

HARDWARE UND GERÄTETREIBER

Björn Döbel (TU Dresden)

Dresden, 10.12.2013


Übersicht

- Kommunikation zwischen Hardware und CPU
 - Interrupts
 - I/O-Ports
 - I/O-Speicher
 - Busse
- Verwaltung von Geräten
 - Dynamisches Hinzufügen/Entfernen
 - Anbindung an das Betriebssystem
- Warum ist das alles so schwer?

Bausteine

Beispiele für Geräte


- Eingabegeräte (*Human Interface Devices (HID)*)
- Netzwerkkarten (*Network Interface Cards (NIC)*)
- Grafik-Karten
- Speichermedien
- CPU-nahe Geräte (Timer, Interrupt-Controller)



Bausteine


Beispiele für Geräte

- Eingabegeräte (*Human Interface Devices (HID)*)
- Netzwerkkarten (*Network Interface Cards (NIC)*)
- Grafik-Karten
- Speichermedien
- CPU-nahe Geräte (Timer, Interrupt-Controller)



Kommunikation zw. Gerät und CPU

- Interrupt signalisiert Zustandsänderung des Geräts
- Interrupt-Controller (PIC):
 - Umwandlung von HW-Interrupts in CPU Exceptions
 - Priorisierung, Kombination von Interrupts
 - Maskieren von Interrupts
 - SMP: senden/empfangen von Inter-Prozessor-Interrupts (IPI)



x86: Exceptions

- 256 CPU exceptions
- 0-31 sind reserviert
 - Vordefinierte CPU-Fehler und -Signale
- 32-255 frei verfügbar
- Programmable Interrupt Controller – (A)PIC:
 - Local Vector Table (LVT) bildet HW-Interrupts auf CPU Exceptions (> 31) ab
 - Mehrere Interrupts können die selbe Exception auslösen (Interrupt Sharing)

Exception	Signal
0	Division durch 0
2	Nicht-maskierbarer Interrupt (NMI)
3	Debug-Interrupt
6	Undefinierte Instruktion
13	Schutzfehler (Protection Fault)
14	Seitenfehler (Page Fault)

Behandeln von Exceptions

- CPU: Interrupt Descriptor Table (IDT)
 - Einsprung-Adresse für Handler-Funktion
 - Tabelle im Hauptspeicher
 - Adresse im IDT Base Register
- Interrupts / Exceptions unterbrechen die Ausführung der aktuellen CPU an beliebigen Zeitpunkten
 - Rettung des aktuellen CPU-Zustands nötig
 - Teil des Zustands wird auf den Stack gelegt
 - Anderer Zustand in Verantwortung des Entwicklers
 - Rückkehr und Wiederaufsetzen mit vorherigen Informationen: `iret`

Ein Blick ins x86-Manual




Figure 6-4. Stack Usage on Transfers to Interrupt and Exception-Handling Routines

Beispiel: Keyboard-Interrupt 0x1

- Setup während des Bootvorgangs
`request_irq(0x1, my_keyboard_handler);`
- Bei Tastendruck:
IRQ 1 →
APIC →
CPU Exception → BS Kern führt Handler-Funktion aus.
- Keyboard-Treiber weiß nun, dass eine Taste gedrückt wurde. Aber welche?

I/O-Ports

- Alternative Möglichkeit zum Zugriff auf x86-Gerätespeicher ("Historisch gewachsen" (tm))
- Spezieller Adressbereich: einmalig 65536 I/O-Port-Bytes
- Nicht Teil des physischen Speichers
- Zugriff mittels spezieller Instruktionen
inb, inw, in
outb, outw, out
- Durchreichen an Anwendungen möglich (IO Privilege Level, IO Bitmap)

I/O-Speicher

- Komplexere Geräte: eigener Speicher
- Von CPU als Teil des phys. Speichers zugegriffen
- Aufteilung des phys. Speichers plattformabhängig
- Aufgabe des BIOS während des Bootvorgangs


Hauptspeicher

Adressier-
barer Spe-
icher

NIC


I/O-Speicher

- Komplexere Geräte: eigener Speicher
- Von CPU als Teil des phys. Speichers zugegriffen
- Aufteilung des phys. Speichers plattformabhängig
- Aufgabe des BIOS während des Bootvorgangs




I/O-Speicher

- Komplexere Geräte: eigener Speicher
- Von CPU als Teil des phys. Speichers zugegriffen
- Aufteilung des phys. Speichers plattformabhängig
- Aufgabe des BIOS während des Bootvorgangs




Direct Memory Access

- I/O-Ports: Zugriff auf max. 4 Byte gleichzeitig
- I/O-Speicher: kann `memcpy()`-Instruktionen (z.B. `rep movs`, SSE-Erweiterungen) benutzen
- Weitere Optimierung: *DMA*




