VFS - Virtual File System Switch

Dinh Khoa Nguyen & Eric Müller

Seminar Dateisystem

Prof. Dr. Thomas Ludwig
Institut für Informatik
Universität Heidelberg
SS 2007

VFS Inhalt

- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- Einstiegsbeispiel
- Definition
- Implementationen des VFS
- Grobe Struktur (Common File Model)

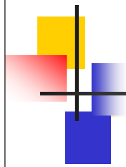

Einstieg (Source: [Understand Linux Kernel])

VFS Inhalt

- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- $ cp /floppy/TEST /tmp/test

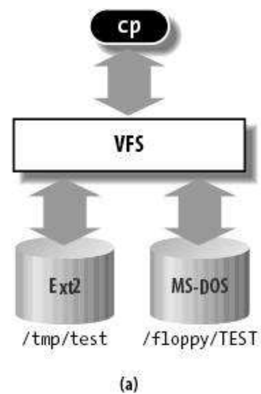


```
inf = open("/floppy/TEST", O_RDONLY, 0);
outf = open("/tmp/test",
       O_WRONLY|O_CREAT|O_TRUNC, 0600);
do {
    i = read(inf, buf, 4096);
    write(outf, buf, i);
} while (i);
close(outf);
close(inf);
```

(a) (b)

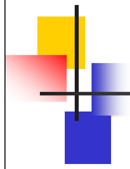

Einstieg

VFS Inhalt

- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- write(outf, buffer, i)

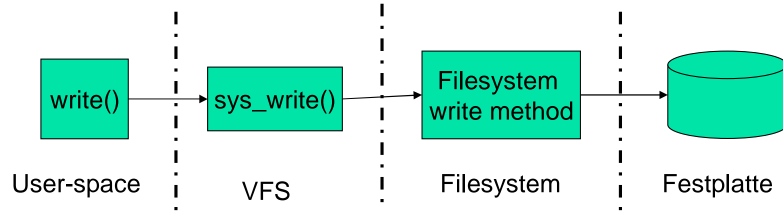

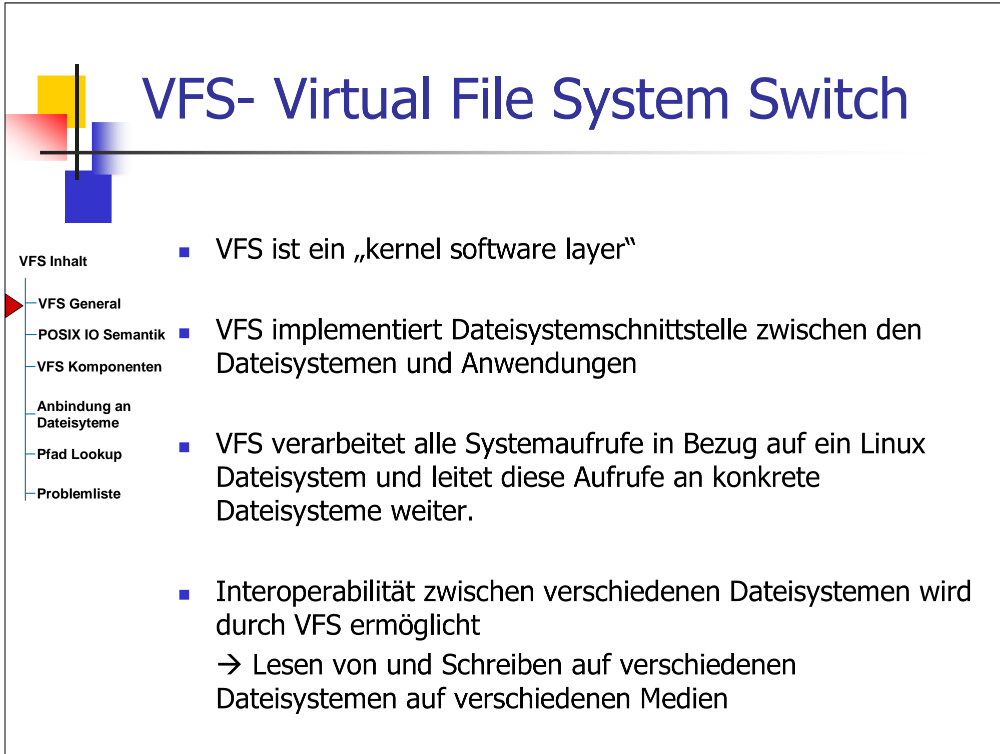

- VFS arbeitet wie ein traditionelles Linux Dateisystem

Dateisysteme unter VFS

VFS Inhalt

- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

Von VFS unterstützte Dateisysteme

- Platten-basierte Dateisysteme:
  - Linux: Ext2, Ext3, ReiserFS,..
  - Unix : SYSV,UFS,..
  - Windows: MS-DOS, VFAT, NTFS
  - CD, DVD: ISO9660, UDF,..
  - JFS, XFS,..
- Netzdateisysteme:
  NFS, Coda, AFS,..
- Spezielles Dateisysteme:
  /proc , /sys

