3. System Calls

Grundlagen System Calls (1)

- Prozessor kennt verschiedene Schutzstufen
  - Ring 0: Kernel Mode / Supervisor Mode
    - voller Zugriff auf alle Ressourcen
    - alle CPU-Instruktionen erlaubt
    - hier läuft das Betriebssystem
  - Ring 3: User Mode
    - eingeschränkter Zugriff auf Ressourcen
    - „privilegierte“ Instruktion verboten
    - hier laufen Anwendungen
  - Ringe 1, 2: nicht benutzt

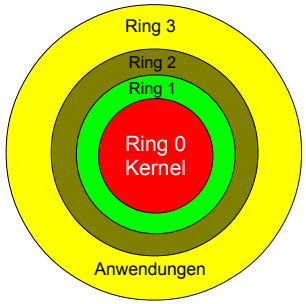

Grundlagen System Calls (2)

- Anwendung kann nicht direkt auf Hardware zugreifen
  - keine Plattenzugriffe
  - keine I/O (USB, Firewire, seriell etc.)
  - kein Zugriff auf Bildschirmspeicher
  - Tastatur / Maus
  - physikalisches RAM (aber: virtueller Speicher)

Grundlagen System Calls (3)

- Anwendung muss Dienste des Betriebssystems nutzen
  - kontrollierter Übergang von Ring 3 → Ring 0 über ein „Gate“
  - realisiert über System Calls / Software Interrupts
    - kein direkter Sprung in BS-Funktion (`call os_print`), sondern
    - Verwendung von Software-Interrupt (`int`):

```
mov eax, OS_PRINT
mov ebx, Stringadresse
int 0x80
```

  - danach Rücksprung in Ring 3 (`iret`)

Grundlagen System Calls (4)

- BS-Funktionen prüfen beim Aufruf, ob Anwender berechtigt ist; können Ausführung verweigern
- während System Call läuft:
  veränderte Sicht auf Speicher (Zugriff auf Prozessspeicher und auf Kernel-Speicher)
- nach System Call:
  Rücksprung in User-Mode, Programm erhält Rückgabewert

Einfaches Beispiel (1)

- Ziel: Ausgabe von „A“ im Textmodus (80x25) in linker oberer Ecke
- technisch:
  - Bildschirmspeicher: 80 x 25 x 2 Bytes ab 0xB8000
  - erste zwei Bytes für Position links oben zuständig (ASCII-Code und Farbe)
  - Aufgabe: `char *addr=0xB8000; *addr='A';`
  - Problem: Anwendung nutzt virtuellen Speicher, Adresse 0xB8000 nicht erreichbar

Einfaches Beispiel (2)

- Lösungsansatz:
  Betriebssystem hat Funktion `write_screen`:

```
int write_screen (short spalte, zeile, char c) {
  int addr = 0xB8000 + 2 * spalte + 160 * zeile;
  char *ptr = (char*) addr;
  *ptr = c;
  return 0;
}
```

- Anwendung müsste

```
write_screen (0, 0, 'A');
```

  aufrufen – wie „kommt sie da ran“?

Einfaches Beispiel (3)

- Betriebssystem installiert System-Call-Handler für verschiedene Dienste, z. B. `write_screen`:

```
#define SYSCALL_WRITE_SCREEN 101

int syscall_handler_0x80 (int eax, ...) {
  switch (eax) {
    case SYSCALL_WRITE_SCREEN:
      // call write_screen (syscall 101)
      // ebx: column, ecx: row, edx: char
      write_screen (ebx, ecx, edx);
      break;
    case SYSCALL_...:
      ...
  };
  asm (iret);
};
```

Einfaches Beispiel (4)

- Programm lädt passende Werte in Register (Linux):

```
asm (
  mov eax, 101    // syscall no.
  mov ebx, 0      // column
  mov ecx, 0      // row
  mov edx, 'A'    // char
  int 0x80        // software int. 0x80
);
```

- Alternative Implementierung über Stack (z. B. FreeBSD):

```
asm (
  mov eax, 101    // syscall no.
  push 'A'        // char
  push 0          // row
  push 0          // column
  int 0x80        // software int. 0x80
);
```


Exkurs Intel x86 Assembler (1)

- Nur das wichtigste zu Assembler …
- C-Compiler übersetzt C-Programme in Assemblersprache, Assembler übersetzt diese in Maschinensprache (ein Binary)
- 32-bittige CPU: Adressen sind 32 Bit breit, Register auch: EAX, EBX, ECX, …;
  C-Typ `int` genau passend
- Spezialregister: EIP, ESP, EFLAGS, … siehe http://de.wikipedia.org/wiki/Intel_80386#Register

