

Systemprogrammierung

Foliensatz D

- Fortgeschrittene I/O

Prof. Dr. Hans-Georg Eßer

Wintersemester 2023/24

v1.0 – 08.11.2023



Fortgeschrittene I/O

- File Descriptors für Standard-I/O
- Standard-Eingabe und -ausgabe umleiten, `dup()`, `dup2()`
- Pipes
- Offene Dateien und `exec()`
- I/O Multiplexing mit `select()`
- Memory Mapped Files: `mmap()`



File Descriptors für Standard-I/O

- Jeder (normale) Prozess besitzt beim Start drei Datei-Deskriptoren für
 - Standardeingabe (STDIN, 0)
 - Standardausgabe (STDOUT, 1)
 - Standardfehlerausgabe (STDERR, 2)
- Zugriff darauf mit `read` / `write` wie bei anderen Dateien möglich, z. B.
 - `read (STDIN_FILENO, &buf, len)`: lesen aus Terminal
 - `write (STDOUT_FILENO, &buf, len)`: schreiben auf Terminal



dup2()

- dup2() leitet einen File Descriptor auf einen anderen um
- häufige Anwendung: stdin/stdout „umbiegen“
- dup2(fd1, fd2);
 - schließt die mit fd2 verbundene Datei
 - Ein-/ Ausgabe-Anforderungen, die an fd2 geschickt werden, landen in fd1

```
#include <stdio.h>
#include <fcntl.h>
int main() {
    int fd = creat("/tmp/out.txt",
                  S_IRUSR | S_IWUSR);
    // stdout -> /tmp/out.txt umleiten
    dup2(fd, 1);
    printf("Hallo, Test\n");
    return 0;
};
```

- stderr auf stdout umleiten: dup2(1,2);

dup()

- dup() kopiert einen File Descriptor und verwendet für die Kopie den kleinsten freien fd:
- int fd2 = dup (fd1);
 - Ein-/ Ausgabe-Anforderungen, die an fd2 geschickt werden, landen in fd1

```
#include <stdio.h>
#include <fcntl.h>
int main () {
    int fd;
    fd = creat ("/tmp/out.txt",
               S_IRUSR | S_IWUSR);

    // stdout schliessen
    close (1);

    // stdout -> /tmp/out.txt
    dup (fd); close (fd);

    printf ("Hallo, Test\n");
    return 0;
};
```

Pipes

- aus der Shell bekannt:
 - Verknüpfung von Std.-Ausgabe eines Prozesses mit Std.-Eingabe eines weiteren
 - prog1 | prog2
- In C-Programmen: pipe() und Umleiten der File Descriptors für stdin bzw. stdout
- erzeugt zwei File Descriptors für (gemeinsame) Pipe: mit dem ersten „Ende“ lesen, mit dem zweiten schreiben

Pipes

- Implementierung der Shell-Funktion `prog1 | prog2:`
 - `pipe(fds)`, `fork()`
 - im 1. Kind:
 - `dup2 (fds[1], 1) (stdout)`
 - `fds[0], fds[1] schließen, exec()`
 - `fork()`
 - im 2. Kind:
 - `dup2 (fds[0], 0) (stdin)`
 - `fds[0], fds[1] schließen, exec()`
 - `fds[0], fds[1] schließen, 2x wait()`

Pipes in C: 2 Prozesse

```
#include <unistd.h>
#include <sys/types.h>
#include <sys/wait.h>
#include <stdio.h>

// implements: ls -al | grep a.out

int main () {
    int pipe_fds[2];
    int pipe_read_fd, pipe_write_fd;

    pipe (pipe_fds);
    pipe_read_fd = pipe_fds[0];
    pipe_write_fd = pipe_fds[1];

    // child 1
    if (fork() == 0) {
        // pipe stuff: stdout -> fds[1]
        close (pipe_read_fd);
        dup2 (pipe_write_fd, 1);
        close (pipe_write_fd);
        // run first program
        execlp ("ls", "ls", "-al", NULL);
    }

    // child 2
    if (fork() == 0) {
        // pipe stuff: stdin -> fds[0]
        close (pipe_write_fd);
        dup2 (pipe_read_fd, 0);
        close (pipe_read_fd);
        // run second program
        execlp ("grep", "grep", "a.out", NULL);
    }

    // parent
    close (pipe_read_fd);
    close (pipe_write_fd);
    wait (NULL);
    wait (NULL);
}
```

