

Computadors

Sistemes Operatius

(3/3)

Grau en Ciència i Enginyeria de Dades

Facultat d'Informàtica de Barcelona (FIB)

Universitat Politècnica de Catalunya (UPC)

Creative Commons License

Aquest document utilitza Creative Commons Attribution 3.0 Unported License




Els detalls d'aquesta licencia es poden trobar a <https://creativecommons.org/licenses/by-nc-nd/4.0>

Index

- Components Bàsics del SO
- Gestió de Processos
- Gestió de la Memòria
- **Gestió de l'E/S i Sistema de Fitxers**
 - **Conceptes Bàsics**
 - Suport del SO

Introducció

- Necessitat de moure dades des de/cap a el sistema des de/cap a altres dispositius



Gestió de Entrada/Sortida

- E/S és una de les activitats clau dels processos
 - L'E/S és la capacitat d'enviar/rebre dades des de/cap a un procés
 - L'acció és sempre realitzada des del punt de vista del procés
 - Això vol dir que també inclou comunicació entre processos
 - Per exemple, “sockets” per comunicar processos mitjançant la xarxa
- Accedir i gestionar dispositius són operacions “privilegiades”
 - Necessita tenir una gestió segura per garantir el correcte ús entre usuaris
 - Root / administrador és qui pot gestionar-ho a nivell d'administrador
- Per poder realitzar operacions d'E/S és necessari l'ús de **crides a sistema**
 - Són independents de les característiques del dispositiu
- **IMPORTANT:** una operació d'E/S pot bloquejar un procés fins que es completi
 - Estat “BLOCKED” i per tant no utilitza CPU
 - Hi ha diverses alternatives per minimitzar impacte
 - E.g. Operacions asíncrones (o no bloquejants), transferències amb buffer, planificació eficient, ...

Device Drivers

- Els programadors no poden desenvolupar codi per tots els diferents dispositius que existeixen
- Els fabricants han de proporcionar el conjunt de codi de baix nivell (codi compilat) que necessita el dispositiu per realitzar la funcionalitat

- El codi + dades per accedir al dispositiu es connecta com **Device Driver**


- Per afegir un nou dispositiu

1. Opció 1: recompilar el kernel 🤔

2. Opció 2: **sense** recompilar el kernel 👍

- El SO ha d'oferir un mecanisme per afegir dinàmicament codi/dades al kernel de manera segura

- *Dynamic Kernel Module Support, Plug & Play*



Device Drivers: controlador de dispositiu

- Conjunt de rutines que gestionen un dispositiu i permet a un programa interactuar amb ell
 - Segueix l'interfície definida per cada SO per implementar tasques genèriques
 - Obrir, llegir, escriure, tancar...
 - Implementa tasques específiques del dispositiu
 - Conté codi de baix nivell per gestionar interrupcions i altres elements del dispositiu
 - Són fitxers binaris

Independència de Dispositiu

- Els dispositius presenten una gran varietat de característiques i necessitats
 - Per exemple, velocitat, tipus de dispositiu, tipus de transferència, etc.
- Classificació interna
 - UNIX/Linux: tots els dispositius estan representats per un fitxer
 - **character/block**, → per exemple, teclat (char) / disc (block)
 - **major** (quin tipus de dispositiu?) → és un número enter ≥ 0
 - **minor** (quina instància és?) → és un número enter ≥ 0
- Per què l' independència del dispositiu és important?
 - **Operacions uniformes d'E/S** – open, close, read, write...
 - **Dispositius virtuals** – només utilitza un identificador (file descriptor)
 - **Redireccionament** – canviar el dispositiu que s'utilitza sense canviar el codi (vist en el Lab)