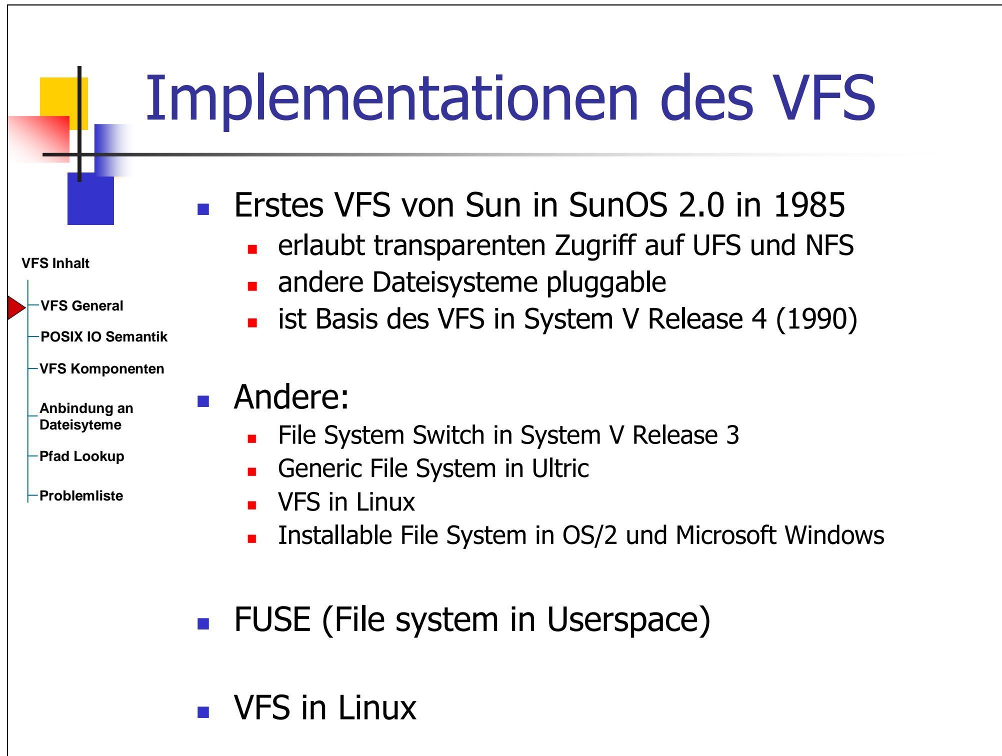

Die Diskussion über VFS in Linux: Wann wurde VFS Linux entwickelt ?

- Im Buch „Linux File Systems“ steht, VFS für Linux kam sehr spät, erst in Version 2.4.0

