Modulo 5: Programmazione di sistema (parte C)

Laboratorio di Sistemi Operativi I
Anno Accademico 2005-2006

Francesco Pedullà
(Tecnologie Informatiche)

Massimo Verola
(Informatica)

System call per la gestione dei file

Sommario system call per la gestione dei file

Nome	Significato
`open`	apre un file in lettura e/o scrittura o crea un nuovo file
`creat`	crea un file nuovo
`close`	chiude un file precedentemente aperto
`read`	legge da un file
`write`	scrive su un file
`lseek`	sposta il puntatore di lettura/scrittura ad un byte specificato
`unlink`	rimuove un file
`remove`	rimuove un file
`fcntl`	controlla gli attributi associati ad un file

Note introduttive

- Un file per essere usato deve essere aperto (open)
- L'operazione open:
  - localizza il file nel file system attraverso il suo pathname
  - copia in memoria il descrittore del file (i-node)
  - associa al file un intero non negativo (file descriptor), che verrà usato nelle operazioni di accesso al file, invece del pathname
- I file standard non devono essere aperti, perché sono già aperti dalla shell. Essi sono associati ai file descriptor:
  0 = standard input (stdin)
  1 = standard output (stdout)
  2 = standard error (stderr)
- Quando non si ha più necessità di accedere al file, bisogna chiuderlo
- La close rende disponibile il file descriptor per ulteriori usi

Gestione file

- **Esempio:**

```
int fd;
...
fd=open(pathname, ...);
if (fd==-1)
{
   /*gestione errore*/
}
/* Il file è aperto correttamente */
read(fd, ...);
write(fd,...);
close(fd);
/* Il file è chiuso */
```

- **Nota:** Un file può essere aperto più volte contemporaneamente, e quindi avere più file descriptor associati.

Apertura file esistente

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

- apre il file specificato da **`pathname`** (assoluto o relativo), secondo la modalità di accesso specificata in **`flags`**
- restituisce il file descriptor con il quale ci si riferirà al file successivamente (o -1 se errore)

- **Valori di `flags`**
  - **`O_RDONLY`** read-only (0)
  - **`O_WRONLY`** write-only (1)
  - **`O_RDWR`** read and write (2)
  - Solo una di queste costanti può essere utilizzata in **`flags`**
  - Altre costanti (che vanno aggiunte in OR ad una di queste tre) permettono di definire alcuni comportamenti particolari

Apertura file

- **Altri valori di `flags`:**
  - **`O_APPEND`** append (scrittura alla fine del file)
  - **`O_EXCL`** con **`O_CREAT`**, ritorna un errore se il file esiste
  - **`O_TRUNC`** se il file esiste, viene svuotato
  - **`O_NONBLOCK`** file speciali (discusso in seguito)
  - **`O_SYNC`** synchronous write
  - **`O_CREAT`** creazione di un nuovo file
- Se si specifica **`O_CREAT`**, è necessario specificare un terzo argomento (vedi prossima slide)

Creazione file

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

- crea un nuovo file regolare con **pathname** specificato, e lo apre in scrittura
- **mode** specifica i permessi iniziali; l'owner è l'effective user-id del processo
- se il file esiste già, lo svuota (owner e **mode** restano invariati)
- **mode** codifica i permessi di accesso al file mediante un numero ottale (ad esempio **0644 = rw-r--r--**).
- le due system call restituiscono il file descriptor, o -1 se errore
- Equivalenze:

  creat(pathname, mode);

  ha lo stesso effetto di

  open(pathname, O_WRONLY | O_CREAT | O_TRUNC, mode);

Chiusura file

```
int close(int filedes);
```

- chiude il file descriptor **`filedes`**
- restituisce l'esito dell'operazione (0 o -1)

- **Nota:**
  - Quando un processo termina, tutti i suoi file vengono comunque chiusi automaticamente dal kernel

Current file offset

- Ad ogni file aperto e' associato ad un "current file offset", che indica la posizione attuale (del puntatore di lettura/scrittura) all'interno del file
- L'offset è un valore non negativo che misura il numero di byte dall'inizio del file
- Le operazioni **`read`**/**`write`** leggono/scrivono dalla posizione attuale e incrementano il current file offset in avanti del numero di byte letti/scritti
- Quando viene aperto un file il current file descriptor viene posizionato a 0, a meno che non sia stata specificata l'opzione **`O_APPEND`**

Spostamento all'interno di un file

```
off_t lseek(int fildes, off_t offset, int whence);
```

- sposta la posizione corrente nel file **filedes** di **offset** bytes a partire dalla posizione specificata dal parametro **whence**, che può assumere i valori:
  - **SEEK_SET** dall'inizio del file
  - **SEEK_CUR** dalla posizione corrente
  - **SEEK_END** dalla fine del file
- restituisce la posizione corrente dopo la **lseek**, o -1 se errore

