


# Betriebssysteme

## Dateisysteme



# Themenübersicht



# Themenübersicht

- FS als API
- Terminologie
- Management

## Grundlagen

- Grundidee
- API-Typen
- Laufzeitsicht
- Dateisysteme registrieren
- Strukturen
  - Superblock
  - Inode
  - Dentry
  - File


## VFS

- Minix
- FAT-Dateisysteme
- ext-Dateisysteme
- Journaling
- Extents
- Copy-On-Write

## Dateisysteme

# Dateisystem als API

- Dateisystem
  - Hierarchische Organisationsstruktur für Dateien auf Datenspeichern
  - Dateien sind zusammengehörende Dateninhalte
- Dateisystem verwaltet
  - Dateinamen
  - Attribute (Metadaten)
- Dateisystem dient als
  - API des Betriebssystems
  - Dateinamen als Schnittstelle
- Wichtige Eigenschaften
  - Geschwindigkeit
  - Geringer Verschnitt



# Hardware

- Dateisysteme adressieren Cluster
  - Jede Datei belegt eine ganzzahlige Menge an Clustern
  - Alternativbegriffe: Zonen oder Blöcke
  - Achtung: Sektoren von Festplatten werden auch manchmal Blöcke genannt
- Größe der Cluster
  - Abhängig vom Dateisystem und von Konfiguration
  - Beeinflusst Effizienz des Dateisystems
    - Steigender Verwaltungsaufwand für große Dateien
    - Abnehmender Kapazitätsverlust durch interne Fragmentierung
  - Wird beim Anlegen des Dateisystems festgelegt

## Hinweis

Unter Linux wird empfohlen die Page-Size des Speichers bei der Wahl der Clustergröße zu berücksichtigen, damit Cluster effizient in den Speicher abgebildet werden können.

# Kommandos

- Verwalten von Dateisystemen (Kommandozeile)
  - `mount [-t fs-type -o options] <device> <mount point>`
  - `umount <mount point>`
  - `mkfs.xxx`
  - `fsck.xxx`
- Beispiel zum Anlegen und Einbinden

## Terminal

```
> dd if=/dev/zero of=loop_fs.img bs=1M count=100
> mkfs.ext2 loop_fs.img
> mkdir /mnt/my-fs
> mount -o loop loop_fs.img /mnt/my-fs
...
> umount /mnt/my-fs/
```

# Linux-Dateisysteme

- Dateien und Verzeichnisse werden als **Inode** (Index Node) abgelegt
- Inode ...
  - ... enthält Metadaten
    - Dateigröße
    - UID/GID
    - Zugriffsrechte
    - Zugriffsdatum
  - ... hat eine eindeutige Inode-Nummer
- Datei-Inode verweist auf Cluster mit Dateiinhalt
- Verzeichnis-Inode enthält Namen und Inode-Nummern für Verzeichnisisinhalt

ext2/ext3 Beispiel


|           |       |
|-----------|-------|
| Dateiname | Inode |
| Dateiname | Inode |
| Dateiname | Inode |
| Dateiname | Inode |
| ...       | ...   |

Verzeichnis

|                                       |
|---------------------------------------|
| Dateityp                              |
| Zugriffsrechte                        |
| Besitzer                              |
| Größe                                 |
| Datum                                 |
| Gruppe                                |
| Anzahl der Links                      |
| Anzahl der Sektoren                   |
| Clusteradresse 1 (direkt)             |
| ...                                   |
| Clusteradresse 12 (direkt)            |
| Clusteradresse 13 (indirekt)          |
| Clusteradresse 14 (doppelt indirekt)  |
| Clusteradresse 15 (dreifach indirekt) |

Inode

# Beispiel ext2/ext3



# Themenübersicht

- FS als API
- Terminologie
- Management

## Grundlagen

- Grundidee
- API-Typen
- Laufzeitsicht
- Dateisysteme registrieren
- Strukturen
  - Superblock
  - Inode
  - Dentry
  - File

## VFS


- Minix
- FAT-Dateisysteme
- ext-Dateisysteme
- Journaling
- Extents
- Copy-On-Write

## Dateisysteme

# Grundidee

- Linux VFS verwendet Objektorientierung (in C)
- Betriebssystem bietet Systemaufrufe an
  - open, close
  - read, write
  - lseek, unlink, mkdir, rmdir, readdir
- Systemaufrufe sind generisch umgesetzt
  - Operieren auf generischen Datenstrukturen
  - Führen grundlegende Buchführung durch
  - Verwendet dateisystemspezifische Funktionen
- Linux bietet eine einfache Möglichkeit neue Dateisysteme zu implementieren.
  - Kernelmodul erstellen
  - Funktionen implementieren
  - Dateisystem registrieren
- Details

<https://git.fh-aachen.de/tb3838s/linux/-/blob/master/Documentation/filesystems/vfs.rst>



<https://www.starlab.io/blog/introduction-to-the-linux-virtual-file-system-vfs-part-i-a-high-level-tour>


# API-Typen

**VFS-Elemente:** Insgesamt gibt es vier Objekte, die das VFS zur Verfügung stellt:

1. **Superblock-Objekt** Ein eingebundenes Dateisystem. Erlaubt das Einbinden und Aushängen.
2. **Inode-Objekt** Eine konkrete Datei im Dateisystem. Stellt Funktionen zum Anlegen, Löschen, Umbenennen usw. zur Verfügung.
3. **Dentry-Objekt** Ein Verzeichniseintrag (Datei oder Verzeichnis) und zugehörige Verzeichnisoperationen, wie Dateinamenvergleich, aushängen aus dem Dateisystembaum
4. **File-Objekt** Stellt eine offene Datei dar und stellt alle dateibezogenen Operationen wie Lesen und Schreiben zur Verfügung

# Laufzeitsicht

- Liste offener Dateien in Prozesstabelleneintrag
- Geöffnete Datei verweist auf dentry-Eintrag
- Dentry-Eintrag referenziert inodes der Datei
- Inode ordnet auf echtes Hardwaregerät zu
- Alle Strukturen sind VFS-Elemente



