

GRABS: Grundlagen der Rechnerarchitektur und Betriebssysteme

Vorlesung 14: Persistente Speicherung – Dateisysteme

Michael Engel (michael.engel@uni-bamberg.de)


Lehrstuhl für Praktische Informatik, insbes. Systemnahe Programmierung


<https://www.uni-bamberg.de/sysnap>

Literatur:

Arpaci-Dusseau [1]
Kap. 39–40


- Bisher haben wir betrachtet:
 - Prozessor (CPU)
 - Hauptspeicher
 - I/O-Geräte
 - Blockorientierte Geräte
- Heute:
"Hintergrundspeicher"






Dateisysteme ermöglichen die **dauerhafte Speicherung** großer Datenmengen

Abbildung



Das Betriebssystem stellt den Anwendungen eine **logische Sicht** bereit und muss diese effizient implementieren



- Unix-Prinzip: "*alles ist eine Datei*"
 - Genaugenommen: jede Ressource im System kann über einen *Namen* in einer Verzeichnishierarchie angesprochen werden
 - Zugriffe auf die Ressource erfolgen durch die bekannten Unix-Systemaufrufe für Dateizugriff
 - Zugriffsrechte kontrollieren den Zugriff auf die Ressourcen
- Beispiele:
 - Reguläre Dateien und Verzeichnisse
 - Spezialdateien für Geräte, symbolische Links, *named pipes*
 - Virtuelle Dateien mit Prozess- und Systeminformationen
- In Unix nicht vollständig konsistent, aber z.B. in Plan 9:
 - Netzwerkverbindungen und -protokolle
 - Zugriff auf den Grafikspeicher


- Dateien werden über prozesslokale Dateideskriptoren (*file descriptors*) angesprochen
 - positive Ganzzahl, kann neu zugewiesen werden
- Die Unix-API zum Dateizugriff besteht aus vier Systemaufrufen:
- `int open(const char *path, int oflag, ...);`
 - Versucht, die Datei mit dem angegebenen Pfadnamen `path` mit dem Zugriffsmodus `flags` (read only, read/write etc.) zu öffnen
 - Gibt bei Erfolg **file descriptor** (fd) zur Verwendung bei Dateizugriffen zurück
- `ssize_t read(int fd, void *buf, size_t nbyte);`
- `ssize_t write(int fd, const void *buf, size_t nbyte);`
 - Liest (schreibt) `nbyte` Bytes von (in) Datei `fd` in (aus) dem Speicher beginnend an Userspace-Speicheradresse `buf`
- `int close(int fildes);`
 - Schließt die Datei: leert alle Puffer und invalidiert Dateideskriptor

Der Unix virtual file system (VFS) switch

Universität Bamberg



- **Systemweiter Namensraum für Dateien**



Virtual file system: mounting

Systemaufruf:

```
int mount(const char *source, const char
    *target, const char *filesystemtype,
    unsigned long mountflags, const void *data);
```


Verbindet ("mounted") ein Dateisystem mit dem angegebenen Verzeichnis in der Verzeichnishierarchie

Systemaufruf:

```
int umount(const char *target);
```


Löst die Verbindung. *Achtung: **umount**, nicht unmount!*

Verwendung dieser Systemaufrufe
nur mit
Systemadministrator-Privilegien!



Beim Booten des Systems
werden alle in **/etc/fstab**
gelisteten Dateisysteme
automatisch gemounted

- Meist benötigen Dateien mehrere Blöcke
 - Eine Platte wird hier als großes Array von Blöcken betrachtet
 - Jeder Block hat identische Größe, z.B. 512 Bytes
 - Dies ist eine *Abstraction* von Köpfen, Spuren und Sektoren einer realen Festplatte
 - In welchen Blöcken soll eine Datei gespeichert werden?