- Andere Quelle: VFS war bereits bei der Version 1.0 (1994) dabei

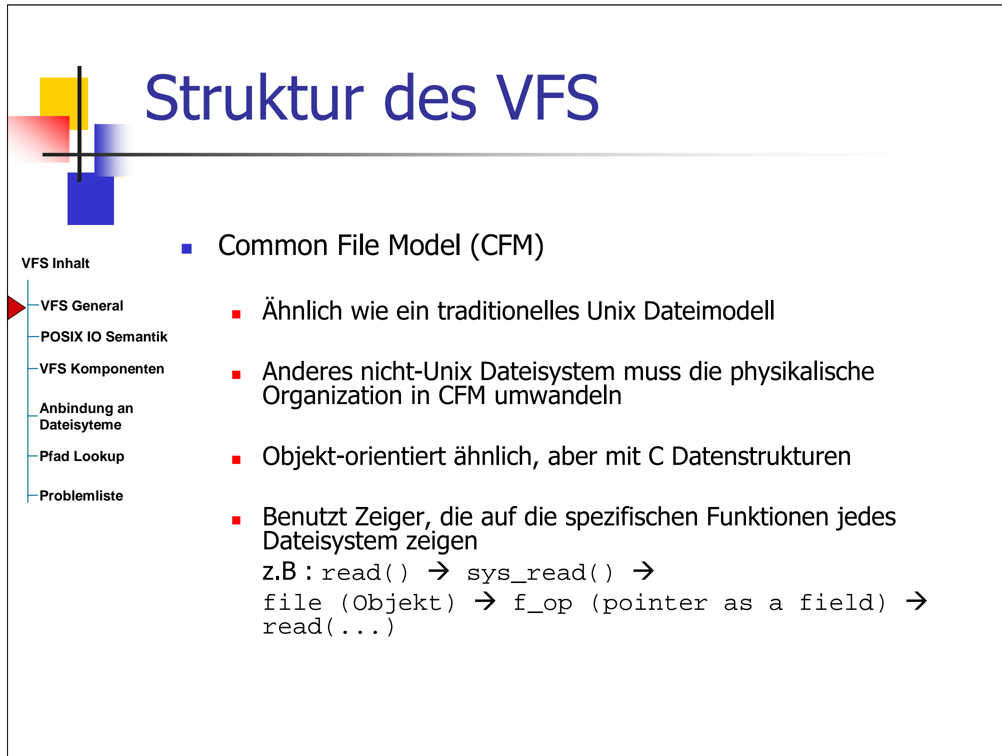

-Common File Model strictly mirrors the file model provided by the traditional Unix system.

-Non-Unix file system : z.B Verzeichnis ist nicht ein File, VFAT, NTFS

-Zeiger: Der Kernel ist verantwortlich dafür, einer Datei beim Öffen die richtige Menge der Pointers zu geben und anhand der Pointers die richtigen Calls aufzurufen

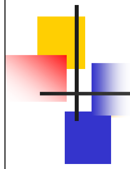

VFS Objekte

VFS Inhalt
- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- Superblock-Objekt
- Inode-Objekt
- Datei-Objekt
- Dentry-Objekt

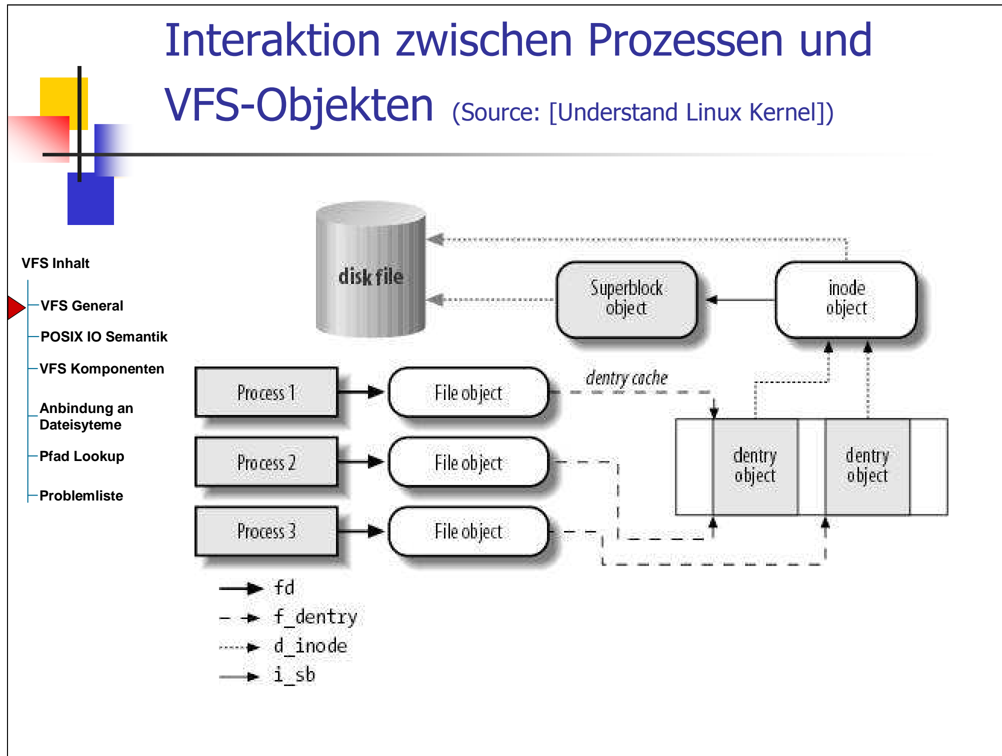

-Wichtige Rolle des VFS mit dentry cache : Speed-up der Transation vom Pfadname zum Inode der letzten Pfadekomponente

-Hier: 3 Prozesse greifen auf dieselbe Datei zu mit 2 hard links. Prozess 1 und 2 benutzen denselben hard link, haben jedoch jeweils ein eigenes Datei-Objekt

