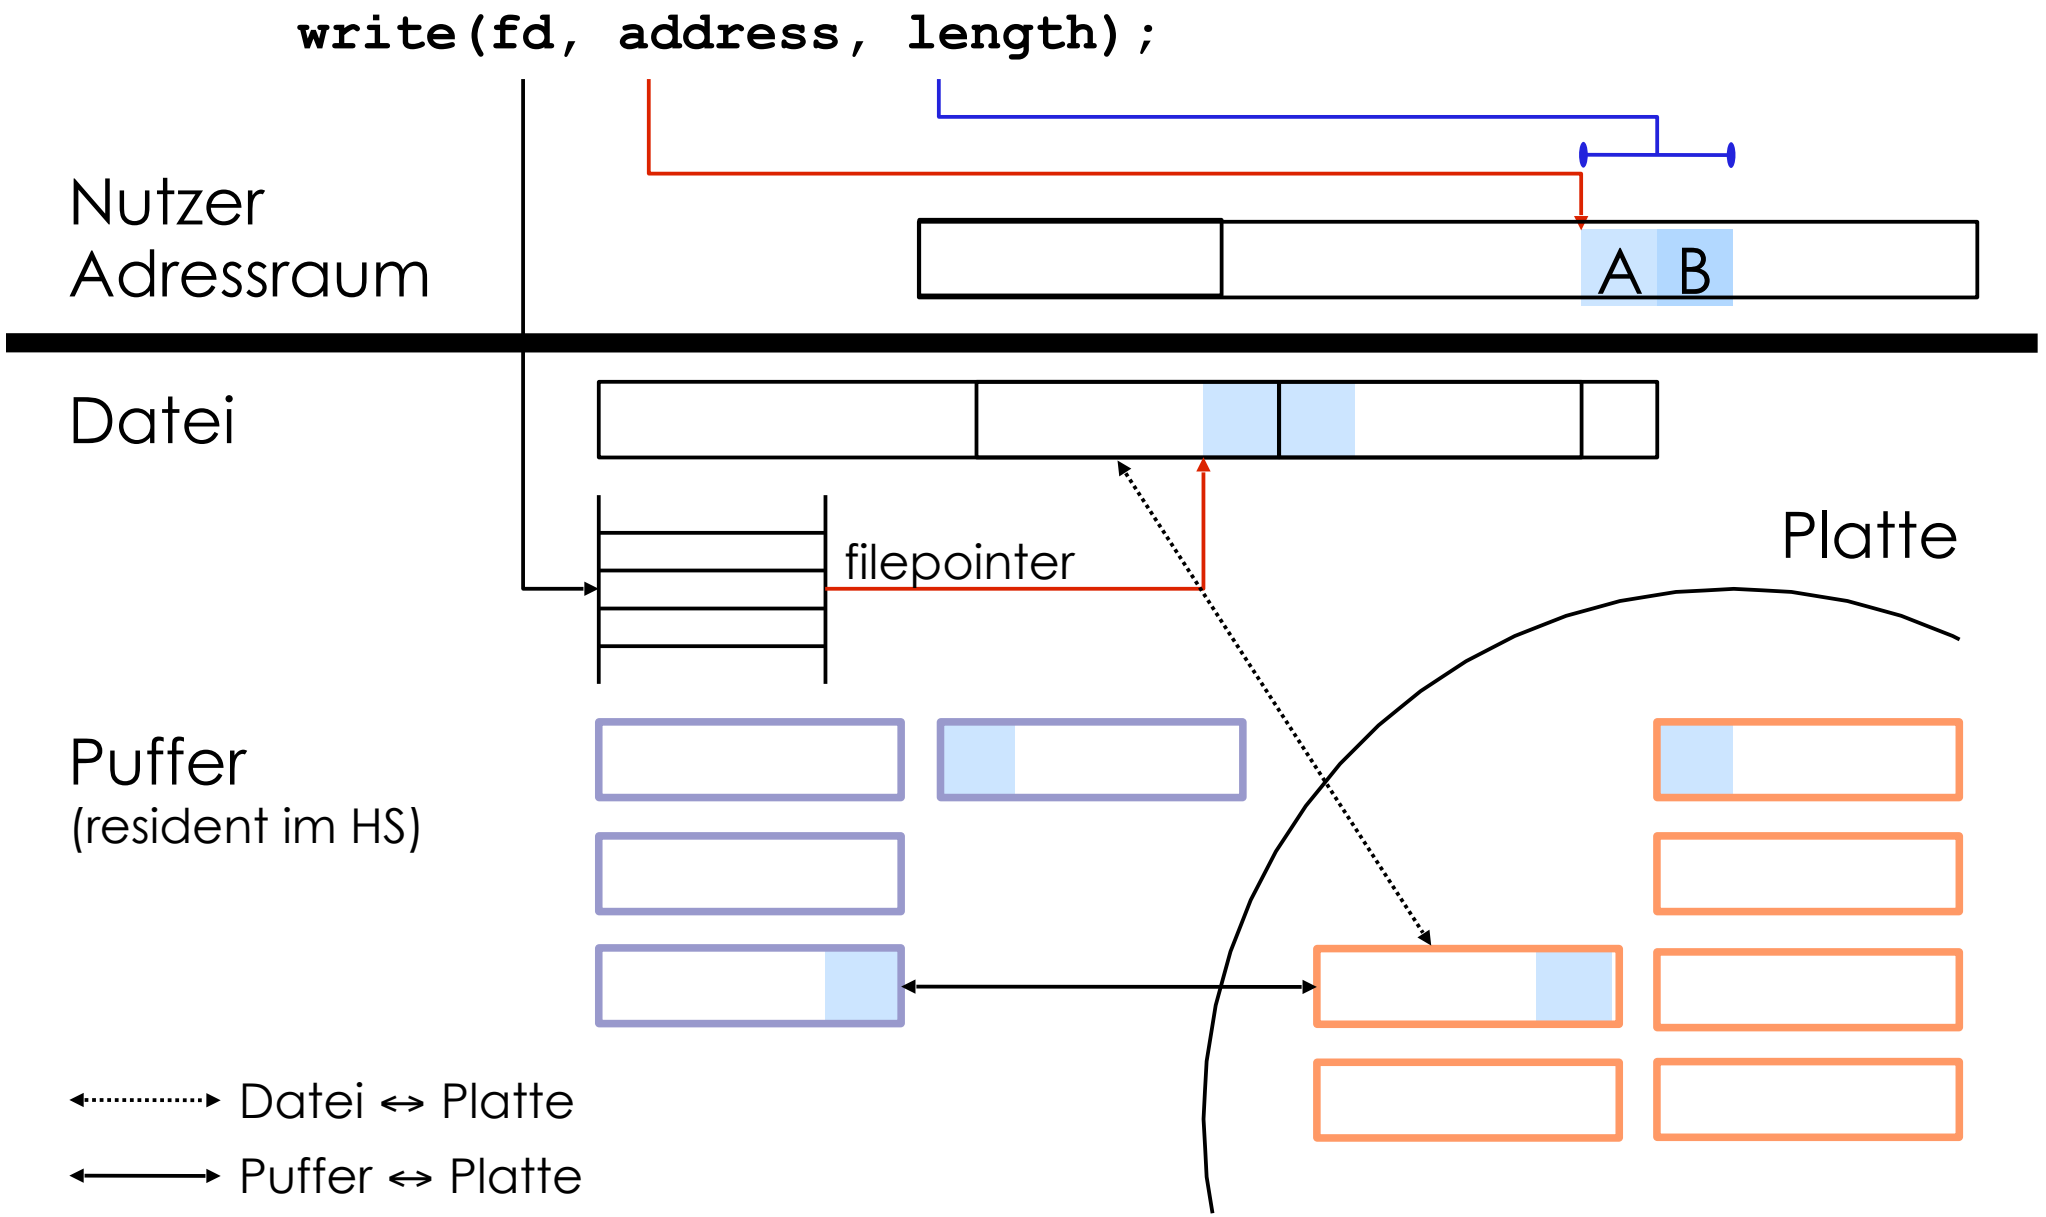

# Ablauf write: Kopieren in Puffer

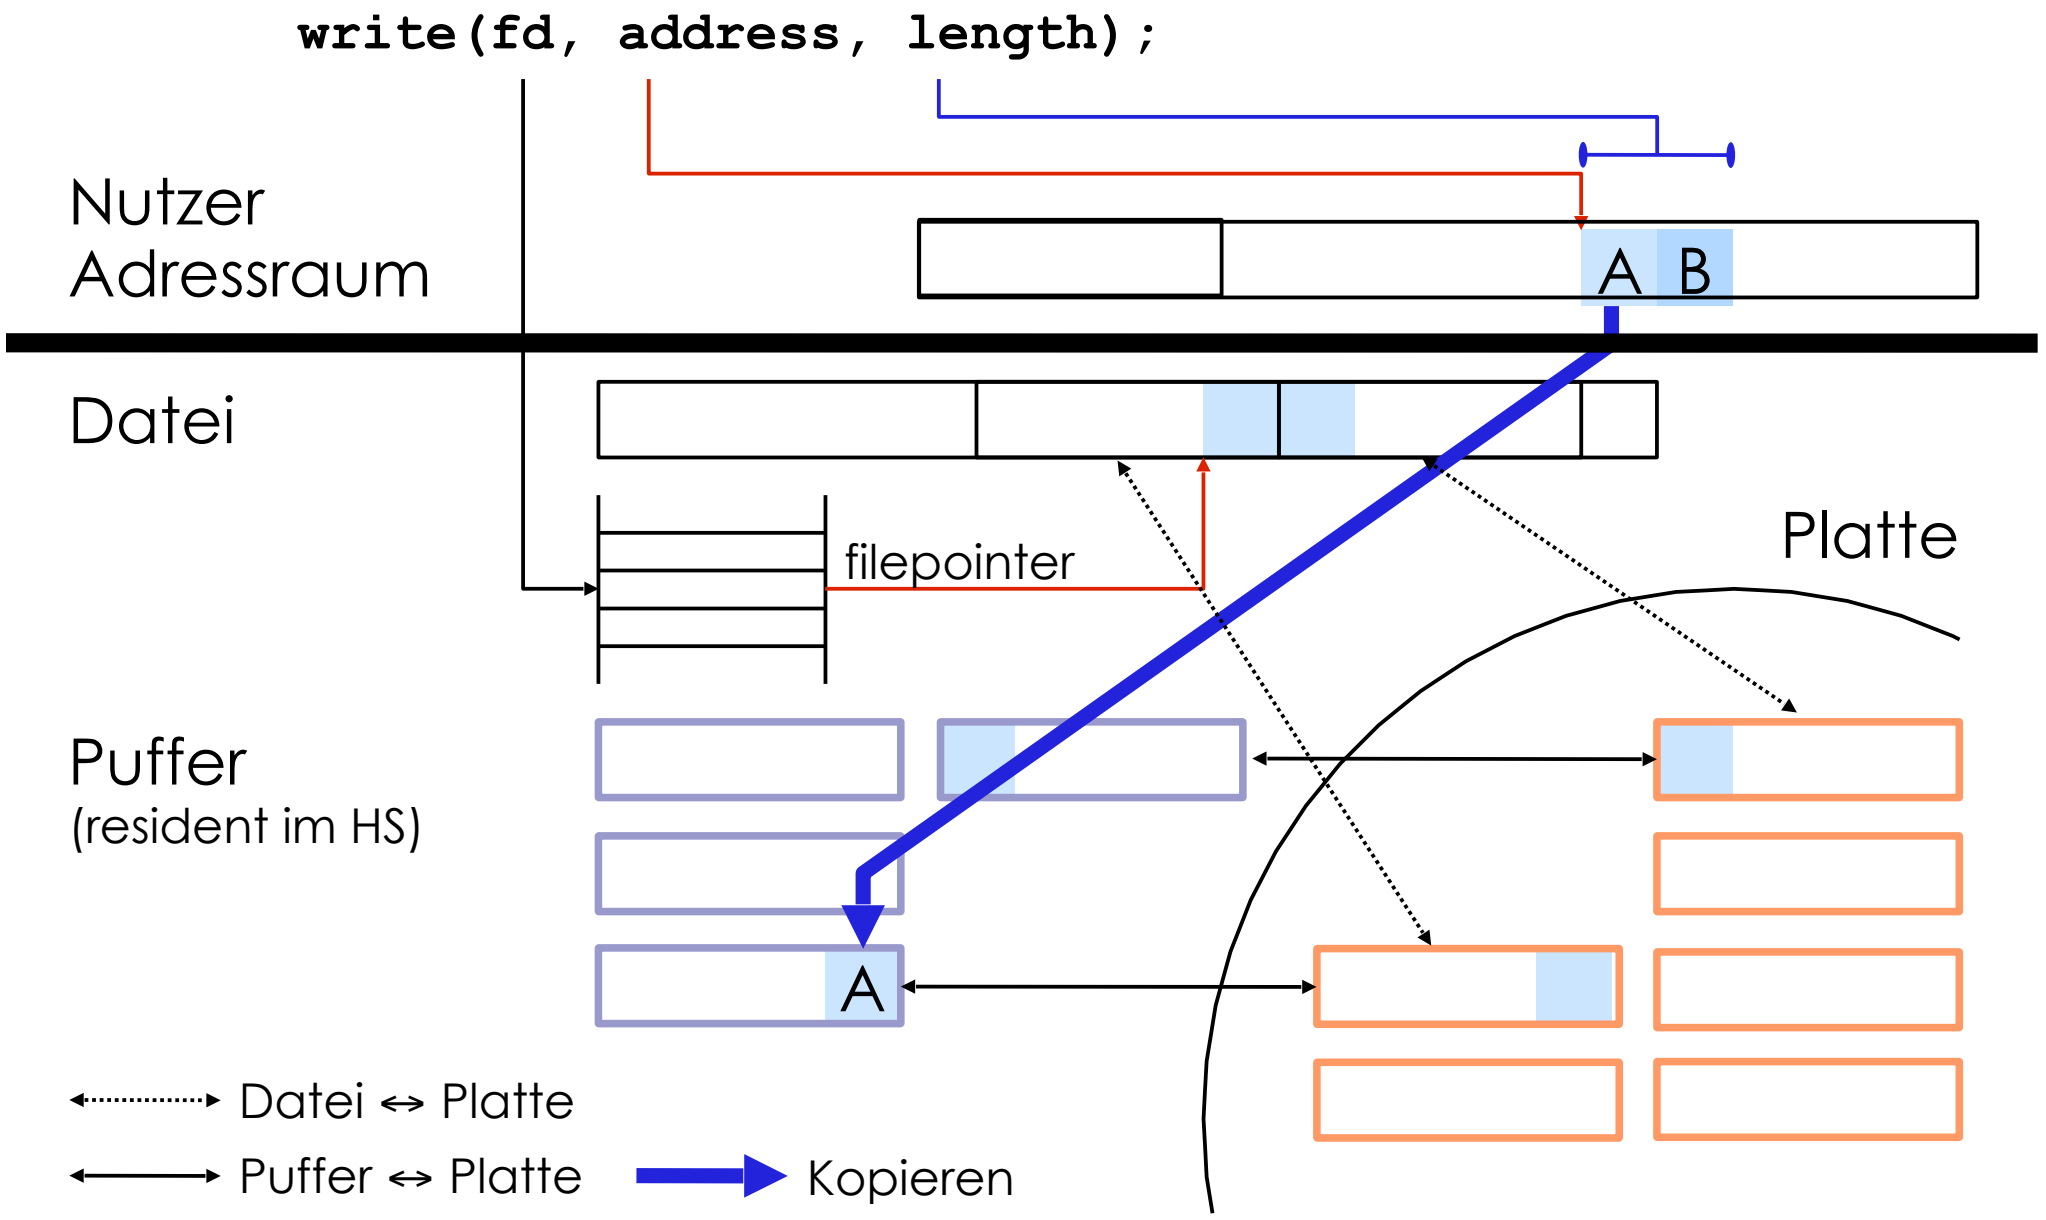

# Ablauf write: Kopieren in Puffer