Per exemple: `./programa < disp1`
`./programa > disp2`

UNIX/Linux: Sistema de Fitxers basat en I-Nodes

- Tot dispositiu té la seva representació en el sistema de fitxers
 - Mitjançant un I-Node
- I-Node: Estructura de dades que conté tota l'informació relativa a un fitxer
 - Alguns camps són:
 - Identificador (ID) de I-Node
 - Mida
 - Tipus de fitxer (regular, directori, disp.caracter, disp.bloc, etc.)
 - Major/minor IDs
 - Protecció (Read / Write / Execute (RWX) per Owner, Group, Others)
 - ...
 - Altres camps els veurem en la part de Sistema de Fitxers

Tipus de Dispositius

- Dispositius de Tipus Caràcter – Transferència de byte en byte
 - Terminals, consoles, teclat, ratolí, pantalla...
 - Impressores
 - Real time clock (rtc)
 - Dispositius especials de dades bàsiques
 - null, zero, full, random, urandom
 - SO
 - Missatges, memòria, ports d'E/S, memòria física
 - Hardware
 - Firmware, registres hardware

Dispositius de Tipus Caràcter

crw-r-----	1	root	kmem	1,	1	Jan	16	08:14	mem
crw-r-----	1	root	kmem	1,	2	Jan	16	08:14	kmem
crw-rw-rw-	1	root	root	1,	3	Jan	16	08:14	null
crw-r-----	1	root	kmem	1,	4	Jan	16	08:14	port
crw-rw-rw-	1	root	root	1,	5	Jan	16	08:14	zero
crw-rw-rw-	1	root	root	1,	7	Jan	16	08:14	full
crw-rw-rw-	1	root	root	1,	8	Jan	16	08:14	random
crw-rw-rw-	1	root	root	1,	9	Jan	16	08:14	urandom
crw-r--r--	1	root	root	1,	11	Jan	16	08:14	kmsg

Tipus de Dispositius

- Dispositius de Tipus Bloc – Transferència de bloc de bytes
 - Disc /dev/sda, /dev/sdb...
 - SCSI, SATA, ATA
 - IDE (/dev/hda, /dev/hdb...)
 - CD/DVD /dev/dvdrom
 - RAMDisks /dev/ram0

Dispositius de Tipus Bloc

```
brw-rw---- 1 root disk      8,    0 Jan 16 08:14 sda
brw-rw---- 1 root disk      8,    1 Jan 16 08:14 sda1
brw-rw---- 1 root disk      8,    2 Jan 16 08:14 sda2


brw-rw---- 1 root disk      7,    0 May 28 10:46 loop0
brw-rw---- 1 root disk      7,    1 Jan 16 08:14 loop1
brw-rw---- 1 root disk      7,    2 Jan 16 08:14 loop2

brw-rw---- 1 root cdrom     18,    0 Dec  1 02:56 sr0

lrwxrwxrwx 1 root root          8   Ago 17 17:32 cdrom -> /dev/sr0
```


Suport del SO pel subsistema d'E/S

- Qualsevol dispositiu d'E/S necessita ser accessible
 - **Nom simbòlic** és el nom que el representa en el Sistema de Fitxers
 - E.g.: un terminal pot ser: `"/dev/pts/0"`
- El SO introdueix varies capes d'abstracció...
 - ...per simplificar la gestió d'E/S
 - Ha d'oferir crides a sistema independents dels internals dels dispositius
- El SO gestiona, per cada procés, una taula privada de dispositius que utilitza. Pel procés són dispositius abstractes (o "virtuals")
 - **File descriptor table**: una taula de punters a una altra estructura global del SO



Taula de descriptors de fitxers

- Cada procés té una taula privada
 - És el punt d'accés per part del codi d'usuari per utilitzar dispositius
 - Totalment independent de les característiques del dispositiu
 - Cada dispositiu està representat pel número de l'entrada que se li ha assignat
 - Quan es demana començar a utilitzar un dispositiu s'assigna la primera entrada disponible
 - Els tres primers (0→STDIN; 1→STDOUT; 2→STDERR) per defecte estan assignats (per defecte a la terminal)




Taula de descriptors de fitxers

En Linux es pot consultar en /proc/<PID>/fd

File Descriptor Table

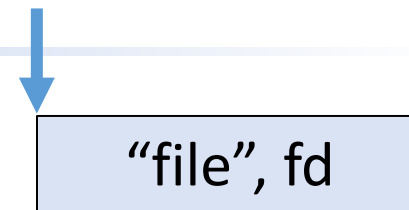
0	stdin
1	stdout
2	stderr
3	myfile.txt
4	
...	...