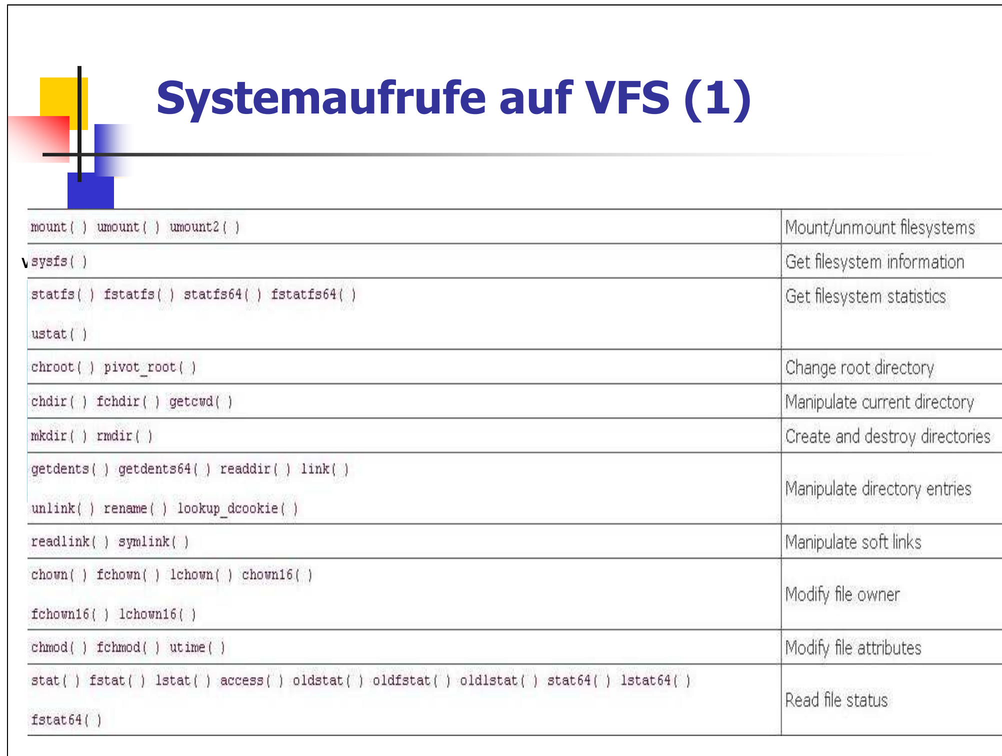

Systemaufrufe auf VFS (1)

System call	Description
mount( ) umount( ) umount2( )	Mount/unmount filesystems
sysfs( )	Get filesystem information
statfs( ) fstatfs( ) statfs64( ) fstatfs64( ) ustat( )	Get filesystem statistics
chroot( ) pivot_root( )	Change root directory
chdir( ) fchdir( ) getcwd( )	Manipulate current directory
mkdir( ) rmdir( )	Create and destroy directories
getdents( ) getdents64( ) readdir( ) link( ) unlink( ) rename( ) lookup_dcookie( )	Manipulate directory entries
readlink( ) symlink( )	Manipulate soft links
chown( ) fchown( ) lchown( ) chown16( ) fchown16( ) lchown16( )	Modify file owner
chmod( ) fchmod( ) utime( )	Modify file attributes
stat( ) fstat( ) lstat( ) access( ) oldstat( ) oldfstat( ) oldlstat( ) stat64( ) lstat64( ) fstat64( )	Read file status

-Außer verteilte und parallele Dateisysteme wie NFS sind diese Aufrufe für andere Dateisysteme unter VFS POSIX-konform

-In einigen Fällen kann VFS die Dateioperationen selbst durchführen, ohne die untere Ebene aufrufen zu müssen.

z.B close(): das Datei-Objekt einfach freigeben. Die eigentliche Datei auf Platte müssen wir nicht anfassen

lseek(): einfach das Feld „pointer“ im Datei-Objekt modifizieren

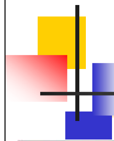

Systemaufrufe auf VFS (2)

open( ) close( ) creat( ) umask( )	Open, close, and create files
dup( ) dup2( ) fcntl( ) fcntl64( )	Manipulate file descriptors
select( ) poll( )	Wait for events on a set of file descriptors
truncate( ) ftruncate( ) truncate64( ) ftruncate64( )	Change file size
lseek( ) _llseek( )	Change file pointer
read( ) write( ) readv( ) writev( ) sendfile( ) sendfile64( ) readahead( )	Carry out file I/O operations
io_setup( ) io_submit( ) io_getevents( ) io_cancel( ) io_destroy( )	Asynchronous I/O (allows multiple outstanding read and write requests)
pread64( ) pwrite64( )	Seek file and access it
mmap( ) mmap2( ) munmap( ) madvise( ) mincore( ) remap_file_pages( )	Handle file memory mapping
fdatasync( ) fsync( ) sync( ) msync( )	Synchronize file data
flock( )	Manipulate file lock
setxattr( ) lsetxattr( ) fsetxattr( ) getxattr( ) lgetxattr( ) fgetxattr( ) listxattr( ) llistxattr( ) flistxattr( ) removexattr( ) lremovexattr( ) fremovexattr( )	Manipulate file extended attributes