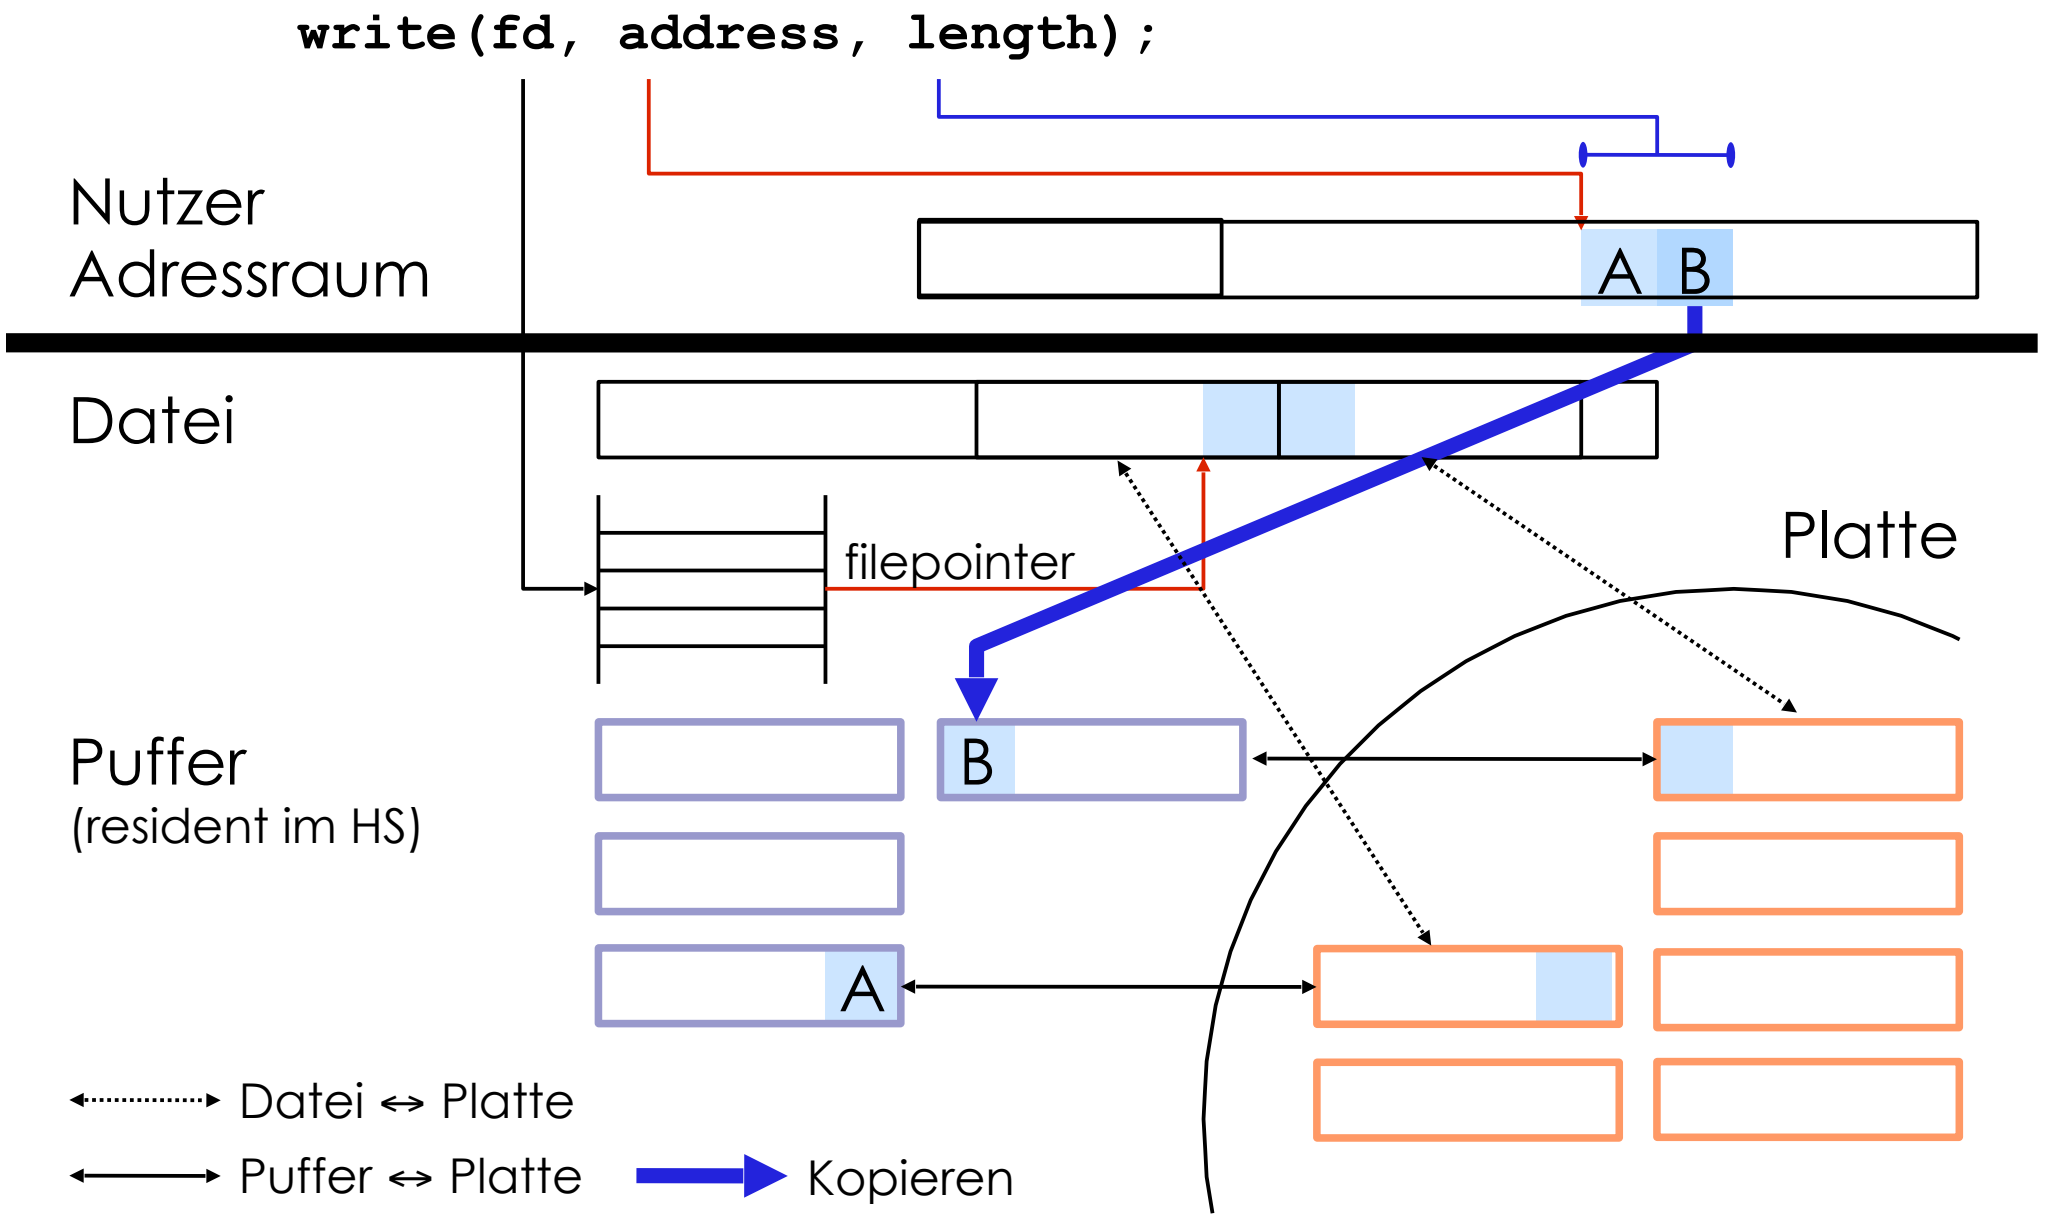

# Ablauf write: Asynchrones Schreiben auf Platte

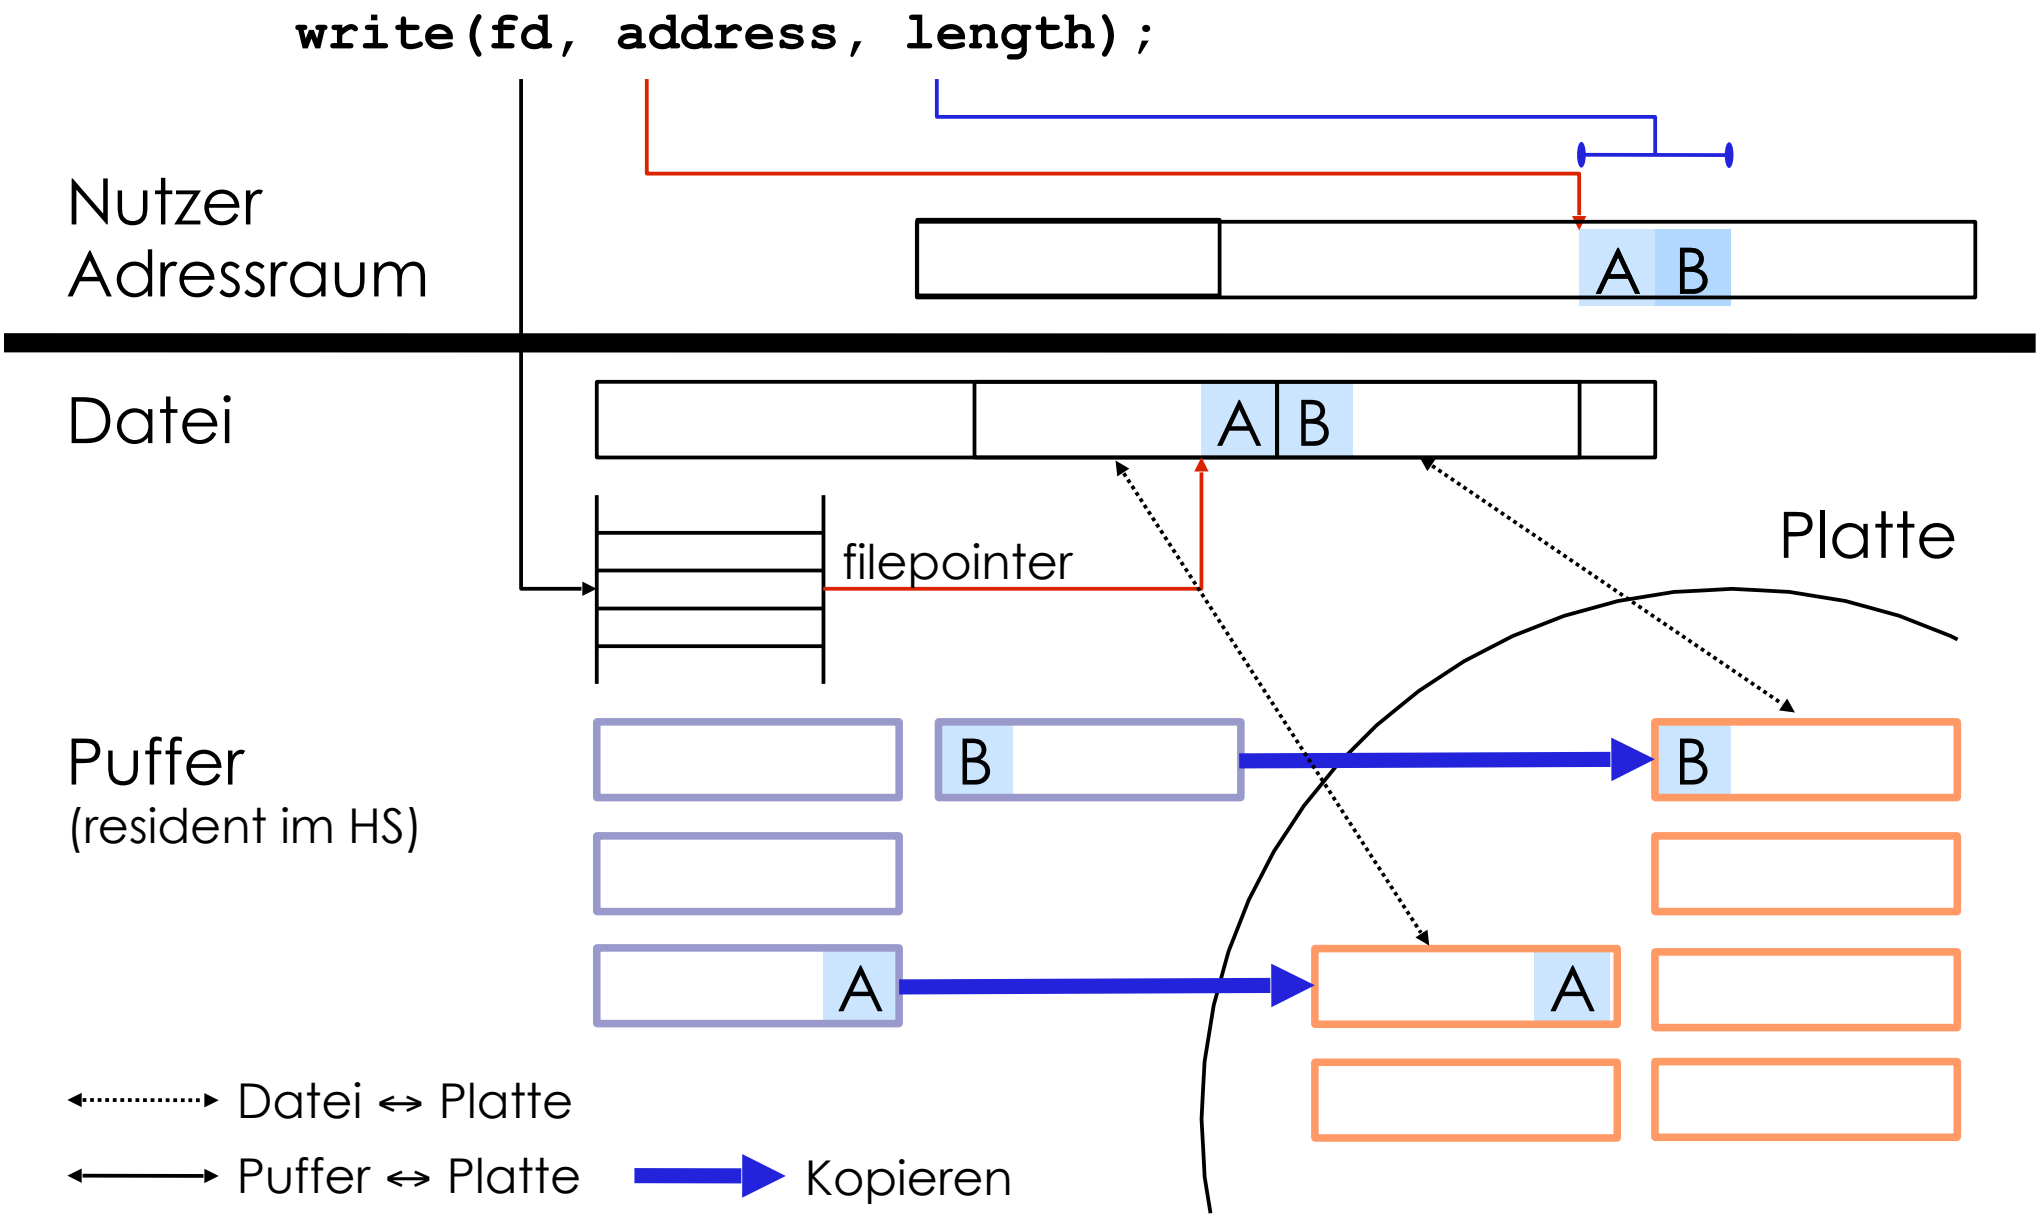

# Gegenüberstellung: read/write vs. map

**read/write**

- Kopie vor jeder Manipulation
- mehrere Prozesse können sich per read eine Kopie holen und dann den vom anderen Prozess vorher geschriebenen Wert überschreiben

**mmap**

- Einsparen von Kopieroperationen
- Synchronisation wie bei gemeinsamem Speicher

# Beispiel: Konto

```
open(Kontodatei, ... );
```

```
KontoAdrInDatei =
                Find_Konto;
read(Kontodatei,
    KontoAdrInDatei,
    &Konto, Länge);

Konto.Stand += Betrag;

write(Kontodatei,
    KontoAdrInDatei,
    &Konto, Länge);
```

```
mmap (Kontodatei, ...);

KontoAdr = Find_Konto;

KontoAdr->Stand += Betrag;
```