- **Nota:**
  - La **lseek** non effettua alcuna operazione di I/O

Offset validi e non validi

- Il parametro offset può essere negativo, cioè sono ammessi spostamenti all'indietro a partire dalla posizione indicata da **whence**, purché non si vada prima dell'inizio del file.
- Tentativi di spostamento prima dell'inizio del file generano un errore.
- E' possibile spostarsi oltre la fine del file: ovviamente non ci saranno dati da leggere in tale posizione.
- Futuri accessi tramite la **read** ai byte compresi tra la vecchia fine del file e la nuova posizione danno come risultato il carattere ASCII null.
- **Esempio:**

```
off_t newpos;
...
newpos = lseek(fd, (off_t)-16, SEEK_END);
/* newpos punta a 16 byte prima della fine */
newpos = lseek(fd, (off_t)16, SEEK_END);
/* newpos punta a 16 byte dopo la fine */
```

Lettura di byte da file

```
ssize_t read(int filedes, void *buf, size_t nbyte);
```

- legge in **`*buf`** una sequenza di **`nbyte`** byte dalla posizione corrente del file **`filedes`**
- aggiorna la posizione corrente
- restituisce il numero di bytes effettivamente letti (che può essere uguale o minore di **`nbyte`**), o -1 se errore
- il numero di byte letti può risultare inferiore al numero di byte richiesti nei seguenti casi:
  - si è giunti alla fine di un file regolare
  - si sta leggendo uno stream proveniente dalla rete e non ci sono abbastanza byte in input
  - si sta leggendo da da terminale e non ci sono abbastanza byte in input

Scrittura di byte su file

```
ssize_t write(int filedes, const void *buf, size_t nbyte);
```

- scrive in **`*buf`** una sequenza di **`nbyte`** byte dalla posizione corrente del file **`filedes`**
- aggiorna la posizione corrente
- restituisce il numero di bytes effettivamente scritti, o -1 se errore

Scrittura alla fine di un file

- Vi sono due modi per scrivere alla fine di un file:
  - usare **lseek** per spostarsi alla fine del file e poi scrivere:

```
lseek(fildes, (off_t)0, SEEK_END);
write(fildes, buf, BUFSIZE);
```

  - usare **open** con il flag **O_APPEND**:

```
fildes = open("nomefile", O_WRONLY | O_APPEND);
write(fildes, buf, BUFSIZE);
```

Esempio: gestione di un hotel

- Sia **`residents.txt`** un file contenente la lista dei residenti di un hotel.
- La linea 1 di tale file contiene il nome della persona che occupa la camera 1, la linea 2 contiene il nome della persona che occupa la camera 2, etc.
- Ogni linea è lunga 41 caratteri, i primi 40 contengono il nome dell'occupante, l'ultimo è un newline (\n).

Esempio: gestione di un hotel

```
/* Programma che stampa i nomi dei residenti in un albergo di 10
   camere */
#define NROOMS 10
main()
{
    int j;
    char *getoccupier(int), *p;
    for (j=1; j <= NROOMS; j++)
    {
        if (p = getoccupier(j))
           printf("Room %2d, %s\n", j, p);
        else
           printf("Error on room %d\n", j);
    }
}
```

Esempio: gestione di un hotel

```
/* getoccupier - restituisce il nome dell'occupante la camera
   passata come parametro */
#include <stdio.h>
#include <fcntl.h>
#include <unistd.h>
#define NAMELENGTH 41
char namebuf[NAMELENGTH]; /* buffer per contenere il nome */
int infile = -1; /* conterra' il file descriptor di
   residents.txt; l'inizializzazione serve affinche' venga
   aperto una sola volta */
/* continua ... */
```

Esempio: gestione di un hotel

```
char *getoccupier(int roomno)
{
    off_t offset; ssize_t nread;
    if (infile == -1 &&
        (infile = open("residents.txt", O_RDONLY)) == -1)
        return (NULL);
    offset = (roomno - 1) * NAMELENGTH;
    /* cerca la linea relativa alla camera e legge il nome */
    if (lseek(infile, offset, SEEK_SET) == -1)
        return (NULL);
    if ( (nread = read(infile, namebuf, NAMELENGTH)) <= 0)
        return (NULL);
    /* crea una stringa rimpiazzando il \n con \0 */
    namebuf[nread - 1] = '\0';
    return (namebuf);
}
```

Esercizi

- Implementare un meccanismo per decidere se una camera è vuota, modificando eventualmente la funzione **`getoccupier`** e il file **`residents.txt.`** Scrivere una procedura **`findfree`** per trovare la prima camera libera.
- Scrivere le procedure:
  - **`freeroom`** per cancellare un occupante da una camera;
  - **`addguest`** per assegnare una camera ad un ospite, controllando che questa sia libera.
- Utilizzando le funzioni **`getoccupier, freeroom, addguest`**, e **`findfree`**, scrivere un programma **`frontdesk`** per gestire il file **`residents.txt`**.