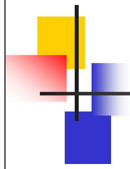

Kapitel 2 : POSIX-I/O

VFS Inhalt
- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- POSIX-I/O-Standard
- Problem mit NFS, und deswegen auch mit VFS

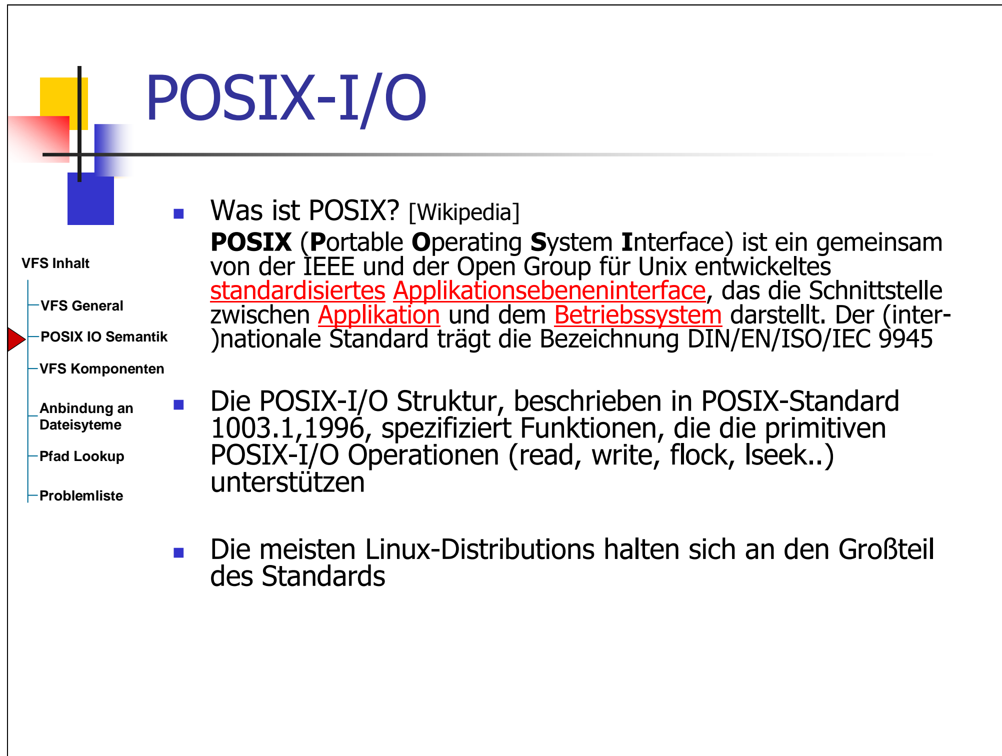

- Außer POSIX-IO-Standard existieren auch noch viele anderen POSIX-Standards wie z.B : Threads-Interface, Real-time-Extensions, Security-Interface, POSIX Command and Utilities, POSIX Comformance Testing,..

Beispiel mit lokalem Dateisystem

VFS Inhalt

- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- (Fast) alle lokale Dateisysteme sind POSIX-konform.
- Z.B: read() & write() synchronisiert, d.h. jeder kann lesen, was die anderen gerade geschrieben haben.
- Z.B write() & write() funktioniert übers File Locking (write-lock, read-lock,..)

- Sind alle Dateisysteme POSIX-konform ??

