Dateisysteme

Betriebssysteme
WS 2006/2007

Jörg Kaiser
IVS – EOS

Otto-von-Guericke-Universität Magdeburg

Themen zu Dateisystemen

- Allgemeine Struktur eines Dateisystems
  - Organisation der Dateien
  - Organisation der Verzeichnisse
  - Zugriff zu Dateien und Verzeichnissen
- Organisation der Platte
  - Blockstruktur der Platte
  - Abbildung von Dateien und Verzeichnissen
  - gemeinsame Nutzung von Dateien
- Verwaltung der Platte auf Blockebene
- Verbessern der Leistung von Dateisystemen
- Zuverlässigkeit und Konsistenz von Dateisystemen

Dateisysteme: Motivation

Wozu wird einen zusätzliche Art von Speicher benötigt?

- **Persistenz ?**
- **Gemeinsame Nutzung ?**
- **Zugriffsschutz ?**
- **Größe ?**

Dateisysteme: Die systemorientierte Sicht

Dateien als allgemeine Abstraktion für langlebige Einheiten:

- Benutzerdokumente: reguläre Dateien
- Programme: ausführbare Dateien
- Strukturen der Dateiorganisation: Verzeichnisse
- Abstraktionen für Speichergeräte: Block-Dateien
- Abstraktionen zur Modellierung v. Geräten: Spezial-Dateien

Unterschiede werden im Dateityp festgehalten.

Dateinamen

Beispiele

name.extension	Bedeutung
name.txt	Textdatei
name.c	C Quelldatei
name.o	Objektdatei (Maschinencode nicht gelinked)
name.bak	Backup-Datei
name. jpg	Datei codiert im JPEG Standard
name.mp3	Datei codiert im MPEG 3 Standard
name.pdf	pdf Datei (portbale document format)

gif, tiff, as, ps, zip, tex, hlp, html, doc, exe, xls.....

Variationen: Characters: upper/lower case, unicode,. .

Erweiterungen: Konventionen vs. interpretiert durch das BS

Informationstruktur

Feld: grundlegendes Datenelement

Record: Menge zusammengehörender Felder

Datei: Menge zusammengehörender Records

Beispiel für die Informationsstruktur: <first name>, <family name>, <origin>, <home address>

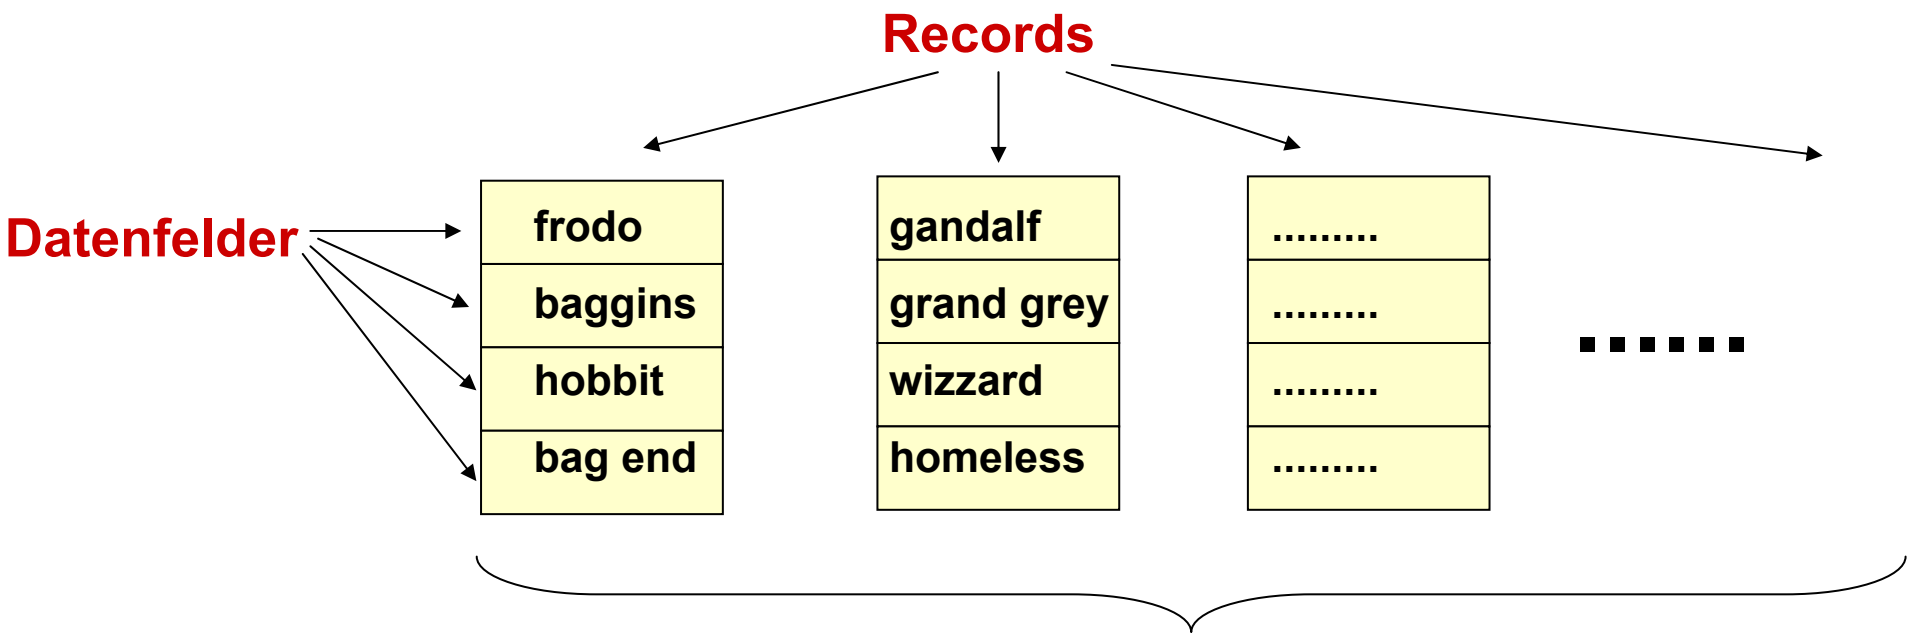

Dateiorganisation

Folge von Bytes

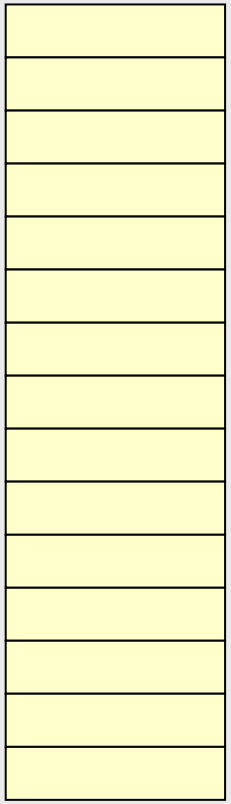

Folge von Records

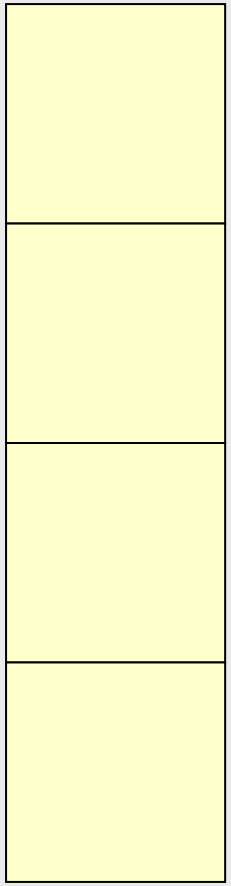

verkettete (Baum-) Struktur

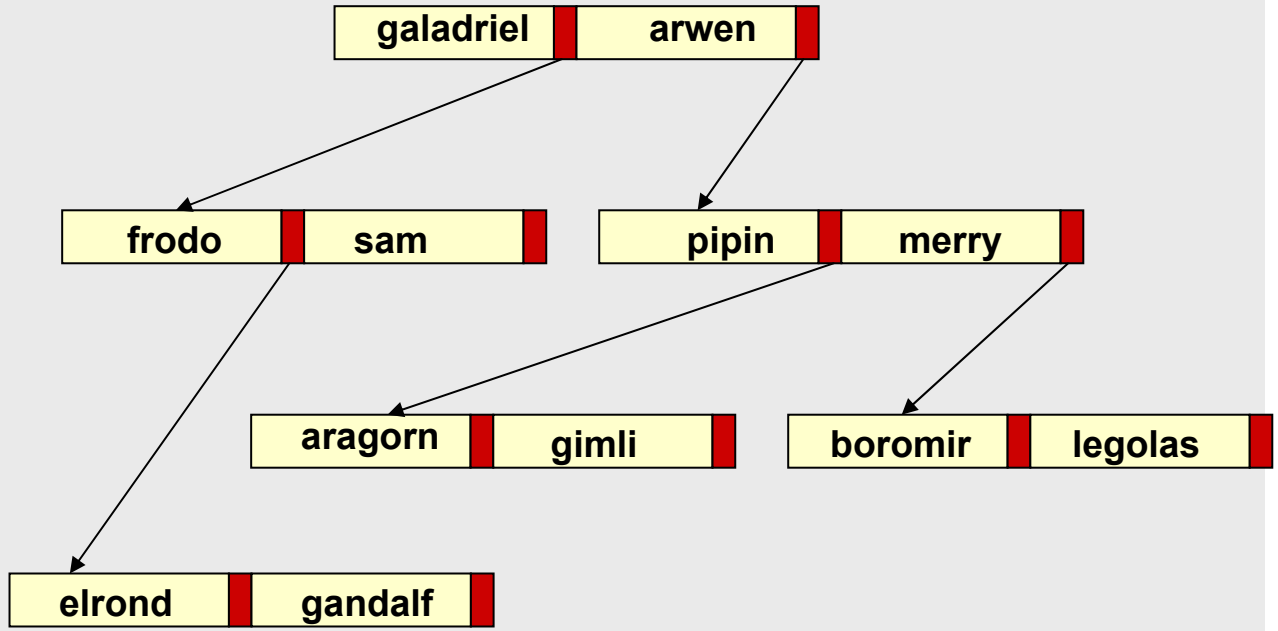

Dateiorganisation und Zugriff

Wie findet man einen Record? Alternativen in der Dateiorganisation:

Sammlung (collection):
Records variabler Länge in chronologischer Reihenfolge.

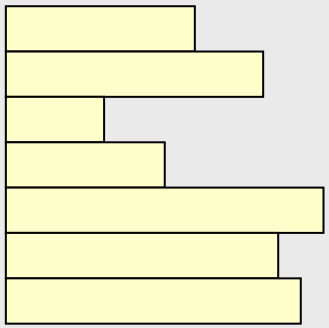

Sequentiell:
Records fester Länge in sequentieller Ordnung gemäß eines Schlüsselfeldes

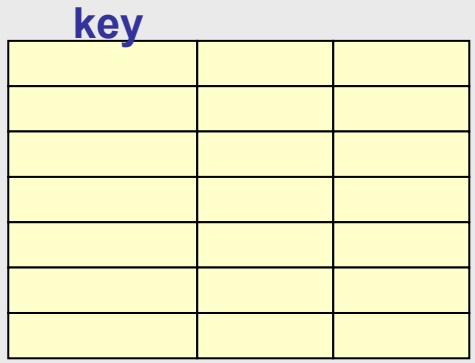

Index sequentiell:
Sequentielle Suche im entsprechenden Bereich

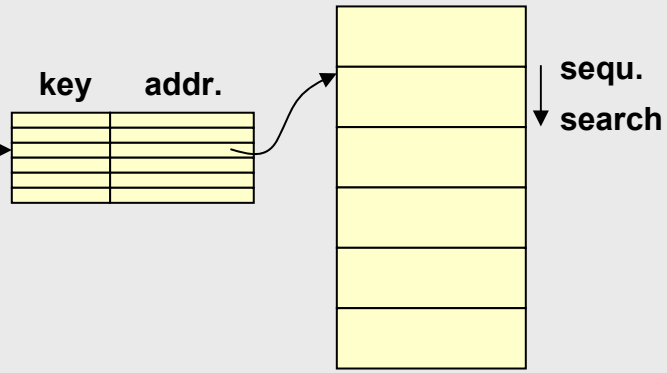

vollständig indiziert:
Index für mehrere Felder
Index für jeden Record
keine sequentielle Suche

Dateiattribute

Basisinformation: Dateiname, Dateityp, (Dateiorganisation)

Addressinformation: Gerät, phys. Startadresse, akt. Größe, max. Größe

Zugriffskontrollinfo.: Besitzer, Zugriffsautorisation, Zugriffsrechte

Dateiinformation: Erzeugungsdaten, Erzeuger ID, letzter Lesezugriff, ID des letzten Lesers, Datum der letzten Modifikation, ID des letzten Schreibers, Datum des Backup, aktuelle Benutzunginformation.

Dateiattribute

Beispiele von Dateiattributen

acces control	who is allowed to do what with the file
passwd	passwd for the file access
creator	ID of the file creator
owner	current owner
read-only-flag	0: R/W, 1:read only
hidden flag	0: default, 1: invisible
system flag	0: normal file, 1: system file
archive flag	0: changes saved, 1: not yet saved
ASCII/binary flag	0: ASCII file, 1: binary file
random access flag	0: sequential file, 1: random access
temporary flag	0: normal, 1: delete file on process termination
lock flags	0: not locked, ≠ 0: file locked
record length	number of bytes in a record
key position	offset to the key in the record
key length	number of bytes in the key
time of last access	date and time of last access to this file
time of last modification	data and time of last change
actual (max) size	number of (max) bytes in file

Dateitypen

Ausführbare Datei

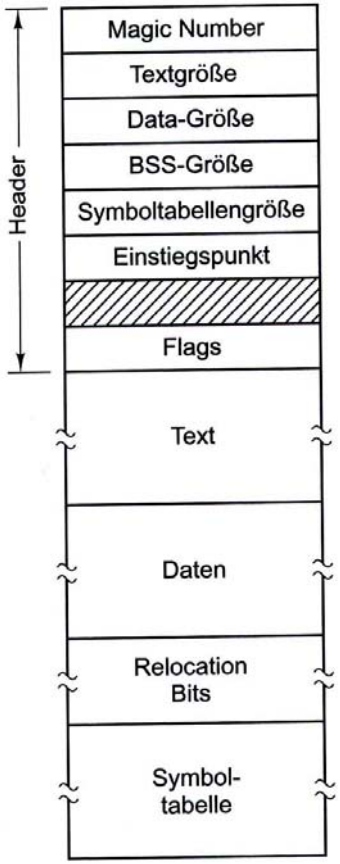

Archiv

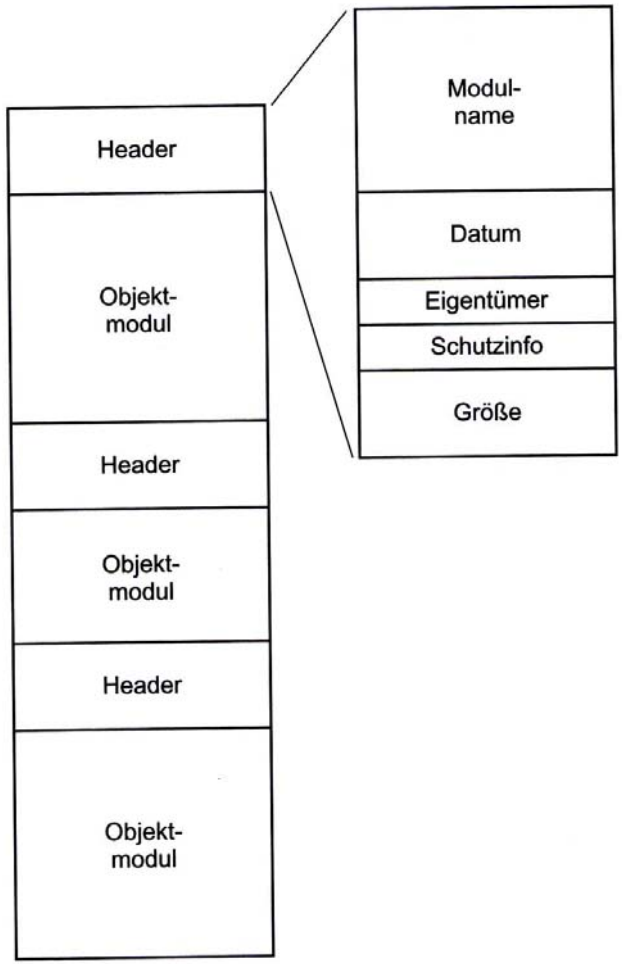

Typische Zugriffsoperationen für Dateien

Vorbeitung zum Dateizugriff	create	delete
	open	close
normaler Dateizugriff	read	write
	append	
Suchen & Verwalten	seek	
	set attributes	get attributes
	rename	

"Memory Mapped" Dateien

Idee: Abbildung von Dateien in den virtuellen Speicher. Ausnutzung des Seiten-Mechanismus, um Dateien zwischen Platte und Hauptspeicher ein- und auszulagern.

Vorteil: Zugriff auf eine Datei kann über normale Lese- und Schreib-operationen auf den Speicher realisiert werden.

Systemaufrufe:

map (virtual address): bildet die Datein in den virtuellen Adressraum ab.
Startadresse: virtual address

unmap: entferne Datei aus dem virtuellen Adressraum.

Probleme: exakte Größe der Ausgabedatei, gemeinsame Nutzung von "Memory Mapped" Dateien, Datei ist größer als der virtuelle Adressraum.

Verzeichnisse und Ordner

Flache Organisationsstruktur: Dateien werden als Sammlung einem Benutzer zugeordnet. Einfache Realisierung.