# Dateisystem registrieren – Kernelmodul

```
#include <linux/init.h>
#include <linux/kernel.h>
#include <linux/module.h>

#include <linux/fs.h>

MODULE_LICENSE("GPL");
MODULE_AUTHOR("Bernhard J. Berger <berber@tzi.de>");
MODULE_DESCRIPTION("Simple filesystem for the lecture operating systems");

// Forward declaration section
struct dentry *bsfs_mount (struct file_system_type *type, int flags,
                           const char *name, void *ptr);

const struct file_system_type bsfs = {
    .owner = THIS_MODULE,
    .name = "bsfs",
    .mount = bsfs_mount,
    .kill_sb = kill_litter_super
};
```

# Dateisystem registrieren – Kernelmodul

```
static int __init module_start(void) {
    printk(KERN_INFO "Registering filesystem BSFS!\n");
    return register_filesystem(&bsfs);
}

static void __exit module_end(void) {
    printk(KERN_INFO "Unregistering filesystem BSFS!\n");
    unregister_filesystem(&bsfs);
}

struct dentry *bsfs_mount (struct file_system_type *type, int flags,
                           const char *name, void *ptr) {
    return NULL; // Implementierung ergänzen
}

module_init(module_start);
module_exit(module_end);
```

# Der Superblock – include/linux/fs.h

- Datenstruktur `struct super_block`
  - Definiert in `include/linux/fs.h`
  - Linux/Unix-spezifische Sicht auf das physische Dateisystem
  - Implementierung muss zwischen Linux und physischer Sicht *vermitteln*

```
struct super_block {  
    struct list_head s_list;  
    dev_t s_dev;  
    unsigned char s_blocksize_bits;  
    unsigned long s_blocksize;  
    loff_t s_maxbytes;  
    struct file_system_type *s_type;  
    const struct super_operations *s_op;  
    const struct dquot_operations *dq_op;  
    const struct quotactl_ops *s_qcop;  
    const struct export_operations  
        *s_export_op;  
    unsigned long s_flags;  
    unsigned long s_magic;  
    struct dentry *s_root;  
    struct rw_semaphore s_umount;  
    ...  
};
```

# Der Superblock – include/linux/fs.h

Liste der eingebundenen Dateisysteme (werden durch ihren Superblock repräsentiert)

```
struct super_block {  
    struct list_head s_list;  
    dev_t s_dev;  
    unsigned char s_blocksize_bits;  
    unsigned long s_blocksize;  
    loff_t s_maxbytes;  
    struct file_system_type *s_type;  
    const struct super_operations *s_op;  
    const struct dquot_operations *dq_op;  
    const struct quotactl_ops *s_qcop;  
    const struct export_operations  
        *s_export_op;  
    unsigned long s_flags;  
    unsigned long s_magic;  
    struct dentry *s_root;  
    struct rw_semaphore s_umount;  
    ...  
};
```

# Der Superblock – include/linux/fs.h

Verweis auf das unterliegende Gerät

```
struct super_block {  
    struct list_head s_list;  
    dev_t s_dev;  
    unsigned char s_blocksize_bits;  
    unsigned long s_blocksize;  
    loff_t s_maxbytes;  
    struct file_system_type *s_type;  
    const struct super_operations *s_op;  
    const struct dquot_operations *dq_op;  
    const struct quotactl_ops *s_qcop;  
    const struct export_operations  
        *s_export_op;  
    unsigned long s_flags;  
    unsigned long s_magic;  
    struct dentry *s_root;  
    struct rw_semaphore s_umount;  
    ...  
};
```

# Der Superblock – include/linux/fs.h

Informationen über die Größe des physikalischen Dateisystems.

```
struct super_block {  
    struct list_head s_list;  
    dev_t s_dev;  
    unsigned char s_blocksize_bits;  
    unsigned long s_blocksize;  
    loff_t s_maxbytes;  
    struct file_system_type *s_type;  
    const struct super_operations *s_op;  
    const struct dquot_operations *dq_op;  
    const struct quotactl_ops *s_qcop;  
    const struct export_operations  
                                     *s_export_op;  
    unsigned long s_flags;  
    unsigned long s_magic;  
    struct dentry *s_root;  
    struct rw_semaphore s_umount;  
    ...  
};
```

# Der Superblock – include/linux/fs.h

Zeiger auf die Superblock-Operationen (siehe Registrierung des Dateisystems).

```
struct super_block {  
    struct list_head s_list;  
    dev_t s_dev;  
    unsigned char s_blocksize_bits;  
    unsigned long s_blocksize;  
    loff_t s_maxbytes;  
    struct file_system_type *s_type;  
    const struct super_operations *s_op;  
    const struct dquot_operations *dq_op;  
    const struct quotactl_ops *s_qcop;  
    const struct export_operations  
        *s_export_op;  
    unsigned long s_flags;  
    unsigned long s_magic;  
    struct dentry *s_root;  
    struct rw_semaphore s_umount;  
    ...  
};
```

# Der Superblock – include/linux/fs.h

Operationen für den Superblock

```
struct super_block {  
    struct list_head s_list;  
    dev_t s_dev;  
    unsigned char s_blocksize_bits;  
    unsigned long s_blocksize;  
    loff_t s_maxbytes;  
    struct file_system_type *s_type;  
    const struct super_operations *s_op;  
    const struct dquot_operations *dq_op;  
    const struct quotactl_ops *s_qcop;  
    const struct export_operations  
                                *s_export_op;  
  
    unsigned long s_flags;  
    unsigned long s_magic;  
    struct dentry *s_root;  
    struct rw_semaphore s_umount;  
    ...  
};
```

# Der Superblock – include/linux/fs.h

```
struct super_block {  
    struct list_head s_list;  
    dev_t s_dev;  
    unsigned char s_blocksize_bits;  
    unsigned long s_blocksize;  
    loff_t s_maxbytes;  
    struct file_system_type *s_type;  
    const struct super_operations *s_op;  
    const struct dquot_operations *dq_op;  
    const struct quotactl_ops *s_qcop;  
    const struct export_operations  
                                     *s_export_op;  
    unsigned long s_flags;  
    unsigned long s_magic;  
    struct dentry *s_root;  
    struct rw_semaphore s_umount;  
    ...  
};
```

Zeiger auf das Wurzelverzeichnis des Dateisystems

# Der Superblock – include/linux/fs.h

Liste aller geladenen inode-Strukturen

```
struct super_block {  
    ...  
    struct list_head s_inodes;  
    struct hlist_bl_head s_anon;  
    struct list_head s_files;  
    struct list_head s_mounts;  
    ...  
    struct block_device *s_bdev;  
    struct backing_dev_info *s_bdi;  
    struct mtd_info *s_mtd;  
    struct hlist_node s_instances;  
};
```

