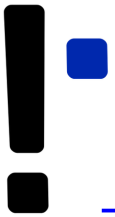

Betriebssysteme 1

SS 2016

Prof. Dr.-Ing. Hans-Georg Eßer
Fachhochschule Südwestfalen

Foliensatz C:

v1.1, 2016/05/17

- Geräte
- Interrupts und Faults
- System Calls

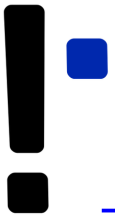

Motivation: Tastatur am PC

Motivation: Tastatur am PC (1)

- Szenario: Standard-PC mit Bildschirm, Maus und Tastatur (PS/2-Anschluss)
- Frage: Wie kommen die Tastendrücke in laufenden Programmen an?

Quelle: https://commons.wikimedia.org/wiki/File%3AIBM_Model_M.png

Motivation: Tastatur am PC (2)

- Klassisch: Kommunikation über **Ports**

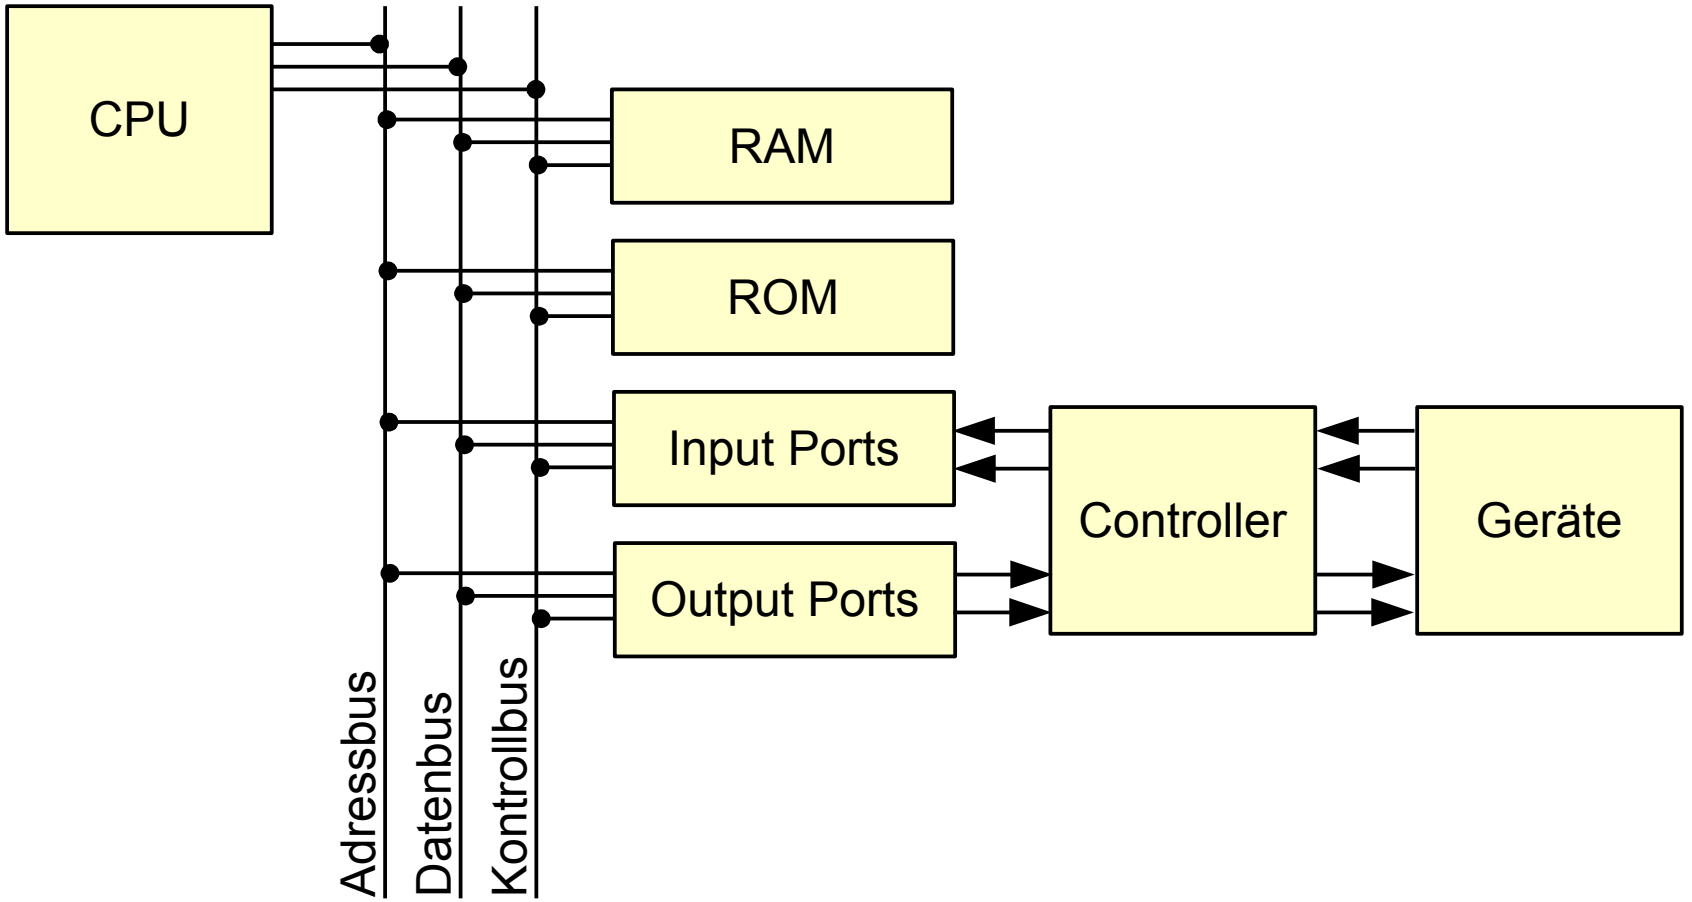

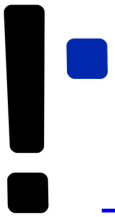

Motivation: Tastatur am PC (3)

- PS/2-Keyboard-Controller hat zwei solche Ports

```
#define  KBD_DATA_PORT      0x60
#define  KBD_STATUS_PORT    0x64
```

- Kommunikation über Assembler-Befehle
  `inb` (liest Wert aus Port, speichert in Reg.),
  `outb` (schreibt Reg.-Inhalt auf Port)

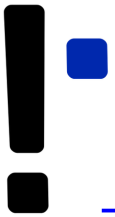

Motivation: Tastatur am PC (4)

- Jeder „Event“ (Ereignis: Tastendruck oder Loslassen) generiert einen Scancode
- Beispiel, Taste „A“:
  - Drücken = Scancode 30
  - Loslassen = Scancode 30 + 128 = 158
- Scancodes über Datenport (`0x60`) des Keyboard-Controllers auslesen:

```
char scancode = inb (KBD_DATA_PORT);
```

- Statusport verrät, ob Event vorliegt

Motivation: Tastatur am PC (5)

Belegung (US-englisch)

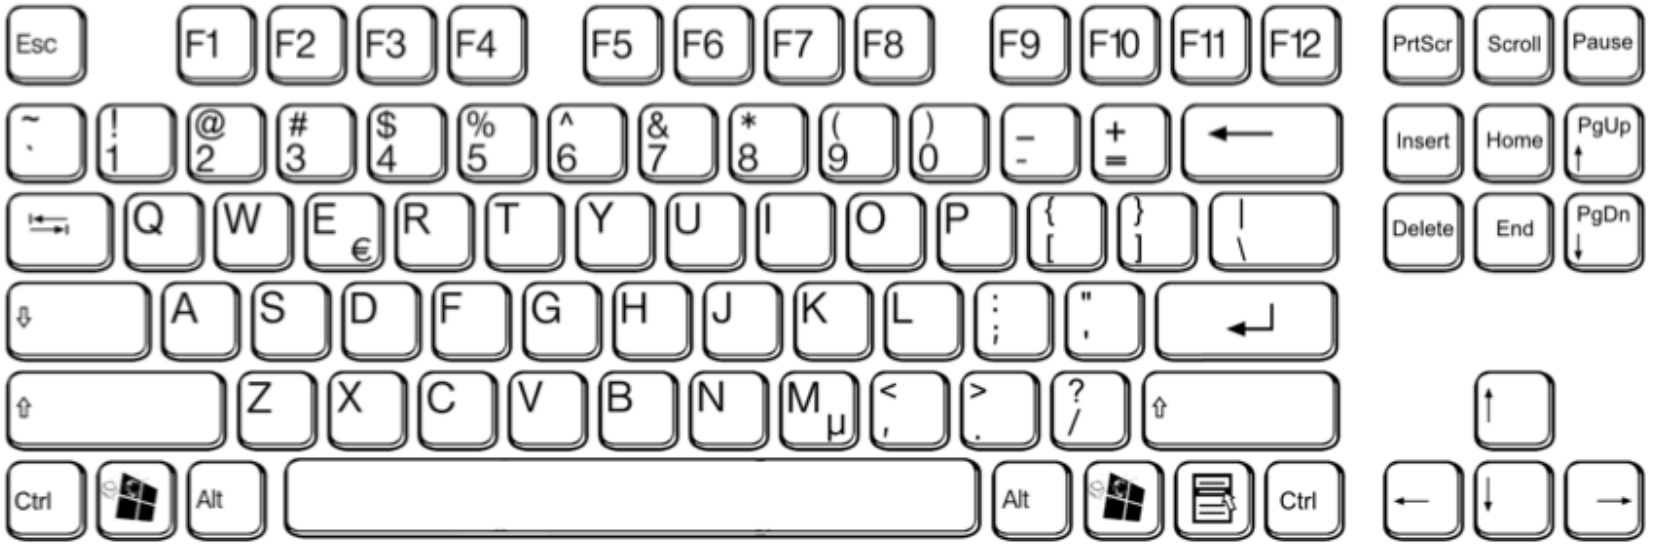

Scancodes („key press“)

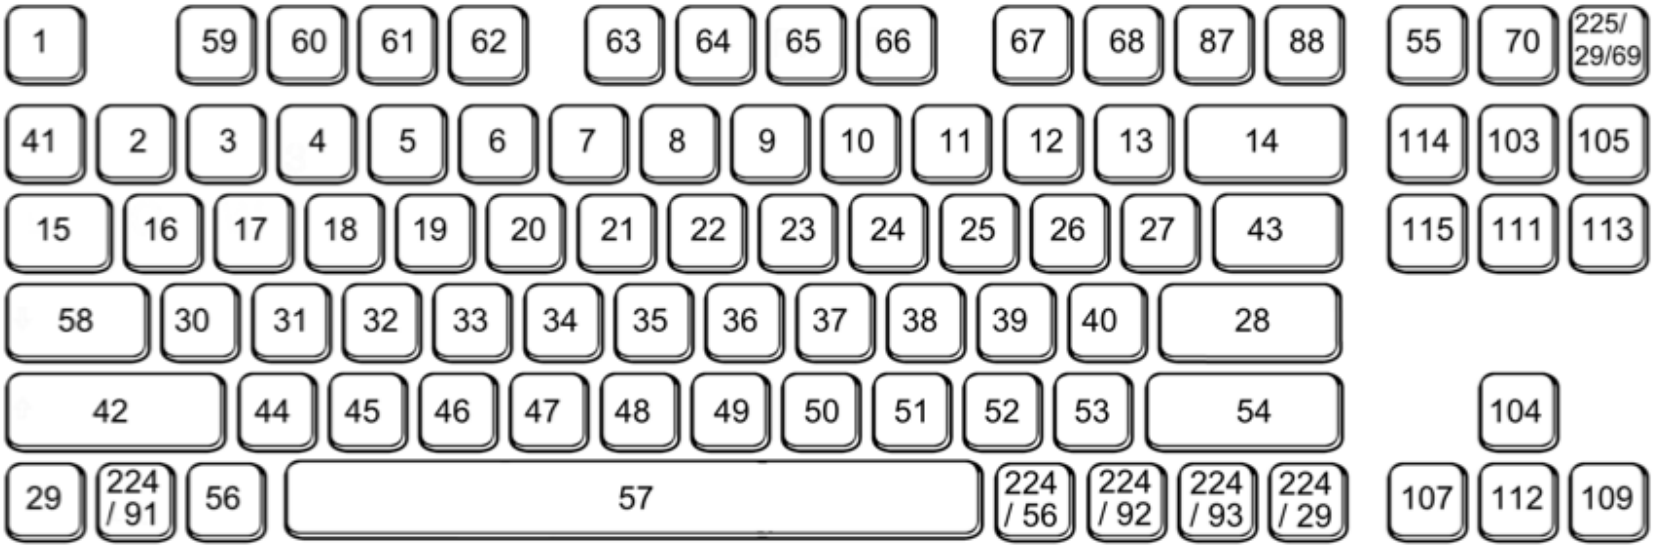

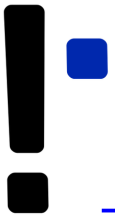

Motivation: Tastatur am PC (6)

- Simpler Treiber (Pseudocode, vereinfacht)

```
do forever {
  // warte auf Event
  while (inb (KBD_STATUS_PORT) != NEW_EVENT) ;

  // lies Scancode
  scancode = inb (KBD_DATA_PORT);

  if (scancode < 128) {
    // nur keypress event verarbeiten
    ascii = lookup_table (scancode);
    printf ("Zeichen %d eingegeben\n", ascii);
  }
}
```

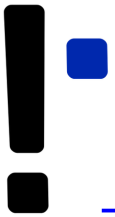

Port-Mapped vs. Memory-Mapped I/O

- auf gleiche Weise (**port-mapped I/O**, PMIO) Kommunikation mit anderen Geräten möglich, z. B. Platten-Controller
- Alternative: **memory-mapped I/O** (MMIO)
  - Controller hat eigenen Speicher
  - Einblendung in Adressraum
  - CPU liest/schreibt einfach „Hauptspeicher“

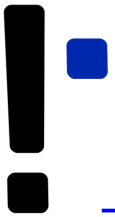

Interrupts

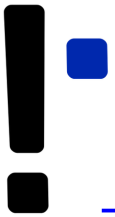

Einführung (1)

- Festplattenzugriff um mehr als Faktor 1.000.000 langsamer als Ausführen einer CPU-Anweisung
  - Taktfrequenz 1 GHz: 1.000.000.000 Instruktionen / s
  - Festplatte: 7.200 Umdrehungen / min = 120 U. / s

    Im Schnitt: halbe Umdrehung (240 / s) nötig, um richtige Position zu erreichen (zzgl. Transferzeit)
  - Plattenzugriff braucht im Schnitt 1.000.000.000 / 240 ≈ 4.166.666 mal so lang wie eine CPU-Instruktion

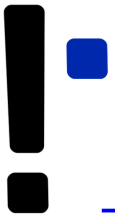

Einführung (2)

- Naiver Ansatz für Plattenzugriff:

```
naiv () {
  rechne (500 ZE);
  sende_anfrage_an (disk);
  antwort = false;
  while ( ! antwort ) {
    /* diese Schleife rechnet 1.000.000 ZE lang */
    antwort = test_ob_fertig (disk);
  }
  rechne (500 ZE);
  return 0;
}
```

Einführung (3)

- Naiver Ansatz heißt „Pollen“: in Dauerschleife ständig wiederholte Geräteabfrage
- Pollen verbraucht sehr viel Rechenzeit:

- Besser wäre es, in der Wartezeit etwas anderes zu tun
- Auch bei Parallelbearbeitung mehrerer Prozesse: Polling immer noch ungünstig

Einführung (4)

- Idee: Prozess, der I/O-Anfrage gestartet hat, solange schlafen legen, bis die Anfrage bearbeitet ist – in der Zwischenzeit was anderes tun

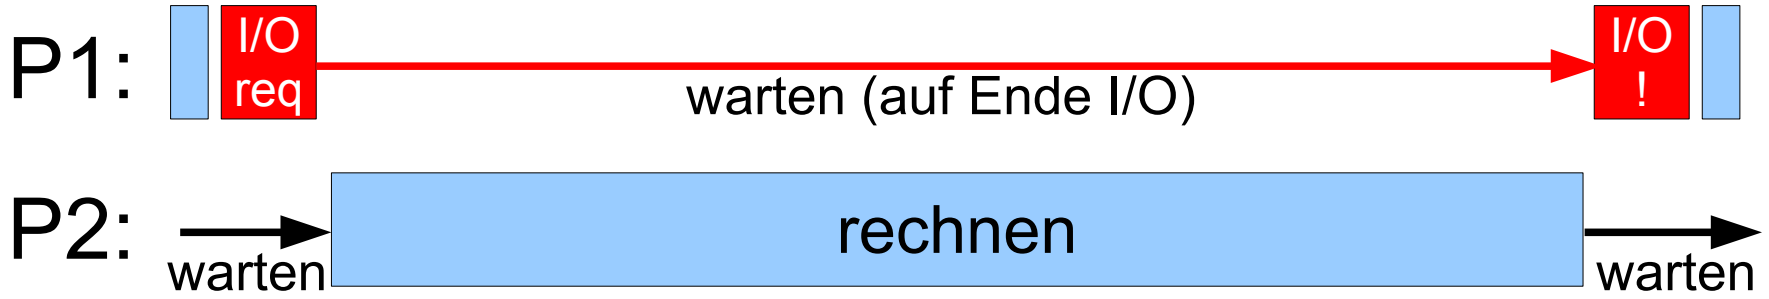

- Woher weiß das System,
  - wann die Anfrage bearbeitet ist, also
  - wann der Prozess weiterarbeiten kann?

