



# Zentrale Linux-Kernalgorithmen und deren zeitliche Korrelationen

„Unix is simple, but it takes a genius to understand the simplicity.“ — Dennis Ritchie

**Florian Westphal && Hagen Paul Pfeifer**

23. Januar 2006



# Vortragsuebersicht

1. Übersicht
2. IRQs
3. Speicherallokationsfunktionen (`sys_brk(2)` && `sys_mmap(2)`)
4. Page Faults (Seitenfehler)

# Was ist der Inhalt dieses Vortrages?


1. ein genaues Verständniss von zeitlichen Zusammenhängen des Betriebssystems
2. einen Wissensschub für Systemprogrammierer (aber auch Anwendungsentwickler). Warum sollte ich eine Datei lieber sequentiell bearbeiten als komplett wahlfrei? ...
3. Viele bunte Bilder! (Oder warum haben ca. 50% der Zeitschriften Bilder zum Inhalt – oder marginalen Textanteil? Eventuell eine gewisse Ignoranz oder Angst der Leser, komplex anmutende Sachverhalte nachzuvollziehen!?)

# IRQ

- Implementierung: arch-spezifisch
- arch/i386/kernel/irq.c
  - do\_IRQ( ), IRQ-Stack, ...
- entry.S enthält u.a.:
  - Makros zum sichern/wiederherstellen der Register
  - CPU-Exception-Handling (Division durch 0, ...)
- Akzeptable Interrupts:  
include/asm-i386/mach-default/irq\_vectors.h

# IRQ-Management

- Interface: `kernel/irq/manage.c`
- Treiber registriert Handler via `request_irq()`
  - z.B. RTC, Tastatur, Floppy, ...
- Intern:
  - allozieren von `struct irqaction`
  - `setup_irq()` registriert Handler && ggf. irq als Entropiequelle
- Freigabe mit `free_irq()`



# Page Faults

- Pagefault Handler wird bei Bootstrapping registriert  
(arch/i386/kernel/entry.S)
- Hardware Pagefault arch/i386/mm/fault.c:do\_page\_fault()
  1. Adresse wird beschaft (movl \%cr2,)
  2. Unterscheidung ob im KS (vmalloc, etc.)
  3. Nach VMA suchen (find\_vma( ))
  4. Generische Funktion: mm/memory:handle\_mm\_fault()
- mm/memory.c:handle\_mm\_fault()

- 1. pmd\_alloc( ) (Beachten: PAE mode)
  - 2. pte\_alloc\_map( )
- 
- mm/memory.c:handle\_pte\_fault()
    - 1. Demand Allocation (do\_no\_page( ))
    - 2. Demand Pagin (do\_anonymous\_page( ))
    - 3. Swap-In (do\_swap\_page)
    - 4. Nicht lineares mapping (do\_file\_page)
    - 5. COW (do\_wp\_page( ))

# Readahead

- Gemeinsamkeiten: große Textdatei & großes Programm:  
nicht jedes Segment wird immer benötigt → erst in den Speicher  
wenn benötigt (das war das was gerade erklärt wurde: paging! ;-)
- ABER: oft werden Abschnitte sequentielle angesprochen:
  1. .text Segment
  2. Logfile mit dem Lieblingseditor lesen
- ALSO: warum nicht Speicher vorlesen (cachen)(es scheint ja das mit großer Wahrscheinlichkeit er bald benötigt wird)
- WICHTIG: Suchoperationen des Festplatten Schreib- und Lesekopfes sind extrem teuer! Wenn er also schon mal zu Besuch ist soll er mehr als PAGE\_SIZE lesen

- TIPP: um eine Datei in den Buffer Cache zu schieben → `cat big_db` (das ist für Benchmarks wichtig, dann passt auch der wahlfreie Zugriff)

# mmap(2)

- whatis mmap: map or unmap files or devices into memory
- Bei !MAP\_ANONYMOUS → dateispezifischen Funktionen aufrufen
- Ausflug: Was macht exec()? mmapped pages (fs/binfmt\_elf.c:elf\_map korrigiert PAGE Attribute und setzt den %EIP auf Entry Point (naja ein bisschen fehlt noch, besonders wenn ein Interpreter (Link Editor) Verwendung findet ;-)  
`readelf --dynamic /usr/bin/xcruiser`
  1. PROT\_EXEC
  2. PROT\_READ
  3. PROT\_WRITE