- Dateien werden in Blöcken mit aufeinanderfolgenden Blocknummern gespeichert
 - Benötigt Information über den StartBlock und die Anzahl an Folgeblöcken, z.B. Start: Block 2, Länge: 3 Blöcke



- Vorteil:
 - Zugriff auf alle Blocks mit minimaler Verzögerung durch Positionierung des Festplattenarms
 - Schneller direkter Zugriff auf beliebige Dateiposition
 - Verwendet für nur-lese-Dateisysteme, z.B. CD-ROM/DVD

- **Finden von freiem Speicher** auf der Festplatte
 - notwendig: ausreichend große Menge zusammenhängender Blöcke
- **Fragmentierung**
 - Freie Blöcke können nicht genutzt werden, wenn die zusammenhängende Menge zu klein für eine Datei ist
- Die **Größe neuer Dateien** ist meist nicht im Voraus bekannt
 - **Erweitern** (Größe erhöhen) einer Datei ist problematisch, falls die folgenden Blöcke schon belegt sind
 - Erfordert **Umkopieren von Daten**, falls nicht genügend freie Folgeblöcke vorhanden sind


- Blöcke einer Datei sind verlinkt



- z.B. bei Commodore-Diskettenlaufwerken (C64/VC1514 usw.)
 - Blockgröße 256 Bytes
 - Erste zwei Bytes: Spur- und Sektornr. des Folgeblocks
 - Falls Spurnummer = 0 → letzter Block
 - 254 Byte Nutzdaten
- Dateien können vergrößert und verkleinert werden

- Verfügbarer Speicherplatz verringert um den **für Zeiger benötigten Speicher**
 - Problematisch bei Verwendung von seitenbasiertem virtuellen Speicher: eine Seite benötigt dann immer Teile zweier Blöcke
- **Fehleranfällig**
 - Eine Datei kann nicht vollständig wiederhergestellt werden, wenn die Zeigerinformation Fehler enthält
- **Direkter Zugriff** auf beliebige Dateipositionen ist schwierig
- Erfordert **dauernde Repositionierung** des Festplattenkopfes, wenn Dateiblöcke über die Platte verteilt sind

- Links sind in separaten Blöcken gespeichert
 - FAT: *file allocation table* (zuerst in MS-DOS verwendet)



Blocks of the file: 3, 8, 1, 9




- Vorteile:
 - Alle Bytes eines Datenblocks sind Nutzdaten
 - Redundante Speicherung der FAT ist möglich
 - Nützlich im Fehlerfall

- **Zusätzliches Laden** mindestens eines Blocks notwendig
 - Es ist möglich, die FAT zur Effizienzsteigerung zu cachen
- **Nicht genutzte Information wird geladen**
 - FAT enthält Links für *alle Dateien*
- **Suchoverhead** für den Datenblock innerhalb einer Datei, der gesuchte Information enthält
- **Dauernde Repositionierung** des Festplattenkopfes notwendig, wenn Datenblöcke über die Festplatte verteilt sind

- Variation:
 - Aufteilen einer Datei in Folge von Blöcken, die zusammenhängend gespeichert werden (*chunk*, *extent* oder *cluster* genannt)
 - Reduziert die Anzahl an Positionierungsvorgängen
 - Verbessert die Geschwindigkeit für die Suche eines Blocks linear
 - abhängig von der *chunk*-Größe
- Probleme:
 - Zusätzliche Information benötigt, um *chunks* zu verwalten
 - Fragmentierung
 - feste Größe: innerhalb einer **Folge (interne Fragmentierung)**
 - variable Größe: außerhalb von **Folgen (externe Fragment.)**
- Wird in der Praxis verwendet, hat aber keine bedeutenden Vorteile


- Ein spezieller Block enthält Blocknummern der Datenblöcke einer Datei:



- Problem:
 - Feste Anzahl an Blöcken im Index-Block
 - Fragmentierung für kleine Dateien
 - Erweiterungen notwendig für große Dateien


Indexierter Speicher: Unix *inodes*

Universität Bamberg




- Verwendung mehrere Indexebenen:
 - inodes benötigen immer einen Block auf der Festplatte (Fragmentierung ist kein Problem bei kleinen Dateien)
 - Mehrere Index-Ebenen ermöglichen es, große Dateien zu verwalten
- Nachteil:
 - mehrere Blöcke müssen (für große Dateien) geladen werden

- In Datenbanken verwendet, um effizient Datensätze zu gegebenem Suchschlüssel zu finden
 - Schlüsselraum kann dünn besetzt sein
- Wird auch verwendet, um Teile (*chunks*) von Dateien mit bestimmter Dateiposition zu finden, z.B. bei NTFS, btrfs, IBM JFS2, Apple HFS+ (B+ tree)