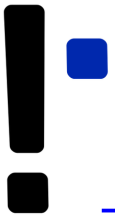

Einführung (5)

- Lösung: Interrupts – bestimmte Ereignisse können den „normalen“ Ablauf unterbrechen
- In der CPU: Nach jeder ausgeführten Anweisung prüfen, ob es einen Interrupt gibt (gab)

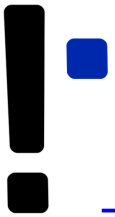

Interrupt-Klassen

- I/O (Eingabe/Ausgabe, asynchrone Interrupts)
  - Meldung vom I/O-Controller: „Aktion ist abgeschlossen“
  - Timer
- Hardware-Fehler, z. B. RAM-Parität
- Software-Interrupts (Exceptions, Traps, synchrone Interrupts)
  - Falscher Speicherzugriff, Division durch 0, unbekannte CPU-Instruktion, ...

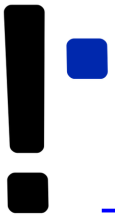

Interrupts: Vor- und Nachteile

Vorteile

- Effizienz
  I/O-Zugriff sehr langsam → sehr lange Wartezeiten, wenn Prozesse warten, bis I/O abgeschlossen ist
- Programmierlogik
  Nicht immer wieder Gerätestatus abfragen (Polling), sondern blockieren, bis passender Interrupt kommt

Nachteile

- Mehraufwand
  Kommunikation mit Hardware wird komplexer, Instruction Cycle erhält zusätzlichen Schritt

Interrupt-Bearbeitung (1)

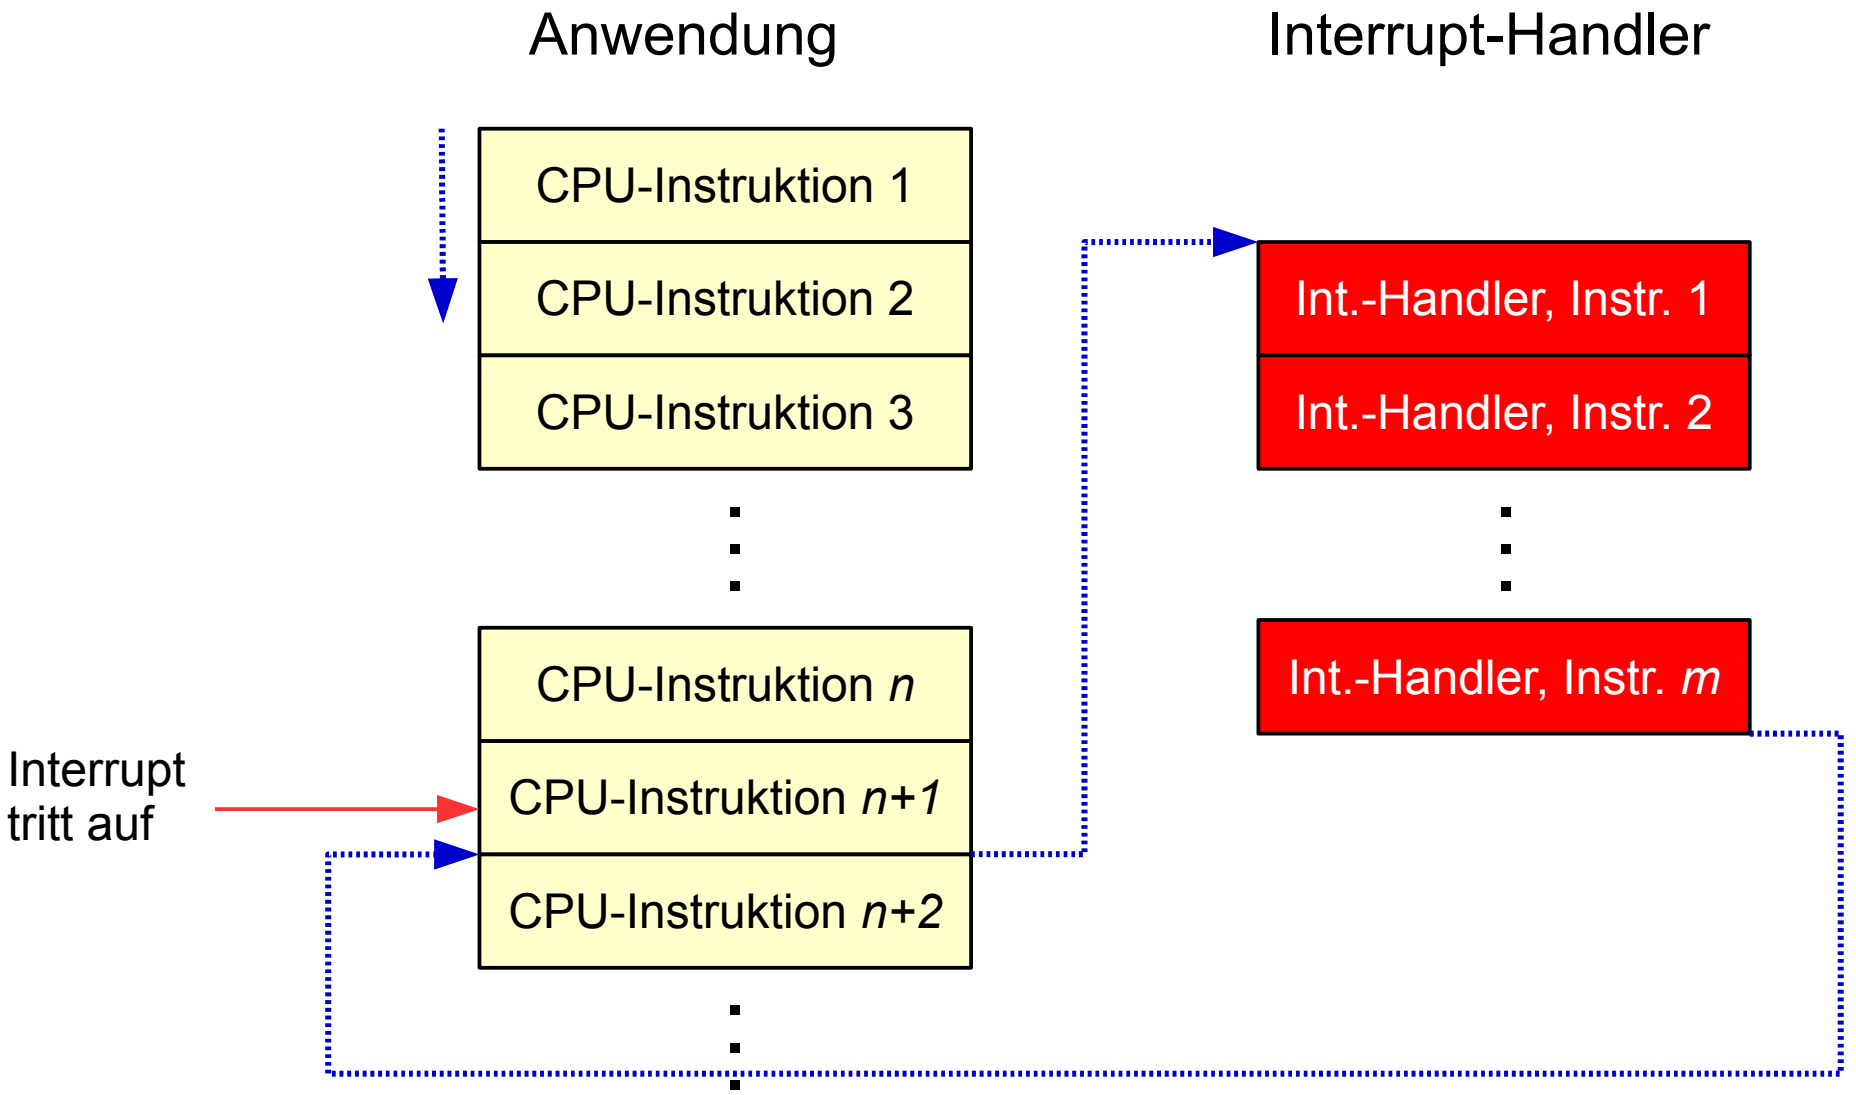

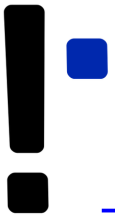

Interrupt-Bearbeitung (2)

Grundsätzlich

- Interrupt tritt auf
- Laufender Prozess wird (nach aktuellem Befehl) unterbrochen, BS übernimmt Kontrolle
- BS speichert Daten des Prozesses (wie bei Prozesswechsel → Scheduler)
- BS ruft Interrupt-Handler auf
- Danach (evtl.): Prozess-Fortsetzung (evtl. ein anderer Prozess)

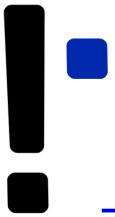

Interrupt-Bearbeitung (3)

Was tun bei Mehrfach-Interrupts?

Drei Möglichkeiten

- Während Abarbeitung eines Interrupts alle weiteren ausschließen (`DI`, disable interrupts) → Interrupt-Warteschlange
- Während Abarbeitung andere Interrupts zulassen
- Interrupt-Prioritäten: Nur Interrupts mit höherer Priorität unterbrechen solche mit niedrigerer

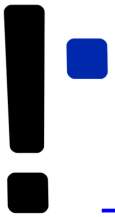

Mehrfach-Interrupts (1)

Variante 1

- Alle Interrupts „gleichwertig“, keine Prioritäten
- zu Beginn einer Int.-Routine alle Interrupts abschalten

  → kein Interrupt unterbricht einen anderen

Mehrfach-Interrupts (2)

Variante 1

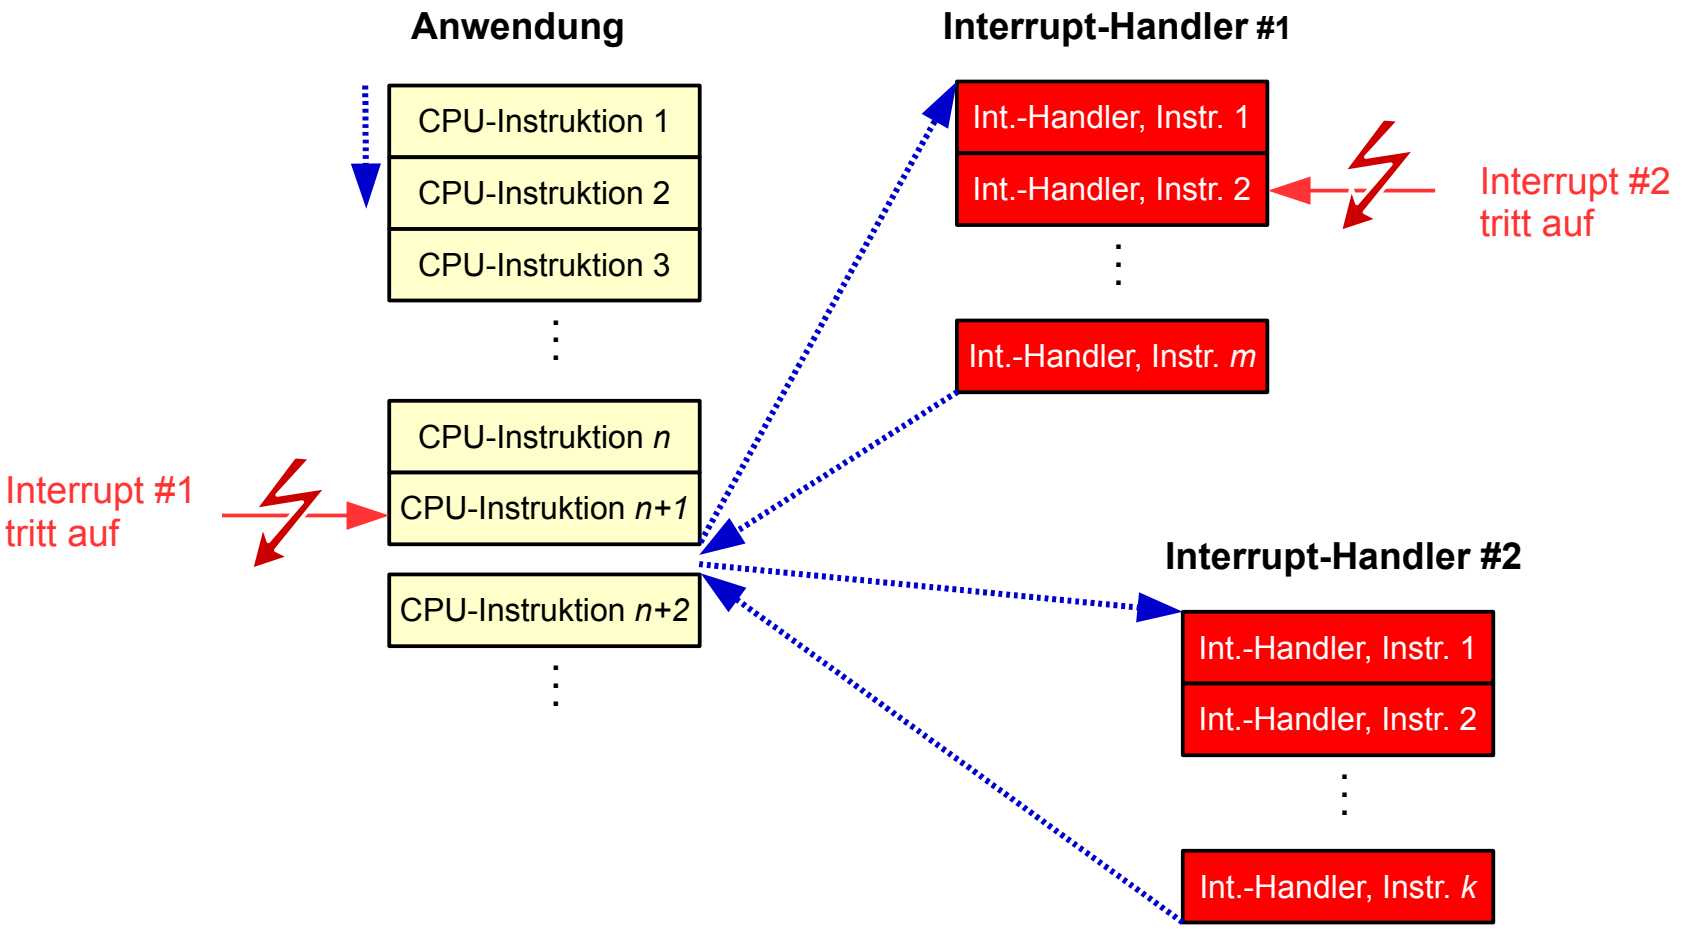

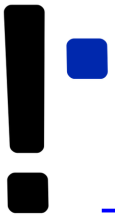

Mehrfach-Interrupts (3)

Variante 2

- Interrupt-Handler können unterbrochen werden
- Rücksprung in vorherigen Interrupt-Handler
- Zustand sichern!