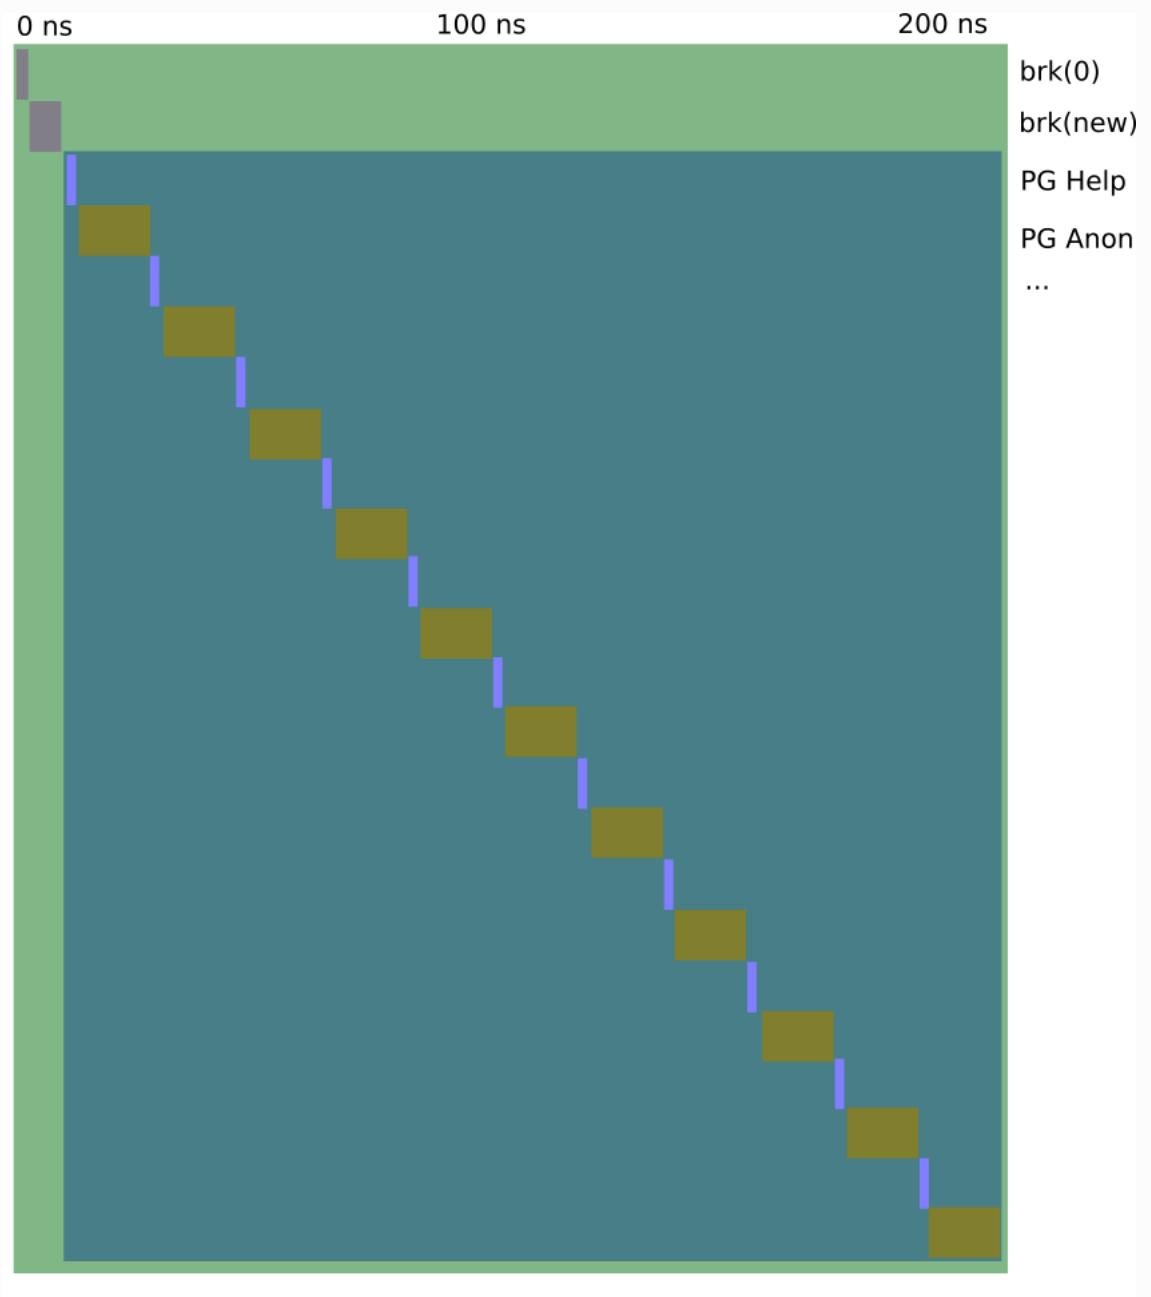
1. MAP\_PRIVATE
  2. MAP\_FIXED
  3. MAP\_DENYWRITE
  4. Beispiel aus den Mapping für den LinkEditor
- 
- Anmerkung: mit diesem Wissen ausgestattet ist es fast möglich ein triviales ABI zu entwerfen **und** zu implementieren (oder ein Userspace ELF loader (ähnlich einer Filesystem Sandbox)!

# **brk(2) versus mmap(2)**

- glibc malloc: dlmalloc
- brk()/mmap allokalieren PAGE\_SIZE große Chunks -> Userspace Implementierung muss sich um Fragmentierung kümmern
- new() ist malloc() welcher auf brk()/mmap() fußt
- /proc/<pid>/ {maps, smaps} als zentrale Informationsstelle für Speicher mappings
- Apropos Mappings: VDSO  
„userland gettimeofday“ (powerpc{32,64})  
Fallback auf syscall implementiert (z.B. interrupt latenz)