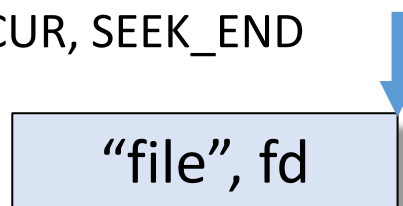

Crides a sistema bàsiques de E/S

- `fd = open(path, flags[, permissions]);`
 - Flags bàsics:
 - `O_RDONLY` `O_WRONLY` `O_RDWR`
 - Combinacions de flags:
 - `O_WRONLY|O_CREAT|O_TRUNC`
 - Permissions:
 - Control d'accés al fitxer que es crea (`0644 -> rw-r--r--`)
- `bytes = read(fd, @data, bytes);`
- `bytes = write(fd, @data, bytes);`
- `new_offset = lseek(fd, offset, whence);`
 - Desplaçarse dins del fitxer sense accessos a disc
 - Whence: `SEEK_SET`, `SEEK_CUR`, `SEEK_END`
- `close(fd);`

Per defecte ens posicionem al principi del fitxer quan es fa l'open



Internament el SO actualitza l'offset (posició) en la que està després de r/w



Es pot anar directament a punts remots del fitxer sense accedir a disc

Suport de la biblioteca C

- Ofereix serveis d'E/S d'alt nivell
 - **FILE** és una estructura que engloba més que el “file descriptor”
 - Afegeix altres característiques per facilitar l'ús
 - Especialment **BUFFERING**
- Cada funció invoca a la crida a sistema corresponent
 - E.g. “fopen” crida a “open”
- Llegir i escriure...
 - ...està preparat per transferir un nombre d'elements d'una mida (*elemsize* bytes)
- Lseek funciona de la mateixa manera

```
FILE * f;
size_t size;  int res;

f = fopen(path, mode);
    // mode = "r"      read-only
    // mode = "w"      truncate, write-only
    // mode = "a"      append
    // mode = "r+"     read-write
size = fread (data, elemsize, numelems, f);
if (size < 0) perror ("fread");

size = fwrite (data, elemsize, numelems, f);

res = fseek(f, newoffset, whence);
    // whence = SEEK_SET, SEEK_CUR, SEEK_END

res = fclose(f);
```

Suport de la biblioteca C

- Hi ha altres funcions addicionals per fer E/S pensades per text
 - printf, escriure per la sortida estàndard **stdout**
 - fprintf, utilitzar una sortida diferent
 - sprintf, escriure en un array de chars
- scanf, llegir una string de format concret des de l'entrada estàndard **stdin**
- fscanf, llegir una string de format concret des d'una entrada diferent
- sscanf, llegir una string de format concret des d'una string

```
FILE *f;
f = fopen("myfile", "r+");
if (f == NULL) {
    fprintf (stderr, "fopen: %s\n", strerror(errno));
    exit(1);
}
fprintf (f, "my message");
```

```
char line[4096];
int i; double d; char str[11];

n = sscanf(line, "%d %lf %10s", &i, &d, str);
// will understand lines like 10 4.5 hola
// and assign i=10, d=4.5, str="hola"
```

