Netzwerk-Programmiermodelle und I/O Optimierungen für Unix Betriebssyteme

Hagen Paul Pfeifer • Florian Westphal
hagen@jauu.net fw@strlen.de

http://www.protocol-laboratories.net

14. Oktober 2006

Vortragsfahrplan

1. Programmiermodelle
   - Asynchrone I/O, fork(), threads, select(), poll()
     /dev/poll, epoll, kqueue, kevent
2. I/O Optimierungen
   - Zero-Copy, Read-Write, Mmap, Sendfile, Splice und Tee
3. Kernelspace Optimierungen
   - NAPI
   - Dynamic Right Sizing

Kapitel 1
Programmiermodelle

Server/Client Programmiermodelle

- `fork()`: Ein Prozess pro Client. Vorteile:
  - Einfache Programmierung (z.B.: Fehlerhandling mit `_exit()`)
  - Gesamt-System weniger Fehleranfällig
- Design ist von Nachteil, wenn:
  - . . . Prozesse untereinander kommunizieren müssen
  - . . . viele Clients (> 1000) zu erwarten sind
- Overhead durch `fork()`,`_exit()`,`waitpid()`
- Performance sehr vom Scheduler abhängig (Linux 2.4: $O(n)$, 2.6: $O(1)$)

Server/Client Programmiermodelle

- Ein Thread pro Client. Vorteile:
  - Threaderzeugung meist schneller als `fork()`(Linux 2.6: ca. $\frac{1}{16} CPU Zyklen)$
  - Programmiermodell dem zu `fork` sehr ähnlich
- Nachteile:
  - Bei gemeinsam genutzten Daten ist Synchronisation notwendig
- Performance von Scheduler und Thread-Modell ($m : n$, $1 : 1$) abhängig

Server/Client Programmiermodelle

- Multiplexer: Ein Prozess/Thread für mehrere (oder alle) Clients. Zwei Möglichkeiten:
  1. Level-Triggered: (”Readiness Notification”)
     - fd wird gemeldet, sobald er bereit ist: `select`, `poll`, Async I/O, etc.
  2. Edge-Triggered: (”Change Notification”)
     - fd wird nur gemeldet, wenn eine Zustandsänderung eintritt
       z.B. Linux RT-Signals; Optional: `epoll`, `kqueue`, Async I/O

Asynchrone I/O

- Vorgehen:
  - `struct aiocb` mit Deskriptor+buffer+Länge
  - `aio_read`, `aio_write` etc. starten Schreib/Lesevorgang
  - I/O läuft ”im Hintergrund” ab, Mitteilung wann beendet entweder mittels Signal oder Polling (`aio_suspend`)

  Nachteil: Auch `open()` kann blockieren; `aio_open` nicht existent
  Alternative: Worker Threads

Multiplexing-Mechanismen: select

- ”Der Klassiker:” 4.2 BSD (1983)

```
int select(int nfds, fd_set *readfds, fd_set *writefds,
           fd_set *exceptfds, struct timeval *timeout);
```

  - Gewöhnungsbedürftiges API (nfds: Anzahl zu untersuchender Bits)
  - nur Deskriptoren kleiner `FD_SETSIZE` erlaubt
  - manche Systeme (Linux) erfordern `O_NONBLOCK` für alle fd

- Am weitesten Verbreitet (Sogar unter Winsock verfügbar . . .)

Multiplexing-Mechanismen: poll

- SVR3 (1986)

```
struct pollfd {
    int   fd;
    short events;
    short revents;
};
int poll(struct pollfd p[], nfds_t nfds, int timeout);
```

  - manche Systeme (Linux) erfordern `O_NONBLOCK` für alle fd
  - Array bei vielen Veränderungen der Größe ungünstig
  - `pollfd[]` muss bei jedem Syscall zweifach kopiert werden

Probleme

- Probleme:
  - ”Doppelte Arbeit”: Applikation und Kernel verwalten dieselben Informationen
  - Lineare Suche im `pollfds` Array (`poll`)
  - Man erhält stets auch alle ”ereignislosen” Deskriptoren
- Wünschenswert:
  - Man erhält nur noch Deskriptoren, die für die gewünschte Operation zu Verfügung stehen

SunOS: /dev/poll

- /dev/poll:
  - setzt auf `poll()` auf, neue Gerätedatei `/dev/poll`
  - Behandlung mit ”alten” Syscalls: `open, read, write`
- Vorgehen:
  - `int fd = open("/dev/poll", O_RDWR);`
  - `pollfd` Struktur(en) initialisieren und nach `fd` schreiben
  - via `ioctl()` auf Ereignisse warten
  - Relevante `pollfd` Strukturen werden in Userspace Buffer kopiert