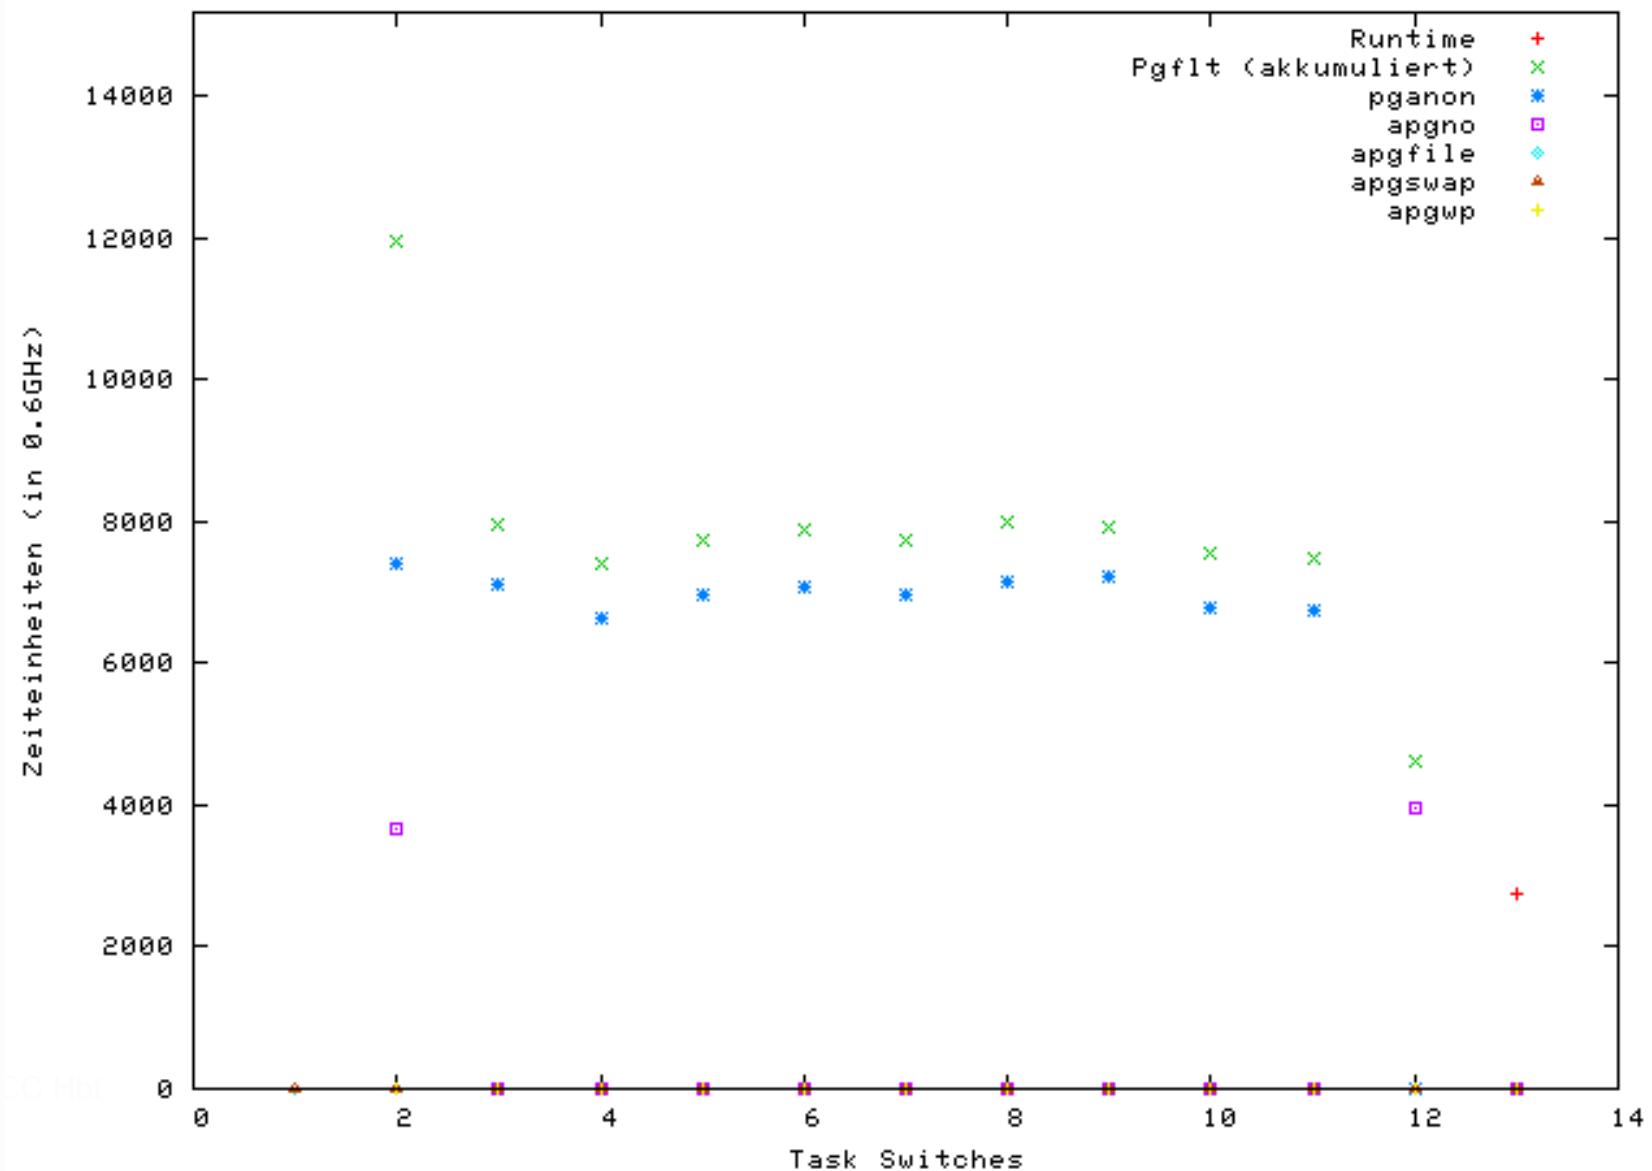
# **brk(2) versus mmap(2)**

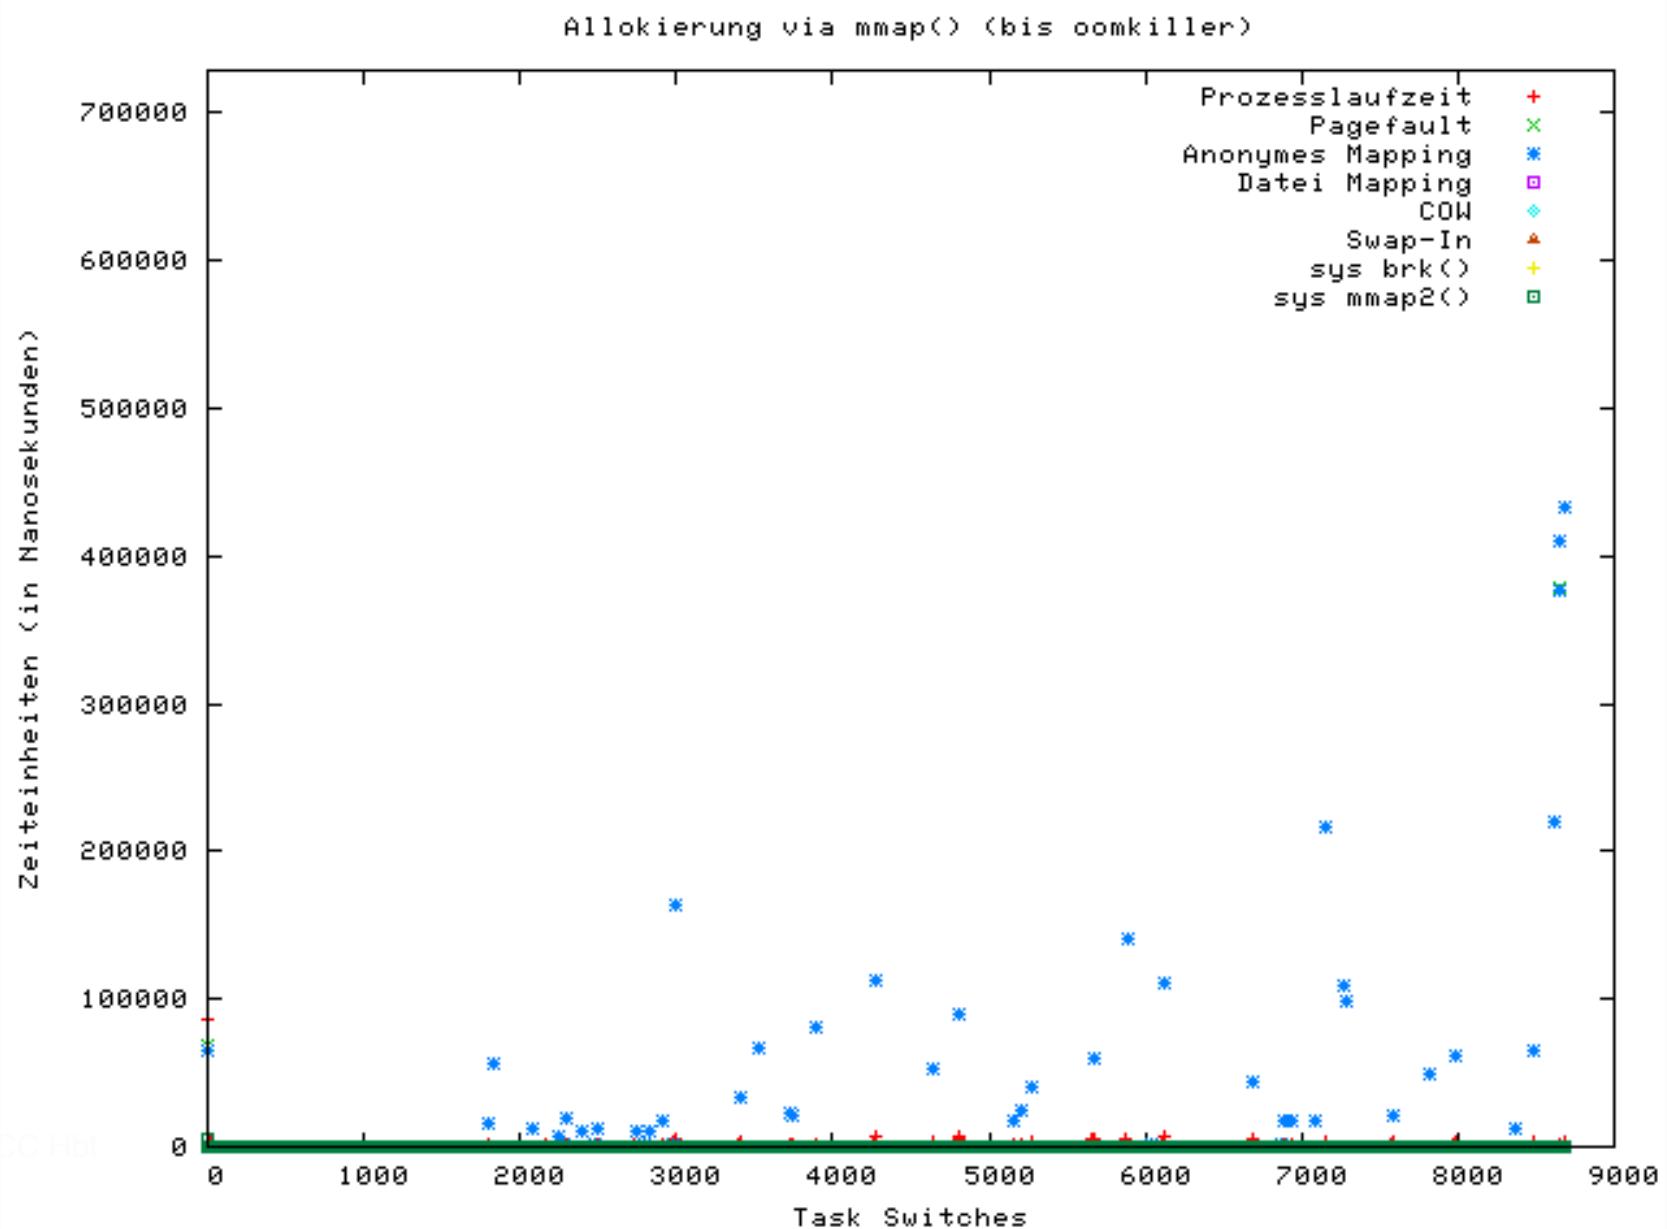
```
[...]
ptr = brk(0);
ptr = brk(ptr + PAGE_SIZE * ALLOC_MULT);
o_ptr = ptr - PAGE_SIZE * ALLOC_MULT;
for (k = 0; k < ALLOC_MULT; k++) {
    memset((o_ptr + ((PAGE_SIZE * (k + 1))) - 10),
           0, sizeof(int));
}
```