# Der Superblock – include/linux/fs.h

Liste aller offenen Dateieinträge

```
struct super_block {  
    ...  
    struct list_head s_inodes;  
    struct hlist_bl_head s_anon;  
    struct list_head s_files;  
    struct list_head s_mounts;  
    ...  
    struct block_device *s_bdev;  
    struct backing_dev_info *s_bdi;  
    struct mtd_info *s_mtd;  
    struct hlist_node s_instances;  
};
```

# Der Superblock – include/linux/fs.h

Zugehöriges Block-Gerät

```
struct super_block {  
    ...  
    struct list_head s_inodes;  
    struct hlist_bl_head s_anon;  
    struct list_head s_files;  
    struct list_head s_mounts;  
    ...  
    struct block_device *s_bdev;  
    struct backing_dev_info *s_bdi;  
    struct mtd_info *s_mtd;  
    struct hlist_node s_instances;  
};
```

# Die Superblock-Operationen – include/linux/fs.h

Anlegen und Zerstören einer inode

```
struct super_operations {  
    struct inode *(*alloc_inode)(struct super_block *sb);  
    void (*destroy_inode)(struct inode *);  
    void (*dirty_inode) (struct inode *, int flags);  
    int (*write_inode) (struct inode *,  
                        struct writeback_control *wbc);  
    int (*drop_inode) (struct inode *);  
    void (*evict_inode) (struct inode *);  
    void (*put_super) (struct super_block *);  
    int (*sync_fs)(struct super_block *sb, int wait);  
    int (*freeze_fs) (struct super_block *);  
    int (*unfreeze_fs) (struct super_block *);  
    int (*statfs) (struct dentry *, struct kstatfs *);  
    int (*remount_fs) (struct super_block *, int *, char *);  
    void (*umount_begin) (struct super_block *);  
    ...  
};
```

# Die Superblock-Operationen – include/linux/fs.h

Inode als geändert markieren. Wird für spezielle Operationen benötigt.

```
struct super_operations {
    struct inode *(*alloc_inode)(struct super_block *sb);
    void (*destroy_inode)(struct inode *);
    void (*dirty_inode) (struct inode *, int flags);
    int (*write_inode) (struct inode *,
                        struct writeback_control *wbc);
    int (*drop_inode) (struct inode *);
    void (*evict_inode) (struct inode *);
    void (*put_super) (struct super_block *);
    int (*sync_fs)(struct super_block *sb, int wait);
    int (*freeze_fs) (struct super_block *);
    int (*unfreeze_fs) (struct super_block *);
    int (*statfs) (struct dentry *, struct kstatfs *);
    int (*remount_fs) (struct super_block *, int *, char *);
    void (*umount_begin) (struct super_block *);
    ...
}
```

# Die Superblock-Operationen – include/linux/fs.h

Schreiben und Löschen einer inode  
auf/von physischem Gerät

```
struct super_operations {  
    struct inode *(*alloc_inode)(struct super_block *sb);  
    void (*destroy_inode)(struct inode *);  
    void (*dirty_inode) (struct inode *, int flags);  
    int (*write_inode) (struct inode *,  
                        struct writeback_control *wbc);  
    int (*drop_inode) (struct inode *);  
    void (*evict_inode) (struct inode *);  
    void (*put_super) (struct super_block *);  
    int (*sync_fs)(struct super_block *sb, int wait);  
    int (*freeze_fs) (struct super_block *);  
    int (*unfreeze_fs) (struct super_block *);  
    int (*statfs) (struct dentry *, struct kstatfs *);  
    int (*remount_fs) (struct super_block *, int *, char *);  
    void (*umount_begin) (struct super_block *);  
    ...  
};
```

# Die Superblock-Operationen – include/linux/fs.h

Superblock freigeben (bei unmount)

```
struct super_operations {
    struct inode *(*alloc_inode)(struct super_block *sb);
    void (*destroy_inode)(struct inode *);
    void (*dirty_inode) (struct inode *, int flags);
    int (*write_inode) (struct inode *,
                        struct writeback_control *wbc);
    int (*drop_inode) (struct inode *);
    void (*evict_inode) (struct inode *);
    void (*put_super) (struct super_block *);
    int (*sync_fs)(struct super_block *sb, int wait);
    int (*freeze_fs) (struct super_block *);
    int (*unfreeze_fs) (struct super_block *);
    int (*statfs) (struct dentry *, struct kstatfs *);
    int (*remount_fs) (struct super_block *, int *, char *);
    void (*umount_begin) (struct super_block *);
    ...
}
```

# Die Superblock-Operationen – include/linux/fs.h

Metadaten des Dateisystems auf das physische Gerät schreiben.

```
struct super_operations {
    struct inode *(*alloc_inode)(struct super_block *sb);
    void (*destroy_inode)(struct inode *);
    void (*dirty_inode) (struct inode *, int flags);
    int (*write_inode) (struct inode *,
                        struct writeback_control *wbc);
    int (*drop_inode) (struct inode *);
    void (*evict_inode) (struct inode *);
    void (*put_super) (struct super_block *);
    int (*sync_fs)(struct super_block *sb, int wait);
    int (*freeze_fs) (struct super_block *);
    int (*unfreeze_fs) (struct super_block *);
    int (*statfs) (struct dentry *, struct kstatfs *);
    int (*remount_fs) (struct super_block *, int *, char *);
    void (*umount_begin) (struct super_block *);
    ...
}
```

# Die inode – include/linux/fs.h

Berechtigungsinformationen

```
struct inode {  
    umode_t i_mode;  
    unsigned short i_opflags;  
    kuid_t i_uid;  
    kgid_t i_gid;  
    unsigned int i_flags;  
    struct posix_acl *i_acl;  
    struct posix_acl *i_default_acl;  
    const struct inode_operations *i_op;  
    struct super_block *i_sb;  
    struct address_space *i_mapping;  
    dev_t i_rdev;  
    loff_t i_size;  
    ...  
};
```