Mehrfach-Interrupts (4)

Variante 2

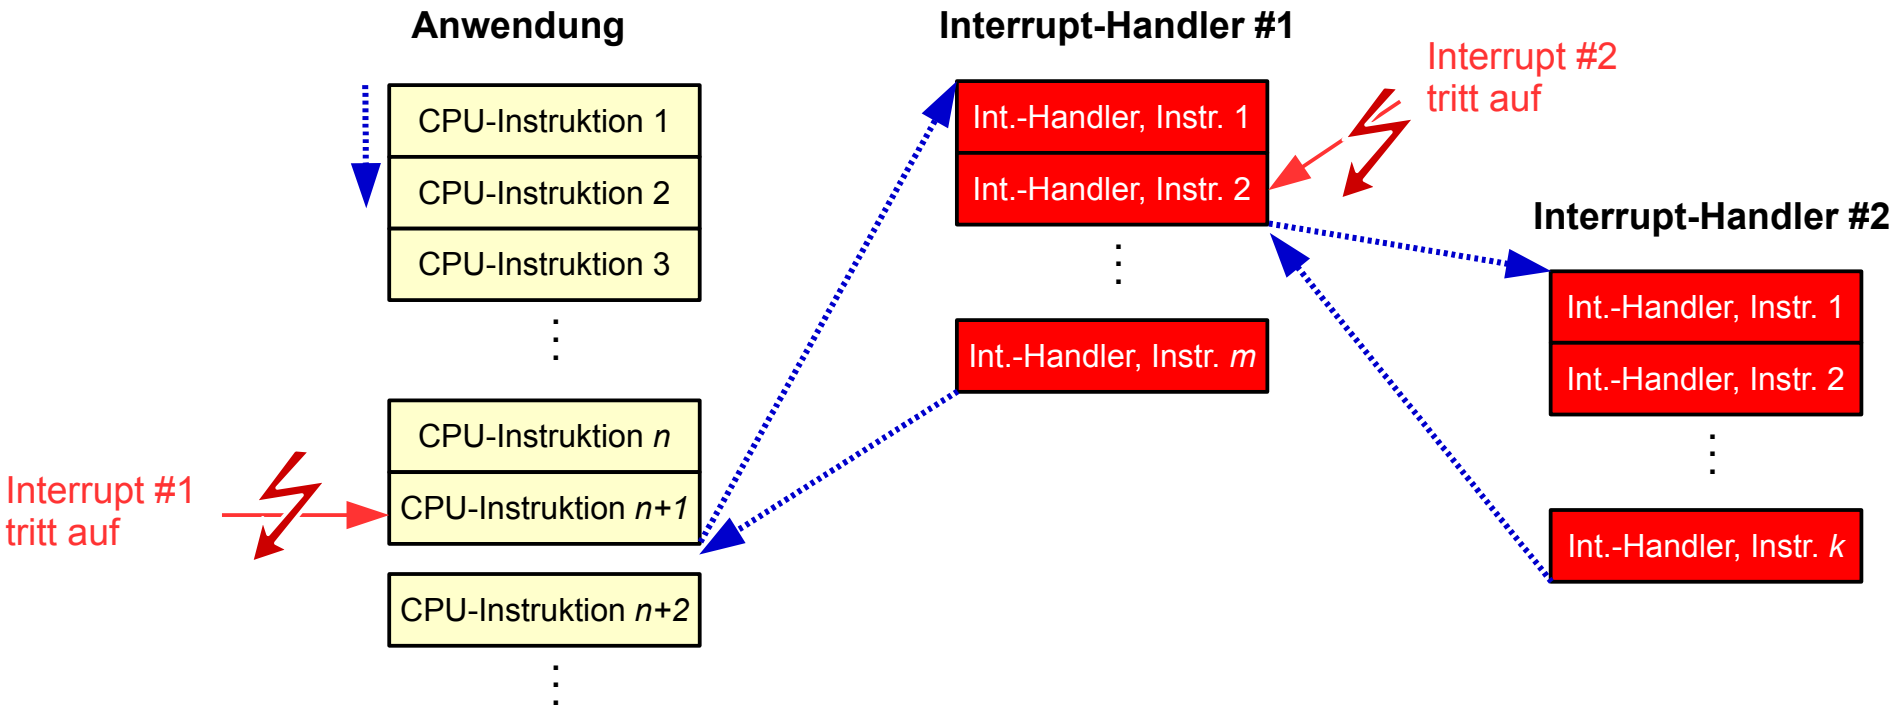

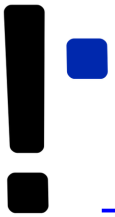

Mehrfach-Interrupts (5)

Variante 3

- Interrupts haben Prioritäten, z. B. Netzwerkkarte > Drucker
- Interrupt mit hoher Priorität unterbricht Interrupt mit niedrigerer Priorität

Mehrfach-Interrupts (6)

Variante 3

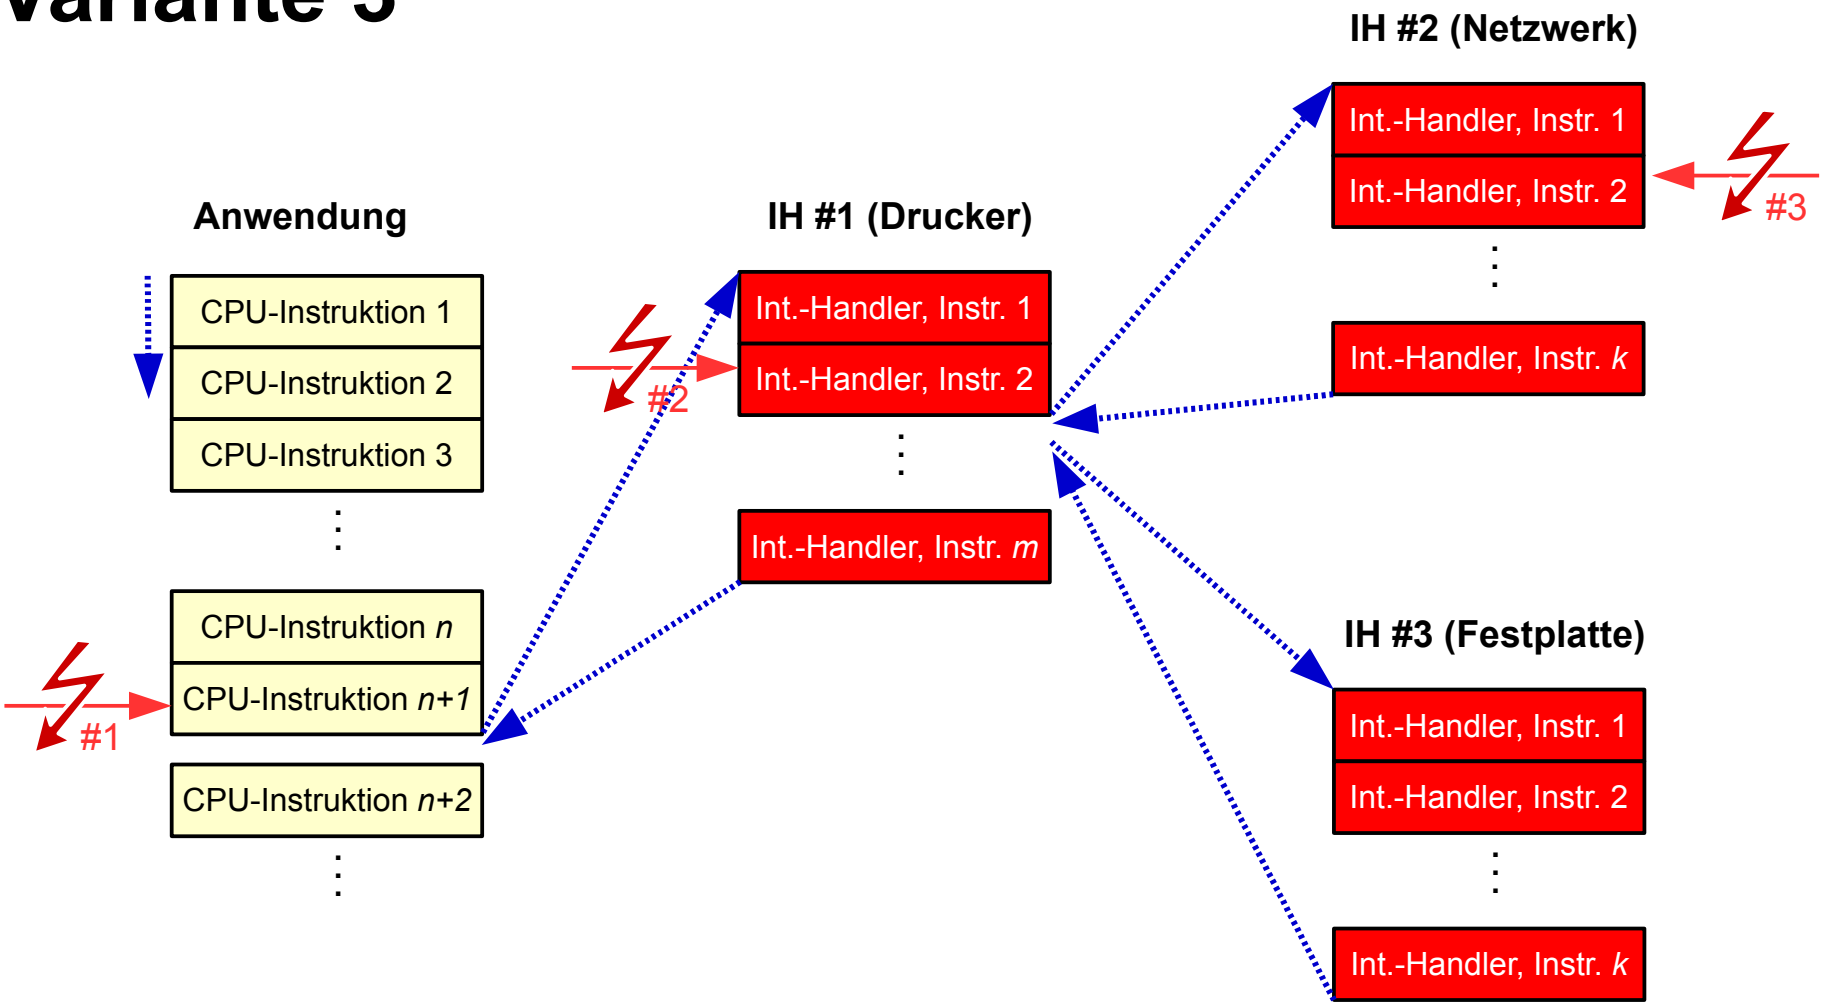

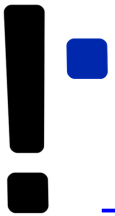

Mehrfach-Interrupts (7)

- Problem bei gesperrten Interrupts: Behandlung muss schnell erfolgen
- Lösung: Aufteilung des Int.-Handlers in zwei Komponenten
  - erste Komponente bestätigt Interrupt, sichert wichtige Informationen und gibt Interrupts wieder frei
  - zweite Komponente läuft später (bei aktivierten Interrupts) und erledigt restliche Aufgaben
  - Beispiel: Linux „top half/bottom half“ → später

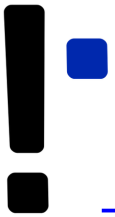

Interrupts unterscheiden (1)

- CPU hat nur einen Interrupt-Eingang – wie kann sie zwischen verschiedenen Geräten unterscheiden, die einen Interrupt erzeugen?
- Interrupt Controller
  - mehrere Eingänge (z. B. 8 beim Intel 8259)
  - ein Ausgang (zur CPU)
  - Kommunikation der Interrupt-Nummer (an CPU) über zusätzliche Datenleitungen

Interrupts unterscheiden (2)

IDE Controller

Interrupt Controller

CPU

Interrupt

INT

setzt Bit in IRR

INT

löscht Bit in IRR

INTA

gibt über D0...D7 Int.-Nr. aus

INTA

liest Nummer über Port

EOI

startet Interrupt Handler

Glossar:

INT	Interrupt
INTA	Interrupt Acknowledge
EOI	End of Interrupt
IRR	Interrupt Request Register

Bildquellen: IDE Controller: http://www.ebay.de/usr/sm-pc, 8259A: http://www.brokenthorn.com/Resources/OSDevPic.html, i386: http://www.cpu-world.com/CPUs/80386/Intel-A80386DX-25%20IV.html

Interrupts unterscheiden (3)

- PCs: Klassischer PIC (**Programmable Interrupt Controller**) Intel 8259 hat nur acht Eingänge