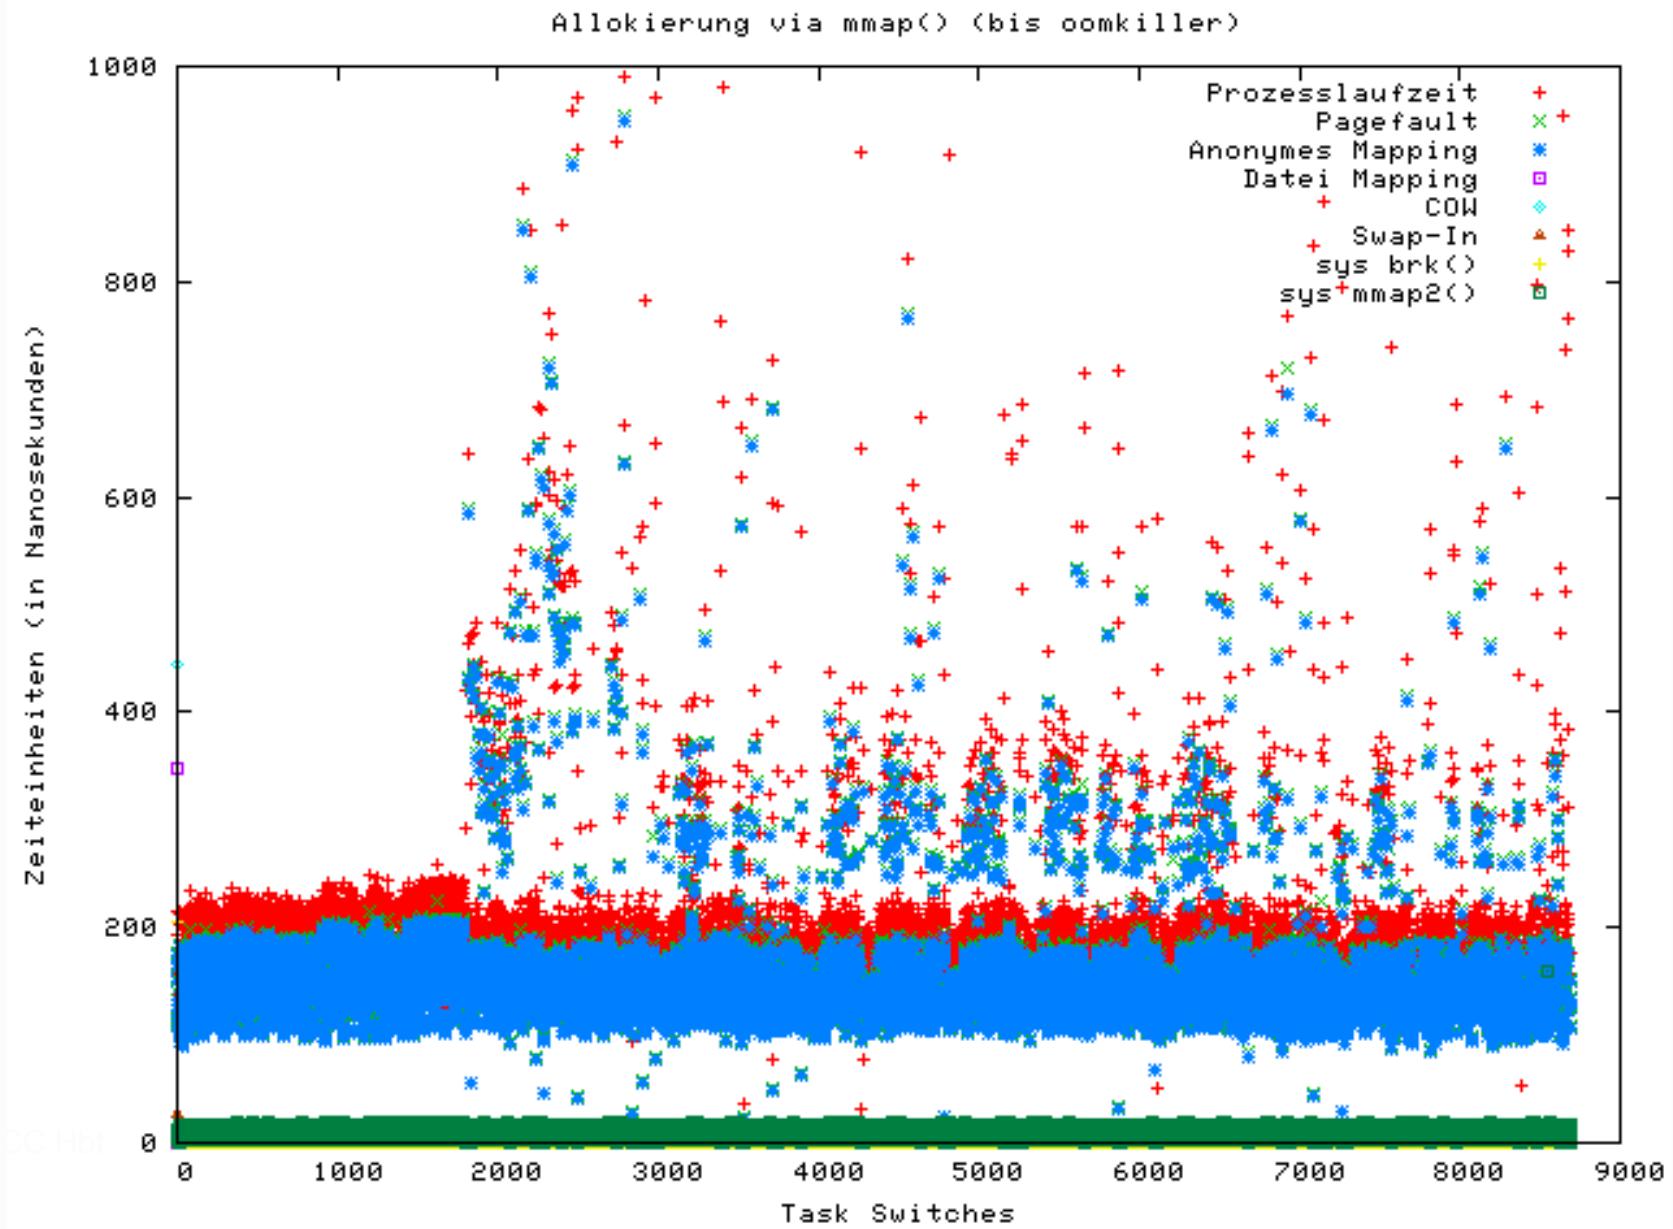


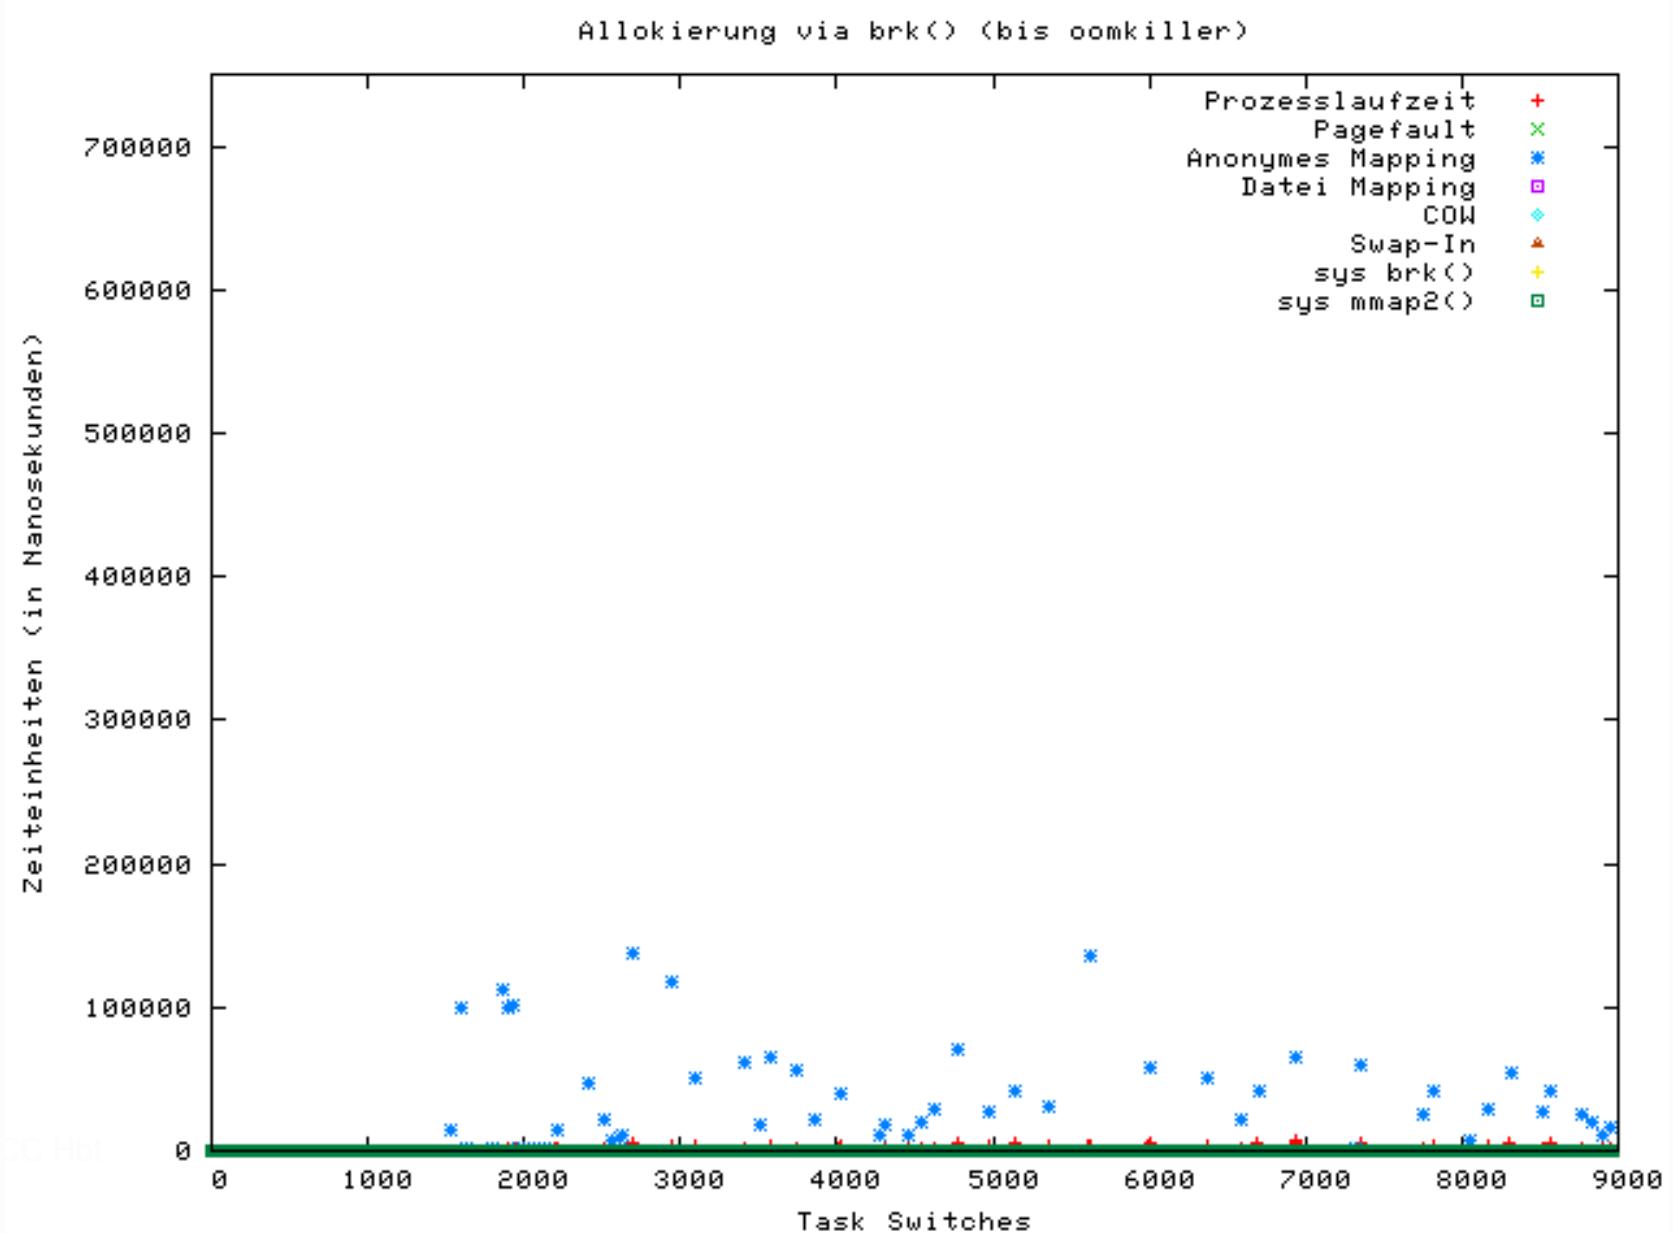
# **brk(2) versus mmap(2)**

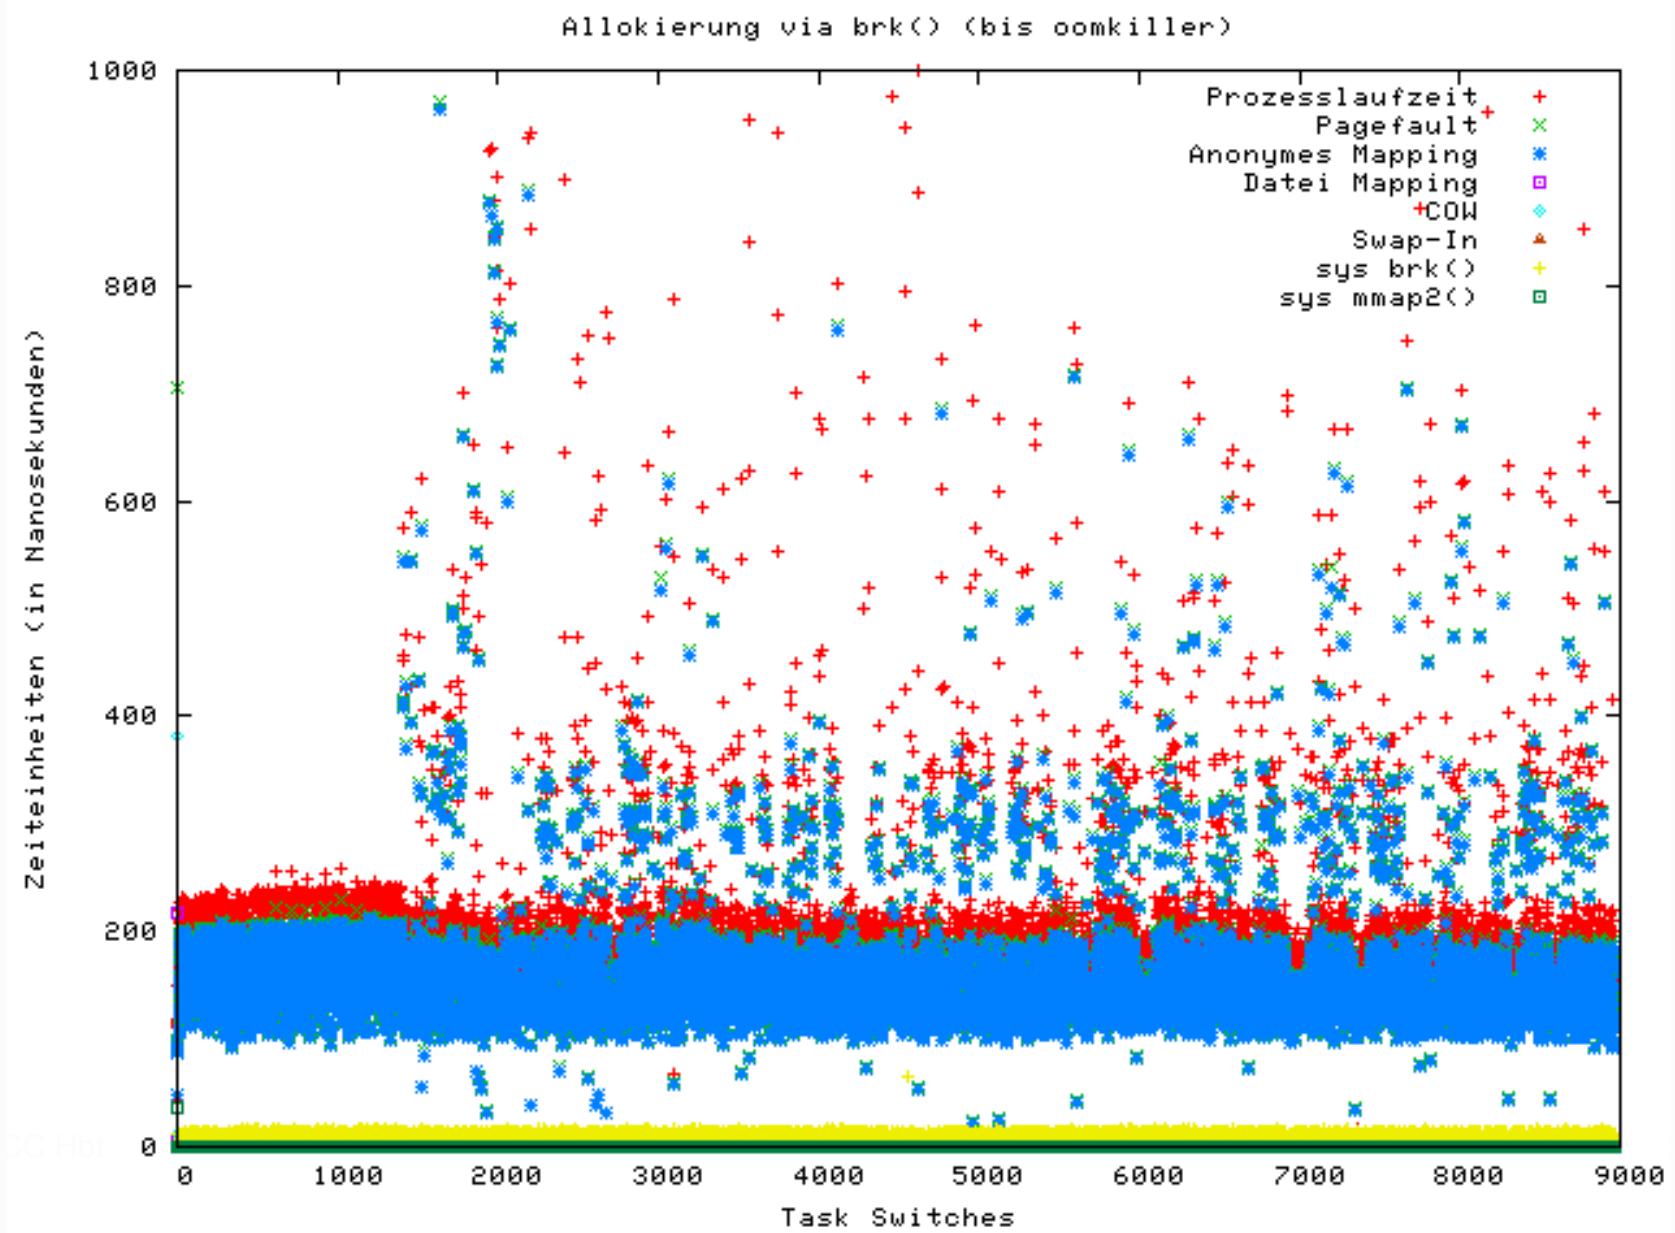
Page Fault Latenz (Allokierung von 2 \* PAGE SIZE)











# Speicher Add-Ons

Java:

- Verwaltet pool aus kleinen, mittleren und grossen Blöcken
- Fallback auf malloc(3)
- By the way:

```
strace java -jar JAP.jar 2>&1 | egrep \
'((.*mmap.*MAP_ANONYMOUS)|(.*brk.*))' - | wc -l
154
```

(ja, auch Java[TM] benötigt Speicher! ;-)(ldd java)

...


```