Linux 2.6: epoll

- Erster Patch: Linux 2.5.44 (2002)
- Neues API: 3 neue Syscalls

```
struct epoll_event{uint32_t events;
                   epoll_data_t data;}
```

- Level oder (optional) Edge Triggered
- letztes `close()` auf fd entfernt diesen Automatisch

epoll: Vorgehen

- `int efd = epoll_create(hint);`
- `epoll_event` initialisieren;
  z.B `epoll_event e = { .events = EPOLLIN };`
- hinzufügen: `epoll_ctl(efd, EPOLL_CTL_ADD, fd, &e);`
- Mit `epoll_wait` auf Ereignisse warten
- Edge-Triggered verhalten kann pro fd eingeschaltet werden: `e.events |= EPOLLET;`

*BSD: kqueue

- FreeBSD 4.1 (2000), OpenBSD 3.5 (2004), NetBSD 2.0 (Dez. 2004)

```
struct kevent {
    uintptr_t ident;  /* identifier for this event */
    short     filter; /* filter for event */
    u_short   flags;  /* action flags for kqueue */
    u_int     fflags; /* filter flag value */
    intptr_t  data;   /* filter data value */
    void      *udata; /* opaque user data identifier */
};
```

- 2 Syscalls, ein Makro
- Filterkonzept: u.a. für Timer und Signale

Vorgehen

- `int kfd = kqueue()`
- `struct kevent` initialisieren, z.B.
  `EV_SET(&kev, fd, EV-`
  `FILT_READ,EV_ADD|EV_ENABLE, 0, 0, 0);`
- `kevent()` aktualisiert fd set und/oder wartet auf Ereignisse

Kevent

- Linux hat kein einheitlichen Mechanismus auf `Events` zu reagieren
- Ziel: möglichst viele Event so schnell wie möglich zu bearbeiten mit wenig System-Overhead
- Probleme bei asynchronen I/O
- Evgeniy Polyakov Patch - kevent
- Kombination und Ideen aus AIO/kqueue Interface
- Ringpuffer welcher ge`mmap()`ed wird
- kvent kann auf folgende Ereignisse reagieren:
  - Alles was `poll()` abdeckt `KEVENT_POLL`
  - Neue Netzwerk-Daten oder Verbindungen `KEVENT_SOCKET`

- `inotify()` Ereignisse `KEVENT_INODE`
- Netzwerk asynchrone I/O Ereignisse `KEVENT_NAIO`
- Timer Ereignisse `KEVENT_TIMER`

- Erste Zahlen (httperf, 40K Verbindungen):
  - `kevent`: 3388.4 req/s
  - `epoll` und `kevent_poll` 2200-2500 req/s

Zusammenfassung

- Alternativen gegeneinander abwägen
  - Protokoll, Zugriffsmuster
  - Betriebssystem(e), Portabilität
- `select`: portabelste Schnittstelle, aber Problematisch bei vielen Deskriptoren
- `poll` : Array; lineare Suche; Array muss verwaltet werden
- Alternativen sind Systemspezifisch (Wrapperbibliotheken wie libevent exisitieren)
- KISS – `fork()` kann Durchaus Mittel der Wahl sein!

Kapitel 2
I/O Optimierungen

Zero-Copy

- Typische Lehrbuch-Serveranwendung:

```
while((cnt = read(filefd, buf, buflen)) > 0) {
        char *bufptr = buf;
        do {
                ssize_t written = write(socket, bufptr, cnt);
                /* handle errors, if any ... */
                cnt    -= written;
                bufptr += written;
        } while (cnt > 0);
}
```

Zero-Copy

- Positiv: einfach und portabel
- Negativ: nicht wirklich Performant
  1. Kopieraktion hohe Kosten
  2. Syscalls verursachen weiteren Overhead
  3. Kontext-Wechsel:
     - Register sichern
     - Cache konsistent mit VM-Mappings, bei neuen VM-Mapping -> TLB flushen, (invXpg)
     - Kein neues VM-Mapping: Kernel-Thread oder US-Threads
     - Einige Architekturen müssen auch Cache flushen (x86: NULL-Makro)