Exkurs Intel x86 Assembler (2)

- Befehlsausführung: linear
- Sprungbefehle
- Schleifen sehen in Assembler immer so aus (Pseudosyntax):

```
<< Variablen für Schleife initialisieren >>
start:
  << Schleifenrumpf >>
  << Test Abbruchbedingung >>
  if (! Test) jump to start;

// hinter der Schleife
```


Exkurs Intel x86 Assembler (3)

- Assembler-Code angucken:
  `gcc -S -masm=intel`
- Beispiel:

```
int main () {
  register int i,j,k;
  i = 0x1234;
  j = 0x5678;
  if (i<j) {
    k = j - i;
  } else {
    k = i - j;
  };
  return k;
}
```

→

```
main:
   push   ebp
   mov    ebp, esp
   push   esi
   push   ebx
   mov    esi, 0x1234
   mov    ebx, 0x5678
   cmp    esi, ebx
   jge    .L2
   sub    ebx, esi
   jmp    .L3
.L2:
   mov    eax, esi
   sub    eax, ebx
   mov    ebx, eax
.L3:
   mov    eax, ebx
   pop    ebx
   pop    esi
   pop    ebp
   ret
```

Exkurs Intel x86 Assembler (4)

Ausgabe von `gcc -S` ...

```
main:
    push    ebp
    mov     ebp, esp
    push    esi
    push    ebx
    mov     esi, 0x1234
    mov     ebx, 0x5678
    cmp     esi, ebx
    jge     .L2
    sub     ebx, esi
    jmp     .L3
.L2:
    mov     eax, esi
    sub     eax, ebx
    mov     ebx, eax
.L3:
    mov     eax, ebx
    pop     ebx
    pop     esi
    pop     ebp
    ret
```

Disassemblieren der erzeugten Object-Datei (`a.out`) mit Tool `udcli`, http://udis86.sourceforge.net/

```
00000394 55              push ebp
00000395 89e5            mov  ebp, esp
00000397 56              push esi
00000398 53              push ebx
00000399 be34120000      mov  esi, 0x1234
0000039e bb78560000      mov  ebx, 0x5678
000003a3 39de            cmp  esi, ebx
000003a5 7d04            jge  0x3ab
000003a7 29f3            sub  ebx, esi
000003a9 eb06            jmp  0x3b1

000003ab 89f0            mov  eax, esi
000003ad 29d8            sub  eax, ebx
000003af 89c3            mov  ebx, eax

000003b1 89d8            mov  eax, ebx
000003b3 5b              pop  ebx
000003b4 5e              pop  esi
000003b5 5d              pop  ebp
000003b6 c3              ret
```


Echtes Beispiel: Text ausgeben

```
section .text
    global _start     ;fuer den Linker (ld)

_start:               ;fuer Linker (wo gehts los)

        mov   edx,len ;Nachrichtenlaenge
        mov   ecx,msg ;Adresse der Nachricht
        mov   ebx,1   ;file descriptor (1=stdout)
        mov   eax,4   ;Syscall-Nr. (sys_write)
        int   0x80    ;Syscall ausfuehren

        mov   eax,1   ;Syscall-Nr. (sys_exit)
        int   0x80    ;Syscall ausfuehren

section .data

msg     db    'Hallo Welt!',0xa   ;Text
len     equ   $ - msg             ;Laenge
```

Quelle des Listings: http://asm.sourceforge.net/intro/hello.html (übersetzt) - Syntax für Assembler `nasm` geeignet

Welche Syscalls gibt es?

In /usr/include/asm/unistd_32.h oder /usr/include/asm/unistd_64.h für 64 Bit:

```
# grep -c __NR unistd_32.h
335
```

(335 System Calls)

```
#define __NR_restart_syscall  0
#define __NR_exit             1
#define __NR_fork             2
#define __NR_read             3
#define __NR_write            4
#define __NR_open             5
#define __NR_close            6
#define __NR_waitpid          7
#define __NR_creat            8
#define __NR_link             9
#define __NR_unlink          10
#define __NR_execve          11
#define __NR_chdir           12
#define __NR_time            13
#define __NR_mknod           14
#define __NR_chmod           15
#define __NR_lchown          16
#define __NR_break           17
#define __NR_oldstat         18
#define __NR_lseek           19
#define __NR_getpid          20
...
```


Wichtige Syscalls

- `fork`: erzeugt (fast) identischen Sohn-Prozess
- `exec`: lädt anderes Programm in aktuellen Prozess
- `wait`: wartet auf Ende eines Sohn-Prozesses
- `open`: Datei öffnen (Spezialfall: `creat`)
- `read`: aus Datei lesen
- `write`: in Datei schreiben
- `close`: Datei schließen