  → Kaskadierung von zwei PICs

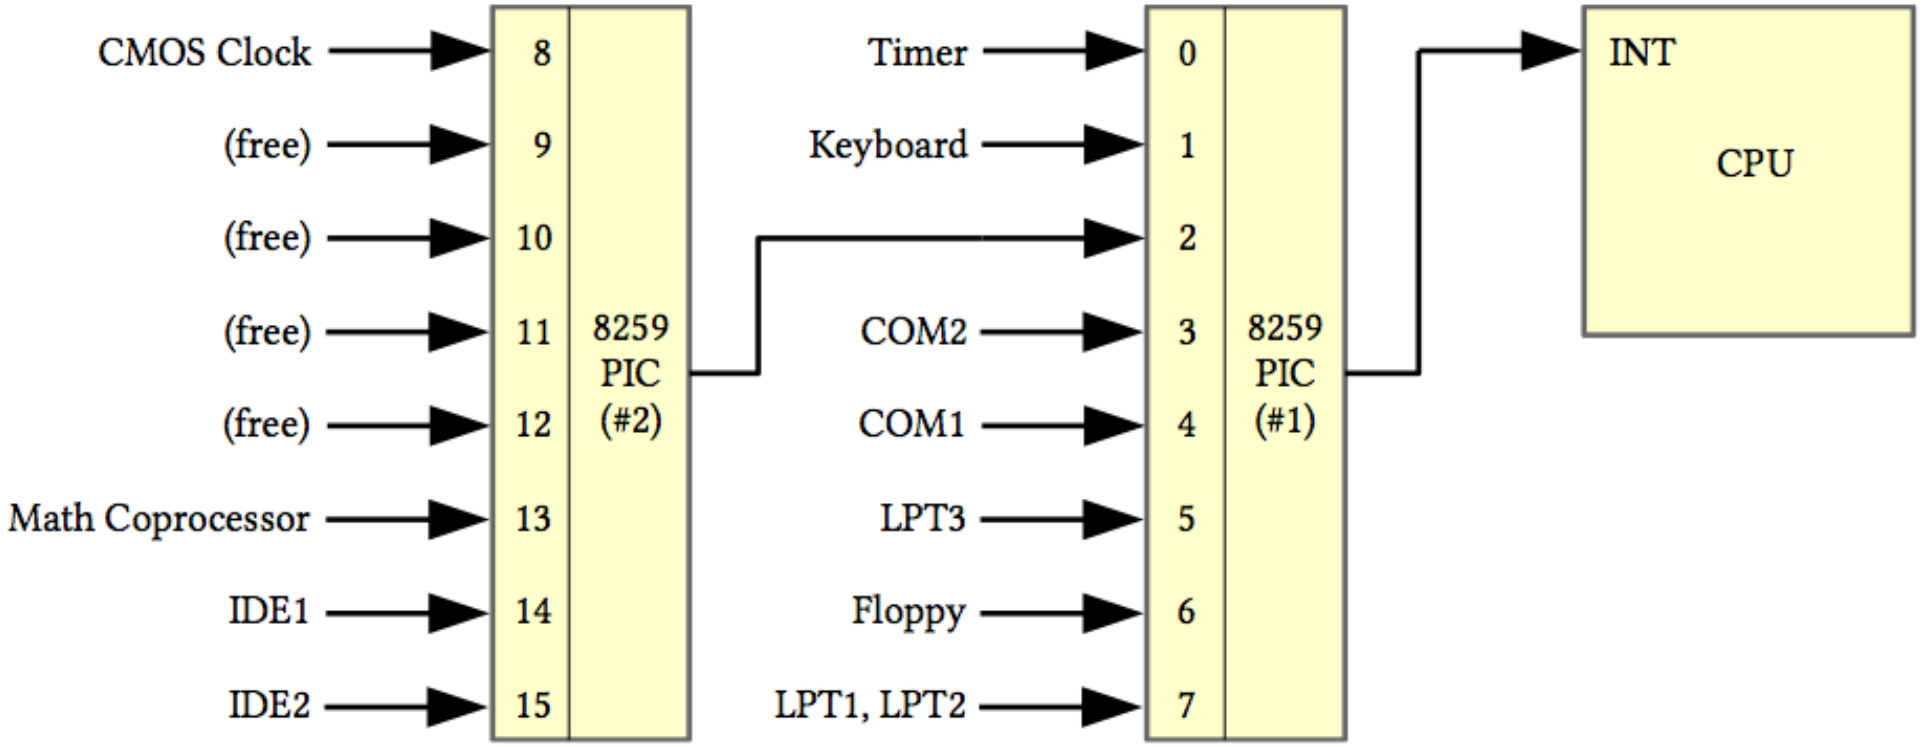

Interrupts unterscheiden (4)

Intel 8259 ist programmierbar. Ziel:

Bildquellen:
siehe Folie 29

CPU

PIC 1

PIC 2

erzeugt Faults (Nr. 0–31)

0 = Division by Zero
1 = Debug
2 = Non-maskable Interrupt
3 = Breakpoint
…

0 1 2 3 4 5 6 7 0 1 2 3 4 5 6 7

programmiertes Mapping gibt höhere Nummer weiter

0 1 2 3 4 5 6 … … 30 31 32 33 34 35 36 37 38 39 40 41 42 43 44 45 46 47

Interrupt-Nummern (aus Sicht des Prozessors und des Betriebssystems)

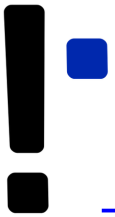

Interrupts unterscheiden (5)

- Teilweise Mehrfachbelegung von Interrupts
- Betriebssystem muss alle Geräte (die sich diesen Interrupt teilen) befragen
- Beispiel Linux-Treiber:
  - für jedes Gerät einen Handler registrieren
  - Interrupt-Handler für Int.-Nummer *X* ruft nacheinander alle Handler (von Geräten mit Int.-Nr. *X*) auf – bis ein Handler sagt: „Das war mein Interrupt.“

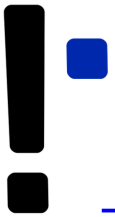

I/O-lastig vs. CPU-lastig (1)

- **CPU-lastiger Prozess**
  - Prozess benötigt überwiegend CPU-Rechenzeit und vergleichsweise wenig I/O-Operationen
  - Längere Rechenphasen werden nur gelegentlich durch I/O-Wartezeiten unterbrochen
- **I/O-lastiger Prozess**
  - Prozess führt viele I/O-Operationen durch und benötigt vergleichsweise wenig Rechenzeit
  - Sehr kurze Rechenphasen wechseln sich mit häufigen Wartezeiten auf I/O ab

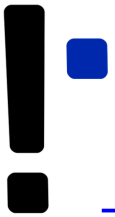

I/O-lastig vs. CPU-lastig (2)

Multitasking und Interrupts

- Multitasking verbessert CPU-Nutzung:
  - I/O-lastiger Prozess wartet auf I/O-Events,
  - CPU-lastiger Prozess rechnet währenddessen weiter
- Prozess stößt I/O-Operation an und blockiert (wartet darauf, dass das BS ihn wieder auf „bereit“ setzt und irgendwann fortsetzt)
- optimale Performance: gute Mischung I/O- und CPU-lastiger Prozesse

I/O-lastig vs. CPU-lastig (3)

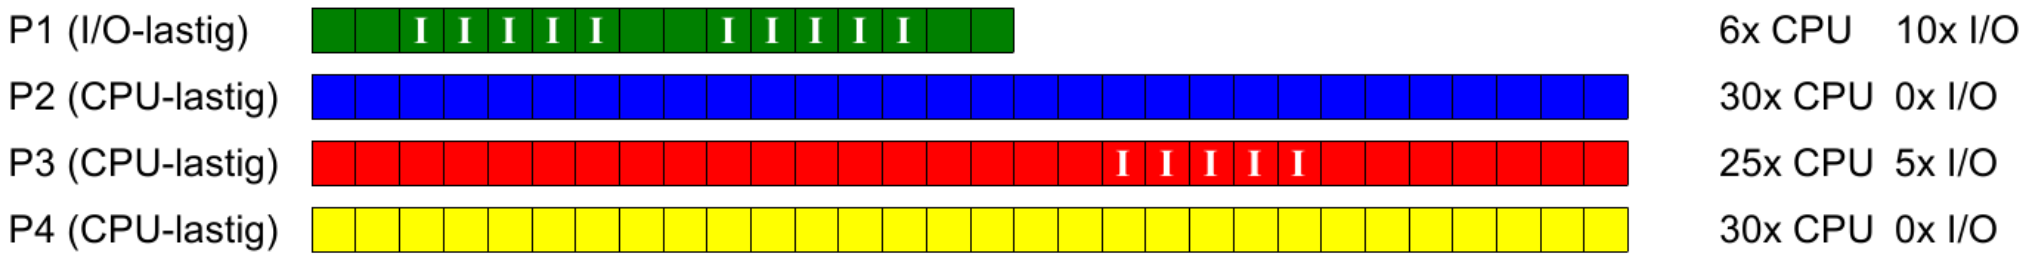

Ausführreihenfolge mit Round Robin, Zeitquantum 15:

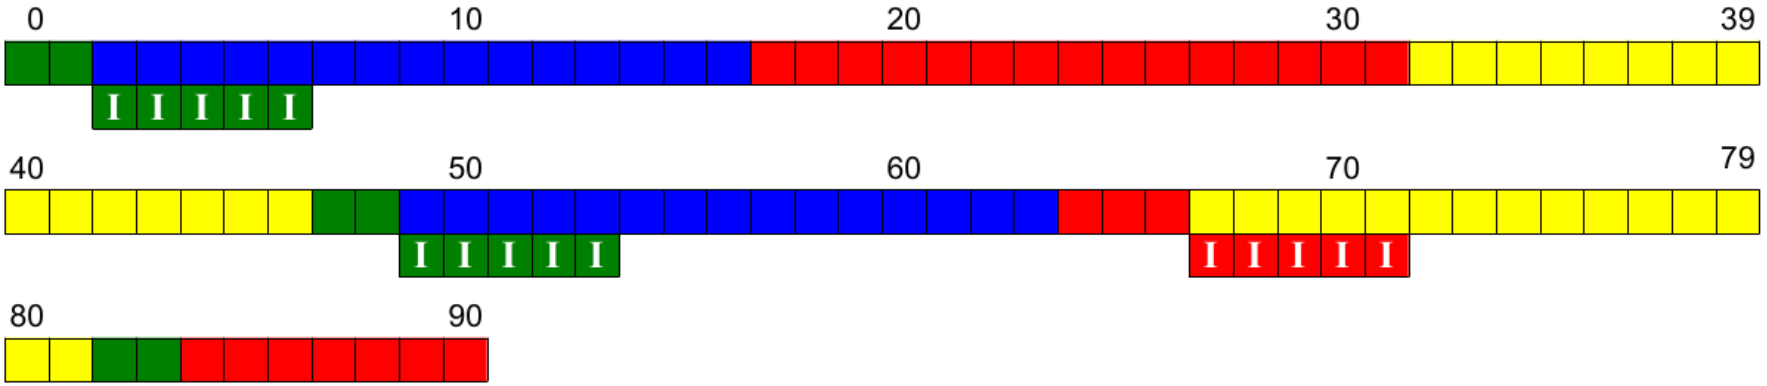

Prozess	CPU-Zeit	I/O-Zeit	Summe	Laufzeit	Wartezeit *)
P1	6	10	16	84	68
P2	30	0	30	64	34
P3	25	5	30	91	61
P4	30	0	30	82	52

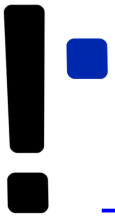

Praxis: Interrupts unter Linux

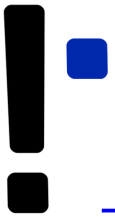

Interrupt-Übersicht (Single-Core-CPU)

```
[esser@server ~]$ cat /proc/interrupts
           CPU0
  0: 3353946487          XT-PIC  timer
  2:          0          XT-PIC  cascade
  3:       4663          XT-PIC  NVidia CK804
  5:  159275991          XT-PIC  ohci1394, nvidia
  7:     971775          XT-PIC  hsfpcibasic2
  8:          2          XT-PIC  rtc
  9:          0          XT-PIC  acpi
 10:      31052          XT-PIC  libata, ohci_hcd
 11:  197906977          XT-PIC  libata, ehci_hcd
 12:   16904921          XT-PIC  eth0
 14:   60349322          XT-PIC  ide0
NMI:          0
LOC:          0
ERR:          0
MIS:          0
```

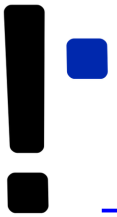

Moderne Maschine mit vier Cores

```
[esser@quad:~]$ cat /proc/interrupts
           CPU0       CPU1       CPU2       CPU3
  0:       5224          3          1          1   IO-APIC-edge      timer
  1:     298114        774        793        793   IO-APIC-edge      i8042
  3:          9          8          6          9   IO-APIC-edge
  4:          8          9          8          6   IO-APIC-edge
  8:          0          0          0          1   IO-APIC-edge      rtc0
  9:          0          0          0          0   IO-APIC-fasteoi   acpi
 12:    3070145      16539      16542      16485   IO-APIC-edge      i8042
 16:    2760924        881        904        886   IO-APIC-fasteoi   uhci_hcd:usb1, nvidia
 18:   24122388       6538       6698       6647   IO-APIC-fasteoi   ehci_hcd:usb6, uhci_hcd:usb7
 19:        281         28         27         10   IO-APIC-fasteoi   uhci_hcd:usb3, uhci_hcd:usb5
 21:      22790          0          0          0   IO-APIC-fasteoi   uhci_hcd:usb2
 22:    7786588   10464141    8251870    8439964   IO-APIC-fasteoi   HDA Intel
 23:        899          0          1          1   IO-APIC-fasteoi   uhci_hcd:usb4, ehci_hcd:usb8
221:    9519152   10751650    9745810   10326363   PCI-MSI-edge      eth0
222:   14462926      38205      38095      38178   PCI-MSI-edge      ahci
NMI:          0          0          0          0   Non-maskable interrupts
LOC:  724999305  786034088  748693018  748218173   Local timer interrupts
RES:    5334382    3576152    3464671    3357556   Rescheduling interrupts
CAL:    2111668    4233550    4067655    3871450   function call interrupts
TLB:     101757     113319      88752     107777   TLB shootdowns
TRM:          0          0          0          0   Thermal event interrupts
SPU:          0          0          0          0   Spurious interrupts
ERR:          0
MIS:          0
```

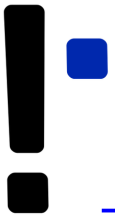

Interrupt Handler (1)

Für jedes Gerät:

- Interrupt Request (IRQ) Line
- Interrupt Handler (Interrupt Service Routine, ISR) → Teil des Gerätetreibers
- C-Funktion
- läuft in speziellem Context (Interrupt Context)
- „top half“ und „bottom half“

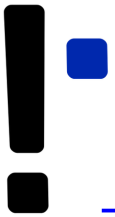

Interrupt Handler (2)

„top half“ und „bottom half“

top half

- Interrupt handler
- startet sofort, erledigt zeitkritische Dinge
- bestätigt (der Hardware) den Erhalt des Interrupts, setzt Gerät zurück etc.
- erzeugt bottom half
- Alles andere → bottom half

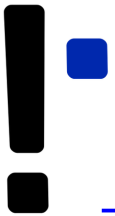

Interrupt Handler (3)

Tasklet (bottom half)

- Tasklets führen längere Berechnungen durch, die zur Interrupt-Verarbeitung gehören – dabei sind Interrupts zugelassen
- Tasklet ist kein Prozess (struct tasklet_struct), läuft direkt im Kernel; im Interrupt-Context
- Zwei Prioritäten:
  - *tasklet_hi_schedule*: startet direkt nach ISR
  - *tasklet_schedule*: startet erst, wenn kein anderer Soft IRQ mehr anliegt

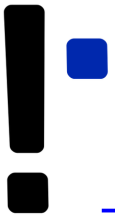

Interrupt Handler (4)

Mehr Informationen:

[1] Linux Kernel 2.4 Internals, Kapitel 2,
http://www.faqs.org/docs/kernel_2_4/lki-2.html

[2] J. Quade, E.-K. Kunst: „Linux-Treiber entwickeln“,
dpunkt-Verlag,
http://ezs.kr.hsnr.de/TreiberBuch/html/

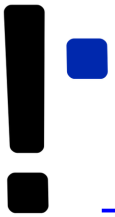

System Calls

User Mode vs. Kernel Mode (1)

- Anwendungen laufen im nicht-privilegierten User Mode
  - Beispiel: Intel
  - Ring 0 = Betriebssystem (Kernel Mode)

    → Vollzugriff auf die Hardware
  - Ring 3 = Anwendung (User Mode)