# Die inode – include/linux/fs.h

Zugriffskontrollinformationen

```
struct inode {  
    umode_t i_mode;  
    unsigned short i_opflags;  
    kuid_t i_uid;  
    kgid_t i_gid;  
    unsigned int i_flags;  
    struct posix_acl *i_acl;  
    struct posix_acl *i_default_acl;  
    const struct inode_operations *i_op;  
    struct super_block *i_sb;  
    struct address_space *i_mapping;  
    dev_t i_rdev;  
    loff_t i_size;  
    ...  
};
```

# Die inode – include/linux/fs.h

Inode bezogene Operationen

```
struct inode {  
    umode_t i_mode;  
    unsigned short i_opflags;  
    kuid_t i_uid;  
    kgid_t i_gid;  
    unsigned int i_flags;  
    struct posix_acl *i_acl;  
    struct posix_acl *i_default_acl;  
    const struct inode_operations *i_op;  
    struct super_block *i_sb;  
    struct address_space *i_mapping;  
    dev_t i_rdev;  
    loff_t i_size;  
    ...  
};
```

# Die inode – include/linux/fs.h

```
struct inode {  
    umode_t i_mode;  
    unsigned short i_opflags;  
    kuid_t i_uid;  
    kgid_t i_gid;  
    unsigned int i_flags;  
    struct posix_acl *i_acl;  
    struct posix_acl *i_default_acl;  
    const struct inode_operations *i_op;  
    struct super_block *i_sb;  
    struct address_space *i_mapping;  
    dev_t i_rdev;  
    loff_t i_size;  
    ...  
};
```

Aktuelle Dateigröße

# Die inode – include/linux/fs.h

Anzahl an Bytes im letzten Block

```
struct inode {  
    unsigned short i_bytes;  
    unsigned int i_blkbits;  
    blkcnt_t i_blocks;  
    struct hlist_node i_hash;  
    struct list_head i_wb_list;  
    struct list_head i_lru;  
    struct list_head i_sb_list;  
    union {  
        struct hlist_head i_dentry;  
        struct rcu_head i_rcu;  
    };  
    u64 i_version;  
    atomic_t i_count;  
    atomic_t i_dio_count;  
    atomic_t i_writecount;  
    const struct file_operations *i_fop;  
    ...  
    struct list_head i_devices;  
    union {  
        struct pipe_inode_info *i_pipe;  
        struct block_device *i_bdev;  
        struct cdev *i_cdev;  
    };  
    ...  
};
```

# Die inode – include/linux/fs.h

Anzahl an Blöcken

```
struct inode {
    unsigned short i_bytes;
    unsigned int i_blkbits;
    blkcnt_t i_blocks;
    struct hlist_node i_hash;
    struct list_head i_wb_list;
    struct list_head i_lru;
    struct list_head i_sb_list;
    union {
        struct hlist_head i_dentry;
        struct rcu_head i_rcu;
    };
    u64 i_version;
    atomic_t i_count;
    atomic_t i_dio_count;
    atomic_t i_writecount;
    const struct file_operations *i_fop;
    ...
    struct list_head i_devices;
    union {
        struct pipe_inode_info *i_pipe;
        struct block_device *i_bdev;
        struct cdev *i_cdev;
    };
    ...
}
```

# Die inode – include/linux/fs.h

Liste von LRU-Seiten, die Blöcke der  
Datei cachten

```
struct inode {
    unsigned short i_bytes;
    unsigned int i_blkbits;
    blkcnt_t i_blocks;
    struct hlist_node i_hash;
    struct list_head i_wb_list;
    struct list_head i_lru;
    struct list_head i_sb_list;
    union {
        struct hlist_head i_dentry;
        struct rcu_head i_rcu;
    };
    u64 i_version;
    atomic_t i_count;
    atomic_t i_dio_count;
    atomic_t i_writecount;
    const struct file_operations *i_fop;
    ...
    struct list_head i_devices;
    union {
        struct pipe_inode_info *i_pipe;
        struct block_device *i_bdev;
        struct cdev *i_cdev;
    };
    ...
}
```

# Die inode – include/linux/fs.h

```
struct inode {
    unsigned short i_bytes;
    unsigned int i_blkbits;
    blkcnt_t i_blocks;
    struct hlist_node i_hash;
    struct list_head i_wb_list;
    struct list_head i_lru;
    struct list_head i_sb_list;
    union {
        struct hlist_head i_dentry;
        struct rcu_head i_rcu;
    };
    u64 i_version;
    atomic_t i_count;
    atomic_t i_dio_count;
    atomic_t i_writecount;
    const struct file_operations *i_fop;
    ...
    struct list_head i_devices;
    union {
        struct pipe_inode_info *i_pipe;
        struct block_device *i_bdev;
        struct cdev *i_cdev;
    };
    ...
}
```

Dateioperationen

# Die inode Operationen – include/linux/fs.h

Sucht file-Eintrag im angegebenen Verzeichnis

```
struct inode_operations {  
    struct dentry * (*lookup) (struct inode *,  
                               struct dentry *,  
                               unsigned int);  
    void * (*follow_link) (struct dentry *, struct nameidata *);  
    int (*permission) (struct inode *, int);  
    struct posix_acl * (*get_acl)(struct inode *, int);  
    int (*readlink) (struct dentry *, char __user *, int);  
    void (*put_link) (struct dentry *, struct nameidata *, void *);  
    int (*create) (struct inode *, struct dentry *, umode_t, bool);  
    int (*link) (struct dentry *, struct inode *, struct dentry *);  
    int (*unlink) (struct inode *, struct dentry *);  
    int (*symlink) (struct inode *, struct dentry *, const char *);  
    int (*mkdir) (struct inode *, struct dentry *, umode_t);  
    int (*rmdir) (struct inode *, struct dentry *);  
    ...  
};
```

# Die inode Operationen – include/linux/fs.h

Gibt ACL-Informationen der Inode zurück.

```
struct inode_operations {
    struct dentry * (*lookup) (struct inode *,
                               struct dentry *,
                               unsigned int);

    void * (*follow_link) (struct dentry *, struct nameidata *);
    int (*permission) (struct inode *, int);
    struct posix_acl * (*get_acl)(struct inode *, int);
    int (*readlink) (struct dentry *, char __user *, int);
    void (*put_link) (struct dentry *, struct nameidata *, void *);
    int (*create) (struct inode *, struct dentry *, umode_t, bool);
    int (*link) (struct dentry *, struct inode *, struct dentry *);
    int (*unlink) (struct inode *, struct dentry *);
    int (*symlink) (struct inode *, struct dentry *, const char *);
    int (*mkdir) (struct inode *, struct dentry *, umode_t);
    int (*rmdir) (struct inode *, struct dentry *);
    ...
}
```