Pipes in C: 3 Prozesse

```
// ls -al | grep a.out | tr rwx RWX

#define CLOSE_ALL_PIPES \
    close (pipe1_read_fd); \
    close (pipe1_write_fd); \
    close (pipe2_read_fd); \
    close (pipe2_write_fd);

int main () {
    int pipe1_fds[2], pipe2_fds[2];
    int pipe1_read_fd, pipe1_write_fd,
        pipe2_read_fd, pipe2_write_fd;
    pipe (pipe1_fds); pipe (pipe2_fds);
    pipe1_read_fd = pipe1_fds[0];
    pipe1_write_fd = pipe1_fds[1];
    pipe2_read_fd = pipe2_fds[0];
    pipe2_write_fd = pipe2_fds[1];

    // child 1
    if (fork() == 0) {
        // pipe stuff: stdout -> fds1[1]
        dup2 (pipe1_write_fd, 1);
        CLOSE_ALL_PIPES;
        // run first program
        execlp ("ls", "ls", "-al", NULL);
    }

    // child 2
    if (fork() == 0) {
        // pipe stuff: stdin -> fds1[0]
        // pipe stuff: stdout -> fds2[1]
        dup2 (pipe1_read_fd, 0);
        dup2 (pipe2_write_fd, 1);
        CLOSE_ALL_PIPES;
        // run second program
        execlp ("grep", "grep", "a.out", NULL);
    }

    // child 3
    if (fork() == 0) {
        // pipe stuff: stdin -> fds2[0]
        dup2 (pipe2_read_fd, 0);
        CLOSE_ALL_PIPES;
        // run third program
        execlp ("tr", "tr", "rwx", "RWX", NULL);
    }

    // parent
    CLOSE_ALL_PIPES;
    wait (NULL); wait (NULL); wait (NULL);
}
```

Offene Dateien und exec()

- Geöffnete Dateien „überleben“ den Programmaufruf mit exec()
- Deswegen funktioniert auch das Pipelining
- Prozess kann durch Blick in /dev/fd/ herausfinden, welche Dateien geöffnet sind

```
$ ls -l /dev/fd/
total 0
lrwx----- 1 root root 64 Apr 28 17:06 0 -> /dev/pts/0
lrwx----- 1 root root 64 Apr 28 17:06 1 -> /dev/pts/0
lrwx----- 1 root root 64 Apr 28 17:06 2 -> /dev/pts/0
lr-x----- 1 root root 64 Apr 28 17:06 3 -> /proc/11830/fd
```

Offene Dateien und exec()

```
// openexec1.c
#include <sys/types.h>
#include <sys/stat.h>
#include <fcntl.h>
#include <unistd.h>
#include <stdio.h>

int main () {
    int fd;
    char s[]="Test von open und exec\n";
    fd = open ("out.txt",
               O_CREAT | O_TRUNC | O_RDWR); // fd == 3
    write (fd, s, sizeof(s));
    lseek (fd, 0, SEEK_SET);
    printf ("openexec1: Opened file, fd = %d\n", fd);
    printf ("openexec1: exec()-ing openexec2\n");
    execl ("./openexec2", "openexec2", NULL);
}

// openexec2.c
#include <unistd.h>
#include <stdio.h>
#include <stdlib.h>

int main () {
    char buf[100];
    int fd = 3; // magic: file 3 is open...
    if (read (fd, &buf, 100) == -1) {
        perror("openexec2"); exit(0);
    }
    printf ("openexec2: reading from file...\n");
    printf ("%s", (char*)&buf);
}
```