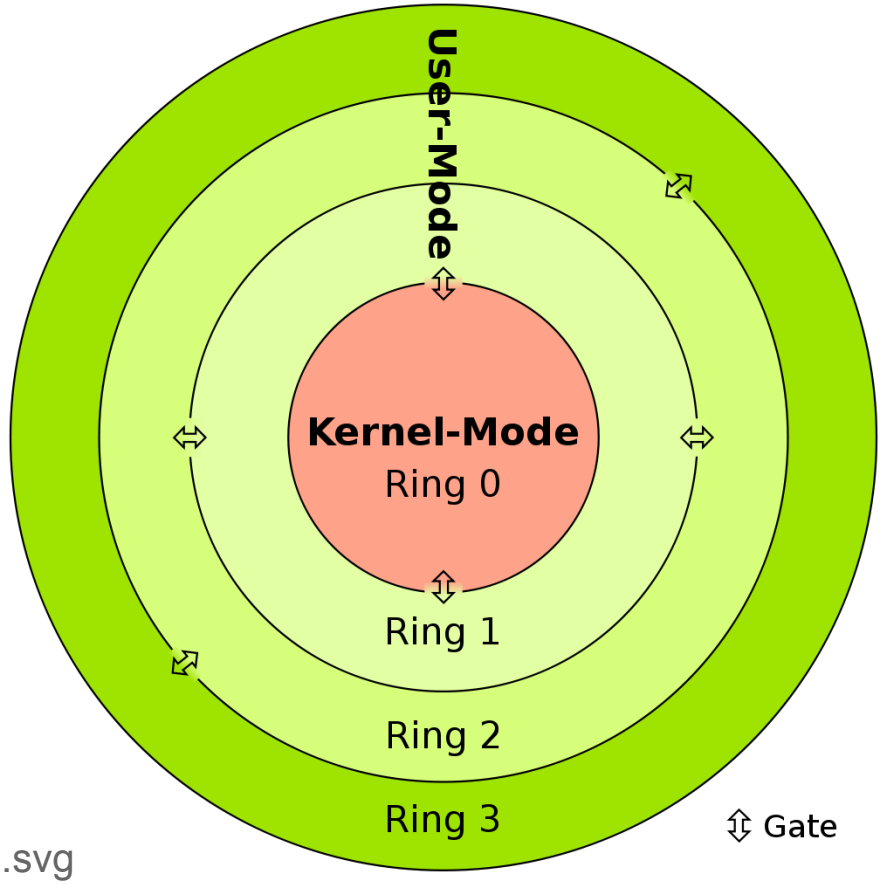

Bild: http://commons.wikimedia.org/wiki/File:CPU_ring_scheme.svg (Autor: http://commons.wikimedia.org/wiki/User:Sven; GNU Free Documentation License)

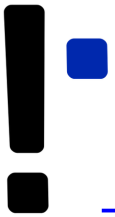

User Mode vs. Kernel Mode (2)

- Problem:
  - Daten und Code des Betriebssystems sollen vor Zugriff durch Anwendungen geschützt sein,

    aber:
  - Anwendungen müssen Betriebssystem-Funktionen nutzen, um z. B. auf Datenträger zuzugreifen.
- Lösung: System Calls – ein kontrollierter Übergang vom User Mode in den Kernel Mode
- Mechanismus: Software Interrupt (CPU-Instruktion)
  - Intel: z. B. `int 0x80`

User Mode vs. Kernel Mode (3)

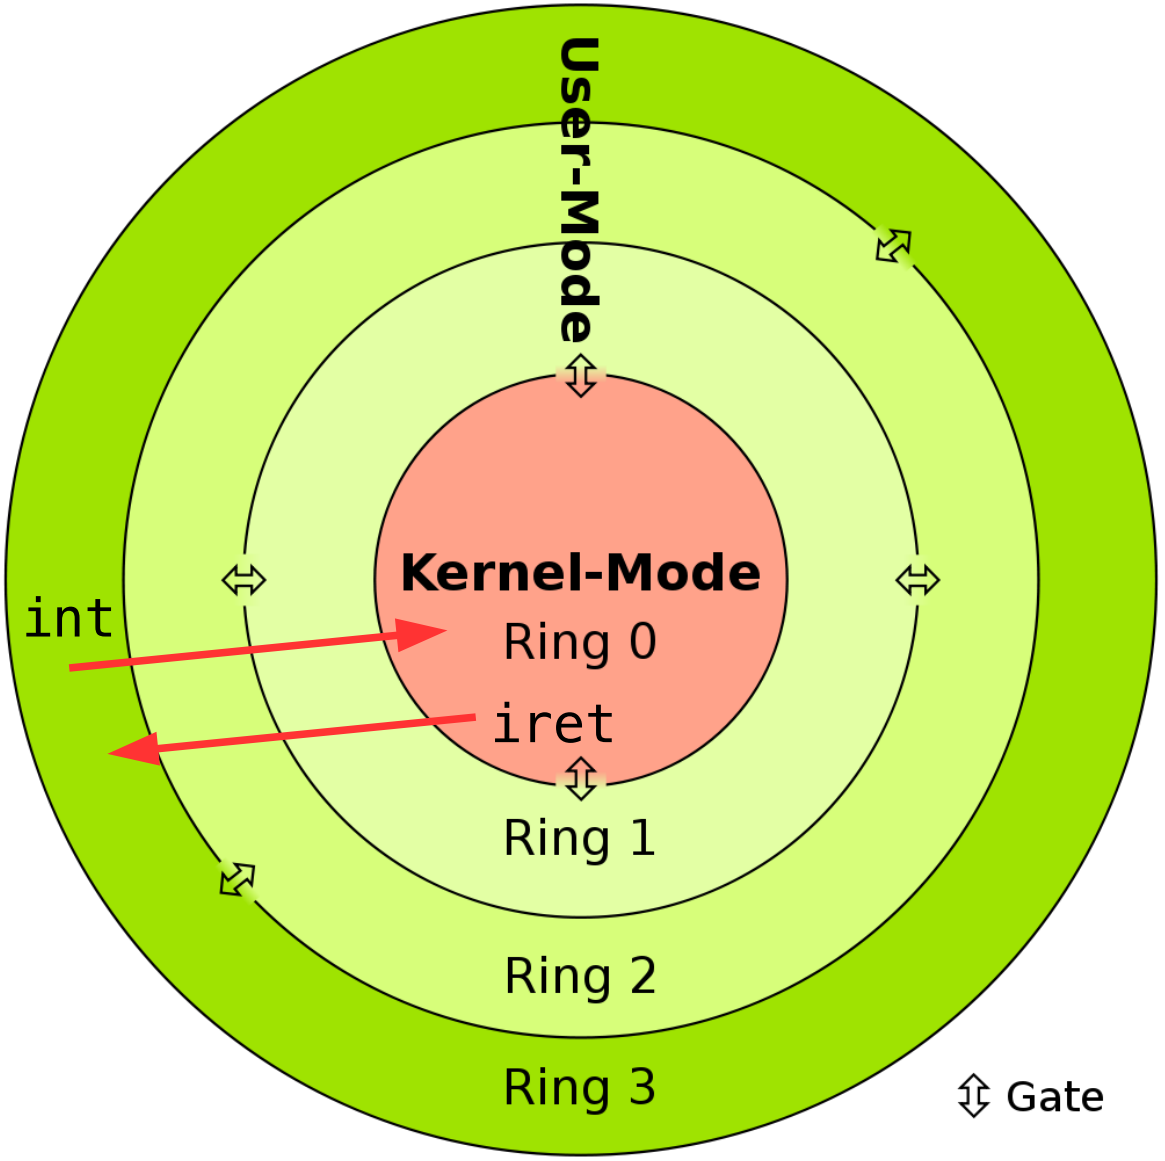

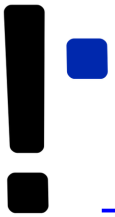

User Mode vs. Kernel Mode (4)

Vorgehensweise:

- Anwendung trägt **System-Call-Nummer** in ein Register ein (oder schreibt sie auf den Stack)
- Parameter für den System Call: in weitere Register (oder Stack)
- Software-Interrupt auslösen → durch spezielle CPU-Instruktion, z. B.
  - `sysenter` (Intel, ab Pentium II),
  - `syscall` (AMD64)
  - `int` (alle Intel und kompatible)
- CPU reagiert auf `int`-Instruktion wie auf einen HW-Interrupt und ruft Interrupt-Handler auf

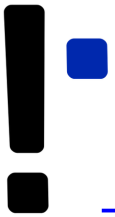

User Mode vs. Kernel Mode (5)

Vorgehensweise (Fortsetzung):

- generischer Interrupt-Handler für System-Call-Behandlung liest System-Call-Nummer (aus Register oder vom Stack)
- über **System-Call-Tabelle** den richtigen **System-Call-Handler** identifizieren und aufrufen
- im spezifischen System-Call-Handler:
  - Argumente auswerten
  - prüfen, ob Anwendung zum Aufruf (diese Funktion, mit diesen Parametern) berechtigt ist
  - Aufruf geeigneter Kernel-Funktionen

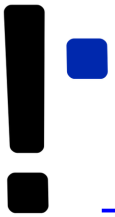

User Mode vs. Kernel Mode (6)

Vorgehensweise (Fortsetzung):

- nach Bearbeitung:
  - Rücksprung aus spezifischem System-Call-Handler (ggf. mit Rückgabe eines Ergebnis-Werts)
  - Rücksprung aus Interrupt-Handler: `sysleave` (Pentium II), `sysret` (AMD), `iret` (Intel); ggf. mit Rückgabe des Ergebnis aus dem Syscall-Handler

    → Übergang von Ring 0 zurück in Ring 3
  - Fortsetzung der Prozess-Ausführung (ggf. Auswertung des Syscall-Ergebnis-Werts)
- zur Vereinfachung für Anwendungs-Entwickler: **User-Mode-Bibliothek** mit Wrappern für die System Calls

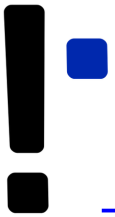

Beispiel für *Anwendung* (Linux)

- Ausgabe auf `stdout`

```
_start:                                 ; tell linker entry point
        mov edx,len                     ; message length
        mov ecx,msg                     ; message to write
        mov ebx,1                       ; file descriptor (stdout)
        mov eax,4                       ; system call number (sys_write)
        int 0x80                        ; software interrupt 0x80
        mov eax,1                       ; system call number (sys_exit)
        int 0x80                        ; software interrupt 0x80

section .data
msg     db 'Hello, world!',0xa          ; the string to be printed
len     equ $ - msg                     ; length of the string
```

Beispiel *Implementation*

Beschreibung folgt später

`syscall3()`

- kopiert drei Argumente in EAX, EBX, ECX
- führt `int 0x80` aus
- liest Rückgabewert aus EAX

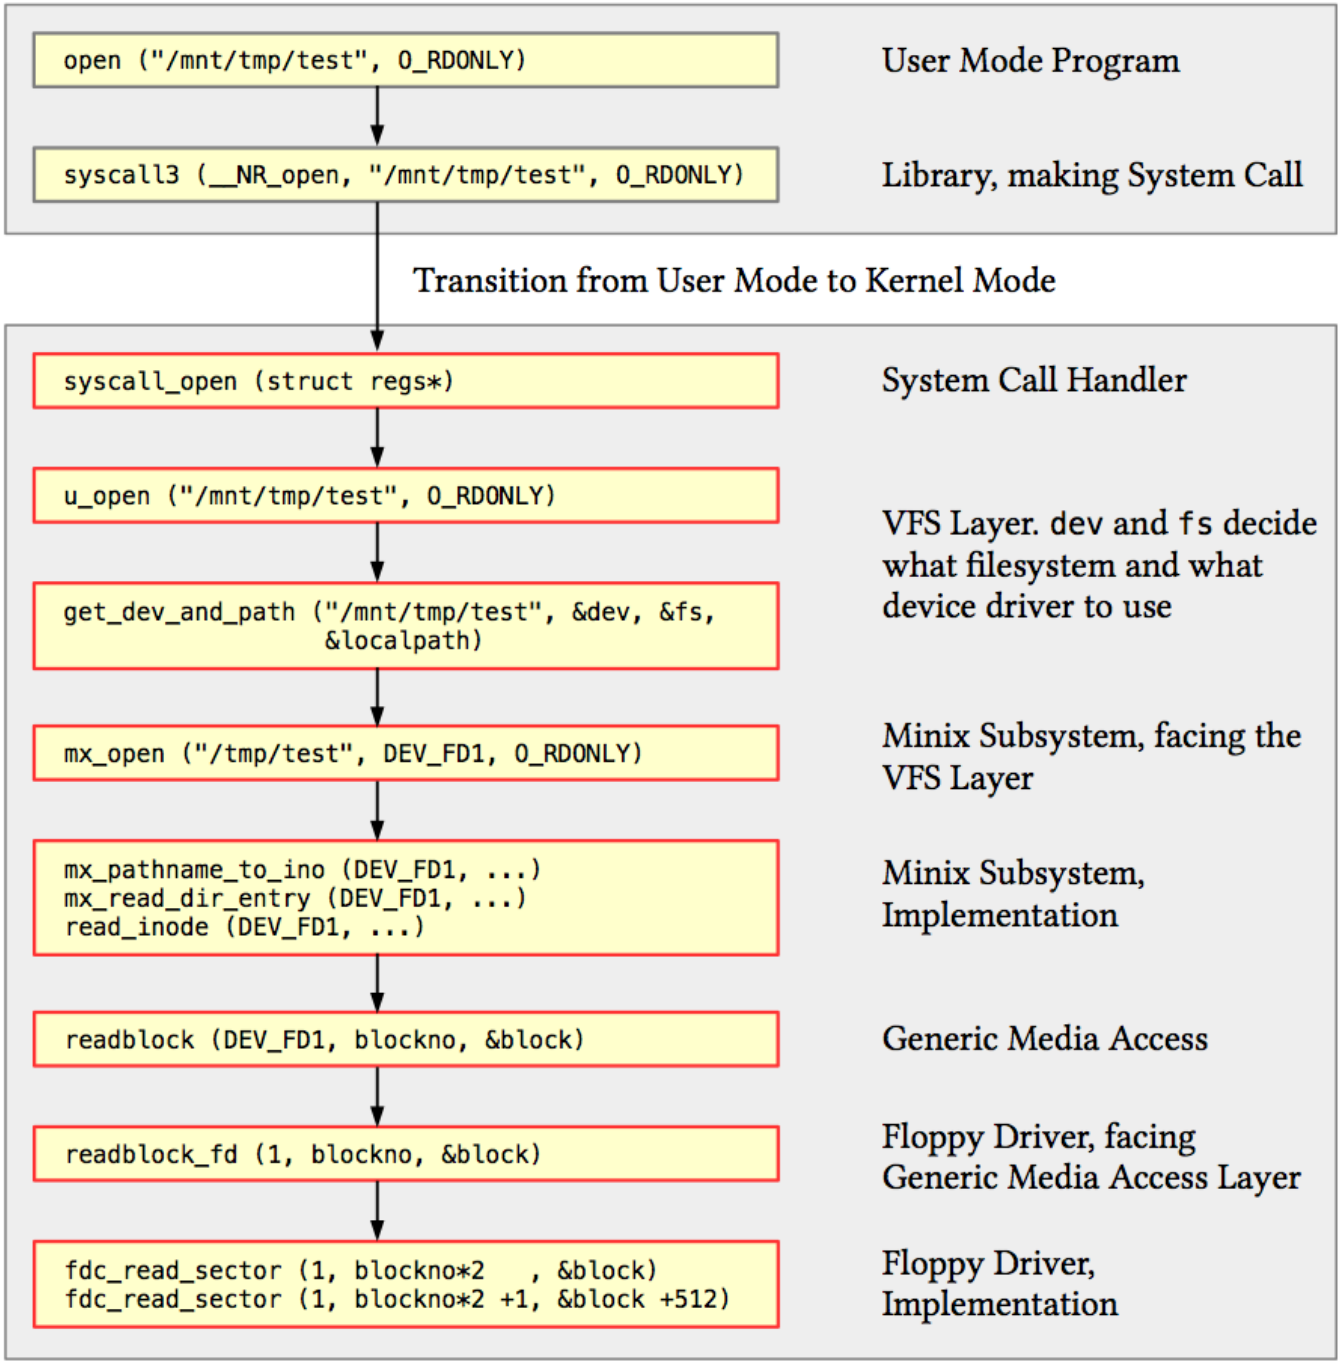

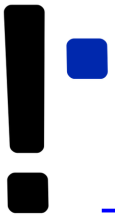

System-Call-Nummern

/usr/include/asm/unistd_32.h: Über 300 System Calls

```
/*
 * This file contains the system call
 * numbers.                                */

#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
#define __NR_mount               21
#define __NR_umount              22
#define __NR_setuid              23
#define __NR_getuid              24
#define __NR_stime               25
#define __NR_ptrace              26
#define __NR_alarm               27
#define __NR_oldfstat            28
#define __NR_pause               29
#define __NR_utime               30
#define __NR_stty                31
#define __NR_gtty                32
#define __NR_access              33
#define __NR_nice                34
#define __NR_ftime               35
#define __NR_sync                36
#define __NR_kill                37
...
```