# Die inode Operationen – include/linux/fs.h

Erzeugt eine neue Inode in dem angegebenen Ordner. Die übergebene Inode wird gefüllt.

```
struct inode_operations {
    struct dentry * (*lookup) (struct inode *,
                               struct dentry *,
                               unsigned int);

    void * (*follow_link) (struct dentry *, struct nameidata *);
    int (*permission) (struct inode *, int);
    struct posix_acl * (*get_acl)(struct inode *, int);
    int (*readlink) (struct dentry *, char __user *, int);
    void (*put_link) (struct dentry *, struct nameidata *, void *);
    int (*create) (struct inode *, struct dentry *, umode_t, bool);
    int (*link) (struct dentry *, struct inode *, struct dentry *);
    int (*unlink) (struct inode *, struct dentry *);
    int (*symlink) (struct inode *, struct dentry *, const char *);
    int (*mkdir) (struct inode *, struct dentry *, umode_t);
    int (*rmdir) (struct inode *, struct dentry *);
    ...
}
```

# Die inode Operationen – include/linux/fs.h

```
struct inode_operations {
    struct dentry * (*lookup) (struct inode *,
                               struct dentry *,
                               unsigned int);

    void * (*follow_link) (struct dentry *, struct nameidata *);
    int (*permission) (struct inode *, int);
    struct posix_acl * (*get_acl)(struct inode *, int);
    int (*readlink) (struct dentry *, char __user *, int);
    void (*put_link) (struct dentry *, struct nameidata *, void *);
    int (*create) (struct inode *, struct dentry *, umode_t, bool);
    int (*link) (struct dentry *, struct inode *, struct dentry *);
    int (*unlink) (struct inode *, struct dentry *);
    int (*symlink) (struct inode *, struct dentry *, const char *);
    int (*mkdir) (struct inode *, struct dentry *, umode_t);
    int (*rmdir) (struct inode *, struct dentry *);
    ...
}
```

Hängt die übergebene Inode aus.

# Die inode Operationen – include/linux/fs.h

```
struct inode_operations {  
    ...  
    int (*rename) (struct inode *, struct dentry *,  
                   struct inode *, struct dentry *);  
    int (*setattr) (struct dentry *, struct iattr *);  
    int (*getattr) (struct vfsmount *mnt, struct dentry *,  
                   struct kstat *);  
    int (*setxattr) (struct dentry *, const char *,  
                    const void *, size_t, int);  
    ssize_t (*getxattr) (struct dentry *, const char *,  
                        void *, size_t);  
    ssize_t (*listxattr) (struct dentry *, char *, size_t);  
    int (*removexattr) (struct dentry *, const char *);  
    int (*fiemap) (struct inode *, struct fiemap_extent_info *,  
                  u64 start, u64 len);  
    int (*update_time) (struct inode *, struct timespec *, int);  
    int (*atomic_open) (struct inode *, struct dentry *,  
                       struct file *, unsigned open_flag,  
                       umode_t create_mode, int *opened);  
};
```

Erzeugt und öffnet eine Datei

# Das dentry Objekt – include/linux/dcache.h

```
struct dentry {  
    unsigned int d_flags;  
    seqcount_t d_seq;  
    struct hlist_bl_node d_hash;  
    struct dentry *d_parent;  
    struct qstr d_name;  
    struct inode *d_inode;  
    unsigned char d_iname[DNAME_INLINE_LEN];  
    unsigned int d_count;  
    spinlock_t d_lock;  
    const struct dentry_operations *d_op;  
    struct super_block *d_sb;  
    ...  
};
```

Die Inode, die diesen dentry darstellt

# Das dentry Objekt – include/linux/dcache.h

```
struct dentry {  
    unsigned int d_flags;  
    seqcount_t d_seq;  
    struct hlist_bl_node d_hash;  
    struct dentry *d_parent;  
    struct qstr d_name;  
    struct inode *d_inode;  
    unsigned char d_iname[DNAME_INLINE_LEN];  
    unsigned int d_count;  
    spinlock_t d_lock;  
    const struct dentry_operations *d_op;  
    struct super_block *d_sb;  
    ...  
};
```

Operationen für den dentry

# Das dentry Operationen – include/linux/dcache.h

Vergleiche zwei Verzeichniseinträge  
anhand ihres Namens.

```
struct dentry_operations {
    int (*d_revalidate)(struct dentry *, unsigned int);
    int (*d_weak_revalidate)(struct dentry *, unsigned int);
    int (*d_hash)(const struct dentry *,
                  const struct inode *,
                  struct qstr *);
    int (*d_compare)(const struct dentry *,
                    const struct inode *,
                    const struct dentry *,
                    const struct inode *,
                    unsigned int,
                    const char *, const struct qstr *);
    int (*d_delete)(const struct dentry *);
    void (*d_release)(struct dentry *);
    void (*d_prune)(struct dentry *);
    void (*d_iput)(struct dentry *, struct inode *);
    char *(*d_dname)(struct dentry *, char *, int);
    struct vfsmount *(*d_automount)(struct path *);
    int (*d_manage)(struct dentry *, bool);
}
```

# Das File Objekt

Liste aller File-Objekte

```
struct file {  
    union {  
        struct list_head fu_list;  
        struct rcu_head fu_rcuhead;  
    } f_u;  
    struct path f_path;  
    struct inode *f_inode;  
    const struct file_operations *f_op;  
    spinlock_t f_lock;  
    atomic_long_t f_count;  
    unsigned int f_flags;  
    fmode_t f_mode;  
    loff_t f_pos;  
    struct fown_struct f_owner;  
    const struct cred *f_cred;  
    struct file_ra_state f_ra;  
};
```