- **Bitvektoren** zeigen für jeden Block an, ob er benutzt ist oder nicht
- **Verkettete Listen** bilden die freien Blöcke ab
 - Verkettungsinformation oft in den freien Blöcken selbst gespeichert
 - Optimierung: Information über freie Block werden an zentraler Stelle gespeichert
 - Optimierung: ein freier Block enthält viele Blocknummern zusätzlicher freier Blöcke und evtl. auch die Blocknummer eines Blocks mit Information zu weiteren freien Blöcken


Freiblockliste mit Referenzen



Freie Blöcke


- Einträge identischer Länge nacheinander in Liste gespeichert:

FAT32:




Lange Dateinamen in VFAT verwenden mehrere Verzeichniseinträge

Unix System V 3.2:




- Probleme:
 - Lineare Suche nach gegebenem Eintrag notwendig
 - Wenn Liste sortiert ist: schnelle Suche, aber aufwändiges Einfügen

- Funktion bildet Dateinamen auf Index in der Verzeichnisliste ab
- Ermöglicht schnelleren Zugriff auf den Eintrag
 - keine lineare Suche notwendig
- Einfaches (aber schlechtes...) Beispiel: $(\sum \text{ASCII-Zeichenwerte}) \bmod N$




- Probleme:
 - Hash-Kollisionen (mehrere Dateinamen auf selben Eintrag abgebildet)
 - Anpassung der Listengröße notwendig, wenn Liste voll ist

- Beispiel: verwendet in 4.2 BSD, System V Rel. 4 usw.




- Probleme:
 - Verwaltung freier Listeneinträge
 - Fragmentierung (Kompaktierung erforderlich)

- Blockorganisation



- Bootblock:** enthält Informationen, um das OS zu laden
- Superblock:** enthält Verwaltungsdaten des Dateisystems:
 - Anzahl an Blöcken und ***inodes***
 - Anzahl an und Liste von freien Blöcken und inodes
 - Attribute (z.B. Angabe, ob das Dateisystem modifiziert wurde)

- Blockorganisation (verwendet ab 4.2 BSD Unix)



- Eine Kopie des Superblocks wird in jeder Zylindergruppe gespeichert
- Eine Datei wird, wenn möglich, innerhalb einer einzelnen Zylindergruppe gespeichert
- Verzeichnisse sind verteilt, Dateien eines Verzeichnisses werden zusammen gespeichert
- Vorteil: reduzierte Positionierungsdauer

Dateisysteme sind eine **Betriebssystemabstraktion**

- Logisch zusammenhängende Informationen werden als Datei repräsentiert und gespeichert
- Oft wird eine hierarchische Verzeichnisstruktur zur Organisation von Daten verwendet

... werden **von der Hardware beeinflusst**

- Minimierung der Positionierungsdauer für Festplatten
- *Wear levelling* für Flash-Speicher

... werden **von Anwendungsprofilen beeinflusst**

- Blockgröße
 - zu klein → management data structures can lead to *performance loss*
 - zu groß → Fragmentierung verschwendet Plattenplatz
- Struktur von Verzeichnissen
 - ohne Hashfunktion → lang dauernde Suchen
 - mit Hashfunktion → höherer Verwaltungsaufwand

- [1] Karels, M.; M. K. McKusick (September 1986).
Towards a Compatible File System Interface.
Proceedings of the European UNIX Users Group Meeting,
Manchester, England: EUUG. pp. 481–496
- [2] Apple Inc. **Inside Macintosh Volume 2: Files.**
- [3] Maurice J. Bach.
Design of the UNIX Operating System.
Prentice Hall 1986, ISBN 978-0132017992
- [4] Marshall Kirk McKusick, William Joy, Samuel Leffler and Robert Fabry.
A Fast File System for UNIX
ACM Transactions on Computer Systems. 2 (3): 181–197, 1984
- [5] R. Card, T. Y. Ts'o, and S. Tweedie.
Design and implementation of the second extended filesystem
Proceedings of the 1994 Amsterdam Linux Conference, 1994.