[lesser@lx:tmp]\$./openexec2
openexec2: Bad file descriptor
[lesser@lx:tmp]\$./openexec1
openexec1: Opened file, fd = 3
openexec1: exec()-ing openexec2
openexec2: reading from file...
Test von open und exec

I/O Multiplexing

- Szenario:
 - mehrere offene Pipes
 - wenn auf einer Pipe „neue Eingabe“ erscheint, soll sie bearbeitet werden
 - Problem: read() blockiert, wenn keine Daten vorhanden sind
- Lösung:
 - nicht-blockierende I/O mit select()

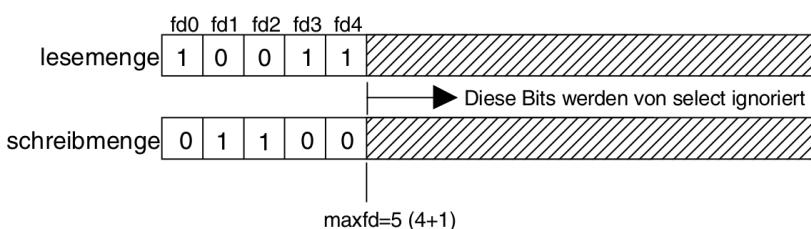
I/O Multiplexing: select()

- `select(maxfd, &fdset1, &fdset2, &fdset3, &timeout)`
 - erhält Menge(n) von File Descriptors (fdset1: zum Lesen, fdset2: zum Schreiben, fdset3: mit Fehlern)
 - kehrt zurück, sobald einer davon bereit zum Lesen ist (oder der Timeout erreicht wurde)
 - vor jedem Aufruf fdset initialisieren:
`FD_ZERO(&fdset);`
`FD_SET(fd, &fdset); // für jeden fd`
 - nach Rückkehr aus `select()` prüfen:
`if (FD_ISSET(fd, &fdset)) read(fd, ...);`
 - maxfd: (größter fd)+1

I/O Multiplexing: select()

Beispiel (aus H. Herold: Linux/Unix Systemprogrammierung)

```
fd_set lesemenge, schreibmenge;
FD_ZERO(&lesemenge);
FD_ZERO(&schreibmenge);
FD_SET(0, &lesemenge);      // stdin
FD_SET(3, &lesemenge);
FD_SET(4, &lesemenge);
FD_SET(1, &schreibmenge);   // stdout
FD_SET(2, &schreibmenge);   // stderr
select(5, &lesemenge, &schreibmenge, NULL, NULL);
```



Grafik: H. Herold

I/O Multiplexing: select()

- `select()` **schläft**, bis I/O bereit ist bzw. Timer abläuft
- Als Timeout kann auch ein Null-Pointer übergeben werden, dann wartet `select()` unendlich lange auf I/O
- Wird 0 als Timeout gesetzt, lässt sich hiermit **Polling** implementieren
- Warum auch für zum Schreiben geöffnete Dateien?
→ Netzwerk-Sockets mit begrenzter Puffergröße

Test-Szenario

```
// fifotest.c
#include <stdio.h>
#include <fcntl.h>
#include <string.h>

int main () {
    int fd1, fd2, count;
    char buf[100];
    fd1 = open ("/tmp/1", O_RDONLY);
    fd2 = open ("/tmp/2", O_RDONLY);

    // abwechselnd aus /tmp/1, /tmp/2 lesen
    for (;;) {
        memset (buf, 0, 100);
        count = read (fd1, &buf, 100);
        if (count>0) printf ("fifo 1: %s", buf);
        memset (buf, 0, 100);
        count = read (fd2, &buf, 100);
        if (count>0) printf ("fifo 2: %s", buf);
    }
}
```