# Das File Objekt

Flags zum genaueren Spezifizieren  
des Eintrags

```
struct file {  
    union {  
        struct list_head fu_list;  
        struct rcu_head fu_rcuhead;  
    } f_u;  
    struct path f_path;  
    struct inode *f_inode;  
    const struct file_operations *f_op;  
    spinlock_t f_lock;  
    atomic_long_t f_count;  
    unsigned int f_flags;
```

```
enum path_flags {  
    PATH_IS_DIR = 0x1,           /* path is a directory */  
    PATH_CONNECT_PATH = 0x4,     /* connect disconnected paths to / */  
    PATH_CHROOT_REL = 0x8,       /* do path lookup relative to chroot */  
    PATH_CHROOT_NSCONNECT = 0x10, /* connect paths that are at ns root */  
  
    PATH_DELEGATE_DELETED = 0x08000, /* delegate deleted files */  
    PATH_MEDIATE_DELETED = 0x10000, /* mediate deleted paths */  
};
```

# Das File Objekt

Dateioperationen

```
struct file {  
    union {  
        struct list_head fu_list;  
        struct rcu_head fu_rcuhead;  
    } f_u;  
    struct path f_path;  
    struct inode *f_inode;  
    const struct file_operations *f_op;  
    spinlock_t f_lock;  
    atomic_long_t f_count;  
    unsigned int f_flags;  
    fmode_t f_mode;  
    loff_t f_pos;  
    struct fown_struct f_owner;  
    const struct cred *f_cred;  
    struct file_ra_state f_ra;  
};
```

# Das File Objekt

```
struct file {  
    union {  
        struct list_head fu_list;  
        struct rcu_head fu_rcuhead;  
    } f_u;  
    struct path f_path;  
    struct inode *f_inode;  
    const struct file_operations *f_op;  
    spinlock_t f_lock;  
    atomic_long_t f_count;  
    unsigned int f_flags;  
    fmode_t f_mode;  
    loff_t f_pos;  
    struct fown_struct f_owner;  
    const struct cred *f_cred;  
    struct file_ra_state f_ra;  
};
```

Position des Lese-/Schreibindex

# Das File Objekt

## Setzen des Lese-/Schreibindex

```
struct file_operations {
    struct module *owner;
    loff_t (*llseek) (struct file *, loff_t, int);
    ssize_t (*read) (struct file *, char __user *,
                     size_t, loff_t *);
    ssize_t (*write) (struct file *, const char __user *,
                      size_t, loff_t *);

    ...
    int (*readdir) (struct file *, void *, filldir_t);
    unsigned int (*poll) (struct file *,
                           struct poll_table_struct *);

    ..
    int (*mmap) (struct file *, struct vm_area_struct *);
    int (*open) (struct inode *, struct file *);
    int (*flush) (struct file *, fl_owner_t id);
    int (*release) (struct inode *, struct file *);
    int (*fsync) (struct file *, loff_t, loff_t,
                  int datasync);


    ...
}
```

# Das File Objekt

Lesen und Schreiben von Daten

```
struct file_operations {
    struct module *owner;
    loff_t (*llseek) (struct file *, loff_t, int);
    ssize_t (*read) (struct file *, char __user *,
                    size_t, loff_t *);
    ssize_t (*write) (struct file *, const char __user *,
                    size_t, loff_t *);
    ...
    int (*readdir) (struct file *, void *, filldir_t);
    unsigned int (*poll) (struct file *,
                        struct poll_table_struct *);
    ..
    int (*mmap) (struct file *, struct vm_area_struct *);
    int (*open) (struct inode *, struct file *);
    int (*flush) (struct file *, fl_owner_t id);
    int (*release) (struct inode *, struct file *);
    int (*fsync) (struct file *, loff_t, loff_t,
                int datasync);
    ...
}
```

# Beispiel eines Systemaufrufs



# Beispiel eines Systemaufrufs - fs/read\_write.c

```
SYSCALL_DEFINE3(read,  
                unsigned int, fd,  
                char __user *, buf,  
                size_t, count)  
{  
    struct fd f = fdget(fd);  
    ssize_t ret = -EBADF;  
    if (f.file) {  
        loff_t pos = file_pos_read(f.file);  
        ret = vfs_read(f.file, buf, count, &pos);  
        file_pos_write(f.file, pos);  
        fdput(f);  
    }  
    return ret;  
}
```

# Beispiel eines Systemaufrufs - fs/read\_write.c

```
SYSCALL_DEFINE3(read,  
                unsigned int, fd,  
                char __user *, buf,  
                size_t, count)  
{  
    struct fd f = fdget(fd);  
    ssize_t ret = -EBADF;  
    if (f.file) {  
        loff_t pos = file_pos_read(f.file);  
        ret = vfs_read(f.file, buf, count, &pos);  
        file_pos_write(f.file, pos);  
        fdput(f);  
    }  
    return ret;  
}
```

```
struct fd {  
    struct file *file;  
    int need_put;  
};
```

# Beispiel eines Systemaufrufs - fs/read\_write.c

```
SYSCALL_DEFINE3(read,  
                unsigned int, fd,  
                char __user *, buf,  
                size_t, count)  
{  
    struct fd f = fdget(fd);  
    ssize_t ret = -EBADF;  
    if (f.file) {  
        loff_t pos = file_pos_read(f.file);  
        ret = vfs_read(f.file, buf, count, &pos);  
        file_pos_write(f.file, pos);  
        fdput(f);  
    }  
    return ret;  
}
```

Aufruf von fget\_light

# Beispiel eines Systemaufrufs - fs/read\_write.c

```
struct file *fget_light(unsigned int fd, int *fput_needed)
{
    struct file *file;
    struct files_struct *files = current->files;
    *fput_needed = 0;
    if (atomic_read(&files->count) == 1) {
        file = fcheck_files(files, fd);
        if (file && (file->f_mode & FMODE_PATH))
            file = NULL;
    } else {
        rcu_read_lock();
        file = fcheck_files(files, fd);
        if (file) {
            if (!(file->f_mode & FMODE_PATH) &&
                atomic_long_inc_not_zero(&file->f_count))
                *fput_needed = 1;
            else
                /* Didn't get the reference, someone's freed */
                file = NULL;
        }
        rcu_read_unlock();
    }
    return file;
}
```

# Beispiel eines Systemaufrufs - fs/read\_write.c

```
struct file *fget_light(unsigned int fd, int *fput_needed)
{
    struct file *file;
    struct files_struct *files = current->files;
    *fput_needed = 0;
    if (atomic_read(&files->count) == 1) {
        file = fcheck_files(files, fd);
        if (file && (file->f_mode & FMODE_PATH))
            file = NULL;
    } else {
        rcu_read_lock();
        file = fcheck_files(files, fd);
        if (file) {
            if (!(file->f_mode & FMODE_PATH) &&
                atomic_long_inc_not_zero(&file->f_count))
                *fput_needed = 1;
            else
                /* Didn't get the reference, someone's freed */
                file = NULL;
        }
        rcu_read_unlock();
    }
    return file;
}
```