- Cold Caches

4. Information Bonbon:

```
(microseconds, lmbench, v2.6.10)
cpu             clock speed     context switch
pentium-M       1.8GHz          0.890
dual-Xeon       2GHz            7.430
Xscale          700MHz          108.2
dual 970FX      1.8GHz          5.850
ppc 7447        1GHz            1.720
```

Read() - Write()

- Read-Write näher betrachtet:

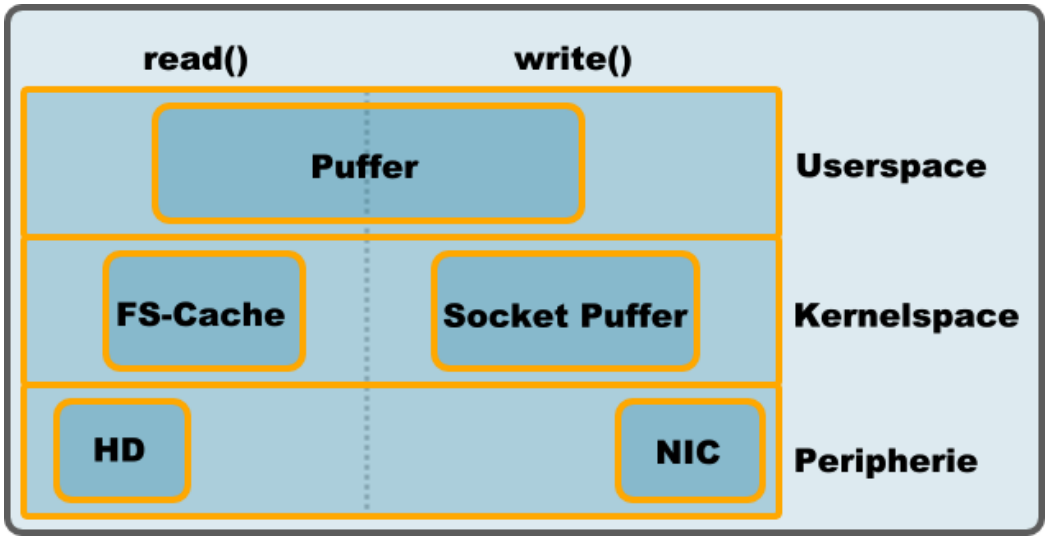

- Speicher muss vier mal kopiert werden (nicht nötig)
- Vier Kontext-Switches
- Von Festplatte und nach NIC normalerweise via DMA

Mmap()

- Mmap-Write näher betrachtet:

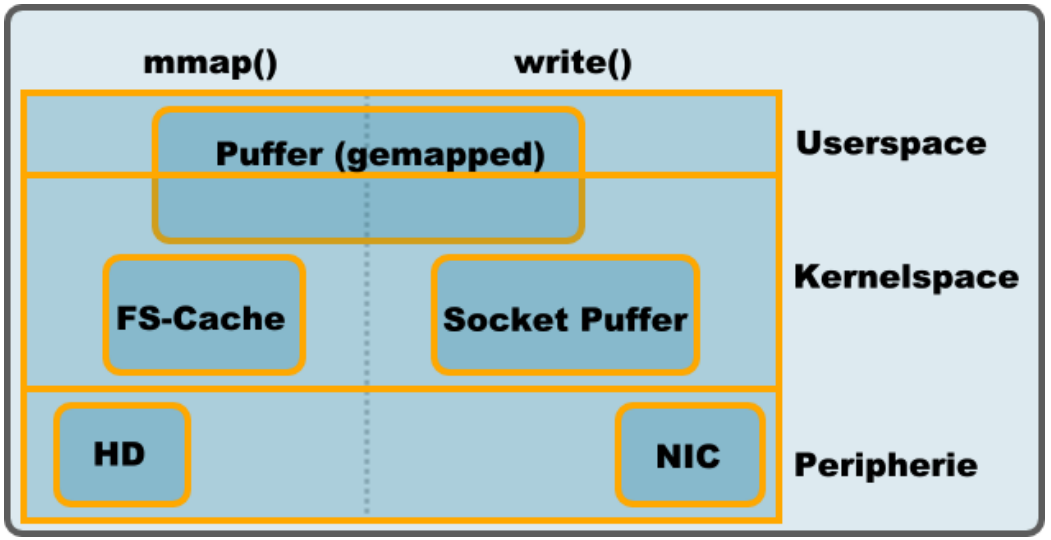

- Auch vier Kontext-Switches
- Aber: Kernelpuffer wird geteilt mit Userspace
- Zwei mal DMA Transfer, Ein mal CPU-Transfer
- Problem: anderer Prozeß stutzt Datei (`SIGBUS`, `RT_SIGNAL_LEASE`)