Syscalls und Funktionen

- Für jeden Syscall (z. B. `exec`) gibt es gleichnamige Funktion (z. B. `exec()`).
- Die Funktion führt den eigentlichen Syscall aus
  - setzt Register
  - führt `int 0x80` aus (älteres 32-Bit-Linux; neuere Versionen nutzen `sysenter`)
  - wertet Rückgabewert aus

Prozesse

Hierarchie

- Prozesse erzeugen einander
- Erzeuger heißt Vaterprozess (parent process), der andere Kindprozess (child process)
- Kinder sind selbständig (also: eigener Adressraum, etc.)
- Nach Prozess-Ende: Rückgabewert an Vaterprozess

Prozesse erzeugen (1/7)

- Neuer Prozess: `fork ()`

```
main() {
  int pid = fork();   /* Sohnprozess erzeugen */
  if (pid == 0) {
    printf("Ich bin der Sohn, meine PID ist %d.\n",
           getpid() );
  }
  else {
    printf("Ich bin der Vater, mein Sohn hat die
           PID %d.\n", pid);
  }
}
```

- erzeugt neuen Prozess
- Rückgabewert im Vater: PID des Sohnes
- Rückgabewert im Sohn: 0

Prozesse erzeugen (2/7)

- Anderes Programm starten: `fork + exec`

```
main() {
  int pid=fork();   /* Sohnprozess erzeugen */
  if (pid == 0) {
       /* Sohn startet externes Programm */
       execl( "/usr/bin/gedit", "/etc/fstab", (char *) 0 );
     }
  else {
       printf("Es sollte jetzt ein Editor starten...\n");
     }
}
```

- Andere Betriebssysteme oft nur: „spawn“

```
main() {
  WinExec("notepad.exe", SW_NORMAL);   /* Sohn erzeugen */
}
```

Prozesse erzeugen (3/7)

Warten auf Sohn-Prozess: **`wait ()`**

```
#include <unistd.h>          /* sleep()                          */

main() {
  int pid=fork();            /* Sohnprozess erzeugen             */
  if (pid == 0) {
    sleep(2);                /* 2 sek. schlafen legen            */
    printf("Ich bin der Sohn, meine PID ist  %d\n", getpid() );
  } else {
    printf("Ich bin der Vater, mein Sohn hat die PID  %d\n", pid);
    wait();                  /* auf Sohn warten                  */
  }
}
```


Prozesse erzeugen (4/7)

Wirklich mehrere Prozesse:

Nach `fork ()` zwei Prozesse in der Prozessliste

```
> pstree | grep simple
   ... -bash---simplefork---simplefork

> ps w | grep simple
25684 pts/16 S+       0:00 ./simplefork
25685 pts/16 S+       0:00 ./simplefork
```


Prozesse erzeugen (5/7)

Abfrage, ob Programmstart über `fork()`, `exec()` erfolgreich war:

```
#include <errno.h>
main() {
  int pid = fork();
  int errno2;
  if (pid==0) {
    execl("/bin/xls",0);
    errno2=errno;
    perror ();
    printf("Fehlercode errno = %d\n",
           errno2);
  } else { wait(); }
}
```

```
> gcc -o fork-exec-fail fork-exec-fail.c
> ./fork-exec-fail
/bin/xls: No such file or directory
Fehlercode errno = 2
```

- `perror()`: Fehlermeldung in lesbarem Format
- `errno`: Globale Fehlervariable
- mehr zu errno/perror: gleich...

Prozesse erzeugen (6/7)

Abbruch aller Kind-Prozesse

Zwei Szenarien:

1. Shell wird mit `exit` verlassen
   ➞ Kind-Prozesse laufen weiter.
2. Shell wird gewaltsam geschlossen
   (`kill`, Fenster schließen etc.)
   ➞ Kind-Prozesse werden auch beendet.

Prozesse erzeugen (7/7)

```
                                [ In 2. Fenster ]   > nedit &

> pstree | grep nedit
     |     |-xterm---bash---nedit
> ps auxw | grep nedit
esser     24676  1.0  0.8   8248  4336 pts/4    S    15:13   0:00 nedit
> cat /proc/24676/status | grep PPid
PPid:   24659
> ps auxw|grep 24659
esser     24659  0.0  0.3   4424  1936 pts/4    Ss+  15:12   0:00 bash

                                [ In 2. Fenster ]   > exit

> cat /proc/24676/status | grep PPid
PPid:   1
```


