

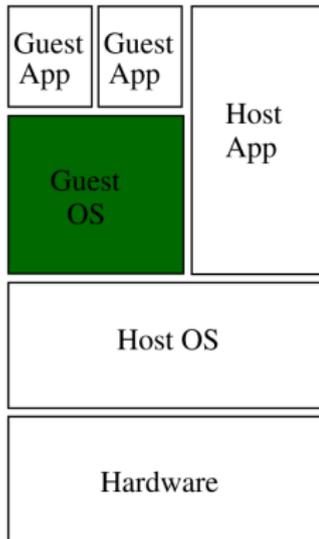
Paravirtualisierung (1)

Dr.-Ing. Volkmar Sieh

Department Informatik 4
Verteilte Systeme und Betriebssysteme
Friedrich-Alexander-Universität Erlangen-Nürnberg

WS 2022/2023





- Unter Gast-OS laufende Applikationen sehen Guest-OS-ABI.
- Gast-OS selbst sieht als „Hardware“ das Gastgeber-OS.

Portierung eines Betriebssystems auf besondere „Hardware“
(Gastgeber-OS)



Supervisor-Instuktionen nicht nutzbar. Diese müssen ersetzt werden.

Gast-OS kann nutzen

- CPU im User-Modus
- Speicher
- System-Calls des Gastgeber-OS



Supervisor-Instruktionen am Beispiel der x86-Architektur:

- `in{b,w,l}, out{b,w,l}` (Ein-/Ausgabe)
- `mov ..., %cr3` (Pointer auf Page-Tabelle laden)
- `cli, sti` (Disable/Enable Interrupts)
- `pushf, popf` (Interrupt Status speichern/laden)
- `lidt` (Pointer auf Interrupt-Tabelle laden)
- ...



Abbildung der x86-Supervisor-Instruktionen auf Unix/Linux System-Calls.

Idee:

phys. Speicher: eine Datei

virt. Speicher: eine gemappte Datei

Interrupts: Signale

Real-Time-Clock/Timer: System-Clock, Timer

Konsole: Terminal oder GUI

Netzwerkkarte: Socket

Sound-Karte: Sound-System

...



in- und out-Befehle in Gerätetreibern.

Gerätetreiber werden ersetzt.

Im Gerätetreiber z.B. nutzbar:

- read-/write-System-Calls (non-blocking)
- send-/recv-System-Calls (non-blocking)
- Grafik-Ausgabe
- Sound-Ausgabe



mmap- und munmap-System-Calls:

```
void *  
mmap(void *addr,      /* virt. Adresse */  
      size_t length, /* 4096 */  
      int prot,       /* read/write/execute */  
      int flags,      /* shared */  
      int fd,         /* File-Descriptor */  
      off_t offset); /* File-Offset (phys. Adresse) */
```

```
int  
munmap(void *addr, /* virt. Adresse */  
        size_t length); /* 4096 */
```



Mit `mmap`- und `munmap`-System-Calls kann eine MMU nachgebildet werden.

Probleme:

- - Viele System-Calls für einen Kontext-Wechsel notwendig.
 - System-Calls langsam.
 - Nicht beliebig viele Mappings möglich.

=> Nur gerade benötigte Teile des Adressraumes „on demand“ mappen (ähnlich TLB).

- Host-OS belegt Teil des virtuellen Adressraums.

=> Guest-OS muss i.A. verschoben werden.



- Guest-OS läuft im User-Modus
- Guest-Applikationen laufen im User-Modus

=> **keine Kernel-Protection!**

=> für Protection Unterstützung des Host-OS notwendig
(„Kontextwechsel“ zwischen Guest-OS und Guest-Applikationen)



Zum Nachbilden der Interrupts können statt dessen Linux-Signale verwendet werden:

- Programmieren der Signale: `sigaction`
- Setzen des Signal-/Supervisor-Stacks: `sigstack`
- Enable/Disable der Signale: `sigprocmask`

`sigstack` notwendig. Signal-Ursache könnte Page-Fault bei Stack-Zugriff sein!



Problem:

- Interrupts werden sehr häufig disabled/enabled.
- Aufruf des `sigprocmask`-System-Calls langsam.

Idee:

Signale immer zulassen; zugehörigen Signal-Handler aber nur aufrufen, wenn er enabled ist. Wenn Signal-Handler disabled ist, Signal als „deferred“ vormerken.



Paravirtualisierung – Interrupts

```
void sig_handler() {
    if (enabled)
        sig_handler2();
    else
        deferred = 1;
}

void sig_enable() {    /* Muesste atomar sein! */
    while (deferred) {
        deferred = 0;
        sig_handler2();
    }
    enabled = 1;
}

void sig_disable() {
    enabled = 0;
}
```



Compilierte sig_enable-Prozedur:

```
sig_enable:
    jmp .L3
.L1:
    movl $0, deferred
    call sig_handler2
.L3:
    cmpl $1, deferred
    je .L1
    movl $1, enabled
    ret
sig_enable_end:
```



Idee: Im Interrupt-/Signal-Handler liegt %eip auf Stack.

`sig_enable <= %eip < sig_enable_end`: setze %eip auf .L1.

`sonst (enable=0)`: setze deferred auf 1.

`sonst (enable=1)`: rufe `sig_handler2()` auf.



Exceptions:

- Exceptions gehen standardmässig zunächst an das Host-OS.
- Sollen eigentlich an das Guest-OS (Host-Applikation) gehen.
- Normalerweise sendet ein OS Exceptions an Applikation weiter (Unix: Signal-Mechanismus)

System-Calls:

- System-Calls gehen an das Host-OS.
- Werden nicht wie Exceptions weitergeleitet.

=> Spezieller Mechanismus im Host-OS notwendig!

Umleitung unter Linux mittels ptrace-Mechanismus (Teil der Debug-Schnittstelle) möglich (aber langsam).



gettimeofday-System-Call des Host-OS benutzt Real-Time-Clock nur einmal beim Booten (Start-Time). Ansonsten werden Timer-Ticks gezählt (Run-Time).

Paravirtualisierung geht ähnlich vor.

Real-Time-Clock: gettimeofday-System-Call

Timer-Ticks: setitimer-System-Call

- gettimeofday-System-Call unproblematisch (nur einmal verwendet).
- setitimer-System-Call auch unproblematisch (nur ein Aufruf; danach kommen SIGALRM-Signale).



setitimer-System-Call kann nur Signale mit einer maximalen Frequenz von 100Hz bzw. 1000Hz zustellen.

=> virtuelle System-Clock ungenau.

Höhere Auflösungen aber auch nicht sinnvoll. Guest-OS kann ge-scheduled werden!

=> **Zeitmessungen in paravirtualisierten Systemen problematisch!**