Sendfile

- `ssize_t sendfile(int out_fd, int in_fd, off_t *off-set, size_t count);`

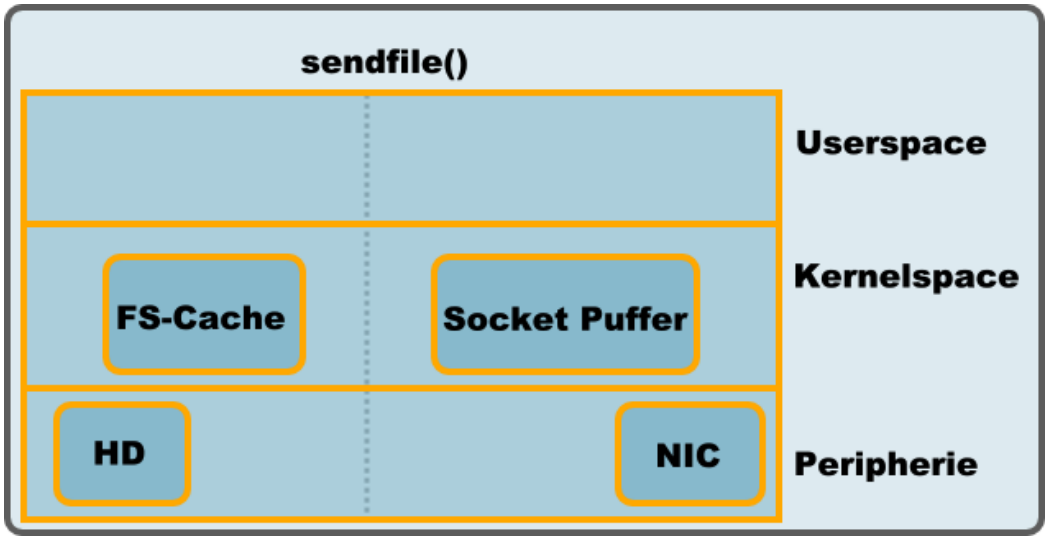

- Ein Kontextwechsel
- Zwei mal DMA Transfer, Ein mal CPU-Transfer
- Nicht portabel (Prototyp unterscheidet sich)
- Wenige Anwendungen nutzen sendfile

(man munkelt Linux hat sendfile nur Aufgrund von Druck der Apache-Gemeinde ;-)

Sendfile (Scatter/Gather IO)

- Wie `vanilla` sendfile, aber CPU-Kopie entfällt
- Kein kontinuirlicher Speicherbereich benötigt (Header, Payload)
- `sk_buff` enthählt Zeiger auf Datenbereich (FS-Cache) (Analogie: writev)
- `dev->feature |= NETIF_F_SG` (linux/netdevice.h)
- Vorteile:
  - komplette Kopiervorgang kann eingespart werden
  - *-Cache wird nicht „verunreinigt“
- 3Com (3CR990 Family): 16 SG-Einträge

Sendfile unter Solaris/BSD/Windows

- Solaris
  - `sendfile()` und `sendfilev()`
- Microsoft Windows
  - `TransferFile()`

Abstecher: madvise

- `int madvise(void *start, size_t length, int advice);`
- Gibt BS Tipp wie Speicherbereich gelesen/verwendet wird
- `MADV_RANDOM, MADV_SEQUENTIAL, MADV_DONTNEED`
- `fadvise()` Pendant für Dateien
- `readahead()`

Sendfile und TCP_CORK

- Oft: generierter Header und Datei als Daten (HTTP)
- Zwei `write()` generieren zwei Pakete (oft)

```
setsockopt(fd, IPPROTO_TCP, TCP_CORK, &on, sizeof(on));
write(fd, http_header, strlen(header));
sendfile(fd, file_fd, &offset, nbytes);
setsockopt(sock, IPPROTO_TCP, TCP_CORK, &off, sizeof(off));
```

- `TCP_CORK` off: Flushed Puffer sofort
- BSD, OS X: `TCP_NOPUSH`
- Portabler: (und nur ein Systemaufruf)

```
struct iovec { void *iov_base;size_t iov_len; };
ssize_t writev(int fd, const struct iovec *vector,
                                        int count);
```

