


SUPSI

Ambienti Operativi: Struttura dei sistemi operativi

Amos Brocco, Ricercatore, DTI / ISIN

Organizzazione di un sistema operativo



Protezione

Cosa devo proteggere?



- **CPU**
 - Controllo del tempo CPU utilizzato dalle applicazioni
 - Evitare che un'applicazione prenda troppo tempo
- **Memoria**
 - Evitare che un processo possa “curiosare” nella memoria di un altro processo
 - Evitare che si possa modificare la memoria che non ci appartiene
- **Accesso alle periferiche**
 - Prevenire l'utilizzo di istruzioni I/O non valide

Parzialmente risolto con l'utilizzo di indirizzi virtuali e il meccanismo di traduzione degli indirizzi

Come proteggere?

- Permettiamo l'accesso diretto alle periferiche e alla memoria tramite indirizzi fisici, e l'esecuzione di certe istruzioni solo a un'entità di cui ci possiamo fidare:

il kernel

Il kernel: “un processo come un'altro”

- Il kernel non è altro che un processo che si contende l'utilizzo della CPU insieme agli altri processi
- A differenza dei processi utente, **il kernel ha un accesso privilegiato** a certe istruzioni del processore che gli altri processi non possono avere
- Il kernel fa da mediatore offrendo dei servizi per
 - l'esecuzione e terminazione dei processi
 - l'accesso a file e directory
 - l'accesso alla rete
 - l'accesso alle periferiche

System call

Come chiamare le funzioni “privilegiate” del kernel?



- **Una chiamata di sistema (system call) permette a un'applicazione di richiedere un “servizio” offerto dal kernel (“mediatore”)**
 - Gestione dei processi
 - fork, exec, exit, wait, kill...
 - Gestione della memoria
 - brk,...
 - Accesso al filesystem
 - open, read, write, close
 - Accesso alle periferiche
 - Comunicazione
- Numero di system call dipende dal kernel:
 - Linux ~ 320
 - POSIX ~130

"Vedere" le chiamate di sistema: strace

- Il comando **strace** su Linux ci permette di vedere quali chiamate di sistema vengono utilizzate da un processo

```
[X] bash
```

```
utente@host:~/Documenti$ strace -o ls.trace.txt ls
```



L'opzione `-o` mi permette di salvare l'output di `strace` in un file

Variabili di ambiente

strace: esempio 'ls'

```
[X] bash
```

```
utente@host:~/Documenti$ strace -o ls.trace.txt ls
```

```
ls.trace.txt
```

```
execve("/bin/ls", ["ls"], [/* 52 vars */]) = 0
brk(0) = 0x9c20000
mmap2(NULL, 4096, PROT_READ|PROT_WRITE, MAP_PRIVATE|MAP_ANONYMOUS, -1, 0) = 0xb7893000
access("/etc/ld.so.preload", R_OK) = -1 ENOENT (No such file or directory)
open("/etc/ld.so.cache", O_RDONLY) = 3
fstat64(3, {st_mode=S_IFREG|0644, st_size=85514, ...}) = 0
mmap2(NULL, 85514, PROT_READ, MAP_PRIVATE, 3, 0) = 0xb787e000
close(3) = 0
open("/lib/libselinux.so.1", O_RDONLY) = 3
read(3, "\177ELF\1\1\1\0\0\0\0\0\0\0\0\3\0\3\0\1\0\0\0p\343P\0004\0\0\0"..., 512) = 512
fstat64(3, {st_mode=S_IFREG|0755, st_size=122436, ...}) = 0
...
open(".", O_RDONLY|O_NONBLOCK|O_LARGEFILE|O_DIRECTORY|O_CLOEXEC) = 3
fcntl64(3, F_GETFD) = 0x1 (flags FD_CLOEXEC)
getdents64(3, /* 140 entries */, 32768) = 4624
getdents64(3, /* 0 entries */, 32768) = 0
close(3) = 0
...
write(1, "bbb.JpG calendari-pap-tp.txt D"..., 156) = 156
write(1, "bhello\t chello\t\t dirmenu.s"..., 170) = 170
write(1, "bla\t comandi\t dirmenu.sh~ "..., 140) = 140
write(1, "bla.sh\t curllogin.sh\t Docu"..., 140) = 140
write(1, "booo\t curllogin.sh~\t dodoc"..., 145) = 145
write(1, ",c\t dati.txt\t dodocurl.py~"..., 136) = 136
close(1) = 0
```

strace: esempio 'bash'

Nella nuova shell

```
[X] bash
```

```
utente@host:~/Documenti$ strace -o bash.trace.txt bash
utente@host:~/Documenti$ echo "Hello world" 2> err.txt 1> out.txt
```

```
ls.trace.txt
```

```
execve("/bin/bash", ["bash"], [/* 52 vars */]) = 0
...
open("err.txt", O_WRONLY|O_CREAT|O_TRUNC|O_LARGEFILE, 0666) = 3
...
dup2(3, 2) = 2
close(3) = 0
open("out.txt", O_WRONLY|O_CREAT|O_TRUNC|O_LARGEFILE, 0666) = 3
...
dup2(3, 1) = 1
close(3) = 0
write(1, "Hello world\n", 12) = 12
...
```

Kernel mode / User mode

Come fa la CPU a distinguere tra processi normali e kernel?