Hierarchische Verzeichnisstruktur:

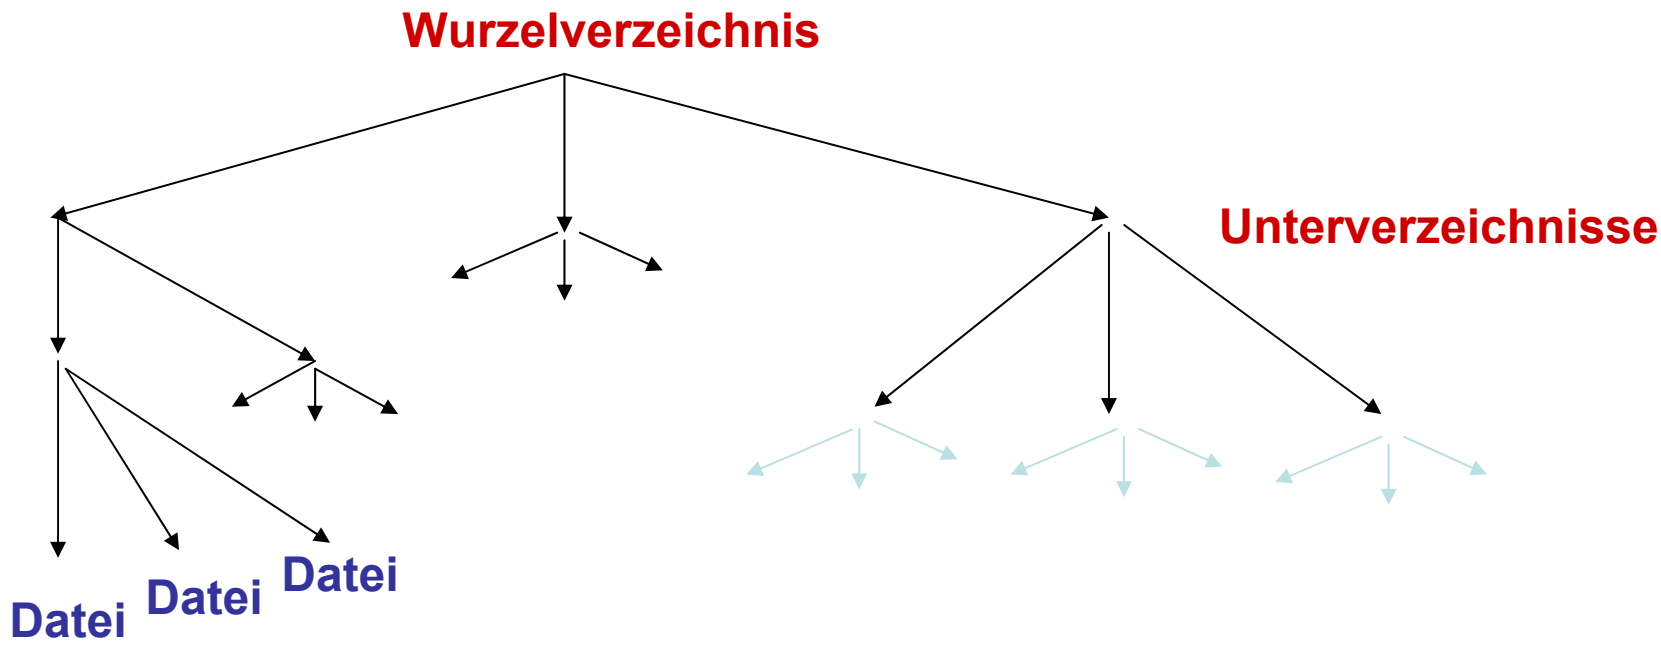

Hierarchische Verzeichnisstruktur und Pfadnamen

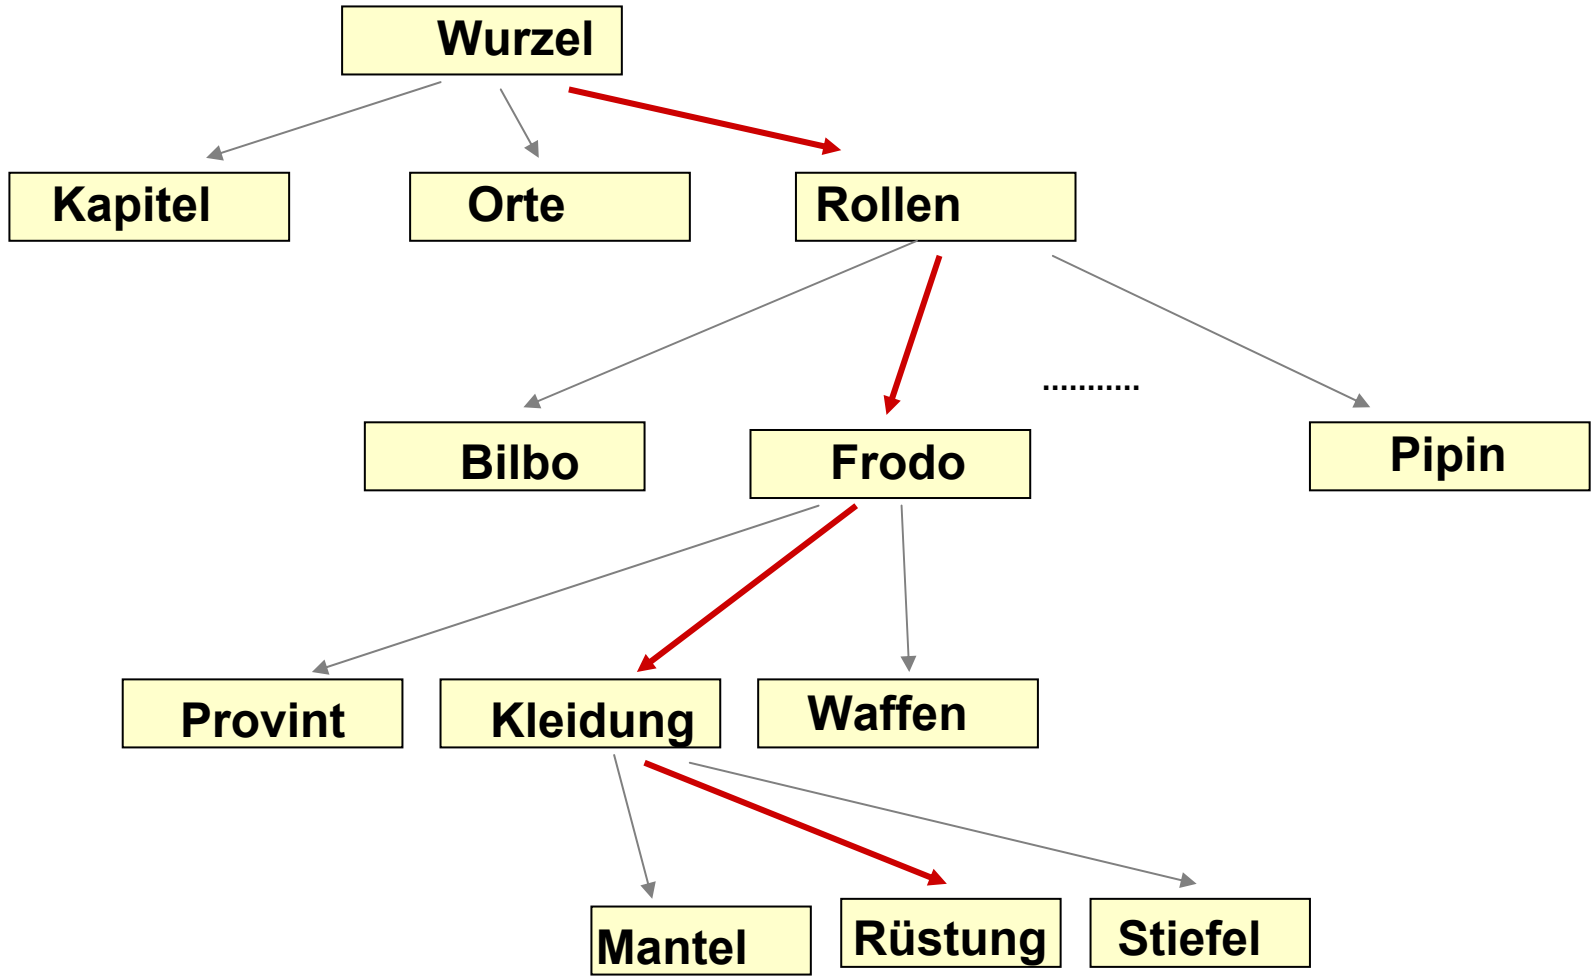

UNIX Dateibaum

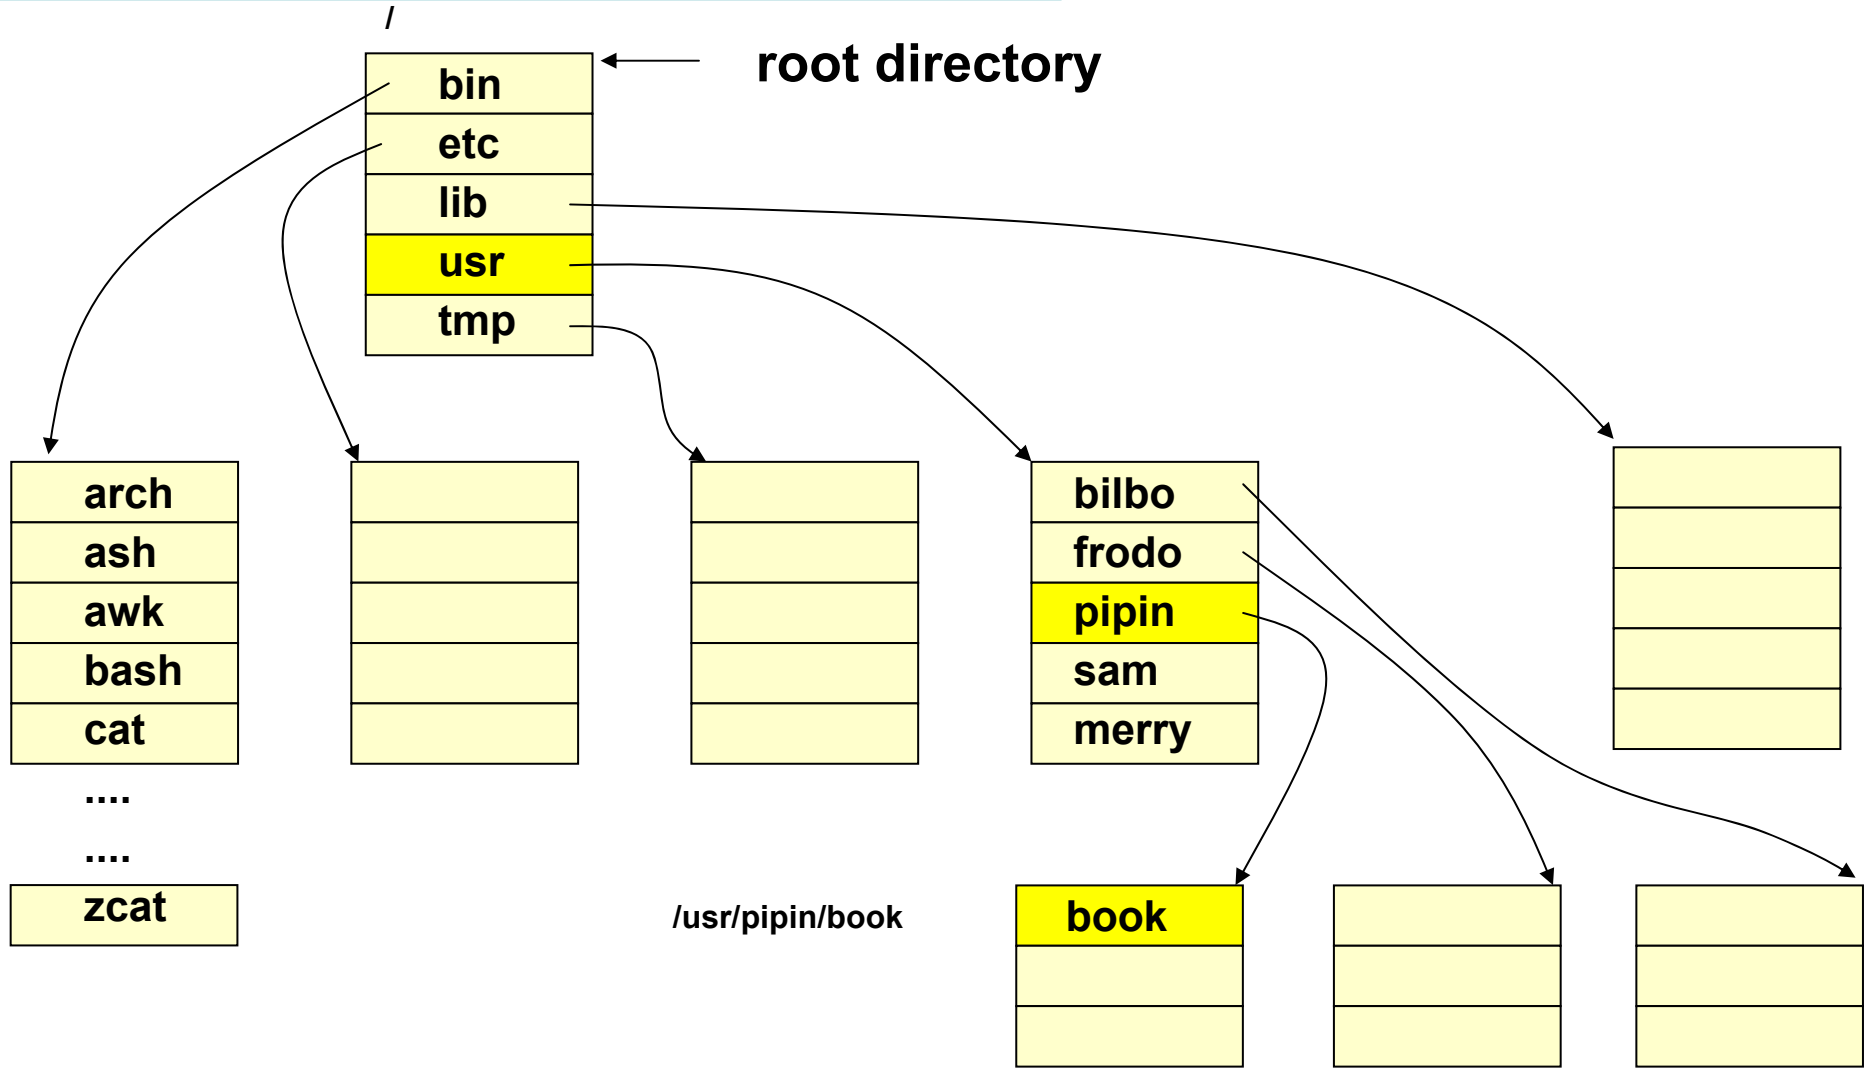

Verzeichnisse und Pfadnamen

Beispieldialog in Unix: eingegebene Kommandos, Reaktion

```
cd /
pwd
/
ls
bin  boot  dev  etc  home  lib  lost+found  tmp  usr  var
cd
pwd
/usr/kaiser
ls -all
drwxr-xr-x  14 kaiser  root    4096 March 22 18:17    .
drwxr-xr-x   3 root    root    4096 Dec   11 2003     ..
-rw-------   1 kaiser usr   742068 Nov   13 2004    pubsub-12112003.tar.gz
....
....
cd ..
pwd
/usr
```

Typische Operationen auf Verzeichnissen

- creat(e)
- delete
- opendir
- closedir
- readdir
- rename
- link
- unlink

Implementierung von Dateisystemen

Punkte:

- **Wie werden Dateien auf Plattenblöcke abgebildet?**
- **Wie werden die entsprechenden Plattenblöcke gefunden?**
- **Wie werden Verzeichnisse realisiert?**
- **Wie werden Dateien gemeinsam genutzt?**

(Physische) Organisation einer Platte

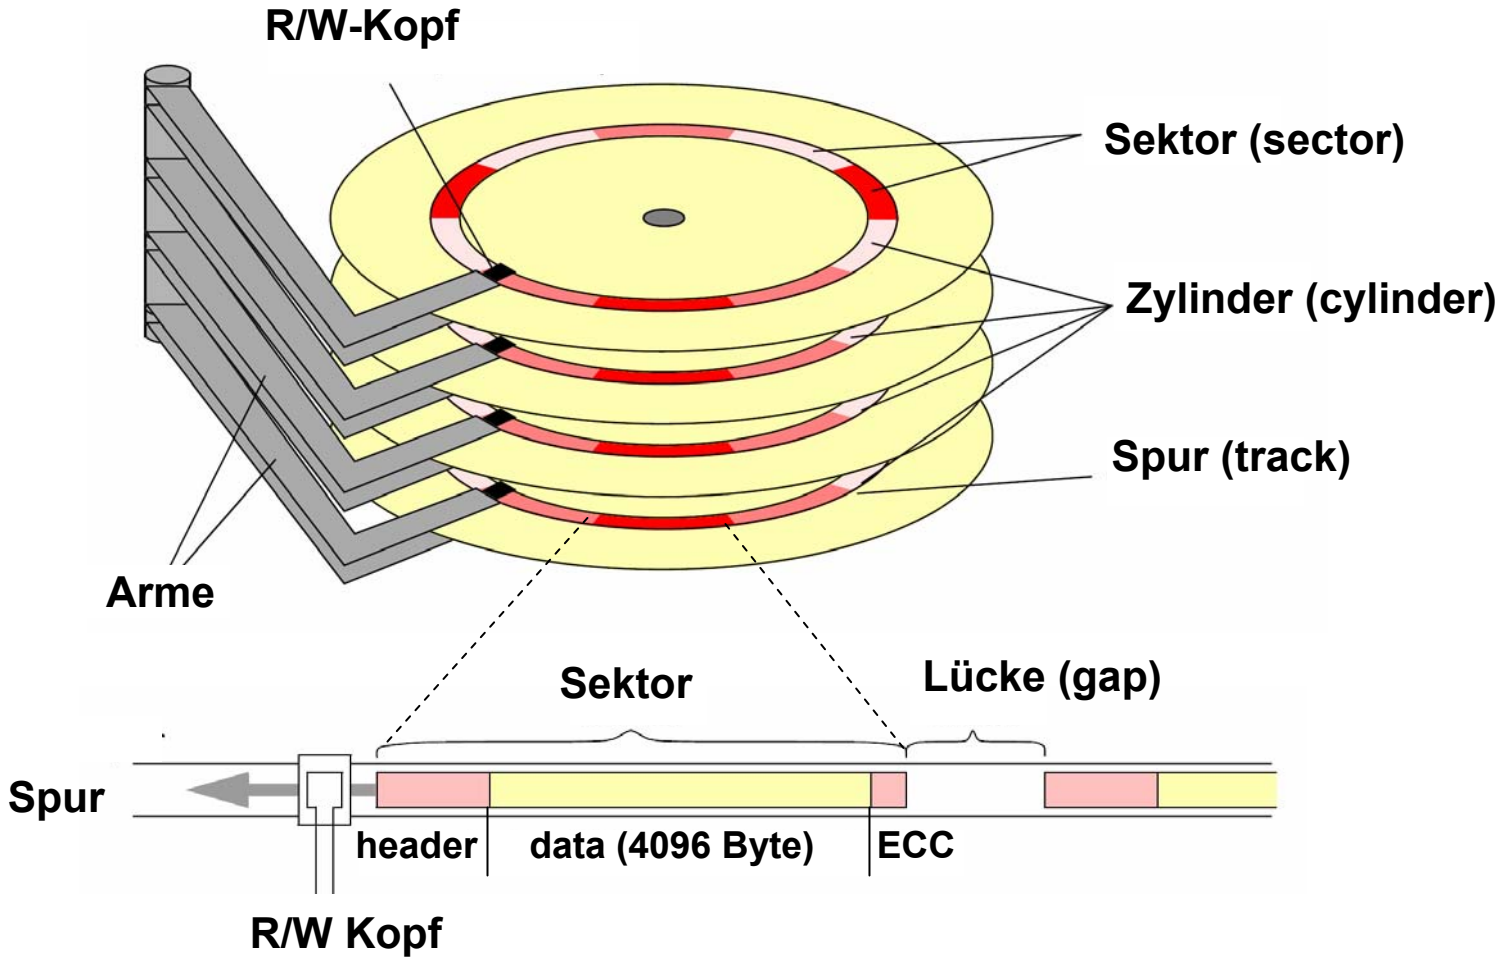

(Physische) Eigenschaften einer Platte

Plattentyp		Seagate ATA-U100	Seagate Cheetah
Kapazität		30 GB	73,4 GB
Platten/Köpfe		1/2	4/8
Zylinderzahl		CHS 16383/16/63	29.594
Cache		2 MB	4 MB
Posititionier-zeiten	Spur zu Spur		0,4/0,6 ms
	mittlere	8,9 ms	5,1/5,5 ms
	maximale		10/11 ms
Transferrate		8,5 MB/s	38–64 MB/s
Rotationsgeschw.		5.400 U/min	10.000 U/min
eine Plattenumdrehung		11 ms	6 ms
max. Stromaufnahme		7,5 W	11 W