cat /proc/$(pidof java)/maps | wc -l
```

245

... und mapped eine Menge Bibliotheken! ;-)

- Ansonsten: JRE Quellcode ultra unleserlich (widerlichster C++ Code  
\*wuerg\*

# execve() - Detailliert



# execve() - Detailliert

- Datei öffnen (fs/exec.c)
- CPU Balancing (kleinster Speicher und Cache Penalty)
- MMU Kontext kopieren (nicht Intel; aber ia64 z.B. Feature (asm-ia64/mmu\_context.h))
- fs/exec.c:prepare\_binprm()
  1. Set-uid (mode & S\_ISUID → bprm->e\_uid=inode->i\_uid;)
  2. Zugriffsberechtigungen, 128 byte read()

- fs/exec.c:search\_binary\_handler()
  - elf
  - aout
  - misc
  - script
- fs/binfmt\_elf.c:load\_elf\_binary()
  1. Checks (ist es wirklich ELF)
  2. Program Header einlesen
  3. Iteration über Program Header (nach Interpreter suchen)
  4. Datei Information verwerfen (für current)
  5. Segmente in Speicher mappen (elf\_map())(mit passenden Rechten)
  6. Wenn Interpreter → load\_elf\_interp() (also mappen)
  7. Register setzen → u.a. %esp (include/asm-i386/processor.h:sta...)