Splice und Tee

- Splice
  - `long splice(int, loff_t, int, loff_t, size_t, unsigned int);`
  - Kernelspeicher im KS für US (Userpipe im KS)
  - Userspace hat Kontrolle über diesem Bereich
  - Bewegt Daten von/nach dem Puffer nach/von Deskriptor
  - Im-Kernel Ersatz für `read/write` zum Puffer
  - Nur wenn keine Bearbeitung am Daten
  - Steigerung der Datentransferrate um bis 70% und 50% CPU
  - Asynchron: SIGIO via `fcntl(2)`

- Neu in `2.6.17-rc1`
- Anwendungen:
  - Socket zu Socket (redirect)
  - Datei nach Datei

Tee

- `long tee(int, int, size_t, unsigned int);`
- Kopiert Daten im KS-Puffer
- `memcpy()` von Kernelpuffer zu Kernelpuffer
- Anwendungen:
  - MPEG-Stream nach Datei **und** Socket
- `tee(1)` Pseudo-Implemntierung

```
while(1) {
        tee(STDIN_FILENO, STDOUT_FILENO, ...);
```

```
        splice(STDIN_FILENO, filefd, ...)
}
```

Kapitel 3
Kernelspace Optimierungen

NAPI

- Ansatz um Netzwerkperformance Performance zu erhöhen
- Problem: Overhead bei Interrupts
- Ansatz:
  - Interrupt startet Verarbeitungsroutine
  - Interrupts werden gesperrt (`Softirq`
  - `dev->poll()` verarbeitet alle Pakete im Ring-Puffer
- Weniger Interrupts, weniger Unterbrechungen
- 1Gbit NIC: 12 μs
- Aber: moderne NIC's Interrups Moderation
- Tipp: e1000 Implementierung

Dynamic Right Sizing

- Empfangspuffer konservative Größe (Embedded Geräte)
- Anpassungen des Empfang- und Sendpuffer
- Problem bei `LFN` (Bandbreiten-Verzöerungs Produkt)
- Weg von manuellen anpassen der Puffer (`setsockopt()`)
- Ziel:
  - Netzwerk-Pipe voll
  - Möglichst wenig Kernelspeicher (Problem: 10k Verbindungen)

Tunnig Tipps

- Für die Netzwerkhacker mit GE

```
ifconfig eth0 mtu 9000
sysctl -w net.ipv4.tcp_sack=0
sysctl -w net.ipv4.tcp_timestamps=0
sysctl -w net.core.rmem_max=524287
sysctl -w net.core.wmem_max=524287
sysctl -w net.core.optmem_max=524287
sysctl -w net.core.netdev_max_backlog=300000
sysctl -w net.ipv4.tcp_rmem="10000000 10000000 10000000"
sysctl -w net.ipv4.tcp_wmem="10000000 10000000 10000000"
sysctl -w net.ipv4.tcp_mem="10000000 10000000 10000000"
sysctl -w net.ipv4.tcp_tw_recycle=1
sysctl -w net.ipv4.tcp_tw_reuse=1
```

Kapitel 4
Prolog

Optimierungs Baustellen

- TCP Metrics (Linux)
- Plugable TCP Congestion Control
- TOE - TCP Offload Engine
- TCP Segmentation Offloading (TSO)
- Net Channels - Van Jacobson
- FireEngine (Solaris)

Weitererführende Links, Quellen

- `man select poll epoll kqueue ...`
- Dan Kegels ”The C10K problem”
  `http://www.kegel.com/c10k.html`
- `libevent, http://www.monkey.org/~provos/libevent/`
- `http://people.freebsd.org/~jlemon/papers/kqueue.pdf`
- Stevens, Rago: ”Advanced Programming in the Unix Environment”
- Stevens: ”UNIX Network Programming, The Sockets Networking”
- McKusick, Neville-Neil ”The Design and Implementation of the FreeBSD Operating System”
- Dynamic Right Sizing:

http://woozle.org/~mfisk/papers/tcpwindow-lacsi.pdf

- INVLPG:
  http://www.cs.tut.fi/~siponen/upros/intel/instr/invlpg

FIN

- Danke für eure Aufmerksamkeit!
- Fragen – Anregungen – Bemerkungen?
- EMail: hagen@jauu.net
  - Key-ID: `0x98350C22`
  - Fingerprint: `490F 557B 6C48 6D7E 5706 2EA2 4A22 8D45 9835 0C22`
- EMail: fw@strlen.de
  - Key-ID: `0xF260502D`
  - Fingerprint: `1C81 1AD5 EA8F 3047 7555  E8EE 5E2F DA6C F260 502D`