Direct Memory Access

- I/O-Ports: Zugriff auf max. 4 Byte gleichzeitig
- I/O-Speicher: kann `mempcy()`-Instruktionen (z.B. `rep movs`, SSE-Erweiterungen) benutzen
- Weitere Optimierung: *DMA*



DMA: Sicherheitsproblem

- Physische Adressierung
- Überschreiben beliebiger Speicher-Regionen
- Also: Überschreiben von Kerndaten möglich
- Lösung: *I/O-MMU*



Geräte-Zustand

- BS liest und modifiziert Zustand via I/O-Speicher und I/O-Ports → Kernaufgabe eines *Gerätetreibers*
- Geräte-spezifische Aktionen
 - Welchen Zustand gibt es?
 - Wie wird er zugegriffen?
 - Wie führt man Geräte-Aktionen aus?
- Herkunft der Informationen variiert
 - Plattform-weite Definition (z.B. PC-Plattform)
 - Standard f. bestimmte Geräteklasse (z.B. SATA-Festplatten)
 - Geräte-Spezifikation (vom Hersteller)

Beispiel: AT-Keyboard

- Definiert durch PC-Plattform
- Interrupt: 0x1
- I/O-Port 0x60: Daten-Register (Scancode)
- I/O-Port 0x64:
 - Lesen: Status-Register
 - Schreiben: Kommando-Register
- Wozu sendet man Kommandos ans Keyboard?
 - PC Speaker
 - Reboot

Beispiel: ATA-Festplatten

- ATA-Standard für Klasse von Geräten
- Kontrollregister via I/O-Ports (4 Bereiche für max. 4 parallel betriebene Geräte → [Primary|Secondary] [Master|Slave])
- Mindest-Anforderung: Byteweises Lesen/Schreiben von Daten auf Platte (PIO-Mode)
- Komplexes Protokoll: Liste von Kommandos und möglichen Antworten
- Erweiterungen:
 - Senden mehrerer Bytes
 - Scatter/Gather DMA

Beispiel: Netzwerkkarten

- Kein einheitlicher Standard, üblicherweise:
- Mind. 2 I/O-Speicher-Bereiche (kb-MB)
 - Eingehende Pakete
 - Ausgehende Pakete
- Mind. 1 Interrupt (auch mehr möglich)
- I/O-Ports oder weitere I/O-Speicherbereiche für Gerätekonfiguration, Statusinformation etc.
- Moderne NICs: eigener Prozessor (TCP Offloading), parallele Paket-Queues

Typischer Ablauf: Netzwerk

- Interrupt trifft ein
- Treiber-IRQ-Handler wird aufgerufen
- Test: Send- oder Receive-Interrupt?
- SEND
 - Bestätigung, dass letztes Paket gesendet
 - Freigabe zugehörigen Speichers
- RECV
 - Test: Paket für mich bestimmt (MAC-Test, Broadcast, Promiscuous Mode)
 - Entfernen des Low-Level-Headers (Ethernet)
 - Weiterreichen an höher liegende Protokoll-Layer (TCP/IP)

Integration in den BS-Kern

Kern definiert Schnittstelle für Geräteklassen Linux
Netzwerk-Treiber-Interface:

```
struct net_device_ops
{
    int (*ndo_init)(struct netdev* dev);

    netdev_tx_t (*ndo_start_xmit)(sk_buff* skb,
                                   struct netdev* dev);


    [.. weitere 30 Funktionen ..]
};
```

Gerätetreiber

- Interrupt-Behandlung (Inspektion und Manipulation des Zustands)
- Kapselt geräte-spezifisches Wissen
- Integration in restliche BS-Infrastruktur

Wie findet man Geräte? Wie die zugehörigen Treiber?

Busse: Vernetzung von Geräten



Aufgaben: Identifikation, Adressierung, Weiterleiten von Kommandos/Interrupts

Peripheral Component Interconnect

- Standardisiertes Interface
- Adressierung über Tupel (Bus, Slot, Funktions-ID)
- PCI Configuration Space
 - Zugriff über I/O-Ports
 - Einheitliche Abfrage von Geräteinformationen
 - Liste der Geräte-Ressourcen

31		16 15		0
Device ID		Vendor ID		00h
Status		Command		04h
Class Code			Revision ID	08h
BIST	Header Type	Lat. Timer	Cache Line S.	0Ch
Base Address Registers				10h
				14h
				18h
				1Ch
				20h
				24h
Cardbus CIS Pointer				28h
Subsystem ID		Subsystem Vendor ID		2Ch
Expansion ROM Base Address				30h
Reserved			Cap. Pointer	34h
Reserved				38h
Max Lat.	Min Gnt.	Interrupt Pin	Interrupt Line	3Ch