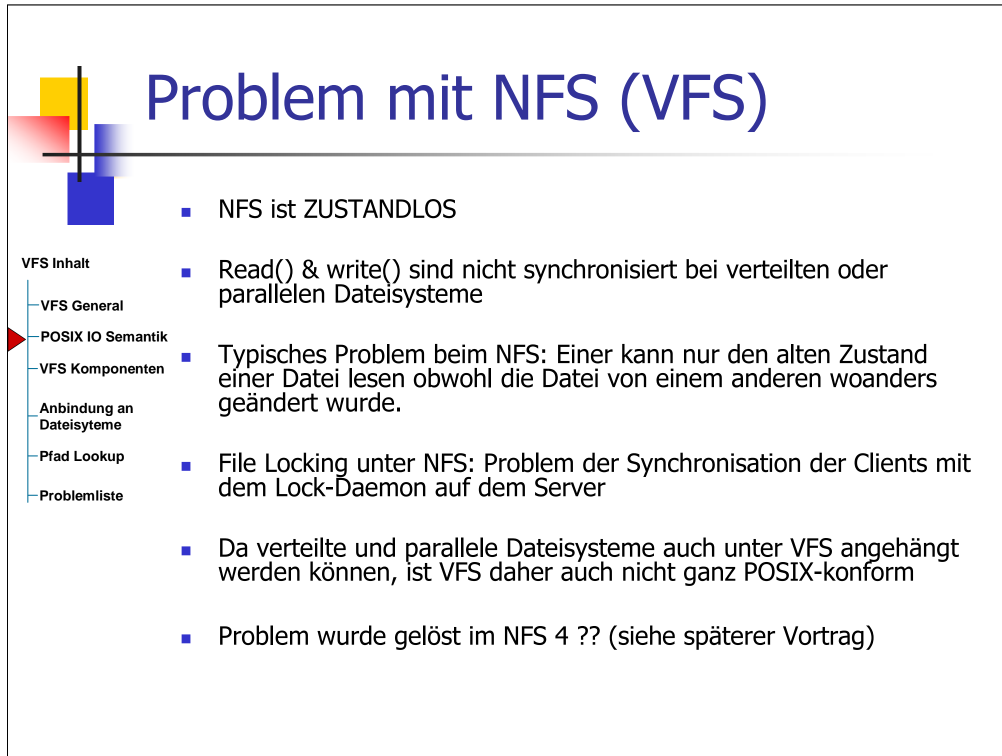

-Problem des Lockings mit NFS : Auf NFS läuft ein Lock-Daemon und wenn ein Client eine Datei sperren will, informiert er den Daemon bescheid. Das Problem ist: was würde passieren wenn der Client abstürzt ? (File ist immer gesperrt), und wenn der Server abstürzt ? (dann denkt der Client immer dass die Datei immer noch für ihn gesperrt wird)

-Im NFS4 wurde wahrscheinlich das Problem von synchron Lesen und Schreiben gelöst, jedoch noch nicht das File Locking Problem