8. wie immer: Aussagen verkürzt! '-)

# **madvise() – paging I/O Behandlung**

long

```
sys_madvise(unsigned long start, size_t len_in, int behavi
```

behaviour beschreibt die zu erwartende Nutzung des Speichers

Linux 2.6.15: Unterscheidet 5 Arten:

1. MADV\_NORMAL – Standard-Verhalten
2. MADV\_SEQUENTIAL – Sequentielles lesen
3. MADV\_RANDOM – Zugriffe erfolgen Wahlfrei
4. MADV\_WILLNEED – Baldigen Zugriff erwarten
5. MADV\_DONTNEED – Keine baldigen Zugriffe erwarten

# **madvise\_vma()**

Kernel-Interne Funktion, übernimmt "Verteilung"

```
switch (behavior) {  
    case MADV_NORMAL:  
    case MADV_SEQUENTIAL:  
    case MADV_RANDOM:  
        error = madvise_behavior(vma, prev, start, end, behav  
        break;  
    case MADV_WILLNEED:  
        error = madvise_willneed(vma, prev, start, end);  
        break;  
    case MADV_DONTNEED:  
        error = madvise_dontneed(vma, prev, start, end);  
        break;
```

# Baldiger Zugriff

MADV\_WILLNEED veranlasst eine page-cache readahead-Operation:

```
force_page_cache_readahead(file->f_mapping,  
    file, start, max_sane_readahead(end - start));
```

mm/readahead.c: \_\_do\_page\_cache\_readahead():

Alloziert Speicher für die einzulagernden Seiten, read\_pages() führt Leseoperation durch: mapping->a\_ops->readpage().

# Baldiger Zugriff (cont.)

```
include/linux/fs.h definiert

struct address_space_operations {
    int (*writepage)(struct page *page,
                     struct writeback_control *wbc);
    int (*readpage)(struct file *, struct page *);
    [ .. ]
}

MADV_DONTNEED veranlasst einen Aufruf der zap_page_range()-
Funktion.
```

# **madvise\_ behaviour()**

- Für MADV\_NORMAL, \_SEQUENTIAL, \_RANDOM:
- Kern versucht vma- Strukturen zu optimieren
- \_SEQUENTIAL bzw. \_RANDOM setzen VM\_SEQ\_READbzw. VM RAND READ
- split\_vma / vma\_merge( ) übernehmen Arbeit

# OOM-Killer

`select_bad_process()`: Soll einen geeigneten Prozess zum terminieren auswählen

- Durchläuft Prozessliste für `p->pid > 1`
- Berechnet via `badness()` für jeden Prozess einen Wert
- Durchlauf vorzeitig beendet, wenn:
  - Prozess im Begriff ist Speicher freizugeben (Fehler liefern)
  - Prozess hat `PF_SWAPOFF` gesetzt (wird sofort gewählt)
- `task_struct` mit höchstem Wert wird zurückgeliefert

# OOM-Kill: badness

- Berechnungsgrundlage: Speicherverbrauch
- vmsize von Kindprozessen wird berücksichtigt
- $\text{badness} / \sqrt{cputime}$
- $\text{badness} / \sqrt{\sqrt{run\_time}}$
- Nicewert  $> 0 \rightarrow$  Wert verdoppeln
- Punkte vierteln, Falls Rawio oder euid = 0
- Um oom\_adj Stellen shiften (Normal 0)

# OOM-Kill: Weiterer Ablauf

- Zuerst wird ein Kindprozess des gewählten Prozesses gewählt
- Prozess erhält SIGKILL(\_\_oom\_kill\_task( ) )
- TIF\_MEMDIE wird gesetzt
- Priorität: p->time\_slice = HZ;
- Falls kein Prozess gefunden wird:

```
panic( "Out of memory and no killable processes...\n");
```

# Abstraktion von Filedeskriptoren

- Intern: struct file
  - Enthält struct file\_operations , diese enthält Funktionszeiger auf konkrete Implementierung (read( ), write( ) etc.)
- Prozess besitzt struct files\_struct
  - Verzeichnet alle von Prozess geöffneten Deskriptoren
  - Zusätzliche Daten (FD\_CLOEXEC, spinlock, ...)
- fs/fs\_table.c:fget(unsigned int fd) liefert entsprechende Struktur

# sys\_accept()

Userspace: int clientfd = accept(listenfd, &saddr, &len)

- net/net/socket.c:sys\_accept()
- Zuerst: Ist listenfd ein Socket?
  - fget(listenfd)
  - if (file->f\_op == &socket\_file\_ops)
- newsock=sock\_alloc();
- sock->ops->accept(sock, newsock, sock->file->f\_flags);
- "return sock\_map\_fd()" (get\_unused\_fd(), filep, ...)

# inet\_accept()

inet/ipv4/af\_inet.c:inet\_accept(): Abstrahiert AF\_INET  
Etablierte, aber noch nicht im Userspace bekannte TCP-Verbindungen  
stehen in FIFO-artiger Queue

```
net/ipv4/inet_connection_sock.c:  
struct sock *  
inet_csk_accept(struct sock *sk, int flags, int *err)
```

... kontrolliert ob queue leer ist:

- Nein: älteste sock-Struktur aus Queue entfernen
- Ja: inet\_csk\_wait\_for\_connect() → TASK\_INTERRUPTIBLE

Links:

Kernel Code Browser: <http://lxr.linux.no/>

# **Das Allerletzte / Linux Intern**

```
$ cd /usr/src/linux &&  
$ egrep -ri \  
'(fixme|xxx|crap|junk|shit|fuck|broken|b0rken)' * \  
| wc -l  
23075
```

# FIN

- Fragen/Anmerkungen/Pizza/Bier
- ```
if(current == rq->idle) {
    /* Hagen Paul Pfeifer <hagen@jauu.net> */
    /* KeyID: 0x98350C22 */
    /* Florian Westphal <fw@strlen.de> */
    /* KeyID: 0xF260502D */
    panic( "additional information needed" );
}
```