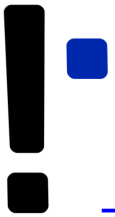

System Calls für Programmierer:

Standardfunktionen in C

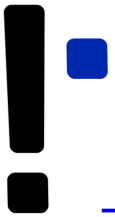

System Calls / User-Mode-Bibliothek

- Standardbibliotheken stellen Wrapper für System Calls bereit
- hier nur kleine Auswahl:
  - Dateizugriff: `open`, `read`, `write`, `close`
  - Prozesse: `fork`, `exit`, `execl(p)`

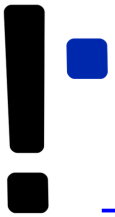

Linux System Calls (2)

open( )
Daten zum Lesen/Schreiben öffnen

```
int open(const char *pathname, int flags);
int open(const char *pathname, int flags, mode_t mode);
int creat(const char *pathname, mode_t mode);
```

Rückgabewert: File Descriptor

```
man 2 open
```

Beispiel:

```
fd = open("/tmp/datei.txt",O_RDONLY);
```

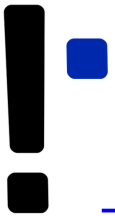

Linux System Calls (3)

`read( )`
Daten aus Datei (File Descriptor) lesen

```
ssize_t read(int fd, void *buf, size_t count);
```

Rückgabewert: Anzahl gelesene Bytes

```
man 2 read
```

Beispiel:

```
int bufsiz=128; char line[bufsiz+1];
int fd = open( "/etc/fstab", O_RDONLY );
int len = read ( fd, line, bufsiz );
```

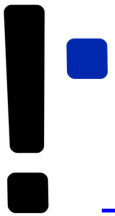

Linux System Calls (4)

Beispiel: `read( )` und `open( )`

```
#include <sys/types.h>
#include <sys/stat.h>
#include <fcntl.h>
#include <unistd.h>
#include <stdio.h>
int main (void) {
  int len; int bufsiz=128; char line[bufsiz+1];
  line[bufsiz] = '\0';
  int fd = open( "/etc/fstab", O_RDONLY );
  while ( (len = read ( fd, line, bufsiz )) > 0 ) {
    if ( len < bufsiz) { line[len]='\0'; }
    printf ("%s", line );
  }
  close(fd);
  return 0;
}
```

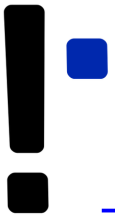

Linux System Calls (5)

write( )
Daten in Datei (File Descriptor) schreiben

```
ssize_t write(int fd, void *buf, size_t count);
```

Rückgabewert: Anzahl geschriebene Bytes

```
man 2 write
```

Beispiel:

```
main() {
  char message[] = "Hello world\n";
  int fd = open( "/tmp/datei.txt",
    O_CREAT | O_WRONLY, S_IRUSR | S_IWUSR );
  write ( fd, message, sizeof(message) );
  close(fd);
  exit(0);
}
```

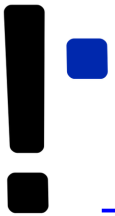

Linux System Calls (6)

`close( )`
Datei (File Descriptor) schließen

```
int close(int fd);
```

Rückgabewert: 0 bei Erfolg, sonst -1 (`errno` enthält dann Grund)

```
man 2 close
```

Beispiel:

```
close(fd);
```

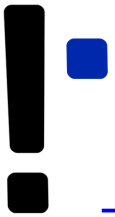

Linux System Calls (7)

`exit( )`
Programm beenden

```
void exit(int status);
```

Kein Rückgabewert, aber *status* wird an aufrufenden Prozess weitergegeben.

```
man 3 exit
```

Beispiel:

```
exit(0);
```

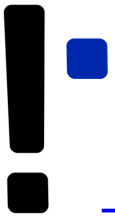

Linux System Calls (8)

`fork( )`
neuen Prozess starten

```
pid_t fork(void);
```

Rückgabewert: Child-PID (im Vaterprozess); 0 (im Sohnprozess); -1 (im Fehlerfall)

```
man fork
```

Beispiel:

```
pid=fork()
```

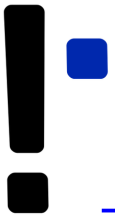

Linux System Calls (9)

exec( )
Anderes Programm im Prozess laden

```
int execl(const char *path, const char *arg, ...);
int execlp(const char *file, const char *arg, ...);
int execle(const char *path, const char *arg , ..., char * const envp[]);
int execv(const char *path, char *const argv[]);
int execvp(const char *file, char *const argv[]);
```

Rückgabewert: keiner (Funktion kehrt nicht zurück)
Parameter arg0 (Name), arg1, ...; letztes Argument: NULL-Zeiger

```
man 3 exec
```

Beispiele:

```
execl ("/usr/bin/vi", "", "/etc/fstab", (char *) NULL);
execlp ("vi", "", "/etc/fstab", (char *) NULL);
```

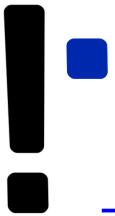

Header-Dateien einbinden

Am Anfang jedes C-Programms:

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

sys/stat.h enthält z. B. S_IRUSR, S_IWUSR
fcntl.h enthält z. B. O_CREAT, O_WRONLY

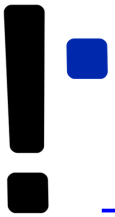

Ulix: Interrupts

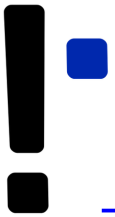

Interrupts: Bedarf bei Ulix

- Timer → u. a. Aufruf des Schedulers (Prozess- bzw. Thread-Wechsel), Hochzählen der Systemzeit
- Tastatur
- Festplatten- und Floppy-Controller
- serielle Schnittstelle

- Quellcode nachlesen im PDF-Dokument *ulix-interrupt-listings.pdf* (Webseite)
- Ziel: Komplexität einer (einfachen) Beispiel-Implementierung sehen (*nicht*: auswendig lernen...)

Kaskadierte PICs [= Folie 30]

- Zwei PICs (Programmable Interrupt Controller)
- kaskadiert

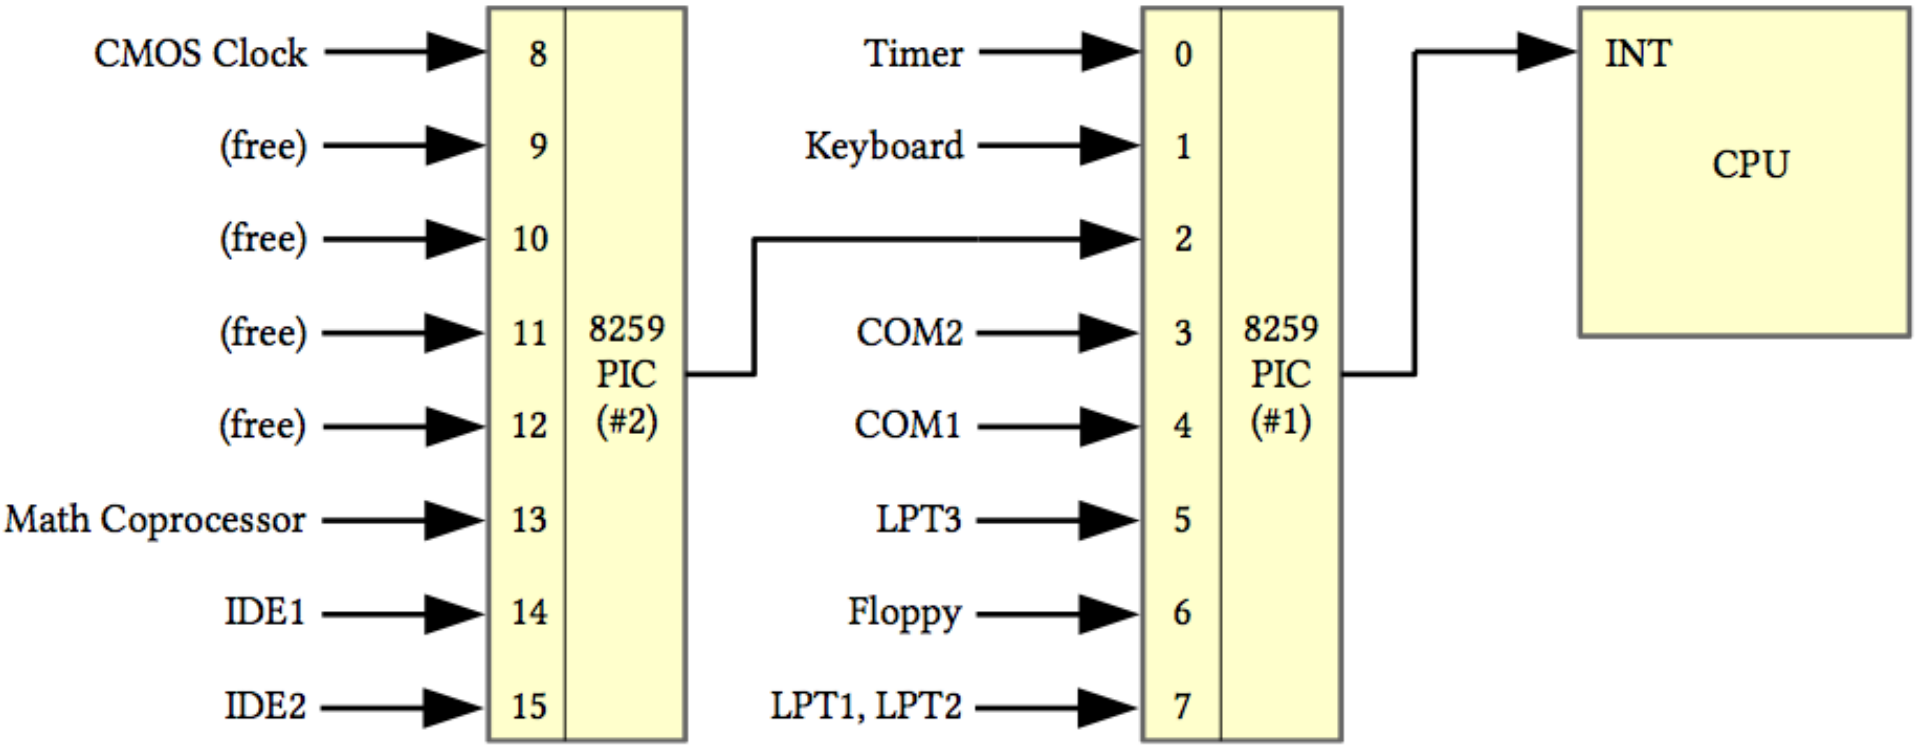

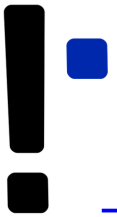

Konstanten für Interrupt-Nummern

irq.h (19–29)

```
19  // IRQ numbers 0 to 7 are handled by the "master PIC", numbers 8 to 15 are
20  // handled by the "slave PIC".
21  // The slave PIC generates an IRQ number 2 on the master PIC.
22
23  #define IRQ_TIMER      0
24  #define IRQ_KBD        1
25  #define IRQ_SLAVE      2     // Here the slave PIC connects to master
26  #define IRQ_COM2       3
27  #define IRQ_COM1       4
28  #define IRQ_FDC        6
29  #define IRQ_IDE       14     // primary IDE controller; secondary has IRQ 15
```

später: Interrupt-Handler für diese Interrupt-Nummern einrichten

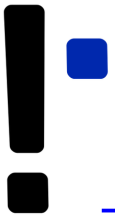

PICs programmieren

- PICs initialisieren
  - über Kaskadierung informieren
  - Mapping der Interrupt-Nummern (jeweils 0–7) auf 32–39 bzw. 40–47 einrichten
- Für Zugriff auf PICs: in- und out-Befehle
  - Lesen und Schreiben von Ports
  - `inportb`, `outportb`: byte-weise (8 bit)
    `inportw`, `outportw`: wort-weise (16 bit)
  - Funktionen nutzen Assembler-Befehle `inb`, `outb`, `inw`, `outw` (und diese nutzen CPU-Register)

32-Bit-Register (EAX, EBX etc.)