- Per impedire che un processo utente utilizzi delle istruzioni “privilegiate” per accedere alle periferiche o alla memoria dobbiamo disporre di un meccanismo per permettere alla CPU di distinguere tra processo kernel e non-kernel.


Kernel mode / User mode

Come fa la CPU a distinguere tra processi normali e kernel?




- La CPU permette di definire più modalità di esecuzione, tipicamente ne sono utilizzati due:
 - **Kernel mode** (modalità kernel): accesso completo all'hardware attraverso istruzioni privilegiate, gestione della memoria e degli interrupt
 - **User mode** (modalità utente): accesso limitato all'hardware, utilizzato dalle applicazioni

Schema a cipolla (anelli di protezione)




Protezione della memoria

- Abbiamo visto che la memoria è divisa in aree logiche, i segmenti
 - i segmenti possono contenere codice macchina o dati
 - possiamo definire il livello di privilegio di un processo assegnando un codice numerico ai segmenti di memoria utilizzati dal processo
 - solo il kernel può cambiare questi livelli



Protezione della memoria


- Quando viene eseguita un'istruzione privilegiata il processore controlla che l'area di memoria abbia il codice dei privilegi necessario, altrimenti ho un errore di protezione



Spostarsi tra aree con privilegi diversi

- Quando richiamo una funzione, effettuo un “salto” (jump) nel codice verso l'indirizzo di memoria che contiene la prima istruzione della funzione
- **Problema: Per ragioni di sicurezza** non è permesso “saltare” tra aree con privilegi diversi durante l'esecuzione per richiamare funzioni di sistema
 - Se fosse possibile saltare da una regione con privilegi più bassi a una con privilegi più alti il meccanismo di protezione della memoria non funzionerebbe
 - Allo stesso modo, se salto da una regione con privilegi più alti a una con privilegi più bassi, quando ritorno ho il problema inverso, ovvero passare da una regione con meno privilegi a una con più privilegi

Chiamata di sistema



Quindi come faccio per chiamare funzioni implementate dal kernel?

Interrupt

Quindi come faccio a richiamare una funzione con più privilegi come una chiamata di sistema?



Con meccanismo diverso: gli interrupt!



- Un **interrupt** (interruzione) permette di interrompere l'esecuzione di un processo, passare il controllo al sistema operativo, ed eseguire una routine di gestione predefinita
 - **Interrupt hardware (asincroni)**: quando una periferica vuole segnalare qualcosa al S.O
 - **Interrupt software (sincroni)**: quando un processo vuole segnalare qualcosa al S.O

Interrupt

- Quando viene eseguito un interrupt avviene un cambio di contesto (context switch):
 - Il controllo viene passato a un punto di accesso specifico del kernel (modalità privilegiata)
 - Il kernel esegue la funzione richiesta
 - Tramite un'istruzione posso ridare il controllo all'applicazione (modalità non-privilegiata)
- Visto che il punto di accesso è definito dal kernel, un processo utente non può eseguire istruzioni da un indirizzo arbitrario

/proc/interrupts

```
[X] bash
```


```
utente@host:~/Documenti$ cat /proc/interrupts
```

	CPU0	CPU1	CPU2	CPU3		
0:	131	0	0	0	IO-APIC-edge	timer
1:	10	0	0	0	IO-APIC-edge	i8042
4:	2	0	0	0	IO-APIC-edge	
7:	0	0	0	0	IO-APIC-edge	parport0
8:	1	0	0	0	IO-APIC-edge	rtc0
9:	37488	24161	0	0	IO-APIC-fasteoi	acpi
12:	129	0	0	0	IO-APIC-edge	i8042
16:	105002	17428	0	0	IO-APIC-fasteoi	ehci_hcd:usb1
17:	418215	66538	0	0	IO-APIC-fasteoi	ehci_hcd:usb2, mmc0, hda_intel
24:	300	0	0	0	HPET_MSI-edge	hpet2
25:	0	0	0	0	HPET_MSI-edge	hpet3
26:	0	0	0	0	HPET_MSI-edge	hpet4
27:	0	0	0	0	HPET_MSI-edge	hpet5
29:	108546	22	2012463	12211960	PCI-MSI-edge	i915
30:	38254	930452	0	0	PCI-MSI-edge	ahci
31:	1450962	0	0	0	PCI-MSI-edge	em1
32:	31965	3310	0	0	PCI-MSI-edge	hda_intel
33:	2587381	0	0	0	PCI-MSI-edge	iwlagn
NMI:	0	0	0	0	Non-maskable interrupts	
LOC:	6945632	4580848	6065484	4045225	Local timer interrupts	
SPU:	0	0	0	0	Spurious interrupts	
PMI:	0	0	0	0	Performance monitoring interrupts	
PND:	0	0	0	0	Performance pending work	
RES:	156739	76288	84755	130210	Rescheduling interrupts	
CAL:	61430	76493	63114	53259	Function call interrupts	