Organisationsvariationen

Fortlaufende Belegung von Plattenblöcken

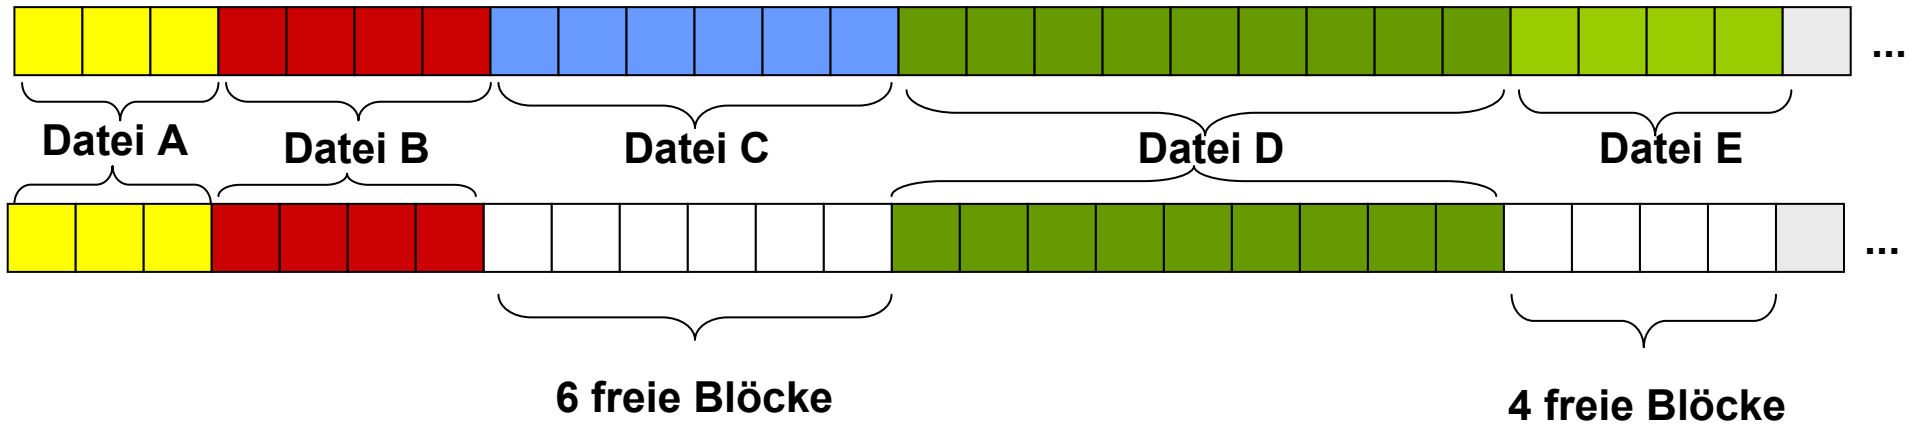

Pro: einfache Implementierung

gute Lese-Performanz

Con: Dateigröße muss a priori bekannt sein

Auffinden und Wiederverwendung von freien Blöcken ist schwierig

Organisationsvariationen

verkettete Liste realisiert durch: File Allocation Table (FAT) im Speicher

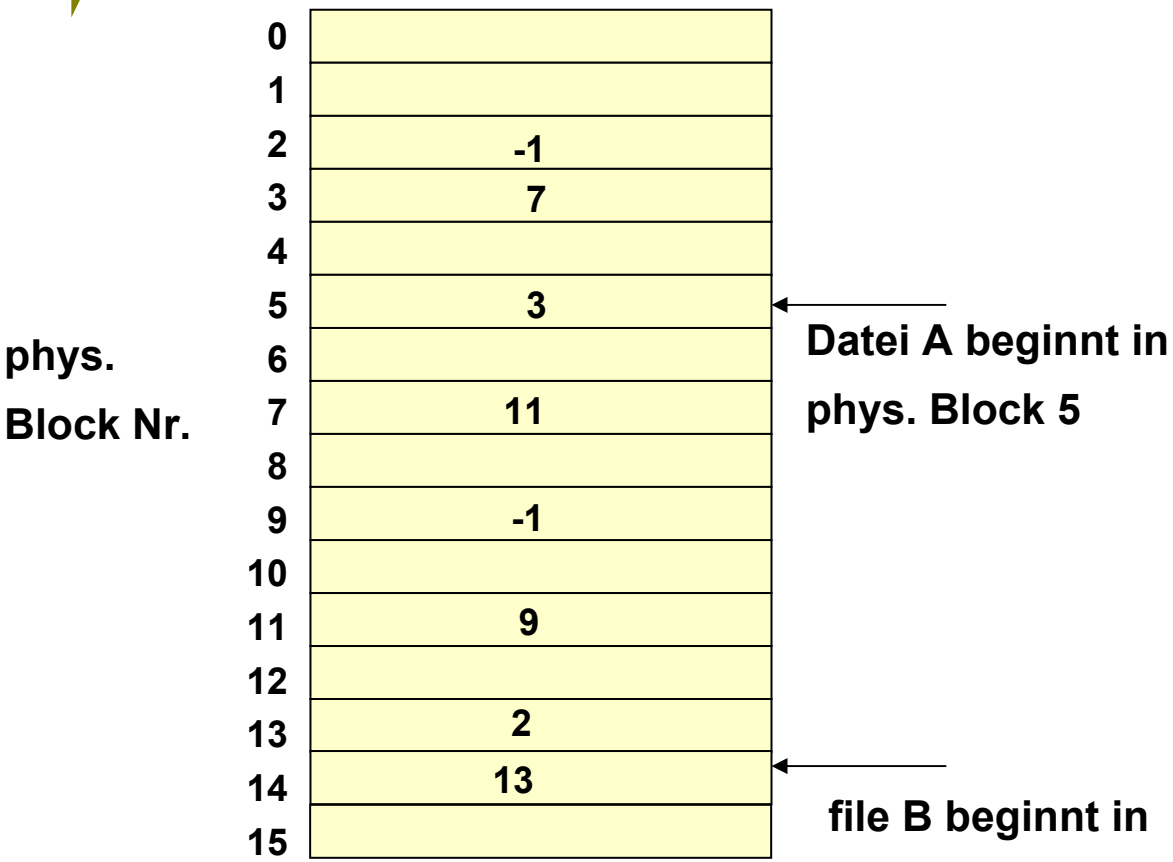

-1: Dateiende symbol

Pro: mildert die Probleme des wahlfreien Zugriffs auf verkettete Listen

Con: die Größe ist proportional zur Plattengröße.

Organisationsvariationen

i-node, inode, index node

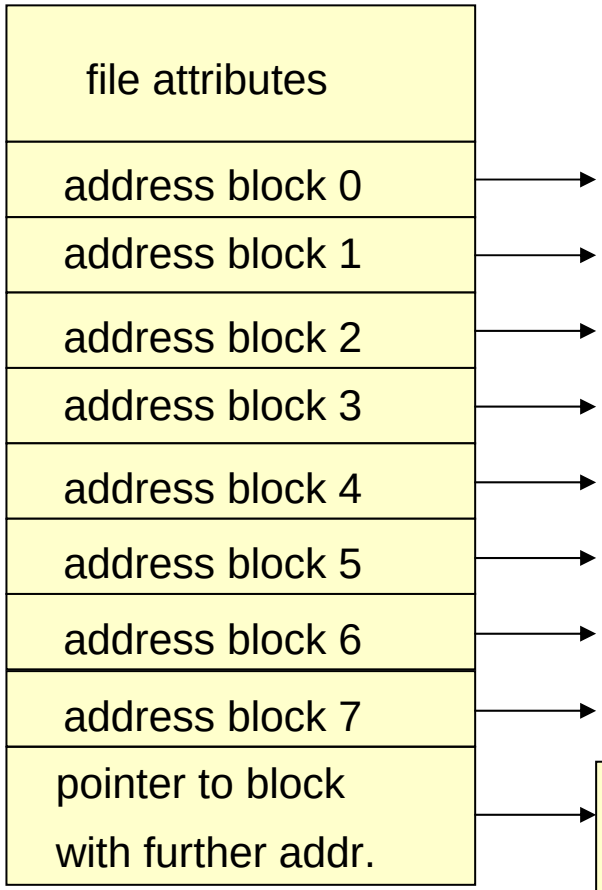

Dateiattribute sind z.B.:

- **owner**
- **file type**
- **access permissions**
- **access time**
- **number of links to the file**
- **file size**

pro: Nur die i-nodes offener Dateien benötigt Platz im Hauptspeicher
nicht mit Plattengröße korreliert

Dateiattribute und Dateiinhalt können getrennt gespeichert werden.

Layout eines Dateisystems

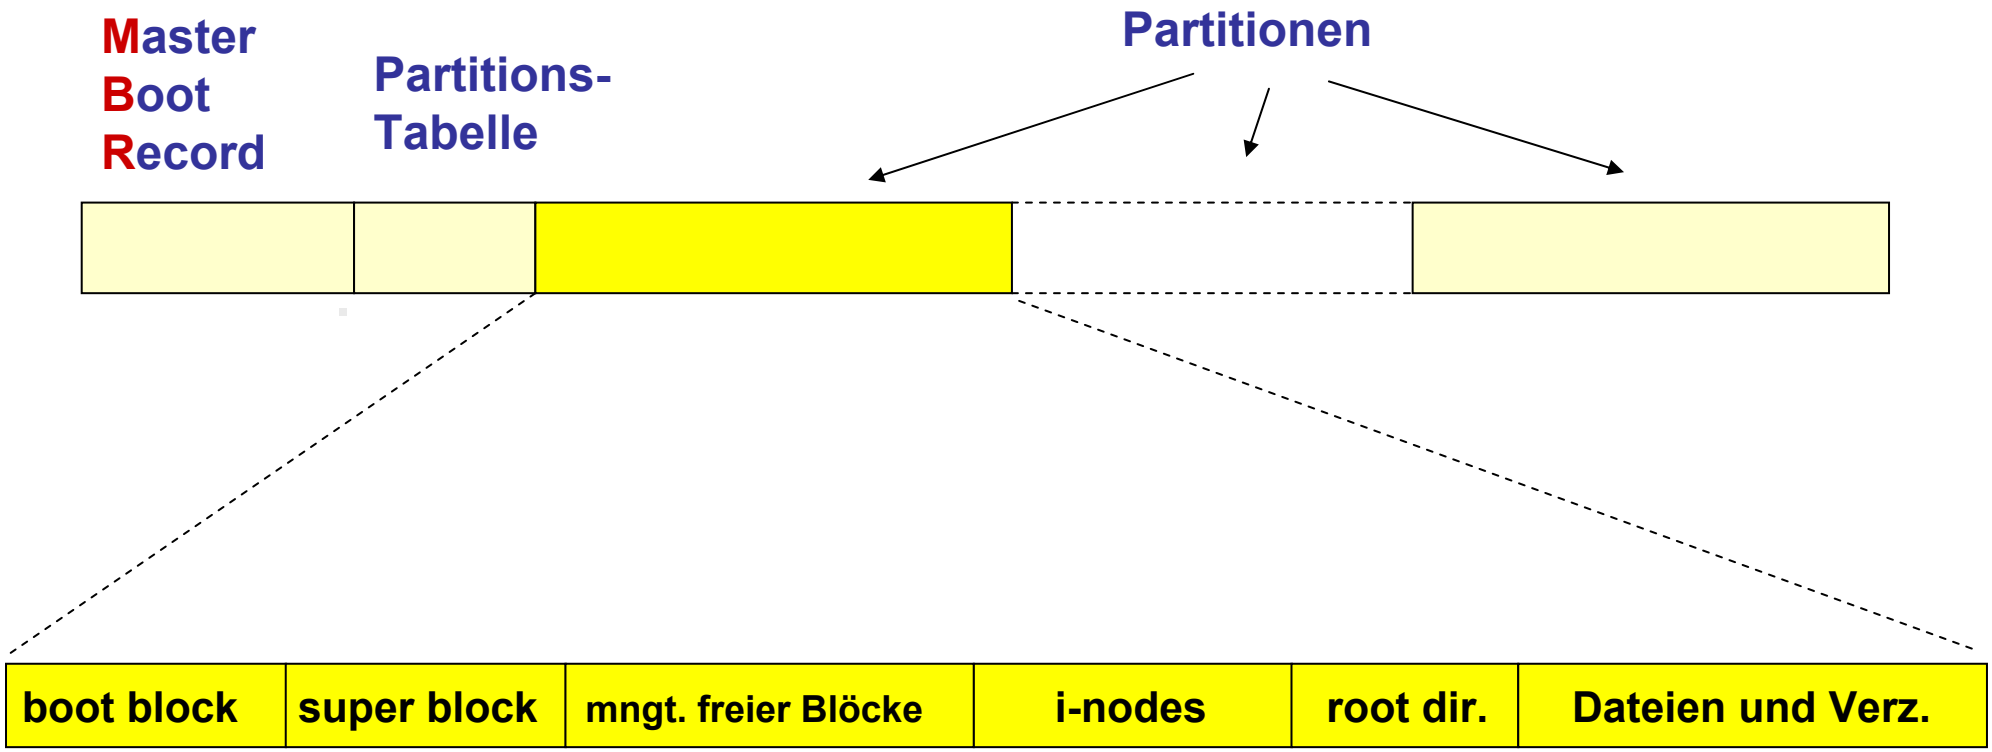

Unix Dateisystem Verwaltung

- Klassisches Unix System

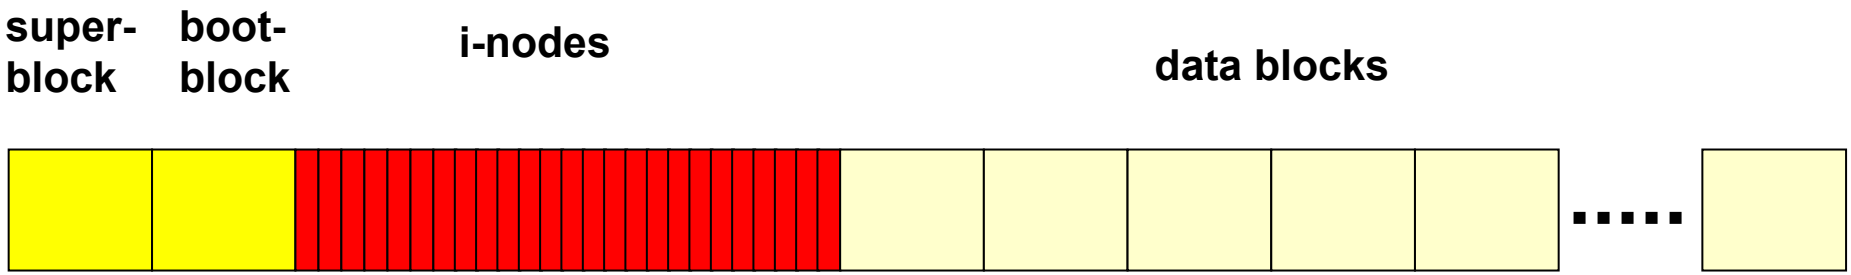

- Berkeley Fast File System:
  - lange Dateinamen (255 Zeichen)
  - Platte wird in Zylindergruppen mit eigenem Super Block, i-nodes und Datenblöcken strukturiert.
  - 2 Blockgrößen zur effiezienten Verwaltung

- Linux File System: sehr ähnlich zum Berkeley Fast File system.

i-nodes in UNIX

File Mode:	16-Bit Flag which stores access rights
	0 .. 2 rights for "all" users <read, write, exec>
	3 .. 5 rights for the "group" <read, write, exec>
	6 .. 8 rights for "owner" <read, write, exec>
	9 ..11 execution flag
	12..14 file type (regular, char./block-oriented, FIFO pipe)
Link Counter	number of directory references to this i-node
UID	Owner ID
GID	Group ID
Size	in Bytes
File address	39 byte file address information
Last access	date/time
Change of i-node	date/time
Address info for blocks	direct, single ind., double ind., triple ind.