Dokumentation

- fork: `man 2 fork`
- exec (mehrere Varianten): `man exec`
  - `execl`: absoluter Programmpfad, Argumente separat, mit Nullzeiger abgeschlossen
  - `execlp`: Programmname, Argumente separat, mit Nullzeiger abgeschlossen
  - `execle`: wie `execl`, zusätzlich Environment nach Argumentliste
  - `execv`: wie `execl`, aber Argumente als Array
  - `execve`: wie `execv`, plus Environment
  - `execvp`: wie `execlp`, aber Argumente als Array

Dokumentation

- wait: `man wait`
  - `wait`: wartet auf beliebigen Prozess
  - `waitpid`: wartet auf Prozess mit angegebener PID (oder auf beliebigen Prozess, wenn -1 übergeben wird; oder auf Prozess, der zur Prozessgruppe PGID gehört, wenn Argument –PGID übergeben wird)
  - `wait (&stat) = waitpid (-1, &stat, 0)`
  - `wait` und `waitpid` geben auch Status des (beendeten) Sohnprozesses zurück (→ später)

Dateizugriffe (1)

- Neue Datei erzeugen: `creat()`

```
#include <sys/types.h>
#include <sys/stat.h>
...

char filename[]="datei.txt";
int fd = creat ((char*)&filename, S_IRUSR | S_IWUSR);
```

- Datei öffnen: `open()`

```
#include <fcntl.h>
...

char filename[]="datei.txt";
int fd = open ((char*)&filename, O_RDONLY);
```

Dateizugriffe (2)

- Optionen beim Öffnen (O_RDONLY etc.) stehen in /usr/include/asm-generic/fcntl.h
  - O_RDONLY: nur lesen
  - O_WRONLY: nur schreiben
  - O_RDWR: lesen/schreiben, ...
- Attribute beim Erzeugen (S_IRUSR etc.) stehen in /usr/include/sys/stat.h
  - S_IRUSR: Leserechte für Besitzer
  - S_IWGRP: Schreibrechte für Gruppe, ...

Dateizugriffe (3)

- Lesen: `read()`

```
read (fd, &buffer, count);
```

  (liest `count` Bytes aus der Datei und schreibt sie in den Puffer; Rückgabewert: Anzahl der gelesenen Bytes)
- Schreiben: `write()`

```
write (fd, &buffer, count);
```

  (schreibt `count` Bytes aus dem Puffer in die Datei; Rückgabewert: Anzahl der geschriebenen Bytes)

Dateizugriffe (4)

- Datei schließen: `close()`

```
close (fd);
```


Fehlerbehandlung (1)

- System Calls können fehlschlagen
  - immer den Rückgabewert des Syscalls überprüfen
  - Manpages erklären, woran man Fehler erkennt
- Beispiele:
  - `fork()`: Prozess kann nicht erzeugt werden, Rückgabewert -1
  - `open()`: Datei kann nicht geöffnet werden, Rückgabewert -1, genauere Fehlerbeschreibung in Variable `errno`

Fehlerbehandlung (2)

- Variable errno: `#include <errno.h>`
- Standard-Fehler-Codes in /usr/include/asm-generic/errno-base.h
- Für Anzeige des Fehlers gibt es Funktion `perror()`.
- Beispiel: Datei öffnen

Fehlerbehandlung (3)

```
/* open1.c, Hans-Georg Esser, Systemprogrammierung */

#include <sys/types.h>
#include <sys/stat.h>
#include <fcntl.h>
#include <stdio.h>
#include <errno.h>
#include <stdlib.h>

int main () {
  int fd = open ("/etc/dontexist", O_RDONLY);

  if (fd == -1) {
    // Fehler
    int err = errno;
    printf ("Fehler bei open(), errno = %d, ", err);

    switch (errno) {
      case ENOENT: printf ("No such file or directory\n"); break;
      case EACCES: printf ("Permission denied\n"); break;
      default: printf ("\n");
    };

    exit (-1);  // Programm mit Fehlercode verlassen
  }

  close (fd);
};
```


Fehlerbehandlung (4)

- mit `perror()`:

```
/* open2.c, Hans-Georg Esser, Systemprogrammierung */

#include <sys/types.h>
#include <sys/stat.h>
#include <fcntl.h>
#include <stdio.h>
#include <errno.h>
#include <stdlib.h>

int main () {

  int fd = open ("/etc/dontexist", O_RDONLY);

  if (fd == -1) {
    // Fehler
    perror ("open2");
    exit (-1);  // Programm mit Fehlercode verlassen
  }

  close (fd);
};
```


Fehlerbehandlung (5)

- Ausgabe `open1.c`:

```
$ ./open1
Fehler bei open(), errno = 2, No such file or directory
```

- Ausgabe `open2.c`:

```
$ ./open2
open2: No such file or directory
```