Aufrufe von read() blockieren

```
sh1$ mkfifo /tmp/1
sh1$ mkfifo /tmp/2
sh1$ cat > /tmp/1
a
a
a

sh2$ cat > /tmp/2
b
b
b
b
b

sh3$ ./fifotest
fifo 1: a
fifo 2: b
fifo 1: a
fifo 2: b
fifo 1: a
fifo 2: b
```



mit select

```
#include <stdio.h>
#include <fcntl.h>
#include <string.h>
#include <sys/select.h>

int main () {
    int fd1, fd2, count,
        retval;
    char buf[100];
    fd_set fds;
    struct timeval tv;

    fd1 = open ("/tmp/1",
               O_RDONLY);
    fd2 = open ("/tmp/2",
               O_RDONLY);
    // timeout: 1 sec
    tv.tv_sec = 1;
    tv.tv_usec = 0;
```

```
// nach Bedarf aus /tmp/1, /tmp/2 lesen
for (;;) {
    FD_ZERO (&fds);
    FD_SET (fd1, &fds);
    FD_SET (fd2, &fds);
    retval = select (fd2+1, &fds,
                    NULL, NULL, &tv);
    if (retval == -1) perror ("select");
    if (retval == 0) continue;

    // Daten in fd1?
    if (FD_ISSET (fd1, &fds)) {
        memset (buf, 0, 100);
        count = read (fd1, &buf, 100);
        if (count>0)
            printf ("fifo 1: %s", buf);
    }

    // Daten in fd2?
    if (FD_ISSET (fd2, &fds)) {
        memset (buf, 0, 100);
        count = read (fd2, &buf, 100);
        if (count>0)
            printf ("fifo 2: %s", buf);
    }
}
```

```
sh1$ mkfifo /tmp/1
sh1$ mkfifo /tmp/2
sh1$ cat > /tmp/1
a
a
a

sh2$ cat > /tmp/2
b
b
b
b
b

sh3$ ./fifotest
fifo 1: a
fifo 1: a
fifo 2: b
fifo 2: b
fifo 1: a
fifo 2: b
fifo 2: b
fifo 2: b
```

select() für Sockets

- Häufiger wird dieses Multiplexing für Netzwerk-Sockets verwendet
- Sockets werden mit socket() statt open() geöffnet, aber man kann auch diese mit read() und write() ansprechen
- Sockets haben einen Socket Descriptor sd, der sich wie ein File Descriptor fd nutzen lässt



- Dateien können auch mit Option O_NONBLOCK geöffnet werden, dann blockieren read()-Aufrufe nicht

```
fd1 = open ("/tmp/1", O_RDONLY | O_NONBLOCK);
fd2 = open ("/tmp/2", O_RDONLY | O_NONBLOCK);
...
```

- Nachteil: Permanentes Polling mehrerer Dateien (ohne neue Daten) verbraucht unnötig Rechenzeit

Memory Mapped Files

- Der Inhalt einer Datei kann in den (virtuellen) Prozessspeicher eingeblendet werden
- Aufruf: `fd = open (filename, ...);
char *addr;
addr = mmap (NULL, len, prot, flags, fd, offset);`
- `prot`:
`PROT_EXEC`: Pages may be executed.
`PROT_READ`: Pages may be read.
`PROT_WRITE`: Pages may be written.
`PROT_NONE`: Pages may not be accessed.
- `flags`:
`MAP_SHARED`: Share this mapping. Updates to the mapping are visible to other processes that map this file [...]
`MAP_PRIVATE`: Create a private copy-on-write mapping. [...]

Memory Mapped Files

- `mmap()` sucht freien Speicherbereich (im virtuellen Adressraum) für das Mapping
- Zugriff auf Speicheradressen in diesem Bereich wird zu Dateizugriff
- Häufig eingesetzt bei Datei, die aus gleich großen Datensätzen besteht:
statt
`lseek (fd, i*recsize, ...); read (fd, &buf);`
Direktzugriff mit `f[i]`