Dateiallokation

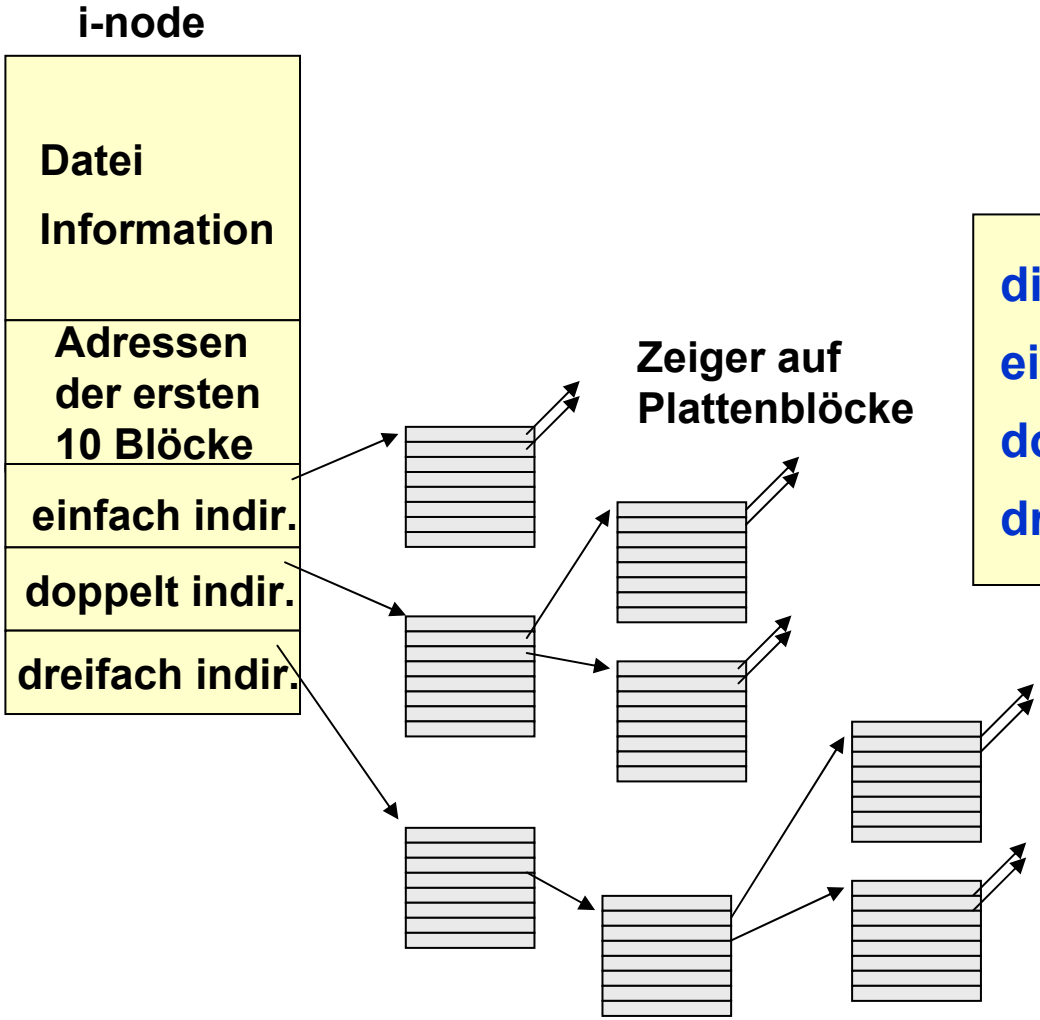

Kapazität des UNIX Dateisystems

direkt	10 Blöcke	10 K
einfach indir.	256 Blöcke	256 K
doppelt ind.	64K Blöcke	64 M
dreifach ind.	256x64K Blöcke	16 G

Impelmentierung von Verzeichnissen

welche Information wird in einem Verzeichniseintrag benötigt?

Informationen über den Dateityp.
Wie wird die Datei auf der Platte gefunden?
Zusätzliche information.

} Dateiattribute

Einfache Verzeichnisstruktur mit Einträgen fester Länge

album	attributes
mail	attributes
papers	attributes
courses	attributes

Verzeichnisstruktur, die i-nodes ausnutzt.

album	inode-no.
mail	inode-no.
papers	inode-no.
courses	inode-no.

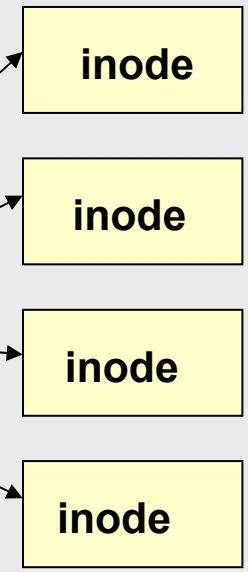

Gemeinsame Nutzung von Dateien

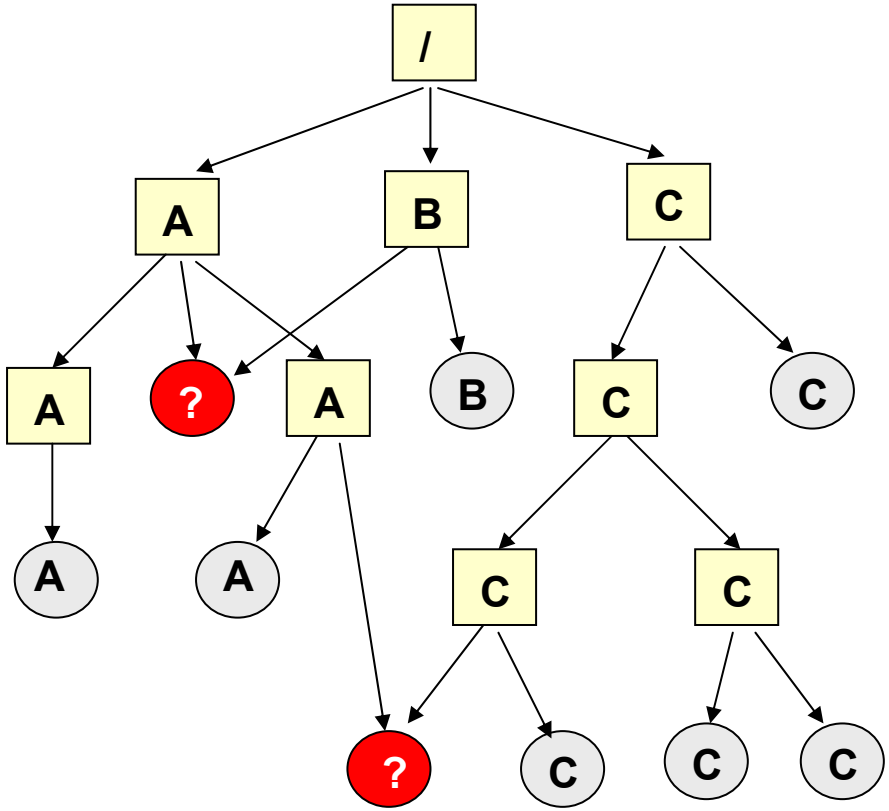

gerichteter azyklischer Graph

Verzeichnis

Datei

gemeinsam benutzte Datei (shared file)

A,B,C : owner

Probleme:

- Wer ist der Besitzer einer "shared" Datei?
- Wie wird die Sichtbarkeit von Änderungen durchgesetzt?

Gemeinsame Nutzung von Dateien

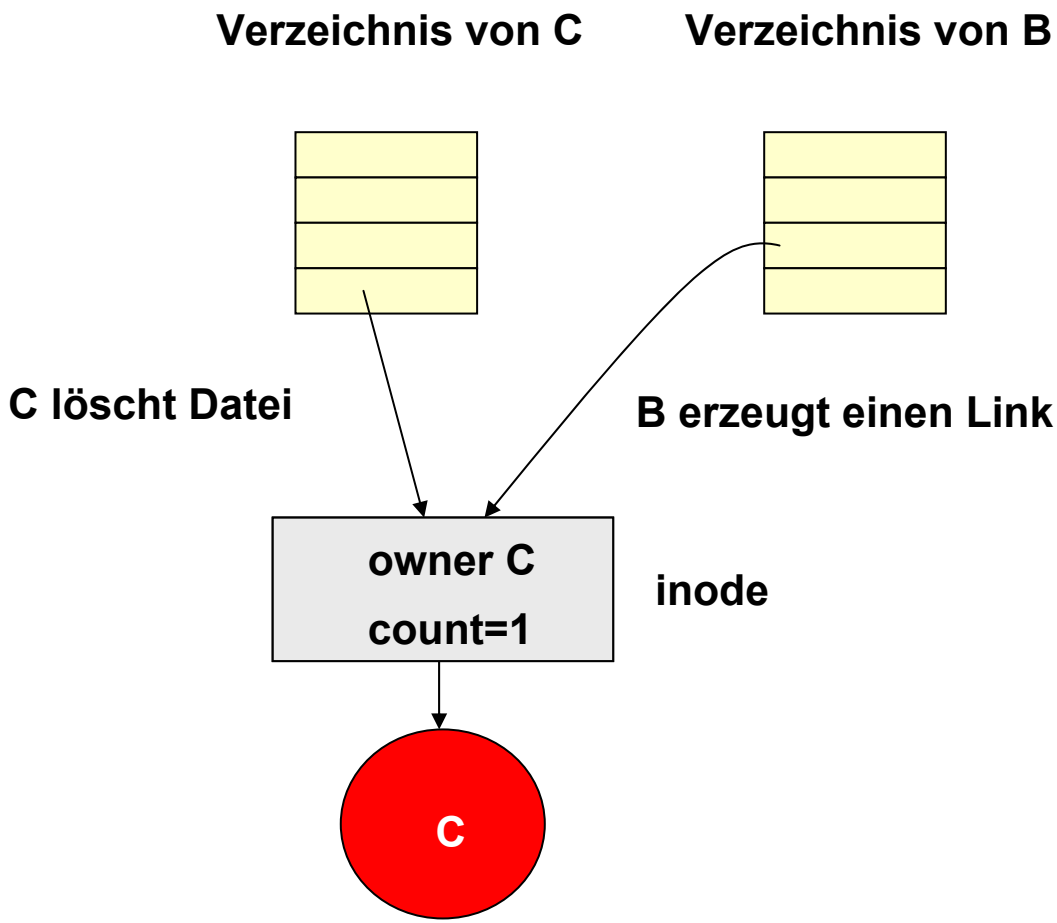

Problem:

B ist der einzige Nutzer einer Datei deren Besitzer C ist.

Datei-Sharing mit symbolischen Links

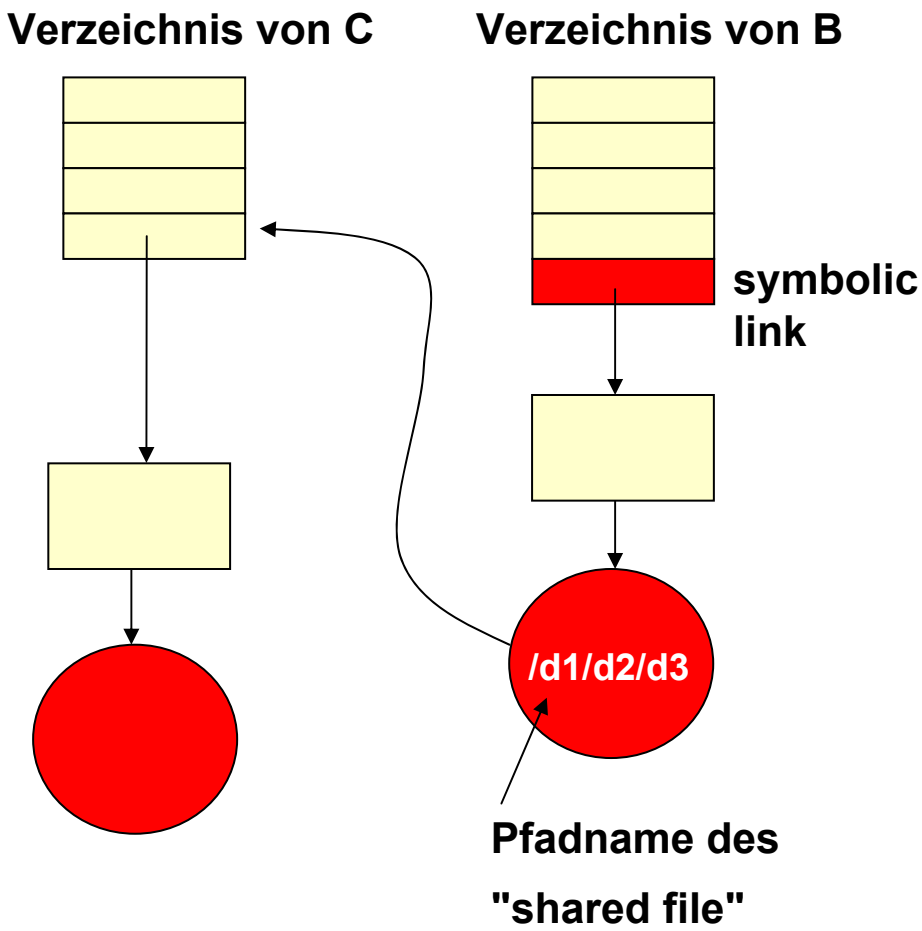

Besitzer hat volle Kontrolle über die Datei.

Problem: Aufwand

- Analyse und Verfolgung des Pfads benötigt zusätzlich Plattenzugriffe

- zusätzlicher i-node für jeden Link.

Verwaltung des Plattenspeichers

Enfluß der Blockgröße auf Datenrate und Speichereffizienz

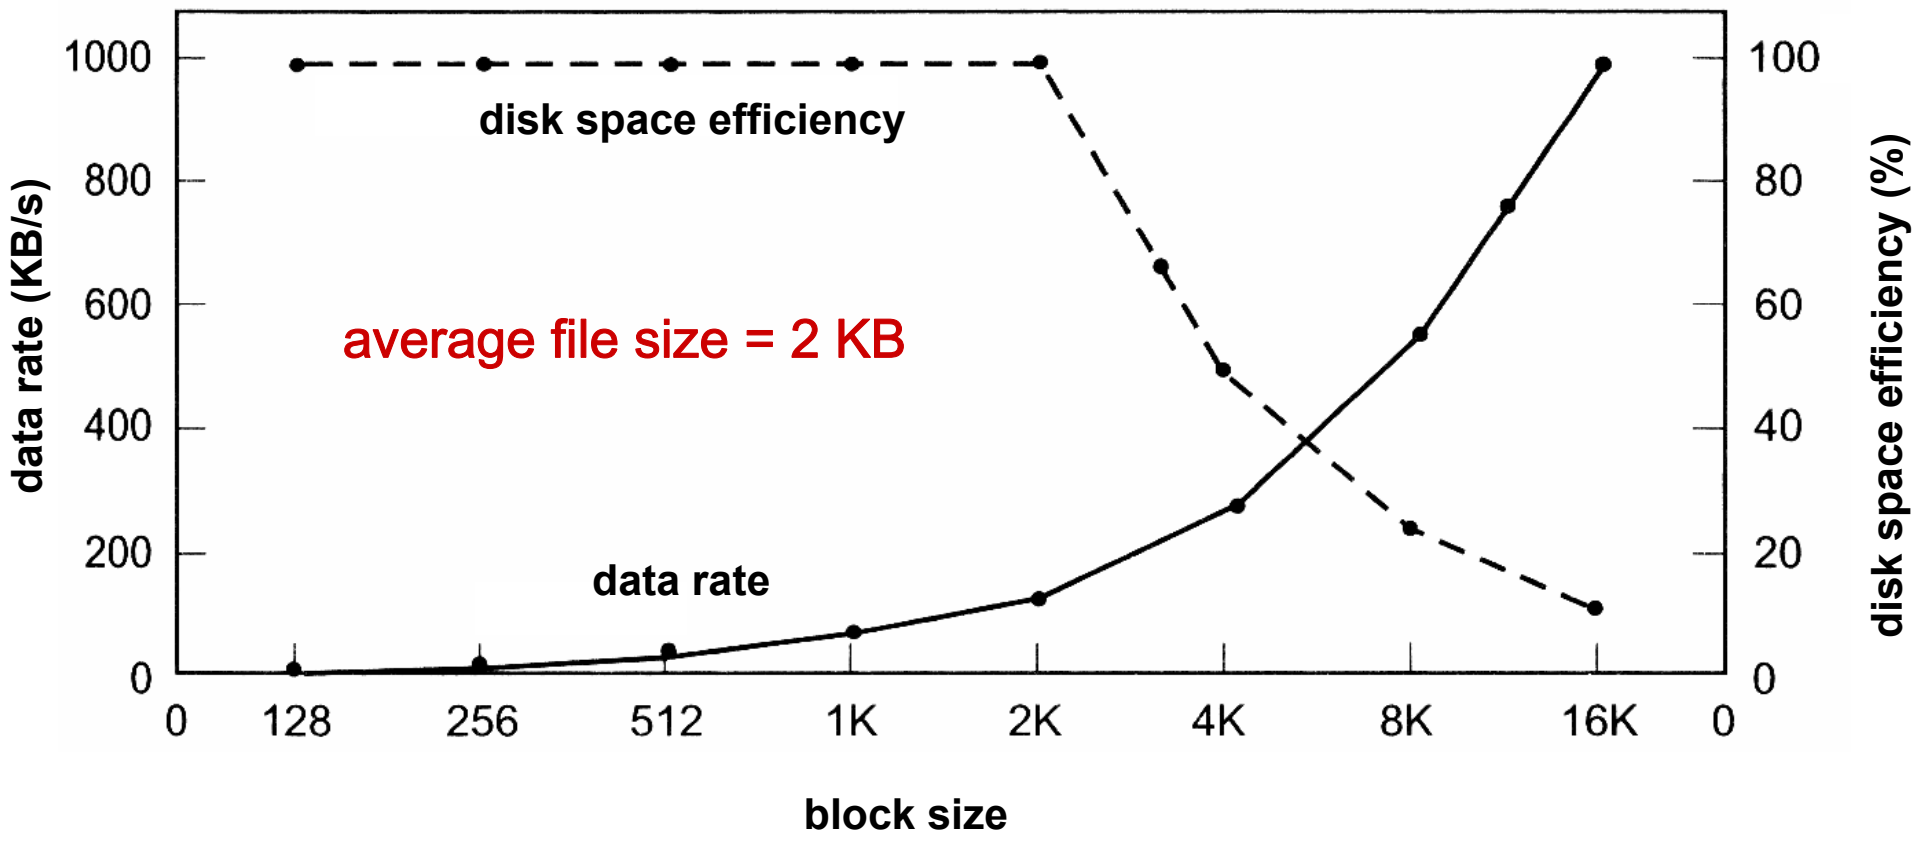

(Tanenbaum 2003)