- Zur Erinnerung: Intel-Register-Struktur

  EAX (32 bit), enthält *AX* (16 bit), *AL* (8 bit)

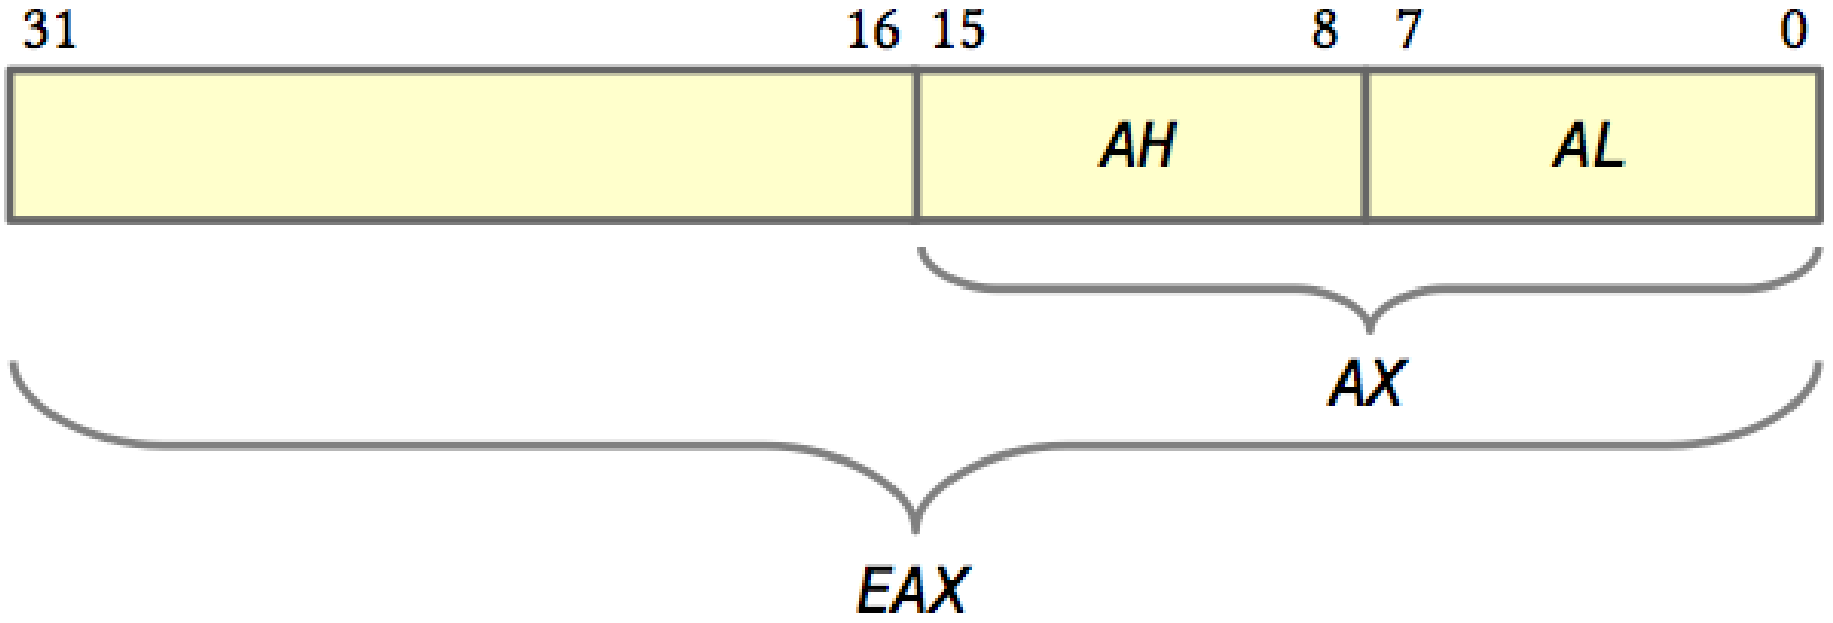

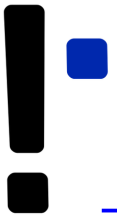

Ein-/Ausgabe

irq.c (31–39, 48–51)

```
31  // The inport*() and outport*() functions retrieve a byte or word
32  // from a port or send it to the port.
33
34  byte
35  inportb (word port) {
36    byte retval;
37    asm volatile ("inb %%dx, %%al" : "=a"(retval) : "d"(port));
38    return retval;
39  }
```

```
48  void
49  outportb (word port, byte data) {
50    asm volatile ("outb %%al, %%dx" : : "d" (port), "a" (data));
51  }
```

analog: `inportw`, `outportw` (mit `inw`, `outw`)

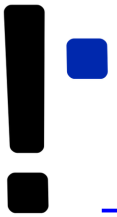

PIC-Register

- Jeder der beiden PICs hat ein **Command Register** und ein **Control Register,** beschreibbar über Ports

irq.h (31–41)

```
31 // The two PICs (programmable interrupt controllers) must be configured:
32 // they have to be aware of their master/slave states and how the slave
33 // connects to the master.
34
35 // I/O Addresses of the PICs:
36
37 #define IO_PIC_MASTER_CMD   0x20  // Master (IRQs 0-7), command register
38 #define IO_PIC_MASTER_DATA  0x21  // Master, control register
39
40 #define IO_PIC_SLAVE_CMD    0xA0  // Slave (IRQs 8-15), command register
41 #define IO_PIC_SLAVE_DATA   0xA1  // Slave, control register
```

PIC programmieren [= Folie 31]

Interrupt-Nummern remappen

Bildquellen:
siehe Folie 29

CPU

PIC 1

PIC 2

erzeugt Faults (Nr. 0–31)

0 = Division by Zero
1 = Debug
2 = Non-maskable Interrupt
3 = Breakpoint
…

0 1 2 3 4 5 6 7 0 1 2 3 4 5 6 7

programmiertes Mapping gibt höhere Nummer weiter

0 1 2 3 4 5 6 … … 30 31 32 33 34 35 36 37 38 39 40 41 42 43 44 45 46 47

Interrupt-Nummern (aus Sicht des Prozessors und des Betriebssystems)

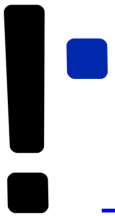

PIC programmieren

- Ziel: Remapping der Interrupt-Nummern
  - Master: 0..7 → 32..39
  - Slave: 0..7 → 40..47
- Dazu: Senden von vier Kontrollsequenzen ICW1 bis ICW4 (Initialization Command Words) an jeden der beiden PICs
- ICW1: Programmierung initialisieren
  → `irq.c`, 165-166

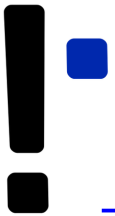

PIC programmieren

- ICW2: Remapping festlegen durch Angabe des Offset; einmal 32 (0x20), einmal 40 (0x28)
  → `irq.c`, 167-170
- ICW3: Slave-Konfiguration
  → `irq.c`, 171-173
- ICW4: 8086 mode
  → `irq.c`, 174-175

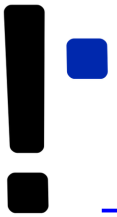

PIC programmieren

irq.c (165–175), setup_irqs_and_faults()

```
165     outportb (IO_PIC_MASTER_CMD,  0x11);  // ICW1: initialize; begin programming
166     outportb (IO_PIC_SLAVE_CMD,   0x11);  // ICW1: dito, for PIC2
167     outportb (IO_PIC_MASTER_DATA, 0x20);  // ICW2 for PIC1: offset 0x20
168                                           //   (remaps 0x00..0x07 -> 0x20..0x27)
169     outportb (IO_PIC_SLAVE_DATA,  0x28);  // ICW2 for PIC2: offset 0x28
170                                           //   (remaps 0x08..0x0f -> 0x28..0x2f)
171     outportb (IO_PIC_MASTER_DATA, 0x04);  // ICW3 for PIC1: there's a slave on
172                                           //   IRQ 2 (0b00000100 = 0x04)
173     outportb (IO_PIC_SLAVE_DATA,  0x02);  // ICW3 for PIC2: your slave ID is 2
174     outportb (IO_PIC_MASTER_DATA, 0x01);  // ICW4 for PIC1 and PIC2: 8086 mode
175     outportb (IO_PIC_SLAVE_DATA,  0x01);
```

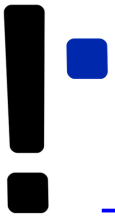

Interrupt-Handler

- CPU muss Adressen der Interrupt-Handler kennen
- Intel-Architektur:
  - CPU-Register IDTR enthält Adresse eines **IDT Pointers**
  - IDT-Pointer speichert Adresse und Länge der **Interrupt Descriptor Table (IDT)**
  - IDT besteht aus mehreren **Interrupt Descriptors**

Interrupt Descriptor (Typ)

irq.h (58–65)

```
56  // idt_entry is an entry in the Interrupt Descriptor Table (IDT)
57
58  struct idt_entry {
59      unsigned int addr_low  : 16;   // lower 16 bits of address
60      unsigned int gdtsel    : 16;   // use which GDT entry?
61      unsigned int zeroes    :  8;   // must be set to 0
62      unsigned int type      :  4;   // type of descriptor
63      unsigned int flags     :  4;
64      unsigned int addr_high : 16;   // higher 16 bits of address
65  } __attribute__((packed));
```

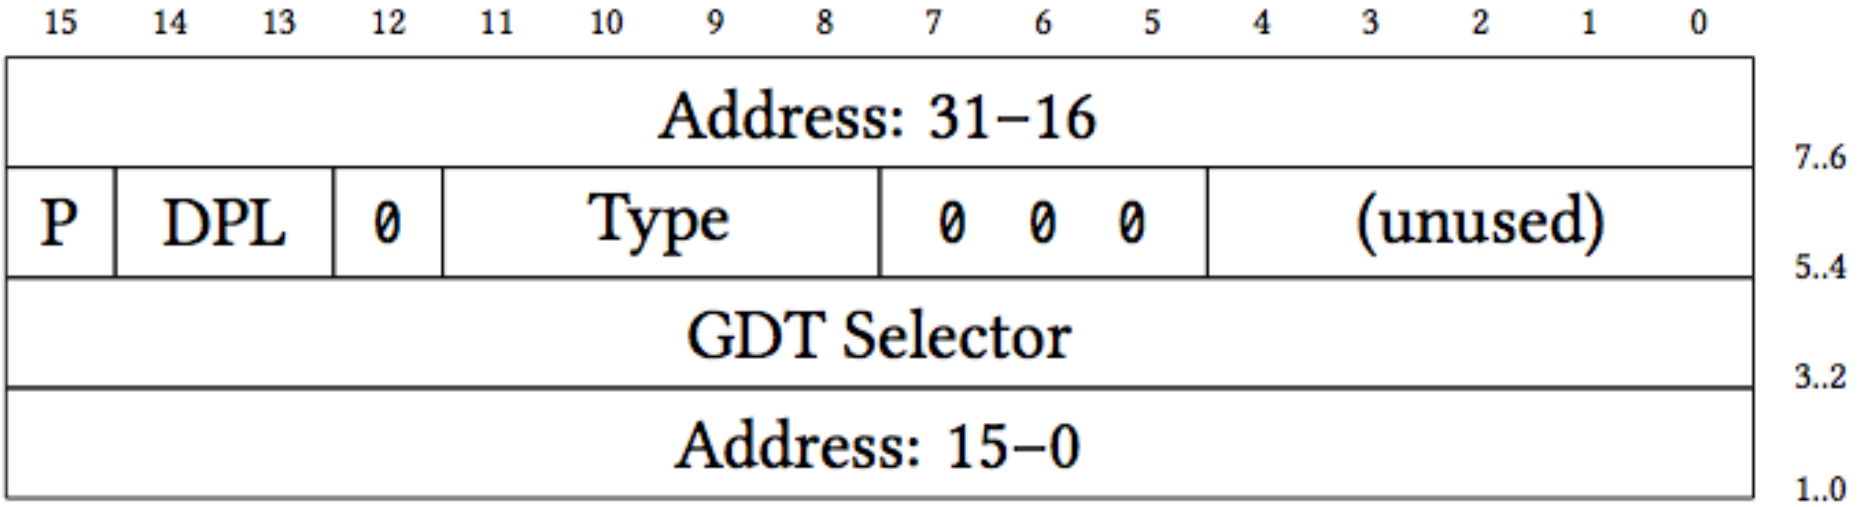

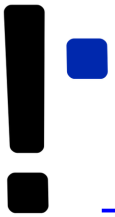

IDT-Pointer (Typ)

irq.h (71–74)

```
68  // idt_ptr describes address and size of the IDT. The address of
69  // this structure must be loaded in the IDTR (IDT register).
70
71  struct idt_ptr {
72      unsigned int limit   : 16;
73      unsigned int base    : 32;
74  } __attribute__((packed));
```

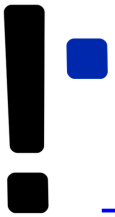

IDT und IDT-Pointer (Variablen)

- Globale Variablen:
  - Die Tabelle selbst (`idt`)
  - der **IDT Pointer** auf die Tabelle (`idt_ptr`)
  - Adresse von `idt_ptr` später in IDTR schreiben

`globals.h (82–83)`

```
81 // interrupts
82 struct idt_entry idt[256] = { { 0 } };
83 struct idt_ptr idtp;
```

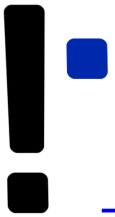

Interrupt Descriptor füllen (1)

- Funktion `fill_idt_entry()` schreibt einen IDT-Eintrag
- hier wichtig: Interrupt-Nummer und Handler-Adresse (zu `gdtsel`, `flags`, `type`: → später)

Interrupt Descriptor füllen (2)

irq.c (72–83)

```
59 // fill_idt_entry() fills an entry in the interrupt descriptor table (IDT).
60 //
61 // arguments:
62 // - byte num:  entry number (0..255)
63 // - unsigned long address:  address of the interrupt handler function
64 // - word gdtsel:  index into the global descriptor table (GDT), this
65 //     will always be set to 0x08 since we have prepared segment 0x08 as
66 //     code/kernel mode (see fill_gdt_entry in memory.c)
67 // - byte flags:  flags for this selector; these will always be set to
68 //     0b1110 (1 = present, 11 = DPL 3, 0)
69 // - byte type:  selector type; this will always be set to 0b1110
70 //     (32 bit interrupt gate)
71
72 void
73 fill_idt_entry (byte num, unsigned long address,
74     word gdtsel, byte flags, byte type) {
75   if (num >= 0 && num < 256) {
76     idt[num].addr_low  = address & 0xFFFF; // address is the handler address
77     idt[num].addr_high = (address >> 16) & 0xFFFF;
78     idt[num].gdtsel    = gdtsel;           // GDT sel.: user or kernel mode?
79     idt[num].zeroes    = 0;
80     idt[num].flags     = flags;
81     idt[num].type      = type;
82   }
83 }
```

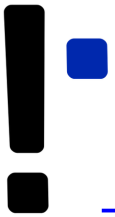

Interrupt-Handler

- `irq0` bis `irq15` sind die Handler-Funktionen
  → Implementation in der Assembler-Datei
- einfacheres „Ansprechen“ über ein Array:

`globals.h (84–87)`

```
84  void (*irqs[16])() = {
85    irq0, irq1, irq2,  irq3,  irq4,  irq5,  irq6,  irq7,      // store them in
86    irq8, irq9, irq10, irq11, irq12, irq13, irq14, irq15      // an array
87  };
```

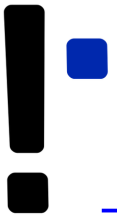

Eintragen der Interrupt-Handler in IDT

irq.c (181–188), setup_irqs_and_faults()

```
181     for (int i = 0;  i < 16;  i++) {
182       fill_idt_entry (32 + i,
183                       (unsigned int)irqs[i],
184                       0x08,
185                       0b1110,     // flags: 1 (present), 11 (DPL 3), 0
186                       0b1110);    // type:  1110 (32 bit interrupt gate)
187     }
188 }
```

- trägt die 16 Handler `irq0` bis `irq15` in die IDT an Positionen 32–47 ein (Mapping!)
- Argument `gdtsel`=0x08: Kernel Mode

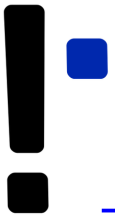

Interrupt-Maske setzen und lesen

- `set_irq_mask()` – Setzen der Interrupt-Maske
  → `irq.c`, 92-96 (über `outportb` auf Data-Ports)
- `get_irq_mask()` – Auslesen der Maske
  → `irq.c`, 104-108 (`inportb` aus Data-Ports)
- Maske ist ein 16-Bit-Wort (1 Bit pro Interrupt)