Holt alle offenen Dateien des aktiven Prozesses

# Beispiel eines Systemaufrufs - fs/read\_write.c

```
struct file *fget_light(unsigned int fd, int
*fput_needed)
{
    struct file *file;
    struct files_struct *files = current->files;
    *fput_needed = 0;
    if (atomic_read(&files->count) == 1) {
        file = fcheck_files(files, fd);
        if (file && (file->f_mode & FMODE_PATH))
            file = NULL;
    } else {
        rcu_read_lock();
        file = fcheck_files(files, fd);
        if (file) {
            if (!(file->f_mode & FMODE_PATH) &&
                atomic_long_inc_not_zero(&file->f_count))
                *fput_needed = 1;
            else
                /* Didn't get the reference, someone's freed */
                file = NULL;
        }
        rcu_read_unlock();
    }
    return file;
}
```

Liefert files->fdt->fd[fd]

# Beispiel eines Systemaufrufs - fs/read\_write.c

```
SYSCALL_DEFINE3(read,  
                unsigned int, fd,  
                char __user *, buf,  
                size_t, count)  
{  
    struct fd f = fdget(fd);  
    ssize_t ret = -EBADF;  
    if (f.file) {  
        loff_t pos = file_pos_read(f.file);  
        ret = vfs_read(f.file, buf, count, &pos);  
        file_pos_write(f.file, pos);  
        fdput(f);  
    }  
    return ret;  
}
```

Hole Lese-/Schreibindex aus f.file

# Beispiel eines Systemaufrufs - fs/read\_write.c

```
SYSCALL_DEFINE3(read,  
                unsigned int, fd,  
                char __user *, buf,  
                size_t, count)  
{  
    struct fd f = fdget(fd);  
    ssize_t ret = -EBADF;  
    if (f.file) {  
        loff_t pos = file_pos_read(f.file);  
        ret = vfs_read(f.file, buf, count, &pos);  
        file_pos_write(f.file, pos);  
        fdput(f);  
    }  
    return ret;  
}
```

Rufe die eigentliche Lesefunktion auf

# Beispiel eines Systemaufrufs

```
ssize_t vfs_read(struct file *file, char __user *buf, size_t count, loff_t *pos)
{
    ssize_t ret;
    if (!(file->f_mode & FMODE_READ))
        return -EBADF;
    if (!file->f_op || (!file->f_op->read && !file->f_op->aio_read))
        return -EINVAL;
    if (unlikely(!access_ok(VERIFY_WRITE, buf, count)))
        return -EFAULT;

    ret = rw_verify_area(READ, file, pos, count);
    if (ret >= 0) {
        count = ret;
        if (file->f_op->read)
            ret = file->f_op->read(file, buf, count, pos);
        else
            ret = do_sync_read(file, buf, count, pos);
        if (ret > 0) {
            fsnotify_access(file);
            add_rchar(current, ret);
        }
        inc_syscr(current);
    }
    return ret;
}
```

# Beispiel eines Systemaufrufs

```
ssize_t vfs_read(struct file *file, char __user *buf, size_t count, loff_t *pos)
{
    ssize_t ret;
    if (!(file->f_mode & FMODE_READ))
        return -EBADF;
    if (!file->f_op || (!file->f_op->read && !file->f_op->aio_read))
        return -EINVAL;
    if (unlikely(!access_ok(VERIFY_WRITE, buf, count)))
        return -EFAULT;

    ret = rw_verify_area(READ, file, pos, count);
    if (ret >= 0) {
        count = ret;
        if (file->f_op->read)
            ret = file->f_op->read(file, buf, count, pos);
        else
            ret = do_sync_read(file, buf, count, pos);
        if (ret > 0) {
            fsnotify_access(file);
            add_rchar(current, ret);
        }
        inc_syscr(current);
    }
    return ret;
}
```

Dateisystem mit Lesen beauftragen

# Beispiel eines Systemaufrufs - fs/read\_write.c

```
SYSCALL_DEFINE3(read,  
                unsigned int, fd,  
                char __user *, buf,  
                size_t, count)  
{  
    struct fd f = fdget(fd);  
    ssize_t ret = -EBADF;  
    if (f.file) {  
        loff_t pos = file_pos_read(f.file);  
        ret = vfs_read(f.file, buf, count, &pos);  
        file_pos_write(f.file, pos);  
        fdput(f);  
    }  
    return ret;  
}
```

Aktualisiere Position im File-Objekt

# Themenübersicht

- FS als API
- Terminologie
- Management

## Grundlagen

- Grundidee
- API-Typen
- Laufzeitsicht
- Dateisysteme registrieren
- Strukturen
  - Superblock
  - Inode
  - Dentry
  - File

## VFS

- Minix
- FAT-Dateisysteme
- ext-Dateisysteme
- Journaling
- Extents
- Copy-On-Write

## Dateisysteme

# Minix-Dateisystem

| Bereich 1                | Bereich 2                 | Bereich 3                    | Bereich 4                   | Bereich 5              | Bereich 6              |
|--------------------------|---------------------------|------------------------------|-----------------------------|------------------------|------------------------|
| Bootblock<br>(1 Cluster) | Superblock<br>(1 Cluster) | Inodes-Bitmap<br>(1 Cluster) | Block-Bitmap<br>(1 Cluster) | Inodes<br>(15 Cluster) | Daten<br>(??? Cluster) |

- **Bootblock** Boot-Loader für das Betriebssystem, Informationen über das Dateisystem,
  - z.B. Anzahl der Inodes und Cluster
- **Inodes-Bitmap** “Bitmap” die speichert, ob Inodes belegt (Wert: 1) oder frei (Wert: 0) sind
- **Cluster-Bitmap** “Bitmap” die speichert, ob Cluster belegt (Wert: 1) oder frei (Wert: 0) sind
- **Inodes** Enthält Inodes mit den Metadaten
  - Jede Datei und jedes Verzeichnis hat einen Inode mit Metadaten (Dateityp, UID/GID, Zugriffsrechte, Größe)
- **Daten** Inhalt der Dateien und Verzeichnisse