-Im Posix-Standard gibt es auch Standard fürs POSIX-Locking

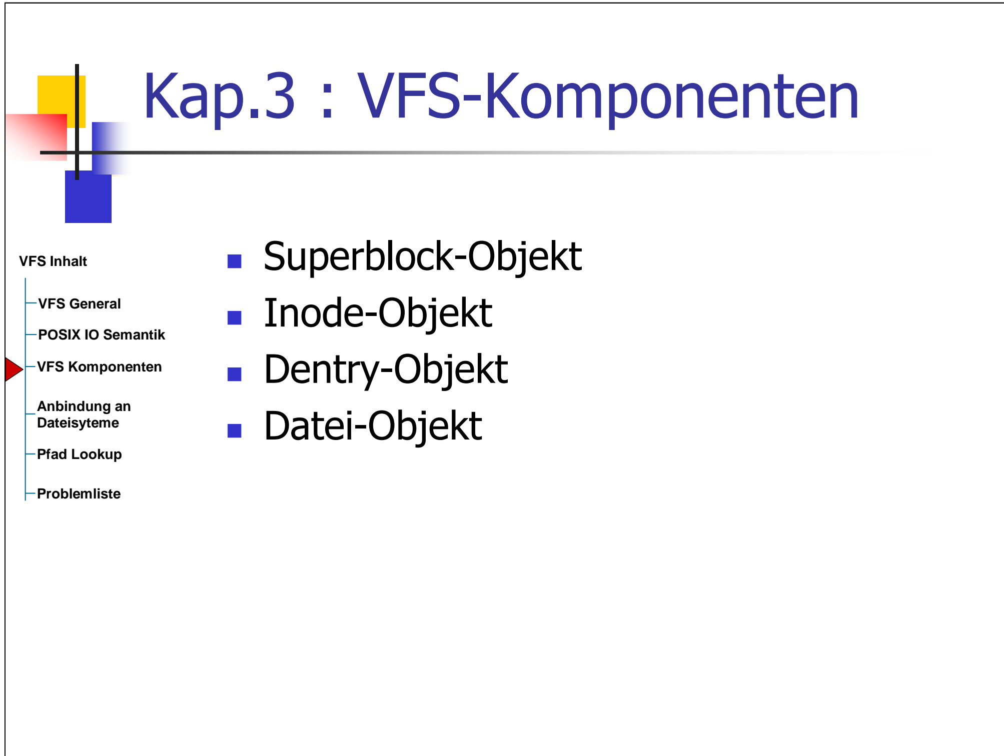

- Diese Objekte haben C Datenstruktur

Superblock-Objekt

VFS Inhalt
- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- Alle Superblock-Objekte in einer Liste
- Objekt wird durch `alloc_super()` beim Mounten erzeugt.
- Repräsentiert die superblock Informationen eines Dateisystems. Das `s_fs_info` zeigt darauf.
  Z.B bei Ext2 zeigt es auf `ext2_sb_info`
- Superblock-Daten werden daher als Duplikat im Speicher gespeichert werden
  → Kein Zugriff nötig für das Update
  → Problem der Synchronisation → Lösung : `s_dirt` Flag
- Das Feld `s_op` zeigt auf die Operationen des Superblock-Objekts (nächste Folie)
- Jedes Dateisystem hat eigene Superblock-Operationen, die aber durch das Feld `s_op` zugegriffen werden können
  Z.B `sb` → `s_op` → `read_inode(inode)`

•Daten von s_fs_info ist Duplikat von Daten auf Platte → wir brauchen keinen Zugriff auf Platte um die Allocations zu aktualisieren

Superblock-Operationen

VFS Inhalt

- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- Einige wichtigen Operationen
  - alloc_inode(sb)
  - destroy_inode(inode)
  - read_inode(inode)
  - dirty_inode(inode)
  - delete_inode(inode)
  - put_super(super)
  - write_super(super)
  - sync_fs(sb,wait)
  - write_super_lockfs(super)
  - unlockfs(super)
  - statfs(super,buf)
  - remount_fs(super,flags,data)
  - umount_begin(super)
  - quota_read(super,type,data,size,offset)
  - quota_write(super,type,data,size,offset)

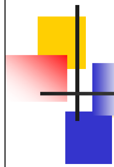

Inode-Objekt

VFS Inhalt

- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- Beinhaltet alle nötigen Informationen einer Datei
- Jede Datei kann verschiedene Dateinamen haben, jedoch nur ein Inode.
- Inode-Objekt hat `inode` Struktur und speichert als Duplikat die Inode-Daten des Dateisystems auf dem Platte.

  Z.B Anzahl der Datenblöcke
- Das Feld `i_state` :
  - `I_DIRTY_SYNC, I_DIRTY_DATASYNC, I_DIRTY_PAGES` : Inode ist „dirty"
    → `I_DIRTY` Macro für das Update
  - `I_LOCK` : Locking
  - `I_CLEAR` : Inode-Inhalt hat keine Bedeutung mehr
  - `I_NEW`: erzeugt aber noch kein Inhalt drin
- Jedes Inode-Objekt wird in einer der folgenden 3 Listen gespeichert
  - List der „unused" Inodes
  - List der „in-use" Inodes
  - List der „dirty" Inodes
- Im Superblock-Objekt gibt's auch das Feld `s_inodes`, das auf die Liste der Inodes zeigt

  Umgekehrt im Inode-Objekt gibt's `i_sb_list`, das auf das Element in der Liste zeigt
- Das Feld `i_op` zeigt auf verschiedene Inode-Operationen

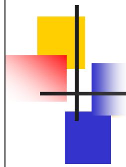

Inode-Operationen

VFS Inhalt
- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- create(dir,dentry,mode,nameidata)
- lookup(dir,dentry,nameidata)
- link(old_dentry,dir,new_dentry)
- unlink(dir,dentry)
- symlink(dir,dentry,symname)
- mkdir(dir,dentry,mode)
- rmdir(dir,dentry)
- mknod(dir,dentry,mode,rdev)
- rename(old_dir,old_dentry,new_dir,new_dentry)
- permission(inode,mask,nameidata)
- setattr(dentry,iattr)
- getattr(mnt,dentry,kstat)

....