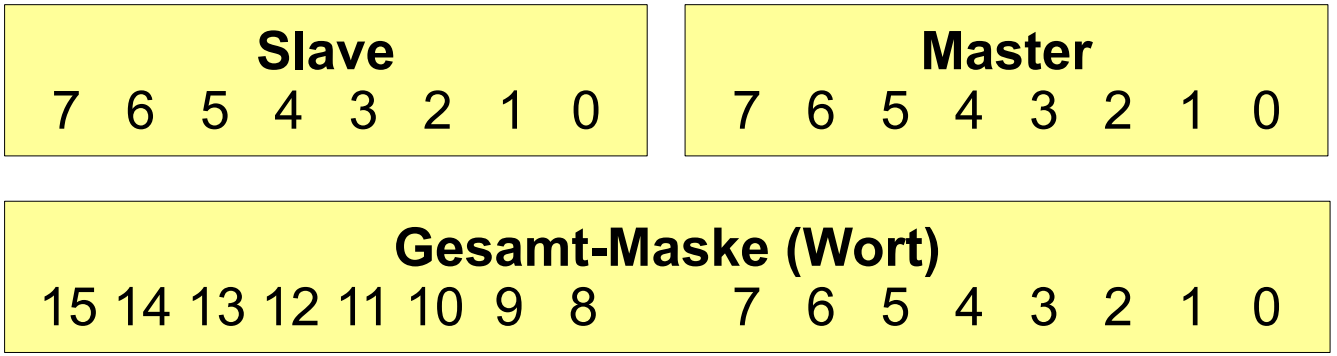

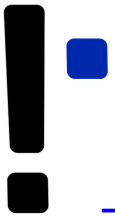

Stack-Einsatz beim Interrupt (1)

- Jeder Prozess besitzt zwei Stacks – für User Mode und Kernel Mode
  - Interrupt tritt im User Mode auf
    → Wechsel in Kernel Mode **und** Wechsel zum Kernel Mode Stack. Alte Stack-Adresse (und alten Modus) sichern!
  - Interrupt tritt im Kernel Mode auf
    → kein Wechsel, aktuellen Stack weiter verwenden
  - Diese Unterscheidung nimmt die CPU automatisch vor. Adresse des Kernel-Stacks steht in einer anderen Datenstruktur (**TSS**, ignorieren wir hier)

Stack-Einsatz beim Interrupt (2)

CPU im Kernel Mode (Ring 0)

→ keine Änderung des Privilege Levels, alten Stack weiter nutzen

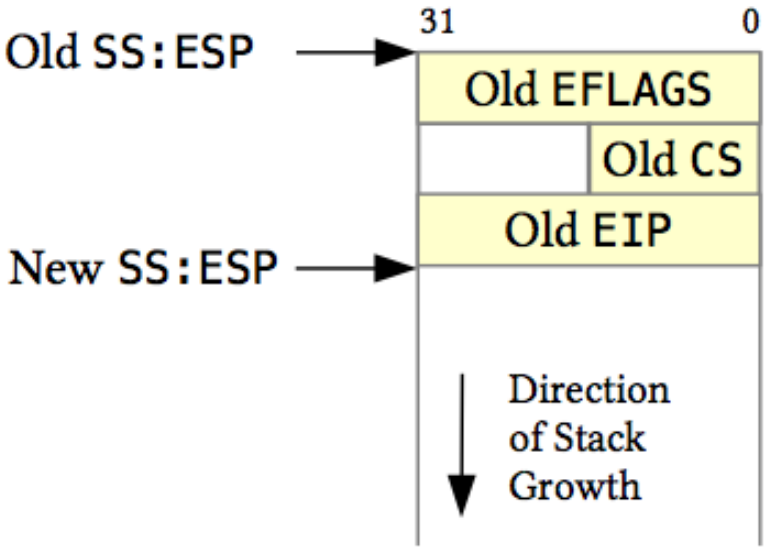

CPU im User Mode (Ring 3)

→ Änderung des Privilege Levels auf Ring 0 (Kernel), neuen (Kernel-) Stack nutzen

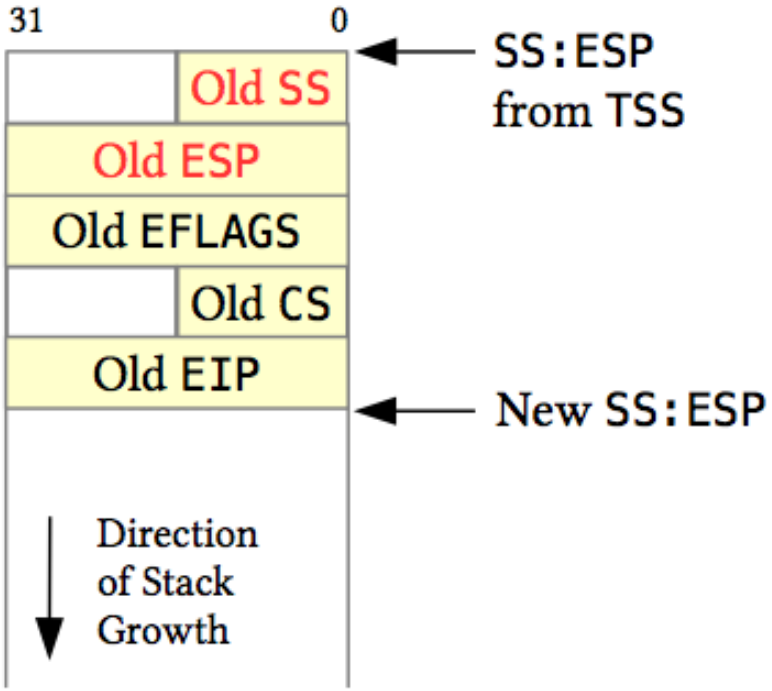

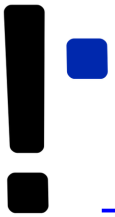

Handler-Funktionen

- Alle Interrupt-Handler haben die Signatur

```
void handler_function (context_t *r);
```

- Dabei ist `context_t` eine Struktur, die alle wichtigen Register enthält
- Beim Interrupt sichert die CPU automatisch einige (wenige) Register auf den Stack; weitere müssen wir selbst (im Handler) sichern

Prozess-Kontext

ulix.h (624–629)

```
624 typedef struct {
625   unsigned int gs, fs, es, ds;
626   unsigned int edi, esi, ebp, esp, ebx, edx, ecx, eax;
627   unsigned int int_no, err_code;
628   unsigned int eip, cs, eflags, useresp, ss;
629 } context_t;
```

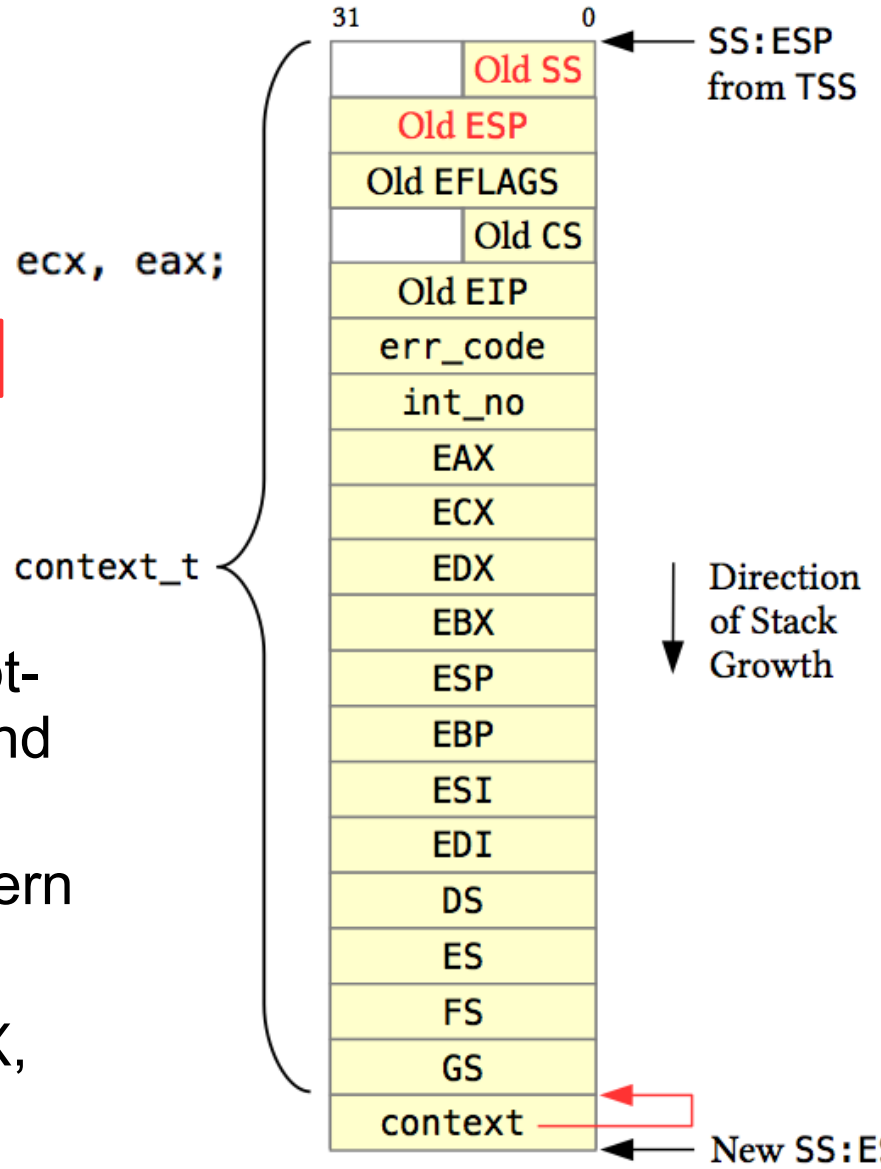

Diesen Teil kopiert die CPU bei der Interrupt-Verarbeitung automatisch auf den Stack (und nimmt ihn bei `iret` wieder runter).

Um den Rest müssen wir uns selbst kümmern

- Interrupt-Nummer und Fehlercode
- Standardregister (EAX, ECX, EDX, EBX, ESP, EBP, ESI, EDI, DS, ES, FS, GS)

Bsp. für kompletten Handler (IRQ 15)

```
1   push byte 0             ; error code
2   push byte 15            ; interrupt number
3   pusha
4   push ds
5   push es
6   push fs
7   push gs
8   push esp                ; pointer to the context_t
9   call irq_handler        ; call C function
10  pop  esp
11  pop  gs
12  pop  fs
13  pop  es
14  pop  ds
15  popa
16  add  esp, 8             ; for errcode, irq no.
17  iret
```

(pusha / popa: *EAX*, *ECX*, *EDX*, *EBX*, *ESP*, *EBP*, *ESI*, *EDI*)

Diesen Code bräuchten wir jetzt 16 mal …

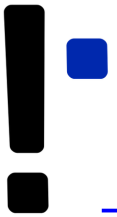

Makro für alle 16 Interrupt-Handler (1)

start.asm (108–112, 131–147)

```
108 %macro irq_macro 1
109   push  byte 0            ; error code (none)
110   push  byte %1           ; interrupt number
111   jmp irq_common_stub  ; rest is identical for all handlers
112 %endmacro

131 extern irq_handler           ; defined in the C source file
132 irq_common_stub:             ; this is the identical part
133   pusha
134   push  ds
135   push  es
136   push  fs
137   push  gs
138   push  esp           ; pointer to the context_t
139   call  irq_handler   ; call C function
140   pop   esp
141   pop   gs
142   pop   fs
143   pop   es
144   pop   ds
145   popa
146   add esp, 8
147   iret
```

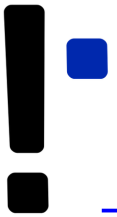

Makro für alle 16 Interrupt-Handler (2)

start.asm (114–129)

```
114 irq0: irq_macro 32
115 irq1: irq_macro 33
116 irq2: irq_macro 34
117 irq3: irq_macro 35
118 irq4: irq_macro 36
119 irq5: irq_macro 37
120 irq6: irq_macro 38
121 irq7: irq_macro 39
122 irq8: irq_macro 40
123 irq9: irq_macro 41
124 irq10:  irq_macro 42
125 irq11:  irq_macro 43
126 irq12:  irq_macro 44
127 irq13:  irq_macro 45
128 irq14:  irq_macro 46
129 irq15:  irq_macro 47
```

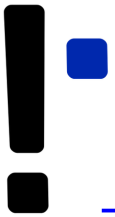

Allgemeiner Interrupt-Handler (1)

- Wird von Assembler-Funktionen `irq0` ... `irq15` aufgerufen
- schickt „End of Interrupt“ an den ersten oder an beide Controller

`irq.h (47)`

```
47  #define END_OF_INTERRUPT    0x20
```

- ruft spezifischen Handler auf, dessen Adresse in Handler-Array gespeichert ist

`globals.h (88)`

```
88  void *interrupt_handlers[16] = { 0 };
```

Allgemeiner Interrupt-Handler (2)

irq.c (206–218)

```
191 // irq_handler() is the generic interrupt handler.
192 //
193 // It is called from the assembler functions irq0(), ..., irq15()
194 // which have already prepared the stack so that the interrupt number
195 // and process context are located on top of it (allowing irq_handler
196 // to access that data structure via its content_t *r argument).
197 //
198 // The primary PIC must be acknowledged via END_OF_INTERRUPT (in all
199 // cases). If the interrupt was raised by the secondary PIC, it must
200 // also be acknowledged. (Otherwise the PIC would stop sending
201 // further interrupt notifications.)
202 //
203 // If a handler function was entered in the interrupt_handlers[]
204 // table, it is called.
205
206 void
207 irq_handler (context_t *r) {
208   int number = r->int_no - 32;                    // interrupt number
209   void (*handler)(context_t *r);                  // type of handler functions
210
211   if (number >= 8) {
212     outportb (IO_PIC_SLAVE_CMD, END_OF_INTERRUPT);  // notify slave  PIC
213   }
214   outportb (IO_PIC_MASTER_CMD, END_OF_INTERRUPT);   // notify master PIC (always)
215
216   handler = interrupt_handlers[number];
217   if (handler != NULL)  handler (r);
218 }
```

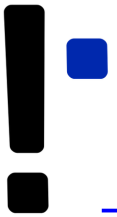

Bestimmten Interrupt-Handler einrichten

irq.c (230–234)

```
221 // install_interrupt_handler() installs a new interrupt handler
222 //
223 // arguments:
224 // - int irq:  entry number for the interrupt_handlers[] array (0..15)
225 // - void (*handler)(context_t *r):  address of the handler function
226 //
227 // If irq is a valid number, the given address is entered into the
228 // right entry of the array that stores the handler addresses.
229
230 void
231 install_interrupt_handler (int irq, void (*handler)(context_t *r)) {
232   if (irq >= 0 && irq < 16)
233     interrupt_handlers[irq] = handler;
234 }
```

Während Kernel-Initialisierung:

```
install_interrupt_handler (IRQ_IDE,   ide_handler);               // in block.c
install_interrupt_handler (IRQ_FDC,   floppy_handler);            // in block.c
install_interrupt_handler (IRQ_COM2,  serial_hard_disk_handler);  // in fs.c
install_interrupt_handler (IRQ_KBD,   keyboard_handler);          // in keyboard.c
install_interrupt_handler (IRQ_TIMER, timer_handler);             // in timer.c
```

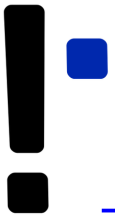

CPU über IDT informieren

irq.c (153–157)

```
153 void
154 setup_irqs_and_faults () {
155   idtp.limit = (sizeof (struct idt_entry) * 256) - 1;   // must do -1
156   idtp.base  = (int) &idt;
157   idt_load ();
```

start.asm (149–153)

```
149 extern idtp                    ; defined in the C file
150 global idt_load
151 idt_load:
152         lidt [idtp]
153         ret
```