# FAT - Dateizuordnungstabelle


- Namensgeber ist Datenstruktur **File Allocation Table** (FAT, Dateizuordnungstabelle)
- Größe der FAT ist fest
- FAT speichert für jeden Cluster folgenden Informationen:
  - Frei
  - Beschädigt
  - Belegt
- Cluster speichert Verweis auf den nächsten Cluster einer Datei
- FAT implementiert das Konzept einer einfach verketteten Liste

# FAT - Dateizuordnungstabelle


| Bereich 1                | Bereich 2              | Bereich 3 | Bereich 4 | Bereich 5        | Bereich 6 |
|--------------------------|------------------------|-----------|-----------|------------------|-----------|
| Bootblock<br>(1 Cluster) | Reservierte<br>Cluster | FAT 1     | FAT 2     | Stammverzeichnis | Daten     |

- **Bootblock** Boot-Loader für das Betriebssystem, Informationen über das Dateisystem
  - z.B. Blöcke pro Cluster, Anzahl an Blöcken
- **Reservierte Cluster** Zusätzlicher Platz für den Bootmanager (wenn notwendig)
- **FAT** Informationen über belegte Blöcke (Bereich ist dupliziert um Ausfallwahrscheinlichkeit zu reduzieren)
- **Stammverzeichnis** Informationen zum Wurzelverzeichnis
  - z.B. Dateinamen, Größe, Datum, Dateityp (Verzeichnis, Datei), FAT-Eintrag
- **Daten** Inhalt der Dateien und Verzeichnisse

# FAT - Dateizuordnungstabelle




# ext-Dateisysteme



- Der Datenträger wird in gleich große Blockgruppen unterteilt
- Jede Blockgruppe enthält alle Informationen für diese Blockgruppe
- Vorteile
  - Lokalisierungsprinzip der Informationen
  - Schnellere Zugriffszeiten bei Festplatten
  - Replikation des Superblocks (Datensicherheit)

# ext-Dateisysteme



- **Bootblock** in Cluster 1 (1 kB)
- Die **Deskriptor-Tabelle** enthält
  - Clusternummer des Block-Bitmaps
  - Clusternummer des Inode-Bitmaps
  - Anzahl der freien Cluster und Inodes in der Blockgruppe
- **Block-** und **Inode-Bitmap** sind jeweils einen Cluster groß
  - Speichern Informationen über die belegten Cluster und Inodes der Blockgruppe
- Die **Inode-Tabelle** enthält die Inodes der Blockgruppe
- Die restlichen Cluster der Blockgruppe sind die **Datenblöcke**

# Journaling

- Beim Modifizieren von Verzeichnisstrukturen oder Metadaten sind Schreibzugriffe notwendig
  - Die Änderungen an dem Dateisystem sind Transaktionen (atomar, konsistent, isoliert, dauerhaft)
- Bei Ausfall während des Schreibens ist anschließende Konsistenzprüfung notwendig
  - In großen Dateisystemen kann die Prüfung sehr lange (Stunden bis Tage) dauern
- Die Konsistenzprüfung zu überspringen, kann zum Datenverlust führen
- „Änderungsjournal“ über die Schreibzugriffe kann Prüfaufwand einschränken



# Journaling

- Dateisystem führt ein Journal und sammelt Schreibzugriffe
- Nach festem Zeitabstand wird das Journal geschlossen und die Operationen durchgeführt
- **Vorteil:**  
Nach einem Absturz müssen nur Dateien und Metadaten aus dem Journal überprüft werden
- **Nachteil**  
Durch Journaling mehr Schreiboperationen, da Änderungen erst ins Journal geschrieben und danach durchgeführt werden
- Varianten:
  - Metadaten-Journaling
  - Vollständiges Journaling



# Journaling


- **Metadaten-Journaling** (Write-Back)
  - Nur Änderungen (Inodes) an Metadaten im Journal
  - Nur Metadaten können auf Korrektheit geprüft werden
  - Konsistenzprüfungen nach wenigen Sekunden abgeschlossen
  - Datenverlust noch immer möglich
  - ext3/4, NTFS und XFS unterstützen diese Version
- **Vollständiges Journaling**
  - Änderungen an Metadaten und Dateien werden protokolliert
  - Konsistenz der Dateien ist gewährleistet
  - Alle Schreiboperation werden doppelt durchgeführt
  - Diese Version ist bei ext3/4 optional
  - NTFS und XFS unterstützen diese Option nicht

# Extents

- Inodes verwenden
  - Direkte Blockadressierung
  - Indirekte Blockadressierung
  - Doppelt indirekte Blockadressierung

Inode bei ext3/4 (Blockadressierung)


Clusternummern (Daten der Datei)




- Hierdurch steigt der Overhead für Verwaltungsinformationen
- Lösung: **Extents**

# Extents

- **Grundlegende Idee:** Cluster sollen nicht einzeln zugeordnet werden. Stattdessen versucht man zusammenhängende Bereiche zuzuordnen.
- Hierfür müssen drei Werte gespeichert werden:
  - Nummer des Start-Clusters des Bereichs (Extents)
  - Größe des Bereichs in Clustern
  - Nummer des ersten Clusters auf dem Speichergerät
- Ergebnis: Weniger Verwaltungsaufwand
- Beispiele: JFS, XFS, btrfs, NTFS, ext4



# Snapshots – Copy on Write



- Schreibzugriffe im Dateisystem ändern/löschen keine Dateiinhalte
  - Veränderte Inhalte werden in freie Cluster geschrieben
  - Anschließend werden die Metadaten auf die neue Datei angepasst
- Ältere Dateiversionen bleiben erhalten und können wiederhergestellt werden
  - Die Datensicherheit ist besser als bei Dateisystemen mit Journal
  - Snapshots können sehr schnell erzeugt werden (nur Metadaten-Änderung)
- Beispiele: ZFS, btrfs und ReFS (Resilient File System)

# Themenübersicht

- FS als API
- Terminologie
- Management

## Grundlagen

- Grundidee
- API-Typen
- Laufzeitsicht
- Dateisysteme registrieren
- Strukturen
  - Superblock
  - Inode
  - Dentry
  - File

## VFS

- Minix
- FAT-Dateisysteme
- ext-Dateisysteme
- Journaling
- Extents
- Copy-On-Write

## Dateisysteme