Verwaltung des Plattenspeichers

1. Verkettete Liste freier Blocks

   Größe der Liste und max. Speicherplatzanforderungen:

   16 GB Platte, Blockgröße 1k:

   --> 16M Einträge a 32 bit

   --> 1 Block 255 (+1 zur Verkettung der Blocks) Einträge --> ~ 40 K Blöcke

   ändert sich mit der Zeit, wenn mehr Blöcke benötigt werden

2. Bit-Matrix freier Blöcke

   Größe der Liste und max. Speicherplatzanforderungen:

   16 GB Platte, Blockgröße 1k:

   --> 16M Einträge a 1 bit

   --> 1 Block 1k x 8 bBits --> ~ 2K Blöcke

   feste Größe

Effizienzsteigerungen

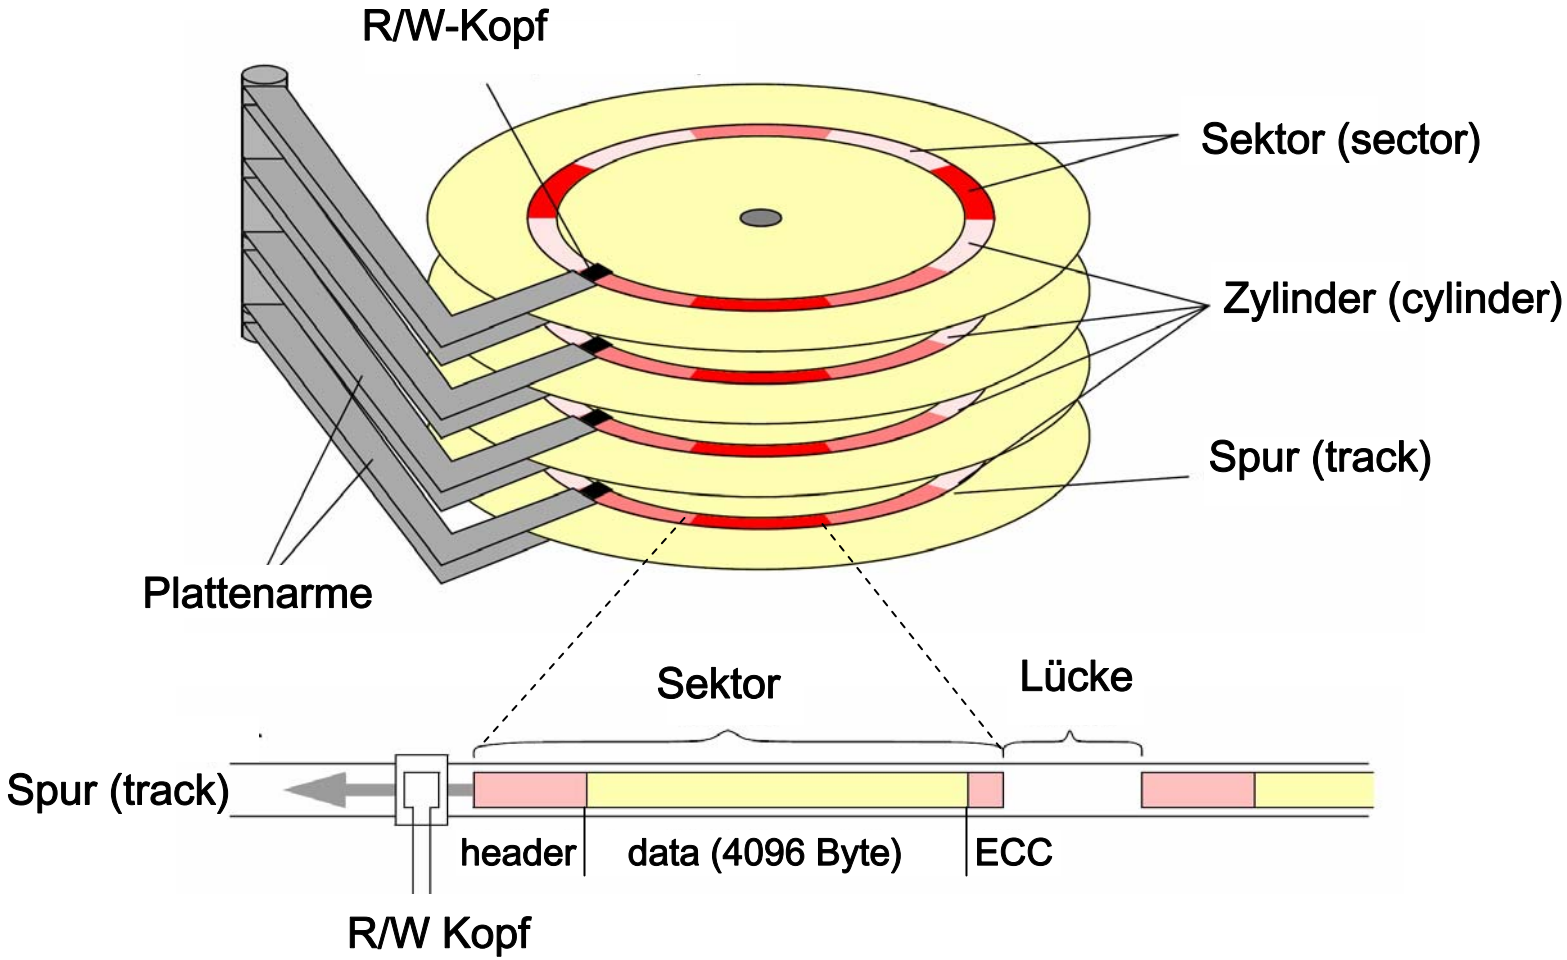

Der Puffer-Cache

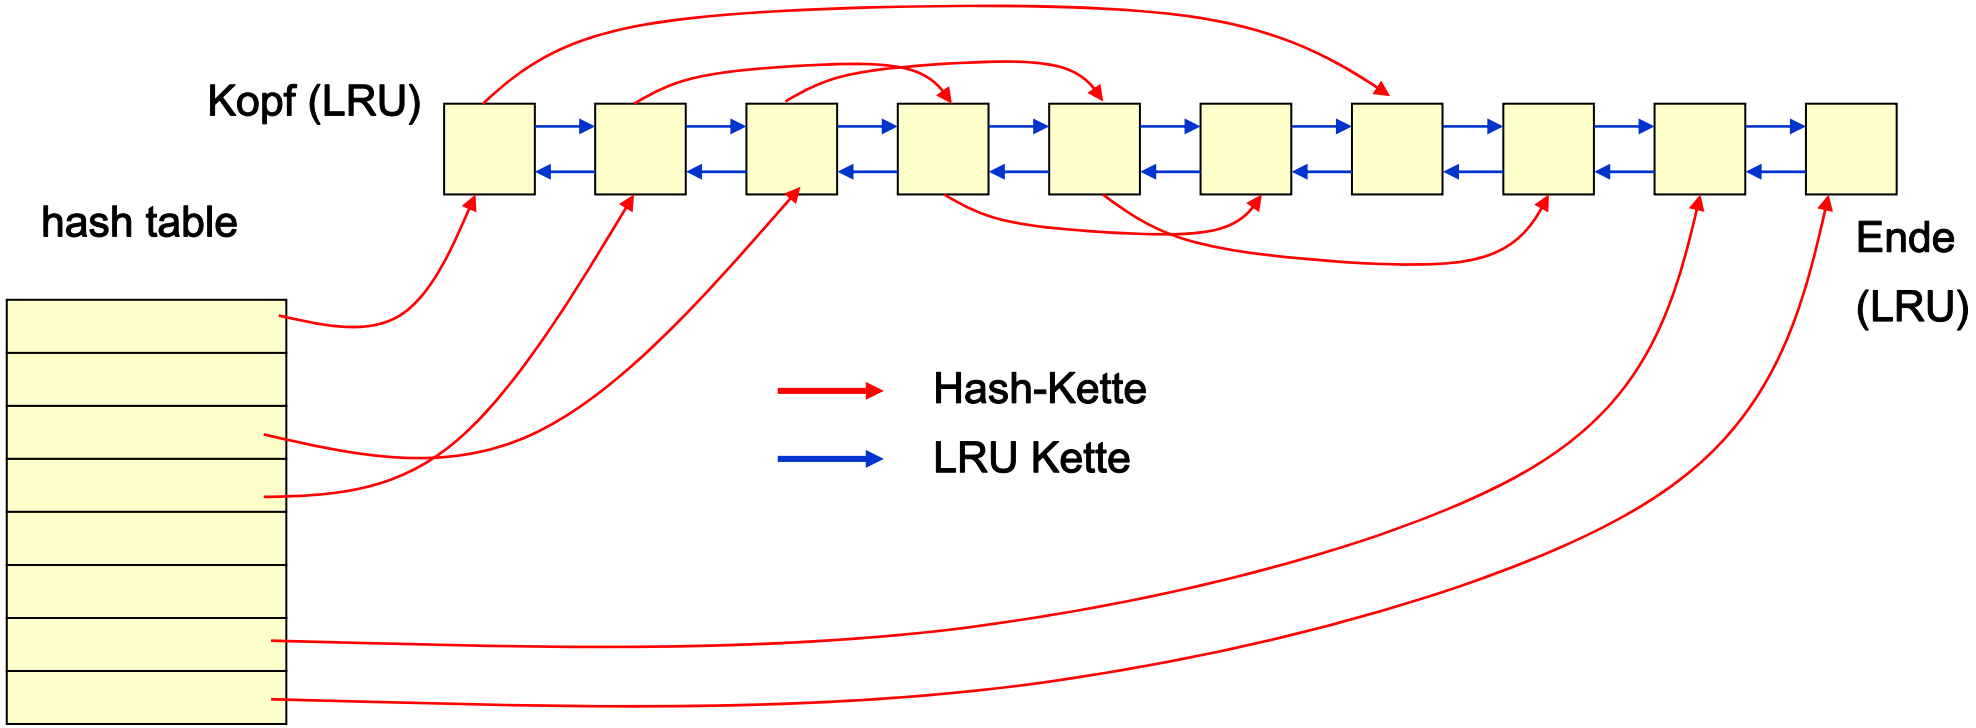

Problem: Inhalt von Plattenblöcken und Cache-Inhalt sind nicht identisch.

- Inkonsistenzen bei Abstürzen.
- Zielkonflikt zwischen häfiger Aktualisierung und Datenverlust.
- Explizite Synchronisation (sync).

Optimierung des Plattenzugriffs

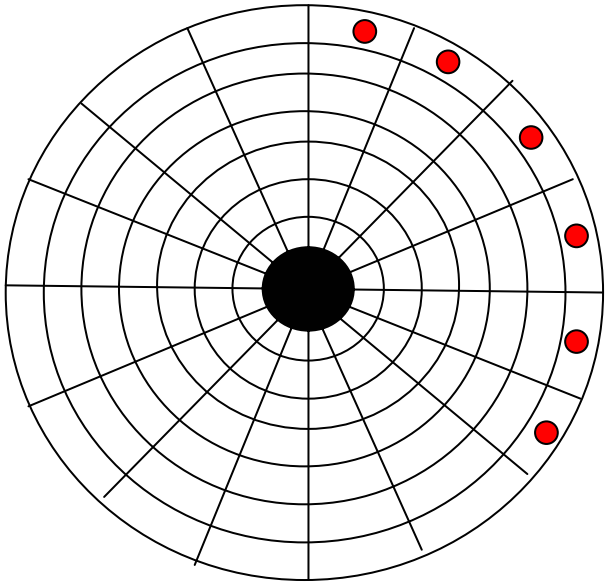

i-nodes stehen alle am Anfang der Platte.

Abstand der i-nodes und der damit assoziierten Plattenblöcke: Anzahl der Zylinder/2

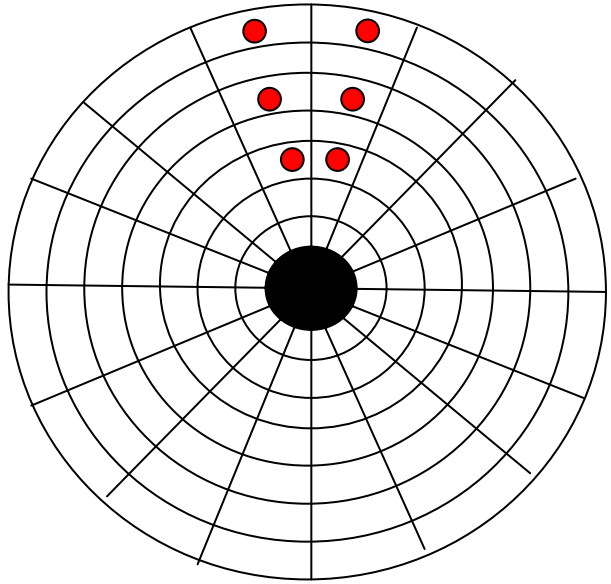

i-nodes und assoziierte Plattenblöcke werden in Zylindergruppen organisiert.

Zuverlässigkeit eines Dateisystems

Datenverlust ist der "Super GAU" in einem Computersystem!

(Hardware-) Kosten eines neuen Computers 5.000 €

Kosten von Datenverlusten: oft mehrere Größenordnungen höher !

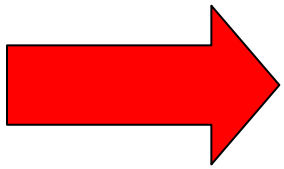

Das Dateisystem muss geschützt werden gegen:

- Plattencrashes
- fehlerhafte Software
- bösartige (nicht autorisierte) Zugriffe

Zuverlässigkeit eines Dateisystems

Impairment	Countermeasures
defective blocks from manufacturing	directory of bad blocks on medium
transient reading and writing errors	code redundancy
physical destruction of disk	backup on redundant medium, mirrored disk (e.g. RAID 2), data replication
software faults	user related access rights, least priviledge
system crashes	fsck, scandisk, journaled file systems
malicious accesses	access protection, encryption, fragmentation
erroneous deletion of files	no physical deletion, backups

Sicherungskopien

Physische Sicherung:	kopiert alle Blöcke der Platte auf ein Sicherungsmedium
pro:	einfach
con:	speichert auch freie Blöcke und hat Probleme mit "bad blocks", nur vollständige Sicherung möglich.

Logische Sicherung:	basiert auf der logischen Dateisystemstruktur. Rekursiv werden Verzeichnisse und Dateien abgespeichert.
pro:	Incrementeller Algorithmus speichert nur Änderungen seit der letzten Sicherung.
con:	kompliziertere Implementierung.

Konsistenz des Dateisystems

Problem: Änderungen werden im schnellen Haupspeicher gemacht und erst später persistent auf Platte gespeichert.

Datei Abbildungen
(einige Dateiblöcke)

Verzeichnis Abbildungen
(einige Verzeichnisblöcken)

i-node Abbildungen
(einige Blöcke der i-node Tabelle)

Abbildung der Freiliste
(einige Blöcke der Freiliste)

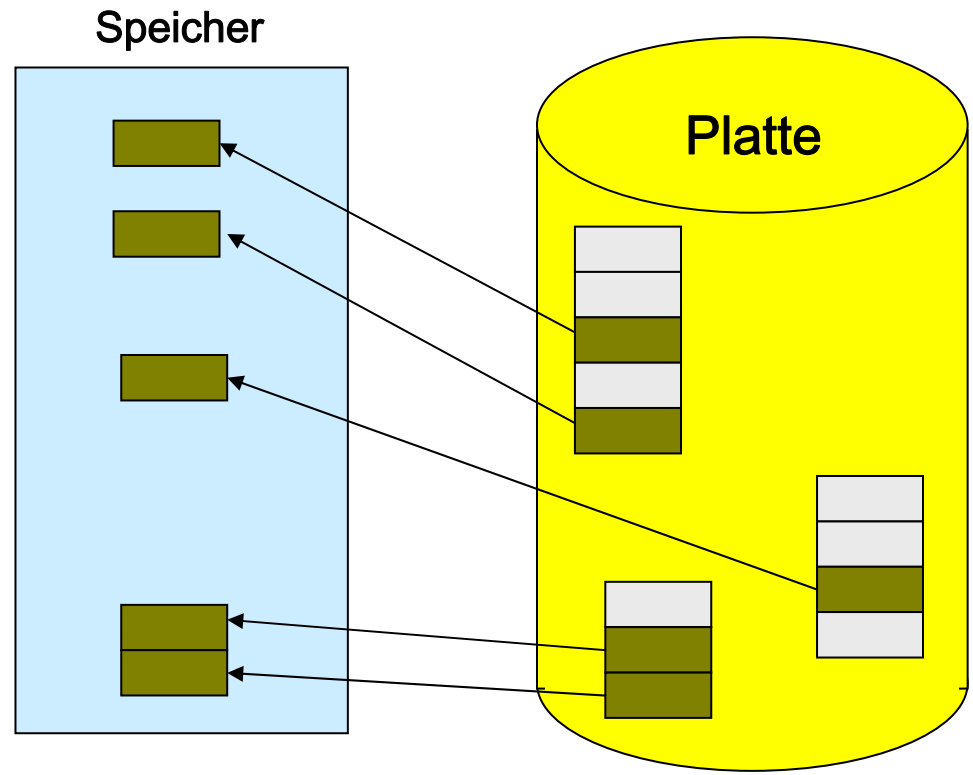

Konsistenz des Dateisystems

nach einem Crash...

Erstes Ziel: Erhaltung der Konsistenz von Meta-Daten,
d.h. alle Datenstrukturen die bei die Verwaltung
des Dateisystems benötigt werden.
Z.b. i-nodes, Verzeichnisse, Freilisten.

Ausnutzen der Redundanz bei der Organisation von Dateisystemen.

Normalerweise nicht berücksichtigt: Modifikation von Daten.
Sie sind verloren.