Impacte en el Rendiment


- Una operació d'E/S pot **bloquejar** un procés (operació síncrona)
 - Si les dades es poden disposar al moment, torna immediatament
 - Si les dades no estan disponibles, el procés passa d'estat "Running" a "BLOCKED" i per tant no utilitza CPU fins que es completi
- Una operació d'E/S pot ser **no bloquejant**
 - Gestió d'identificadors de l'operació asíncrona
 - Retorna immediatament tant si l'operació s'ha completat com si no
- Les rutines d'E/S són crides a sistema
 - Tenen l'overhead implícit per passar a mode privilegiat (executar codi del kernel)
 - Utilitzar buffers per reduir el nombre de crides a sistema

Index

- Components Bàsics del SO
- Gestió de Processos
- Gestió de la Memòria
- **Gestió de l'E/S i Sistema de Fitxers**
 - Conceptes Bàsics
 - **Suport del SO**

Virtual File System (VFS)

- Capa d'abstracció per gestionar particions de diferents tipus de sistema de fitxers
 - Proporcionar un única interfície de crides a sistema per qualsevol tipus de sistema de fitxers
 - VFS és per UNIX/Linux. Altres SOs utilitzen mètodes similars
- Tipus de Sistemes de Fitxers
 - FAT (File Allocation Table)
 - Dispositius extraïbles
 - exFAT (Extended FAT)
 - Dispositius extraïbles més grans de 4GB
 - NTFS (New Technology Transfer)
 - Windows
 - **Sistemes de Fitxers basats en I-node (UNIX/Linux)**
 - Ext3, ext4, Reiser4, XFS, F2FS
 - Sistemes de Fitxers en el Núvol
 - GlusterFS, Ceph, HadoopFS, ElasticFileSystem (Amazon)




Altres Sistemes de Fitxers

- Espai Swap: en SOs UNIX/Linux és un Sistema de Fitxers que estén la memòria principal
 - Windows implementa l'espai swap en un únic fitxer redimensionable
- FUSE: Filesystem in Userspace
 - Permet definir un sistema de fitxers en espai d'usuari. És a dir, sense modificar o afegir mòduls en el kernel (les rutines s'executen en espai d'usuari)
 - E.g.: GDFS (Google Drive), WikipediaFS, proprietary File Systems
- Les característiques dels Sistemes de Fitxers tenen impacte en el rendiment, fiabilitat, resiliència, seguretat, etc

Partició/Unitats Lògiques


- Partició: Un grup de sectors consecutius. És identificat amb una etiqueta única
 - Pot ser gestionat com una **unitat lògica** independent
 - Windows: C: D: Linux: /dev/sda1 /dev/sda2
 - Un dispositiu d'emmagatzematge físic pot ser dividit en varies particions
- Sectors de Gestió
 - MBR: Master Boot Record (fins a unitats físiques de 2TB)
 - GPT: GUID Partition Table (substitueix MBR)
 - Superbloc & gestió (una per partició): Informació crítica per gestionar la partició
 - Boot Sector: Pocs Bytes per arrencar el SO instal·lat en aquesta partició



Sistema de Fitxers basat en I-Nodes

- I-Node: Estructura de dades que conté tota l'informació relativa a un fitxer
 - Alguns camps són:
 - Identificador (ID) de I-Node
 - Mida
 - Tipus de fitxer (regular, directori, disp.caracter, disp.bloc, etc.)
 - Major/minor IDs
 - Protecció (Read / Write / Execute (RWX) per Owner, Group, Others)
 - Propietari
 - Marques de temps
 - Nombre de Links (# relacions directes entre nom simbòlic i ID de I-Node)
 - Punters a blocs de dades (index multinivell). Acostuma tenir 12-13 punters.