Condivisione di file (I)

- Linux supporta la condivisione dei file (***file sharing***) aperti tra processi differenti
- Per comprendere i meccanismi del file sharing è necessario conoscere le strutture dati che il kernel mantiene per i file aperti
- Ricordiamo che il kernel mantiene in memoria una ***process table*** con le informazioni di ogni processo
- Le strutture dati relative ai file aperti mantenute dal kernel sono:
  - ***file table***, i cui elementi sono le ***file table entry***
  - ***v-node table,*** i cui elementi sono i ***v-node***

Condivisione di file (II)

- Ad ogni processo e' riservata un'area dedicata nella ***process table (process table entry)***
- All'interno di ogni ***process table entry*** c'è una tabella, detta ***table of open file descriptors***, relativa ad ogni singolo processo (*process-wide*), che contiene i descrittori di file aperti per quel processo
- Sono associati a ciascun ***file descriptor*** nella ***table of open file descriptors***:
  - I flag del file descriptor
  - Un puntatore a una ***file table entry***

Condivisione di file (III)

- La ***file table*** e' una tabella dei file aperti da tutti i processi nel sistema (system-wide)
- Ogni entry della ***file table***, detta ***file table entry,*** contiene:
  - i flag di stato del file (read, write, append, sync, nonblocking, ...)
  - Il file offset corrente
  - Un puntatore alla entry corrispondente al file in questione nella ***v-node table***

Condivisione di file (IV)

- La ***v-node table*** e' una tabella di ***v-node***, i quali contengono informazioni sul tipo del file e i puntatori alle funzioni che possono operare sul file
- Ogni entry della ***v-node table*** contiene:
  - Informazioni sul tipo di file
  - Puntatori alle funzioni che operano sul file
  - In molti casi, contengono l'i-node del file (o un puntatore ad esso). L'i-node contiene il proprietario del file, la dimensione, i puntatori ai blocchi dei dati del file, ...

Condivisione di file (V)

```
struct inode {
        struct hlist_node       i_hash;
        struct list_head        i_list;
        struct list_head        i_sb_list;
        struct list_head        i_dentry;
        unsigned long           i_ino;
        atomic_t                i_count;
        umode_t                 i_mode;
        unsigned int            i_nlink;
        uid_t                   i_uid;
        gid_t                   i_gid;
        dev_t                   i_rdev;
        loff_t                  i_size;
        struct timespec         i_atime;
        struct timespec         i_mtime;
        struct timespec         i_ctime;
        unsigned int            i_blkbits;
        unsigned long           i_blksize;
        unsigned long           i_version;
        unsigned long           i_blocks;
        unsigned short          i_bytes;
        spinlock_t              i_lock;
        struct semaphore        i_sem;
        struct rw_semaphore     i_alloc_sem;
        struct inode_operations *i_op;
        struct file_operations  *i_fop;
        struct super_block      *i_sb;
        struct file_lock        *i_flock;
        struct address_space    *i_mapping;
        struct address_space    i_data;
#ifdef CONFIG_QUOTA
        struct dquot
    *i_dquot[MAXQUOTAS];
#endif
        struct list_head        i_devices;
        struct pipe_inode_info  *i_pipe;
        struct block_device     *i_bdev;
        struct cdev             *i_cdev;
        int                     i_cindex;
        __u32                   i_generation;
#ifdef CONFIG_DNOTIFY
        unsigned long           i_dnotify_mask;
        struct dnotify_struct   *i_dnotify;
#endif
        unsigned long           i_state;
        unsigned long           dirtied_when;

        unsigned int            i_flags;

        atomic_t                i_writecount;
        void                    *i_security;
        union {
                void            *generic_ip;
        } u;
#ifdef __NEED_I_SIZE_ORDERED
        seqcount_t              i_size_seqcount;
#endif
};

// file: /usr/src/kernels/.../include/linux/fs.h
```

Condivisione di file (VI)