Berücksichtigt werden:

1. vermisste oder duplizierte Blöcke

2. Verzeichnisstrukturen

Konsistenz des Dateisystems

Vermisste oder duplizierte Blöcke: fsck

1. geht durch alle i-nodes, generiert die Liste der benutzten Blöcke
2. gleicht sie mit der Liste oder der Bit-Matrix freier Blöcke ab

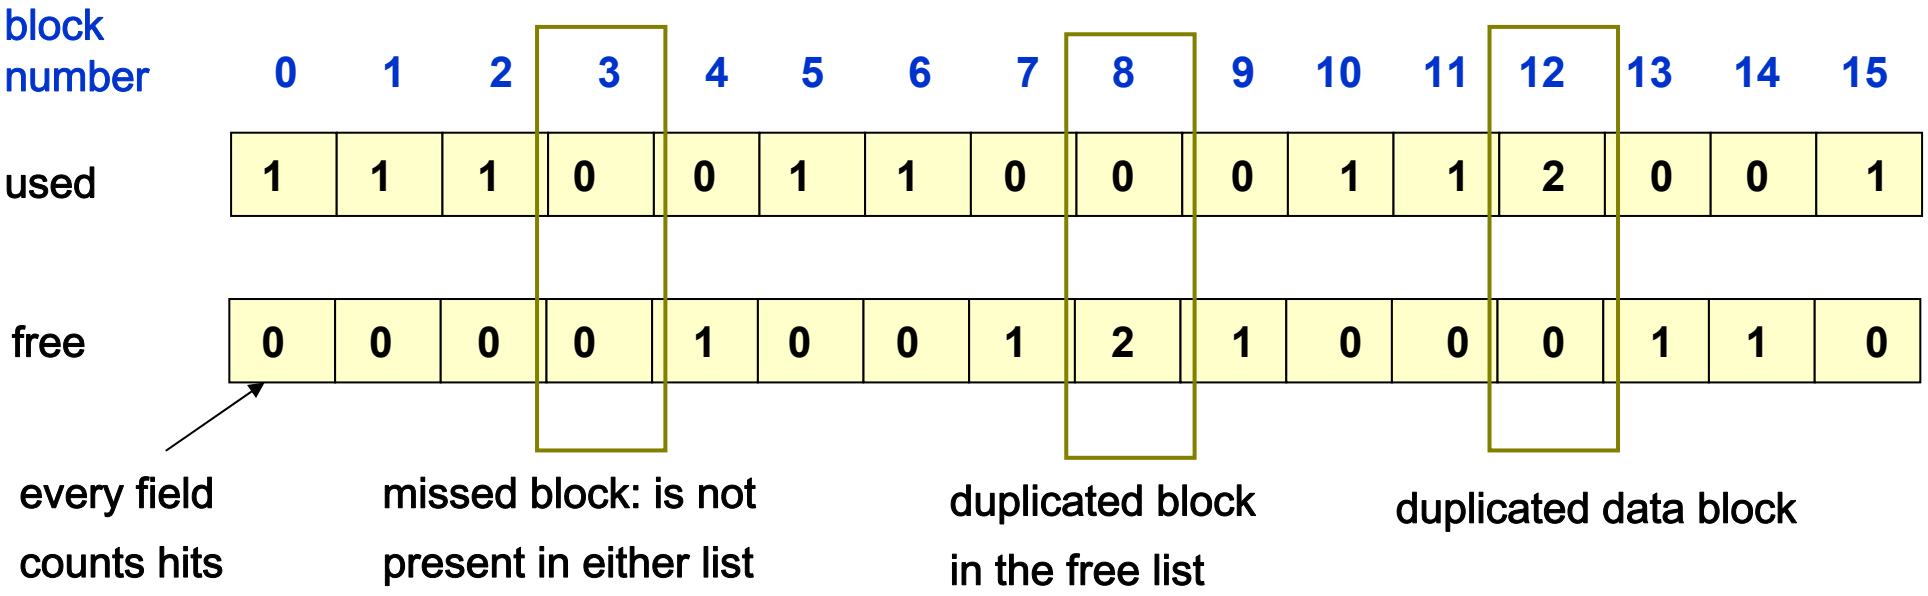

Konsistenz des Dateisystems

1. Fall: Vermisster Block

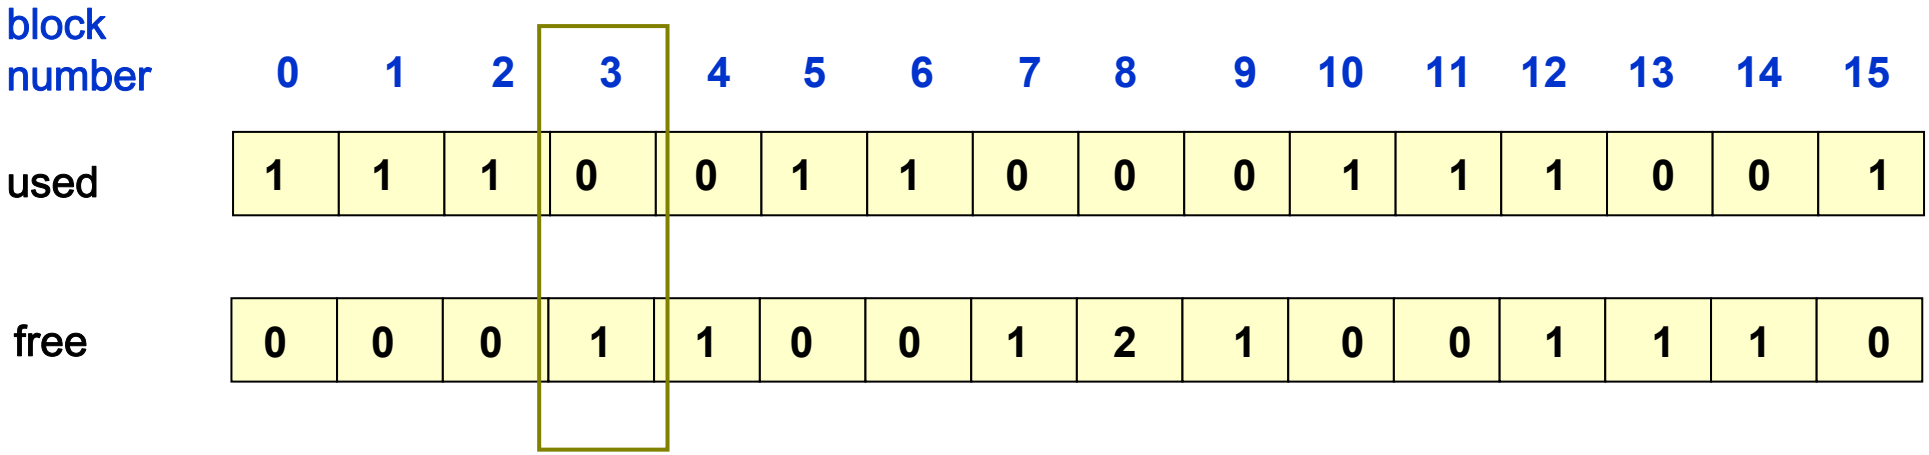

Problem: verminderte Plattenkapazität

Lösung: Vermisster Block wird der Freiliste zugeordnet

Konsistenz des Dateisystems

Fall 2: Duplizierte Blöcke in der Freiliste

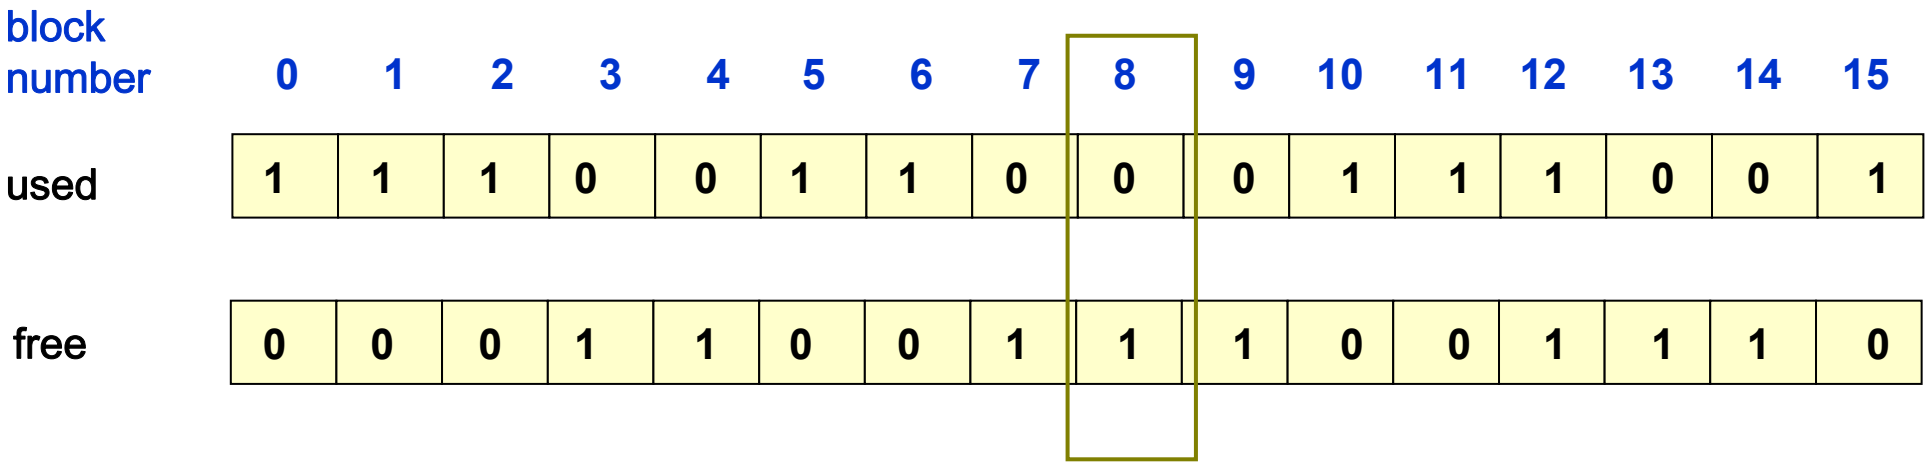

Lösung: Erneuter Aufbau der Freiliste und Löschen des Blocks

Konsistenz des Dateisystems

Fall 3: Duplizierter Block, d.h. der Block erscheint in mehreren Dateien

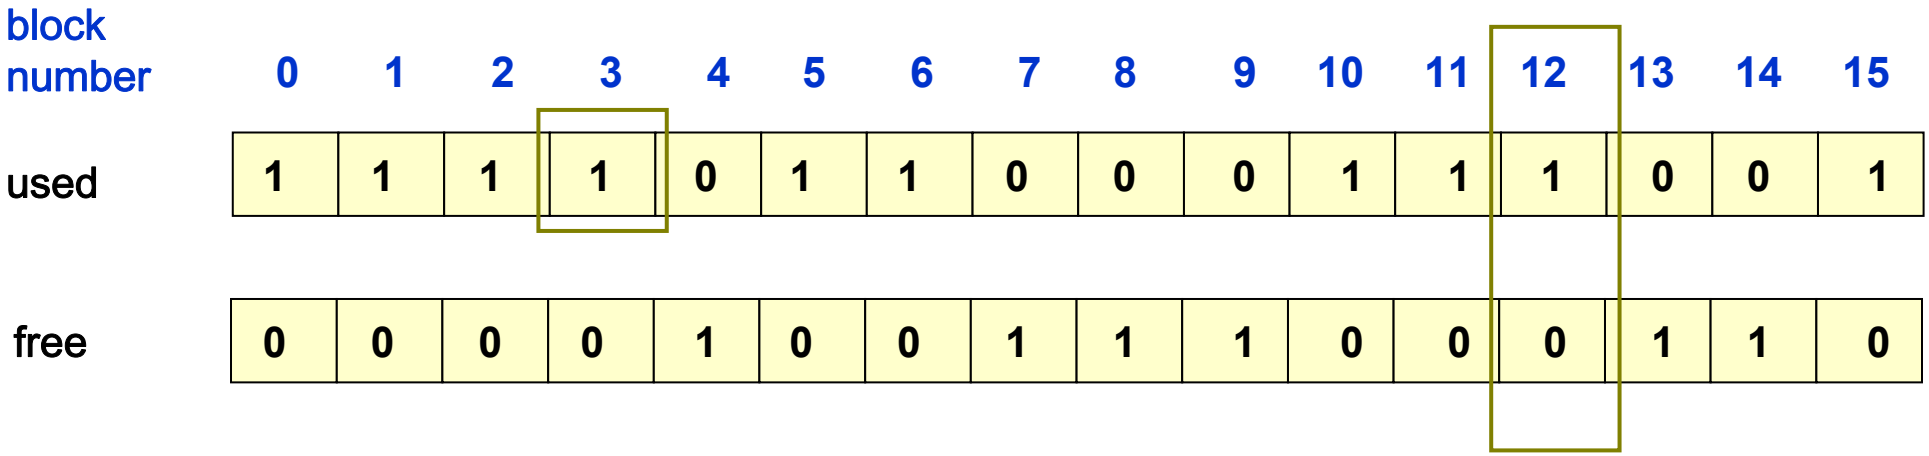

Problem: Einfaches Löschen resultiert in weiteren Inkonsistenzen.

Lösung: Kopieren eines Blocks in einen freien Block und Aktualisierung der Listen

Überprüfung des Verzeichnissystems

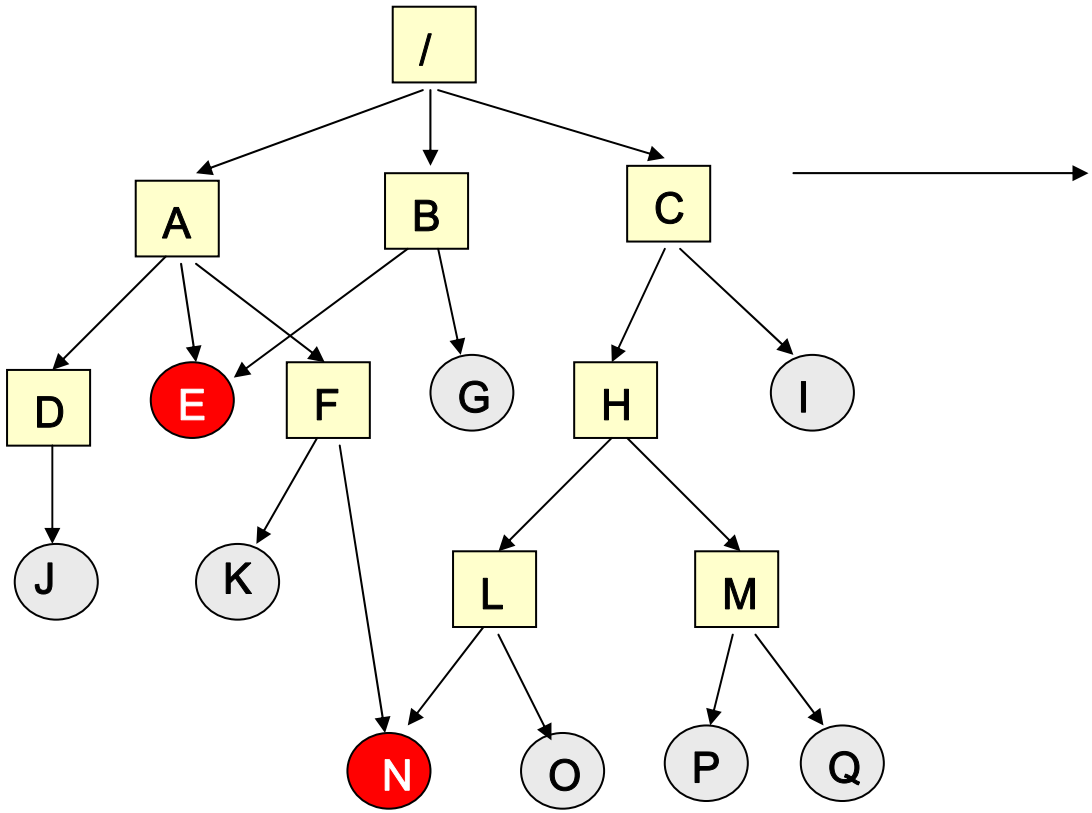

i-node # A	count=1
i-node # B	count=1
i-node # C	count=2
i-node # N	count=3
i-node # E	count=1
i-node # Q	count=1

Zähler zu hoch

Zähler zu niedrig

1. Schritt: Durchwandern des Dateisystems. Dabei Aufbau einer Liste die durch i-node Nummern indiziert wird. Zählen des Auftretens einer Datei in jedem Verzeichnis.
2. Schritt: Vergleichen der Liste mit den Zählerständen in den i-node-Einträgen für die Dateien.

Überprüfung des Verzeichnissystems

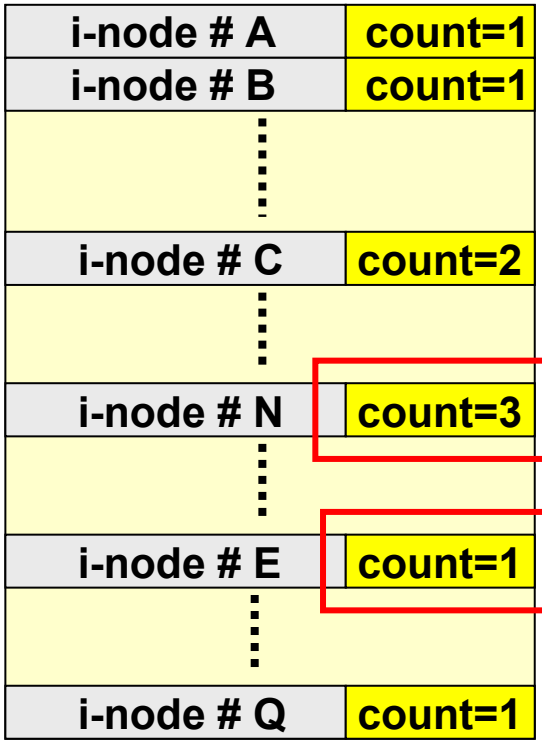

unkritisch: i-node bleibt bestehen, sogar wenn alle Dateien des Verzeichnisses gelöscht sind.

→ ein Effizienzproblem !

link Zähler im i-node
ist höher als der aktuelle Zähler in der aufgebauten Liste.

link Zähler im i-node
ist niedriger als der aktuelle Zähler in der aufgebauten Liste.

kritisch: i-node wird gelöscht, auch wenn noch ein Verweis zu einer Datei in einem Verzeichnis besteht. Wenn der Zähler auf "0" geht, würde der i-node als frei gekennzeichnet und die assoziierten Blöcke werden freigegeben.