SuperBloc &
Gestió



Gestió de blocs

- Cada sistema de fitxers té el seu mecanisme per gestionar...
 - ...blocs ocupats/l·liures
 - ...els blocs d'un fitxer donat (i.e. com accedir als continguts d'un fitxer)
- Depenent del sistema de fitxers, l'implementació canvia. Per exemple:
 - FAT: té una taula global amb tantes entrades com blocs té el dispositiu
 - Accés al fitxer basat en llista enllaçada
 - Basat en I-nodes: té una estructura, I-node, que guarda tota l'informació necessària per gestionar un fitxer
 - Accés al fitxer basat en índex (índex multinivell), guardat en el I-node
- Buffer Cache
 - Zona de memòria que guarda temporalment qualsevol transferència des de/cap el sistema de fitxers
 - Si el I-node o bloc està en la cache, no cal fer l'accés al disc → **augment de rendiment**

Directoris


- **Directori:** Estructura lògica per organitzar fitxers
 - És un tipus de fitxer particular gestionat pel SO
 - “/” és el directori arrel (el directori més superior de tot el sistema de fitxers)
 - Cada partició té el seu directori arrel (**ID de I-node 2**)
 - “.” & “..” són entrades obligatòries en qualsevol directori
 - Encara que el directori no tingui fitxers
- Ruta: conjunt de caràcters que identifiquen de manera única la localització d'un fitxer
 - Relativa (des de qualsevol directori) vs Absoluta (des de la carpeta arrel)
- **Hardlink:** Relació directe entre nom simbòlic i ID de I-node

Nom	I-node
.	2
..	2
home	3
App	4

Directori: /


Nom	I-node
.	5
..	3
F1	6
F2	7

Directori: /home/usr1




Directoris

- Directoris están organitzats en grafs
 - Un fitxer pot ser accedit des de diferents directoris
- Tipus de links
 - Hardlinks
 - Relació directa entre nom simbòlic i ID de I-Node (name→I-node ID)
 - **Softlinks**
 - Un **nou fitxer** que té una ruta
 - Similar a un accés directe
 - Pros/Cons/restriccions entre ells



Muntar

- Fer accessibles els continguts d'una partició en el Virtual File System
 - E.g.: `mount -t ext4 /dev/sda2 /home` // muntar la partició en /home
 - `mount -t iso9660 /dev/cdrom /mnt/cdrom` // muntar el CDROM
 - `unmount /dev/sda2` // desmuntar la partició





Journaling

- Sistema de fitxers basat en transaccions
 - Enregistra els canvis a realitzar en el sistema de fitxers encara no completats
 - Ho enregistra en un fitxer especial com si fos un “diari” (journal)
 - Té un àrea dedicada en el sistema de fitxers
- En cas de fallo en el sistema o tall de corrent elèctrica...
 - El sistema de fitxers pot tornar enrere i desfer un canvi no completat, minimitzant la probabilitat d'errors
- Alguns sistemes de fitxers que implementen Journaling
 - Ext3, Ext4, ReiserFS, XFS, JFS

RAID: Redundant Array of Independent Disks

- Tecnologia de virtualització d'emmagatzematge que combina múltiples dispositius físics en un únic de lògic
 - Software driver vs controlador hardware
 - Impacte en el rendiment i capacitat
- Varis alternatives (es poden combinar)
 - RAID 0: Stripping → dades distribuïdes
 - RAID 1: Mirroring → dades replicades
 - RAID 1+0 vs RAID 0+1
 - RAID 5: amb blocs de paritat distribuïts



Bibliografia

- Computer Systems – A Programmer's perspective (3rd Edition)
 - Randal E. Bryant, David R. O'Hallaron, Person Education Limited, 2016
 - https://discovery.upc.edu/permalink/34CSUC_UPC/11q3oqt/alma991004062589706711
 - Chapter 10
- Operating system concepts (John Wiley & Sons, INC. 2014)
 - Silberschatz, A.; Galvin, P.B.; Gagne, G
 - http://cataleg.upc.edu/record=b1431631~S1*cat
- Operating systems: internals and design principles (Prentice Hall, 2015)
 - Stallings, W
 - http://cataleg.upc.edu/record=b1441252~S1*cat