Geräte-Erkennung

- Während des Bootvorgangs
- BS “scannt” die PCI-Busse
 - Lesen der Geräte-ID
 - Rückgabewert $\neq 0xFFFFFFFF$ → Gerät vorhanden
- Findend es zugehörigen Treibers
 - Treiber liefert Liste der unterstützten Geräte-IDs
 - BS ruft `init()`-Funktion auf, wenn entsprechendes Gerät gefunden

Treiber-Entwicklung

- Oft: Hersteller $\neq$ BS-Hersteller
- Unterstützung zukünftiger Geräte nötig
- Lösung: nachladbare Treiber
 - Linux: Loadable Kernel Modules
 - Windows, MacOS analog
- Nutzung von Platzhalter-Symbolen
- Auflösung beim Laden durch Module Loader
- Resultat: Treiber muss für jede Kern-Version neu gebaut werden

Probleme bei Treiber-Entwicklung

- Entwicklung in “unsicherer” Programmiersprache
 - C → Pointer-Arithmetik, Bit-Operationen etc.
- Kompliziertes Kern-Interface
- Komplizierte Hardware
 - Fehlende HW-Spezifikationen

Eine Anekdote

- 08.08.2008: Bug-Report auf LKML
 - Intel e1000 PCI-X NICs durch Linux 2.6.27 unbrauchbar
 - Überschriebenes NVRAM

Eine Anekdote

- 08.08.2008: Bug-Report auf LKML
 - Intel e1000 PCI-X NICs durch Linux 2.6.27 unbrauchbar
 - Überschriebenes NVRAM
- 01.10.2008: Quickfix durch Intel
 - Gerätespeicher an anderer Adresse eingeblendet


Eine Anekdote

- 08.08.2008: Bug-Report auf LKML
 - Intel e1000 PCI-X NICs durch Linux 2.6.27 unbrauchbar
 - Überschriebenes NVRAM
- 01.10.2008: Quickfix durch Intel
 - Gerätespeicher an anderer Adresse eingeblendet
- 15.10.2008: Grund für den Fehler: Linux Dynamic Function Tracing
 - Komplett unabhängiges Kernel-Feature
 - Fehlerhaftes Verhalten bei `cmpxchg` auf Gerätespeicher

Eine Anekdote

- 08.08.2008: Bug-Report auf LKML
 - Intel e1000 PCI-X NICs durch Linux 2.6.27 unbrauchbar
 - Überschriebenes NVRAM
- 01.10.2008: Quickfix durch Intel
 - Gerätespeicher an anderer Adresse eingeblendet
- 15.10.2008: Grund für den Fehler: Linux Dynamic Function Tracing
 - Komplett unabhängiges Kernel-Feature
 - Fehlerhaftes Verhalten bei `cmpxchg` auf Gerätespeicher
- 02.11.2008: Fehler korrigiert in Linux 2.6.28-rc3

Ein Bisschen Statistik



- L. Rhyzyk et al.: *Dingo – Taming Device Drivers*, 2009
- Analyse von Bug-Reports für eine Reihe von Linux-Treibern
- Andere Quellen: 85% aller Crashes von Windows XP sind auf fehlerhafte Treiber zurück zu führen.

Noch Mehr Statistik

- 2001: A. Chou et al.: *An Empirical Study of Operating System Errors*
- 2011: N. Palix et al.: *Faults in Linux: Ten Years Later*
- Automatisierte Analyse des Linux-Kerns mit statischen Code-Analyse-Tools

Linux: Lines of Code






Figure 1. Linux directory sizes (in MLOC)


Fehlerrate (2001)



Fehlerrate (2011)



Fehlerentwicklung



Lebensdauer von Fehlern




Figure 16. Lifetime of faults across versions

Was tun gegen Treiber-Fehler?

- Testen vs. Hardware-Verfügbarkeit
 - Simulatoren (bedingt geeignet)
- Statische Analyse / Formale Verifikation
 - Windows Certified Drivers
- Wiederverwendung von Treibern anderer Betriebssysteme
 - Linux: Windows WiFi-Treiber
 - Forschungs-BS: Nutzung von Linux-Treibern

Adressraum-Isolation

- Ziel: Verhindern, dass ein kaputter Treiber das ganze System zum Absturz bringt
- *Nooks*: komplizierte Modifikation des Linux-Kerns
- *Mikrokerne*: Treiber als Nutzer-Anwendungen
- *Virtuelle Maschinen*: ein BS pro Treiber