Consistency of a file system

A consistent state of the file system has the following properties:

- The number of directory entries that point to an i-node exactly equals a link count in the i-node.
- Each disk block belongs to, at most, one file (one pointer in an i-node or in an indirect block).
- Each block is contained exactly once in either the list of free blocks or the list of used blocks.

Problems with recovery in large file systems

The system must scan all of the meta-data structures of the entire file system on disk to restore a consistent state. Thus, recovery time is related to file system size.

File systems grow dramatically and hence recovery time reaches the order of hours (or even days).

Idea: Relate the recovery effort to the last few operations before the crash which may have caused an inconsistent state.

Consequence: We have to know which operations occured before a crash.
Need a logging facility.

Log structured file systems

Motivation:

CPU performance
disk capacity
main memory capacity
} grow rapidly

Problem: disk access time doesn't improve much (seek ~10ms, wait ~4ms, write 50µs).

- ➡ **read accesses can be optimized through caching.**
- ➡ **write accesses will be the most frequent operation (to disk!).**
- ➡ **write acces to disk becomes a substantial bottleneck.**

idea: collect all changes to disk blocks and write them in a single segment to disk.
The resulting data structure is called a "log".

Journaling (logging) file system

Journaling file systems use data base techniques to secure sequences of operations:

Motivation: Long recovery times (log operations on meta-data)
Data loss (log operations on all data)

- all changes on metadata are written to a serial log,
- a serial log is a persistent data structure which survives crashes,
- efficiency can be traded against data loss,
- usually only meta-data are written to the log,
- recovery effort is related to the amount of log data rather than to total file system size.

Examples: IBM JFS, Veritas, Sprite LFS, MAC OS X, XFS (Open Source, developed by Silicon Graphics)

Log structured file systems

Creating files in a conventional file system (FFS):

creating:
/dir/F1 and
/dir/F2

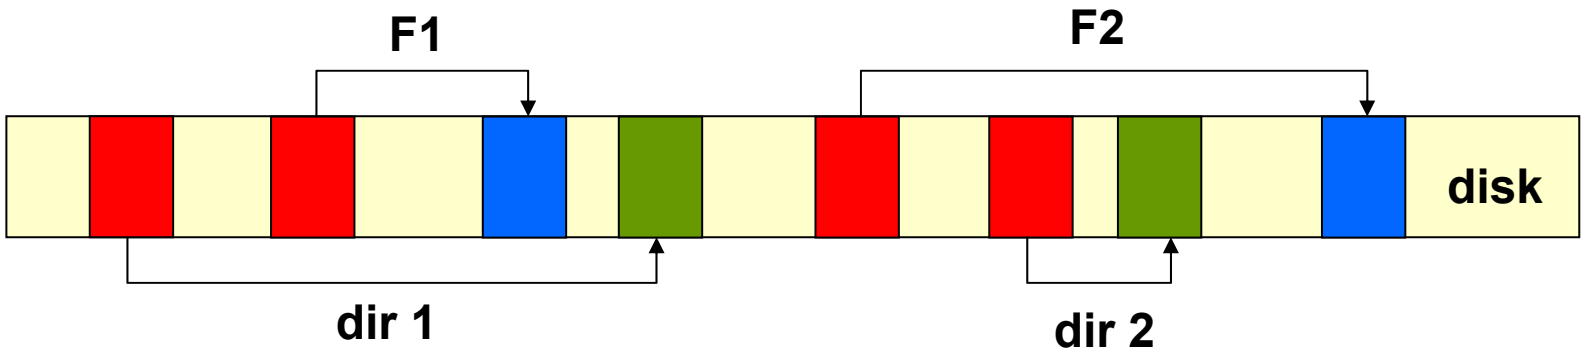

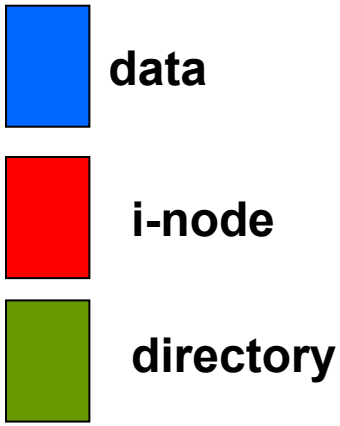

FFS:

FFS requires 10 non-sequential writes preceeded by a seek. (I-nodes for new files are written twice to ease recovery)

Log structured file systems

creating:
/dir/F1 and
/dir/F2

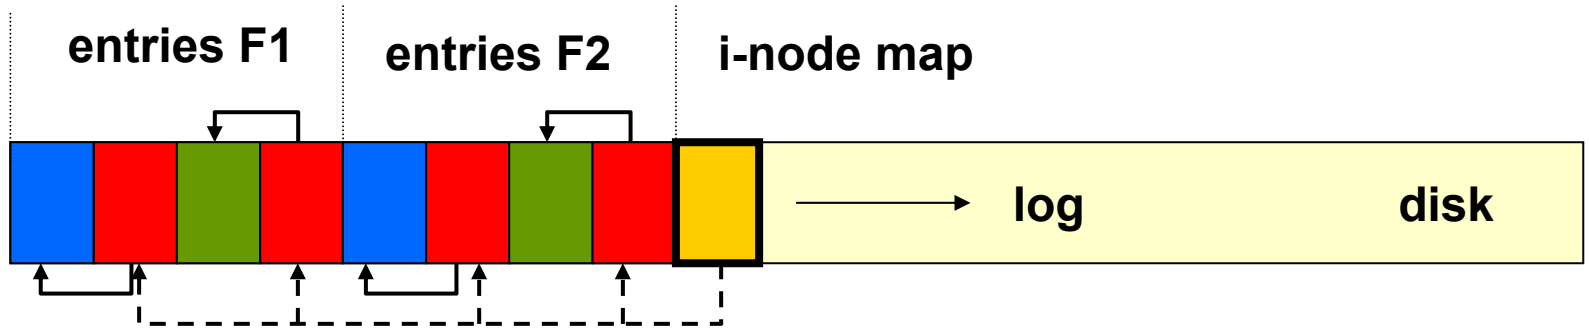

data

i-node

directory

i-node map

LFS:

new data and metadata is written in a single large write.

Log structured file systems

Traditional file systems:

achieve LOGICAL LOCALITY assuming certain access patterns and organize information optimally for certain read patterns. LOGICAL LOCALITY pays in the writing process to organize information appropriately.

Log-structured file systems:

achieve TEMPORAL LOCALITY info which is created or modified at the same time is grouped closely on disk. TEMPORAL LOCALITY pays in the reading process. This however can be moderated by caching.

Log structured file systems

Problem: No infinite disk! ➡ **Free space management is needed.**

Free space management alternatives for log-structured file systems:

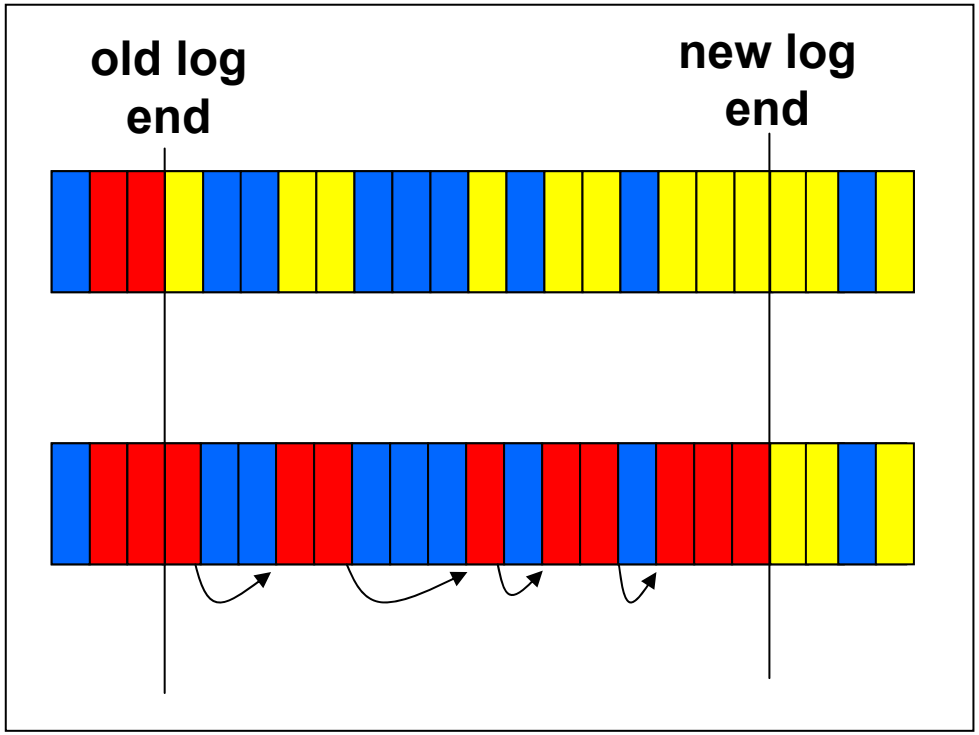

threaded log

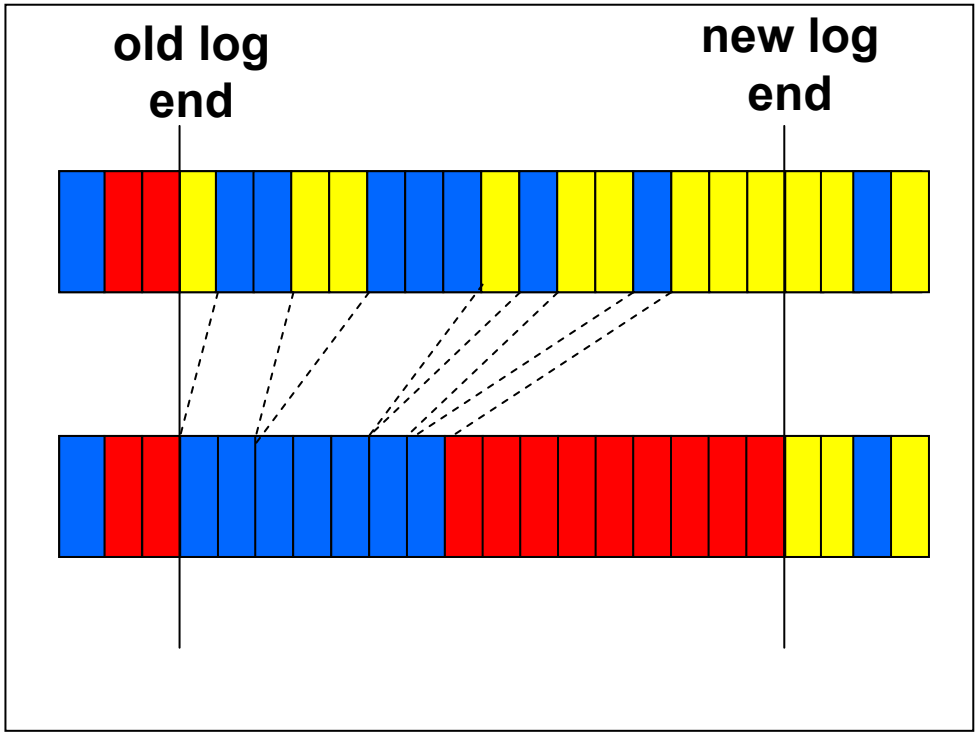

copy and compact log

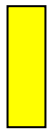

free blocks

Log structured file systems

Problems with "Threading":

Over time the log becomes fragmented and the benefits are lost

Problems with "Copy and Compact" in a circular log:

Long-lived files have to be copied in every pass of the log across the disk.

Combine threading and copying.

Log-structured File System (LFS)

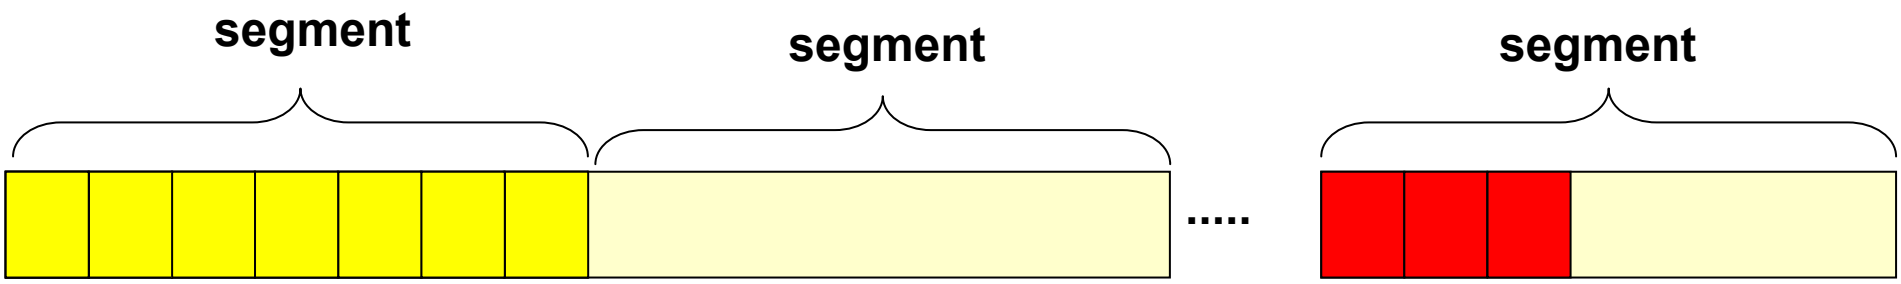

segments: - large number of fixed size contiguous blocks

- transfer time for read and write of the whole segment is large compared to the cost of a seek to the beginning of the segment. (LFS segment size 512k or 1M)

Segmented structure allows a combination of threading and copying.

- All segment are written sequentially from the beginning to the end.
- Before a segment can be rewritten all "live" data must be copied out
- Long-lived data is collected together in segments which are skipped over.

Recovery in LFS

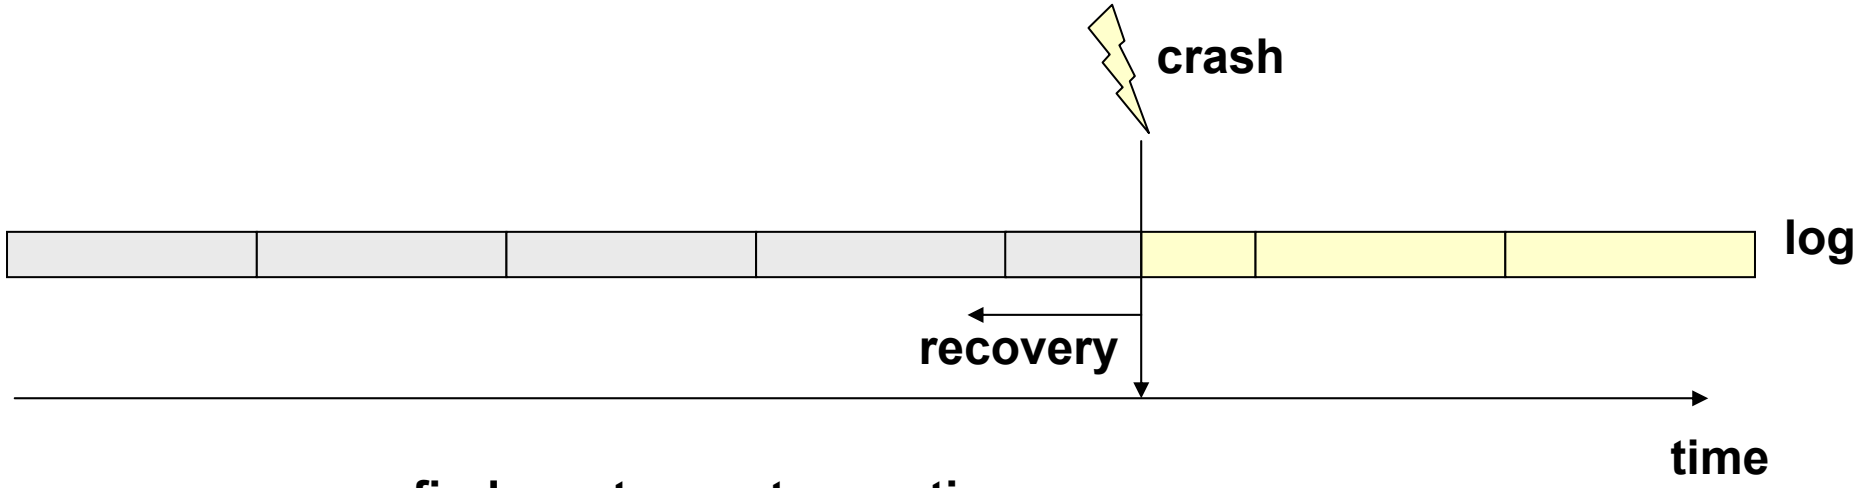

find most recent operations
which may have left the file
system in an inconsistent state

Problem: How far to go back?