Interrupt software

Interrupt

- Hardware



- Software



System call con interrupt

- Il numero (identificatore) della funzione da chiamare è memorizzato in un registro (piccola memoria all'interno della CPU)
- I parametri possono essere memorizzati nei registri o sullo stack
 - Il kernel può accedere allo stack del processo utente
- Quando ritorno dalla system call il processo utente riprende la sua normale esecuzione

System call più veloci con SYSENTER/SYSEXIT

- Quando utilizzo un interrupt software (istruzione int) sono necessari **più accessi alla memoria** per ottenere l'indirizzo della routine di gestione degli interrupt (interrupt handler)
- **Soluzione più efficiente:**
 - A partire dal Pentium 2 è stato introdotto il “Fast System Call”
 - Idea: definiamo l'indirizzo dove si trova la routine per la gestione della chiamata in un registro che può essere modificato solo dal kernel
 - L'istruzione SYSENTER (SYSCALL su processori AMD) salta direttamente a questo indirizzo

Kernel mode / User mode

- Passare da modalità utente a modalità kernel è “più costoso” che chiamare una funzione nello stesso livello di protezione:
 - quindi perché non eseguire la maggior parte delle operazioni in modalità kernel?
 - sicurezza, robustezza
 - vale il “*principio del privilegio minimo*”
 - concedere ad ogni funzione del S.O. solo i privilegi di cui ha realmente bisogno


Struttura dei sistemi operativi

- Diverse tipologie di sistemi operativi possono definire diversamente quali funzionalità sono da eseguire in modalità “utente” e quali in modalità “kernel”
 - Non tutto *può* essere eseguito in modalità utente
 - Non tutto *deve* essere eseguito in modalità kernel

Tipologie di kernel


- **Sistemi micro-kernel**
 - Solo le funzionalità strettamente necessarie vengono eseguite in modalità kernel
 - Basato su server indipendenti eseguiti in modalità utente che comunicano tramite messaggi (più robusto)
- **Sistemi monolitici**
 - Tutte le funzionalità sono eseguite in modalità kernel
- **Sistemi ibridi**
 - Struttura modulare simile a un microkernel ma eseguita in modalità kernel

Tipologie di kernel




Kernel monolitico

Sistema operativo basato su kernel monolitico




Esempio di sistema monolitico: Linux




Microkernel

Sistema operativo basato su microkernel




Esempio di sistema microkernel: Minix




The MINIX 3 Microkernel Architecture

Kernel ibrido

Sistema operativo basato su
kernel ibrido

Esempio di sistema ibrido: Windows NT



Virtualizzazione

- **Macchina virtuale (Virtual Machine)**
 - implementa un ambiente virtuale che emula una macchina fisica
- **System Virtual Machine**
 - emula un'architettura completa che permette, per es. l'esecuzione di sistemi operativi diversi sullo stesso sistema
- **Application Virtual Machine**
 - è un software che implementa un'astrazione che nasconde i dettagli dell'hardware e permette la programmazione indipendente dalla piattaforma (es. Java Virtual Machine, Common Language Runtime)

System virtual machine: motivazione



- Disponibilità di sistemi multi-processore e multi-core
 - Aumento delle performance
 - ma non sempre utilizzate al 100%
 - richiesta di servizi on-demand
 - Diminuzione dei prezzi
 - più performance a un prezzo minore rispetto al passato
- Con la virtualizzazione è possibile creare più sistemi virtual su una sola macchina fisica, sfruttando più efficientemente le risorse disponibili

Benefici

- Possibilità di utilizzare **più sistemi operativi** contemporaneamente
- **Isolazione**
 - Sistemi con requisiti diversi
 - Sicurezza
- **Consolidazione**: riunire più servizi su un solo sistema
 - Utilizzo più efficace delle risorse
 - Riduzione dei costi per il mantenimento dell'hardware
- Mantenimento di applicazioni “legacy”
- On-demand computing
 - Allocazione dinamica delle risorse
 - Bilanciamento del carico

Hypervisor

- Virtual Machine Monitor (VMM)
- Software che gestisce le virtual machines
 - Regola l'accesso all'hardware
 - “Sistema operativo per sistemi operativi”
- **Tipo 1 “bare metal” (VMWare ESX, Citrix XenServer,...)**
 - L'hypervisor viene eseguito direttamente sull'hardware e ha il controllo delle risorse
 - Non c'è un sistema operativo “host”
- **Tipo 2 “hosted” (VirtualBox, KVM, XEN,...)**
 - L'hypervisor viene eseguito sul sistema operativo principale “host”
 - Altri sistemi (detti “guest”) possono essere gestiti dal hypervisor



Requisiti per la virtualizzazione (Popek e Goldberg)

- **Equivalenza / Fedeltà**
 - Un programma che viene eseguito in un VMM deve mostrare un comportamento essenzialmente identico a quello mostrato quando esso viene eseguito direttamente sulla macchina
- **Controllo delle risorse / Sicurezza**
 - Il VMM deve avere il controllo completo delle risorse virtualizzate
- **Efficienza / Performance**
 - Una percentuale statisticamente significativa delle istruzioni macchina deve essere eseguita senza l'intervento del VMM