# Inkonsistente Datenstrukturen

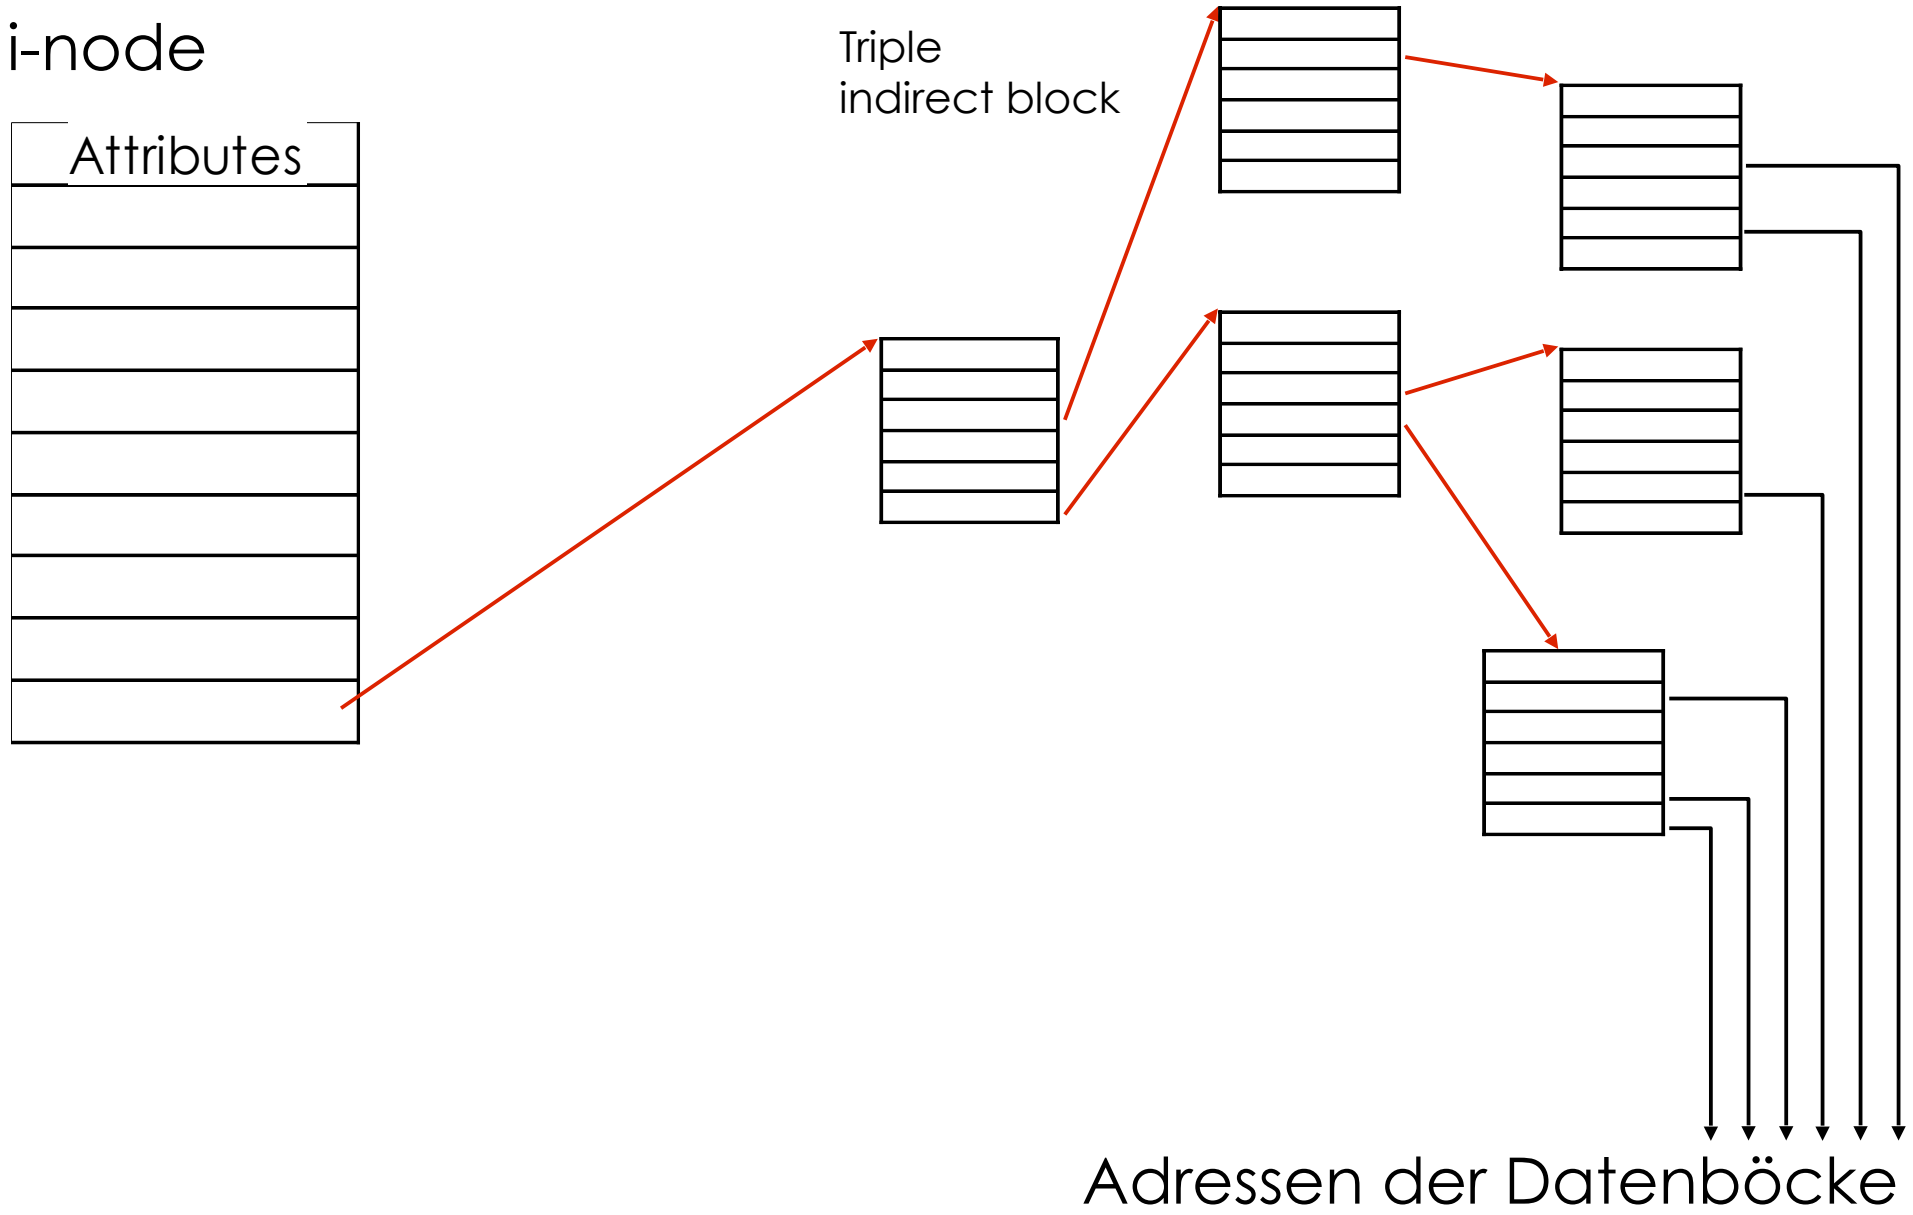

# Zusammenfassung

- Integration von Dateisystemen in Systemarchitektur
- Prinzipielle Teilaufgaben
- Ein einfaches altes Beispiel

# ABER: Limitationen

- Kleine Blöcke, riesige Dateien
- Ausfall von Platten
- Absturz eines BS → Verlust von Pufferinhalten, Inkonsistenzen
- Platte ./. Flash-Speicher

- spätere Kapitel in dieser Vorlesung