Log-structured File System (LFS)

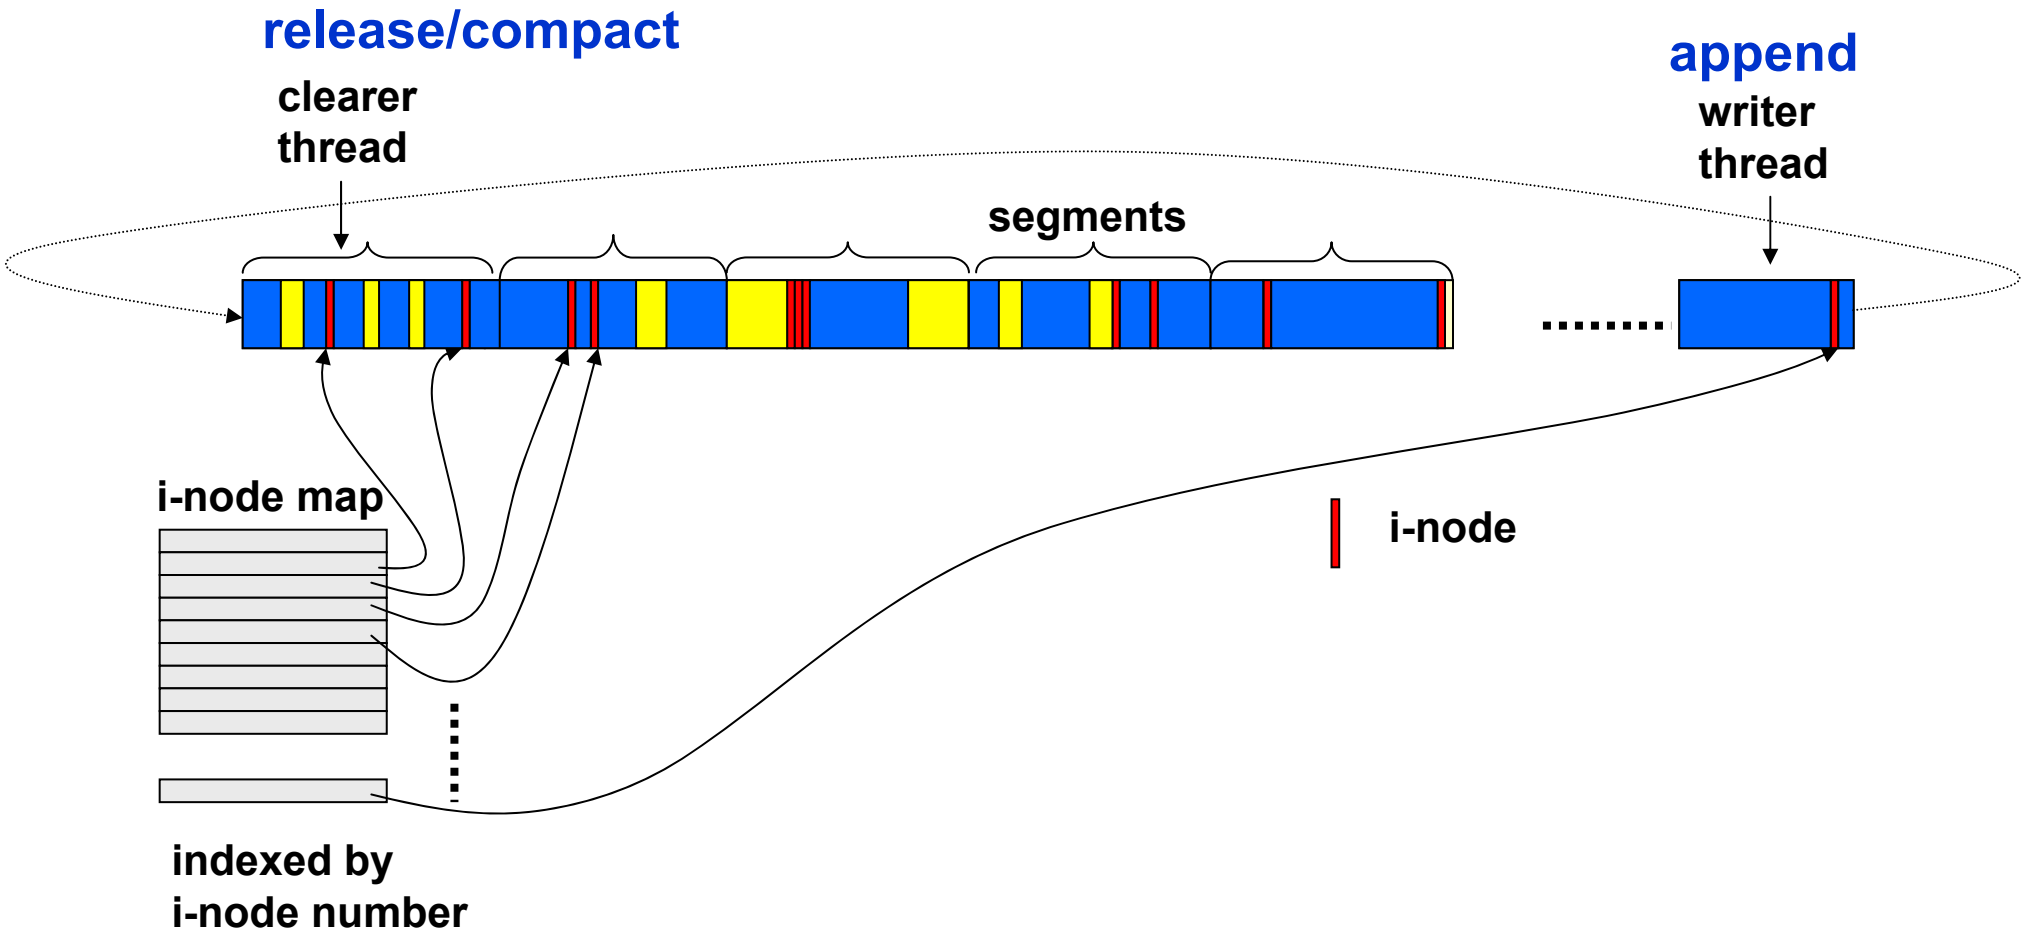

Recovery in LFS

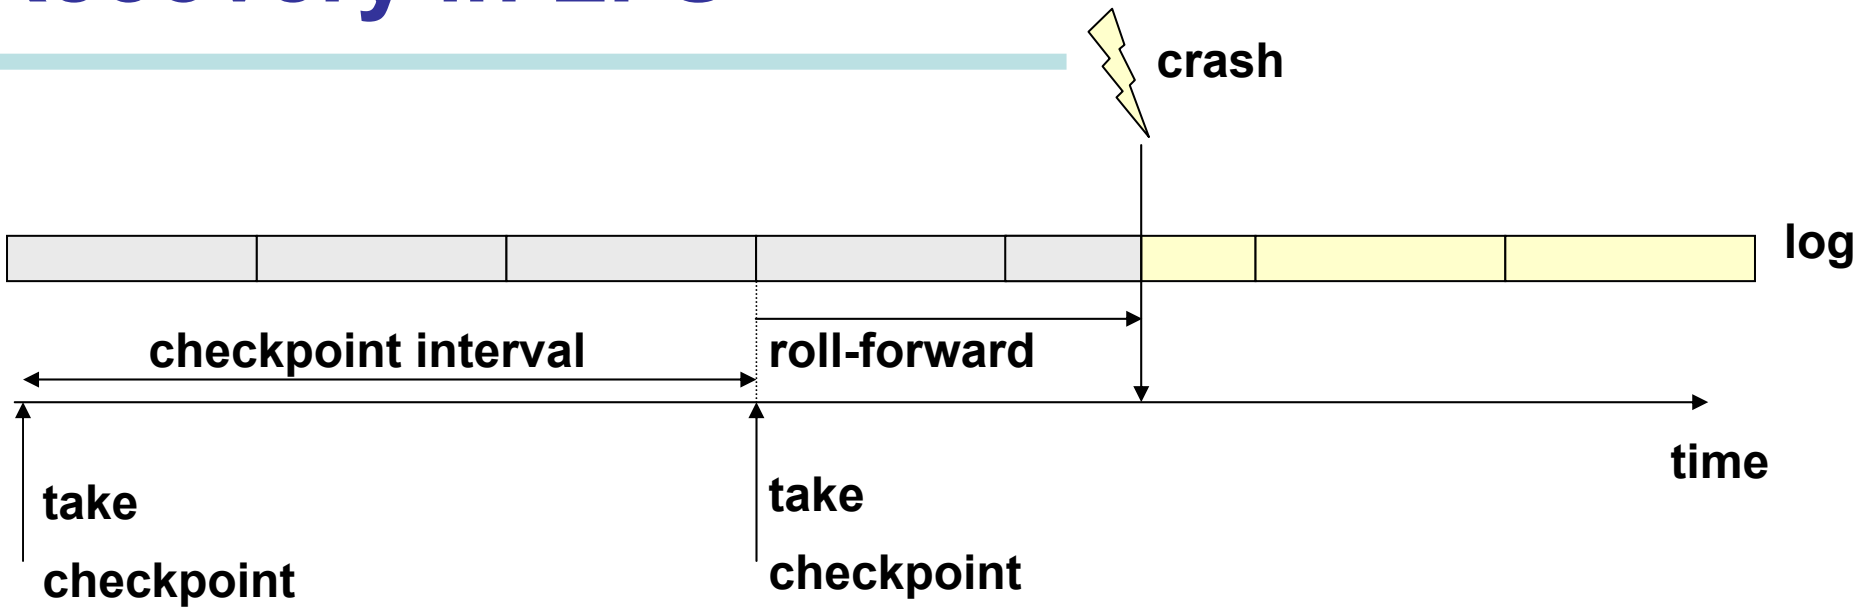

- checkpoint regions are kept in special fixed positions on disk
- checkpoint region contains:
  - addr. of all blocks in the i-node map
  - segment usage tables
  - current time and pointer to last segment written

Log-structured File System (LFS)

- segments are written periodically or on demand
- more overhead for finding information
- much better performance than regular UNIX file system on writing small amounts of data
- better or similar as ordinary UNIX file system for reads and writing large portions of data

Log-structured File System (LFS)

performance comparison: small file performance

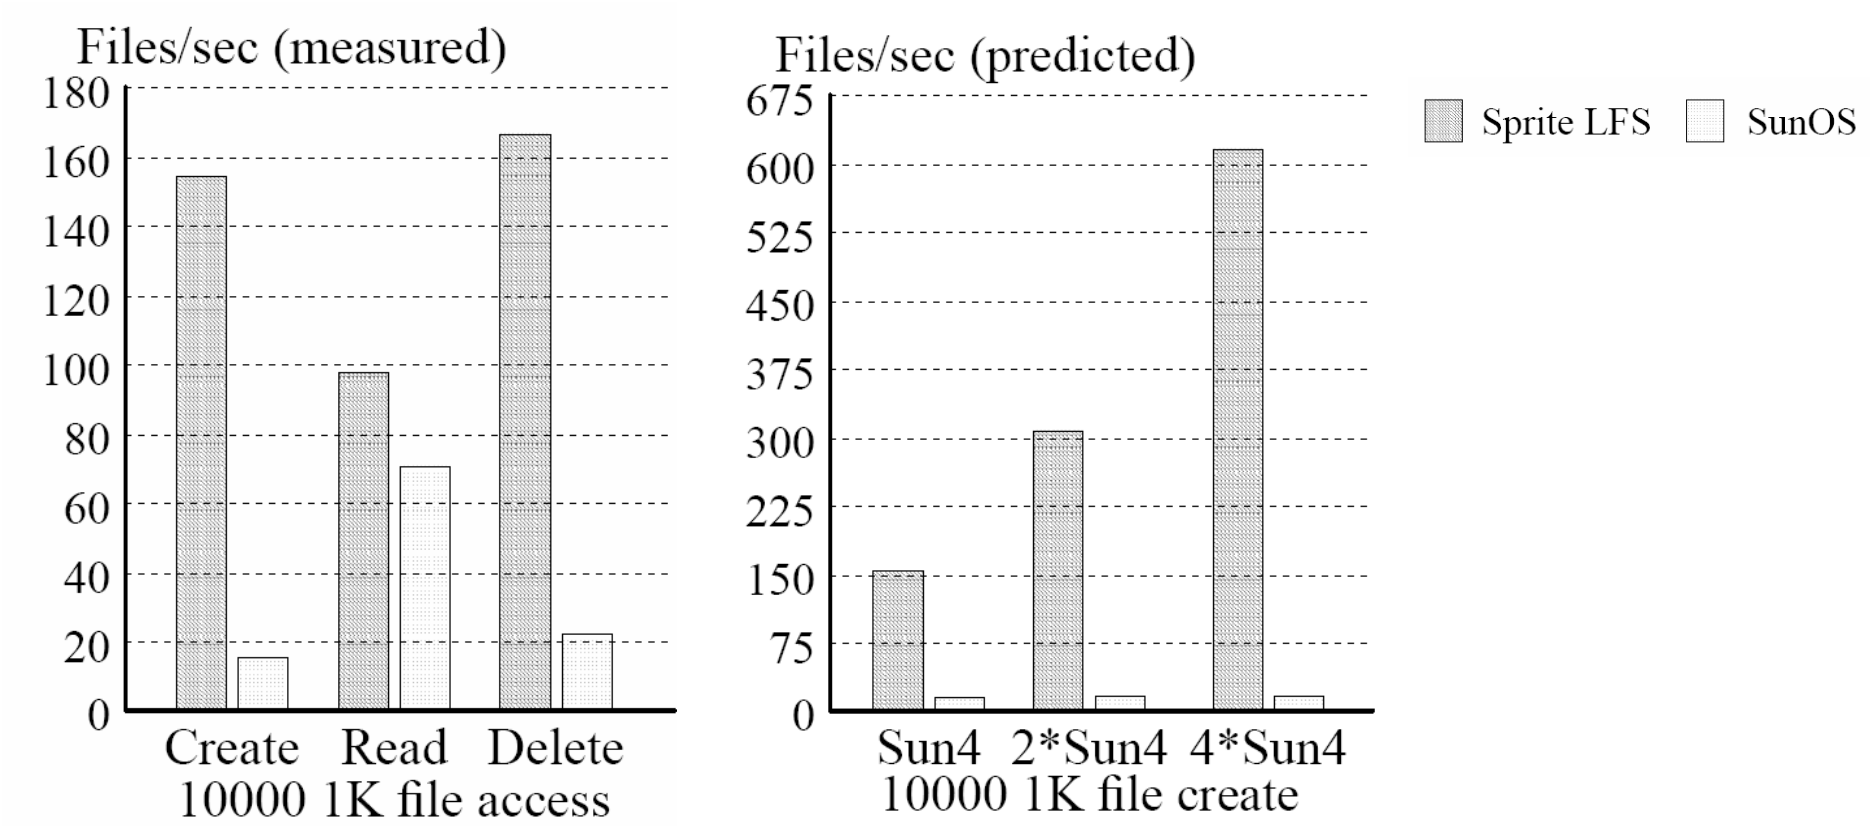

Mendel Rosenblum, John K. Ousterhout: The Design and Implementation of a Log-Structured File System, ACM Transactions on Computer Systems, 1991

Log-structured File System (LFS)

performance comparison: large file performance

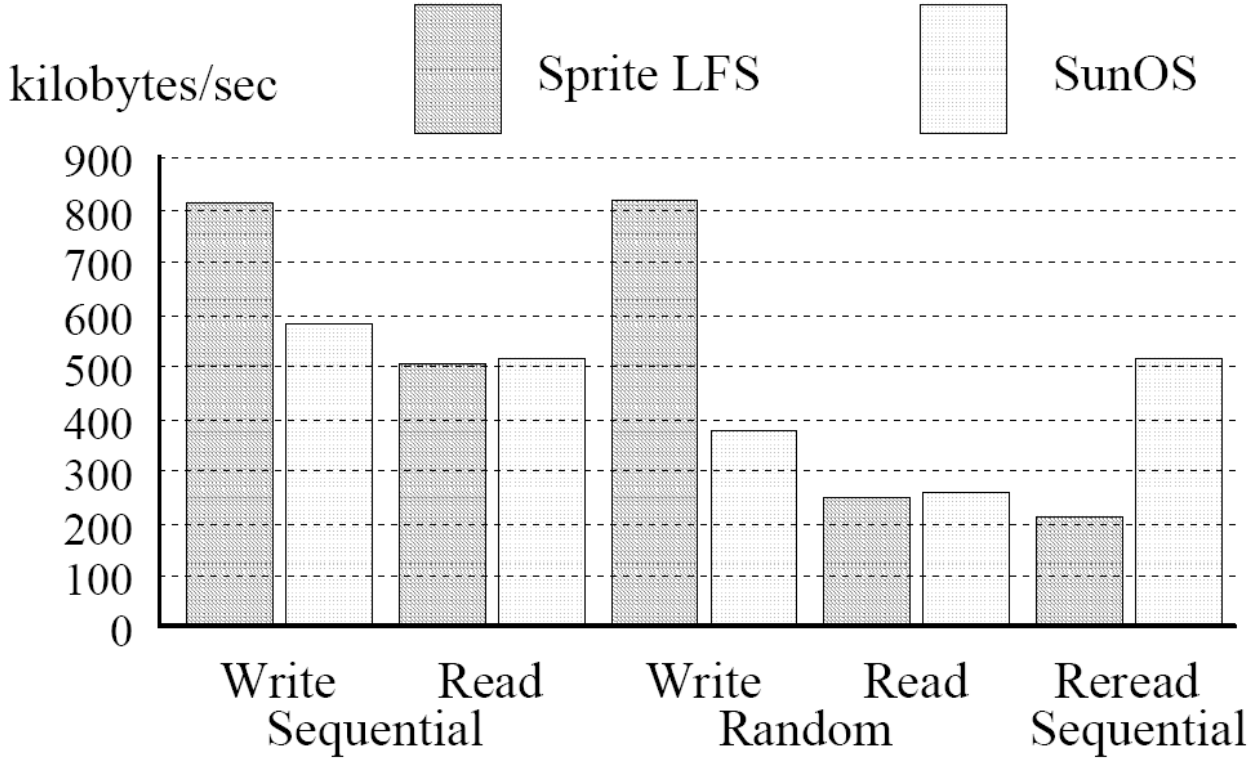

Mendel Rosenblum, John K. Ousterhout: The Design and Implementation of a Log-Structured File System, ACM Transactions on Computer Systems, 1991

Characteristics of Journaling File Systems

	Ext3	ReiserFS	XFS	JFS	OSX
Largest block size supported	4 Kb	4 Kb	4 Kb	4 Kb	32 Kb
File size maximum	2 Tb	1 Eb	9 EB	4 Pb	16 Tb
Growing the file system size	Patch	Yes	Yes	Yes	No
Access Control Lists	Patch	No	Yes	Yes*	No
Dynamic disk inode allocation	No	Yes	Yes	Yes	Yes
Data logging	Yes	No	No	No	No
Place log on an external device	Yes	Yes	Yes	Yes	No

Tb = Terabyte, or 1024 Gigabytes = 10^{12} bytes

Pb = Petabyte, or 10^{15} bytes,

Eb = Exabyte or 10^{18} bytes

From: http://www.backupbook.com/03Freezes_and_Crashes/02Journaling.html

Lernziele

- Allgemeine Struktur eines Dateisystems
  - Organisation der Dateien
  - Organisation der Verzeichnisse
  - Zugriff zu Dateien und Verzeichnissen
- Organisation der Platte
  - Blockstruktur der Platte
  - Abbildung von Dateien und Verzeichnissen
  - gemeinsame Nutzung von Dateien
- Verwaltung der Platte auf Blockebene
- Verbessern der Leistung von Dateisystemen
- Zuverlässigkeit und Konsistenz von Dateisystemen