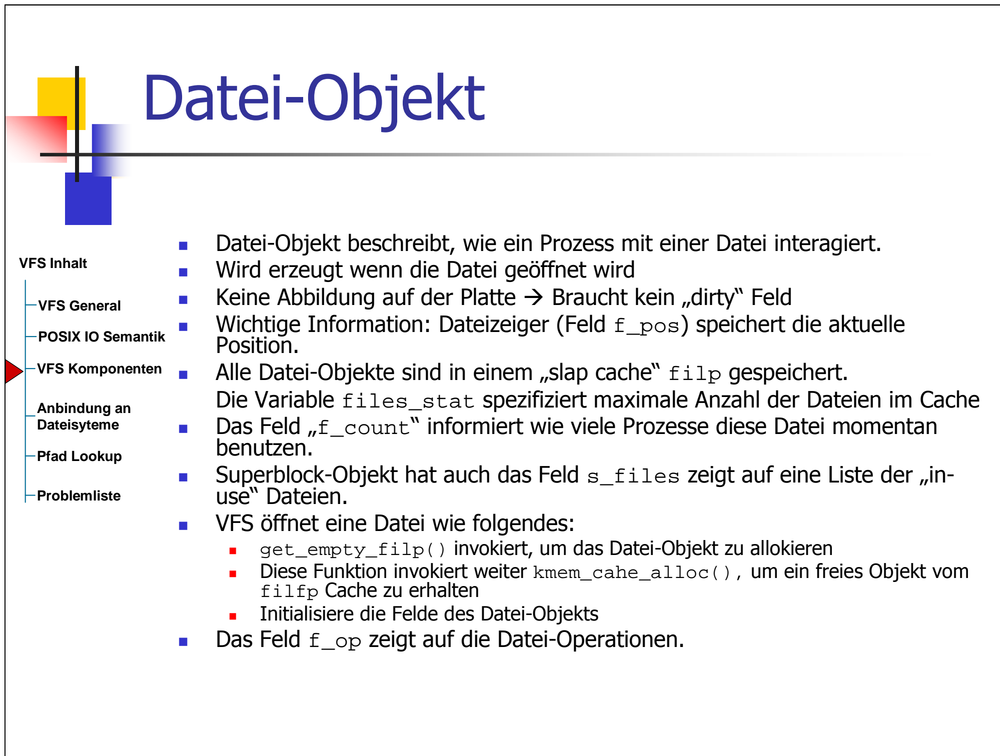

- f_op wurde vom i_fop initialisiert

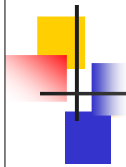

Datei-Operationen

VFS Inhalt
- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- llseek(file,offset,origin)
- read(file,buff,count,offset)
- aio_read(reg,buf,len,pos)
- write(file,buf,count,offset)
- aio_write(reg,buf,len,pos)
- open(inode, file)
- fsync(file,dentry,flag)
- release(inode,file)
- lock(file,cmd,file_lock)

……

Dentry-Objekt

- Spezifiziert die Verknüpfung von einer Datei zu einem Verzeichnis
- Jede Komponente vom Pfadname einer Datei wird zu einem Dentry-Objekt umgesetzt
- Keine Abbildung auf Platte → braucht kein „dirty" Feld
- Dentry-Objekte werden in einem slap-Cache `dentry_cache` gespeichert.

  erzeugt mit `kmem_cache_alloc()`

  gereinigt mit `kmem_cache_free()`
- 4 Zustände der Dentry-Objekte
  - free
  - unused
  - in use
  - negative
- Das Feld `d_op` zeigt auf die Operationen

Dentry-Cache

VFS Inhalt

- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- Problem: Lesen und Konstruieren ein Dentry-Objekt vom Platte langsam
  → halte im Speicher die dentry-Objekte
- Dentry-Cache enthält
  - Eine Liste der Dentry-Objekte in 4 Zuständen
  - Eine Hash-Liste für schnelles Finden der Dentry-Objekte einer Datei und ihres darüberliegenden Verzeichnisses
- Inode-Cache in RAM: hält Inode-Objekte der „unused" Dentry-Objekte im Speicher

Datei & Prozess

VFS Inhalt
- VFS General
- POSIX IO Semantik
- VFS Komponenten
- Anbindung an Dateisyteme
- Pfad Lookup
- Problemliste

- Jeder Prozess hat ein Zeiger `fs` auf eine `fs_struct` Struktur für die Interaktionen mit einem Dateisystem. Einige wichtigen Felder
  - struct dentry* root
  - struct dentry* pwd
  - atomic_t count
  - rwlock_t lock
- Ein anderer Zeiger `files` auf die `files_struct` Struktur spezifiziert welche Dateien momentan von diesem Prozess geöffnet werden
  - int max_fds
  - struct file** fd
  - fd_set * open_fds
  - fd_set open_fds_init
  - struct file*[] fd_array
- Für jede Datei im Array `fd` ist die Arrayindex der Datei-Deskriptor

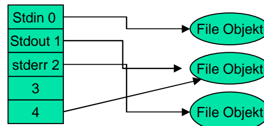

- Prozess greift auf das File Objekt via Datei-Deskriptor zu
  `current → files → fd[fd]`

•Bei der Initialisierung zeigt fd (Zeiger auf Datei-Objekte) auf fd_array und open_fds (Zeiger auf Dateibeschreibung) auf open_fds_init

•Die Anzahl der Datei-Deskriptors ist begrenzt. Jedoch kann der Kernel erweitern wenn nötig.

•Das Feld fd hat als Standard

- 1. Datei-Deskriptor ist stdin

- 2. Datei-Deskriptor ist stdout

- 3. Datei-Deskriptor ist stderr

•2 Indexe von fd können auf dasselbe Objekt zeigen