Esempio: le tre tabelle con un processo che apre due file distinti

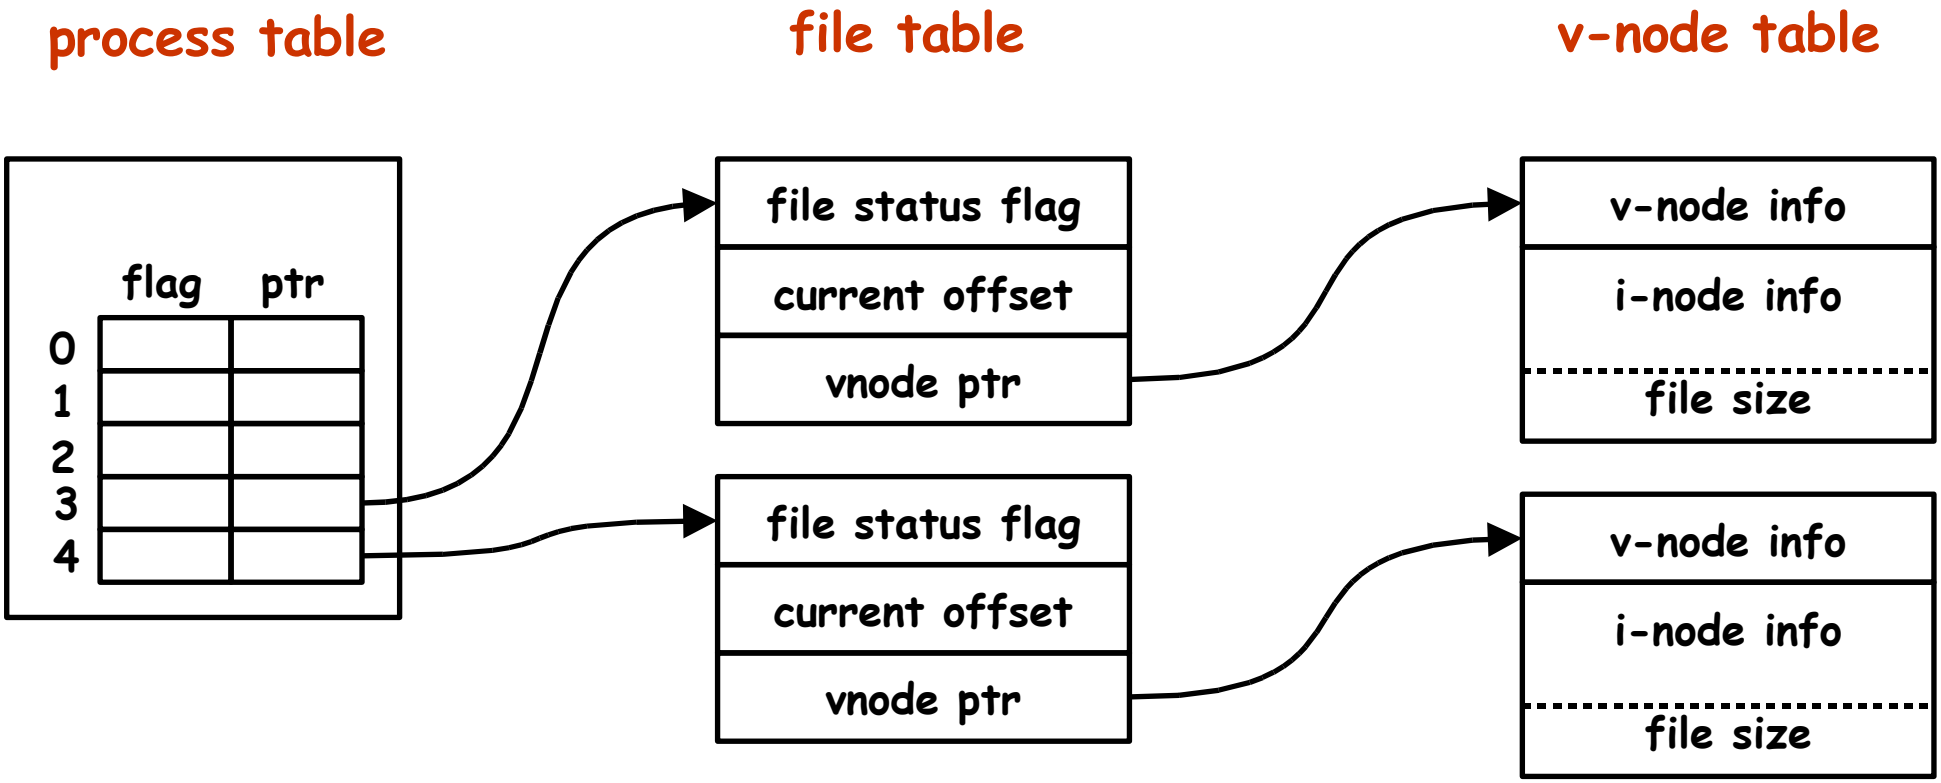

Condivisione di file (VII)

Esempio: le tre tabelle con due processi che aprono lo stesso file

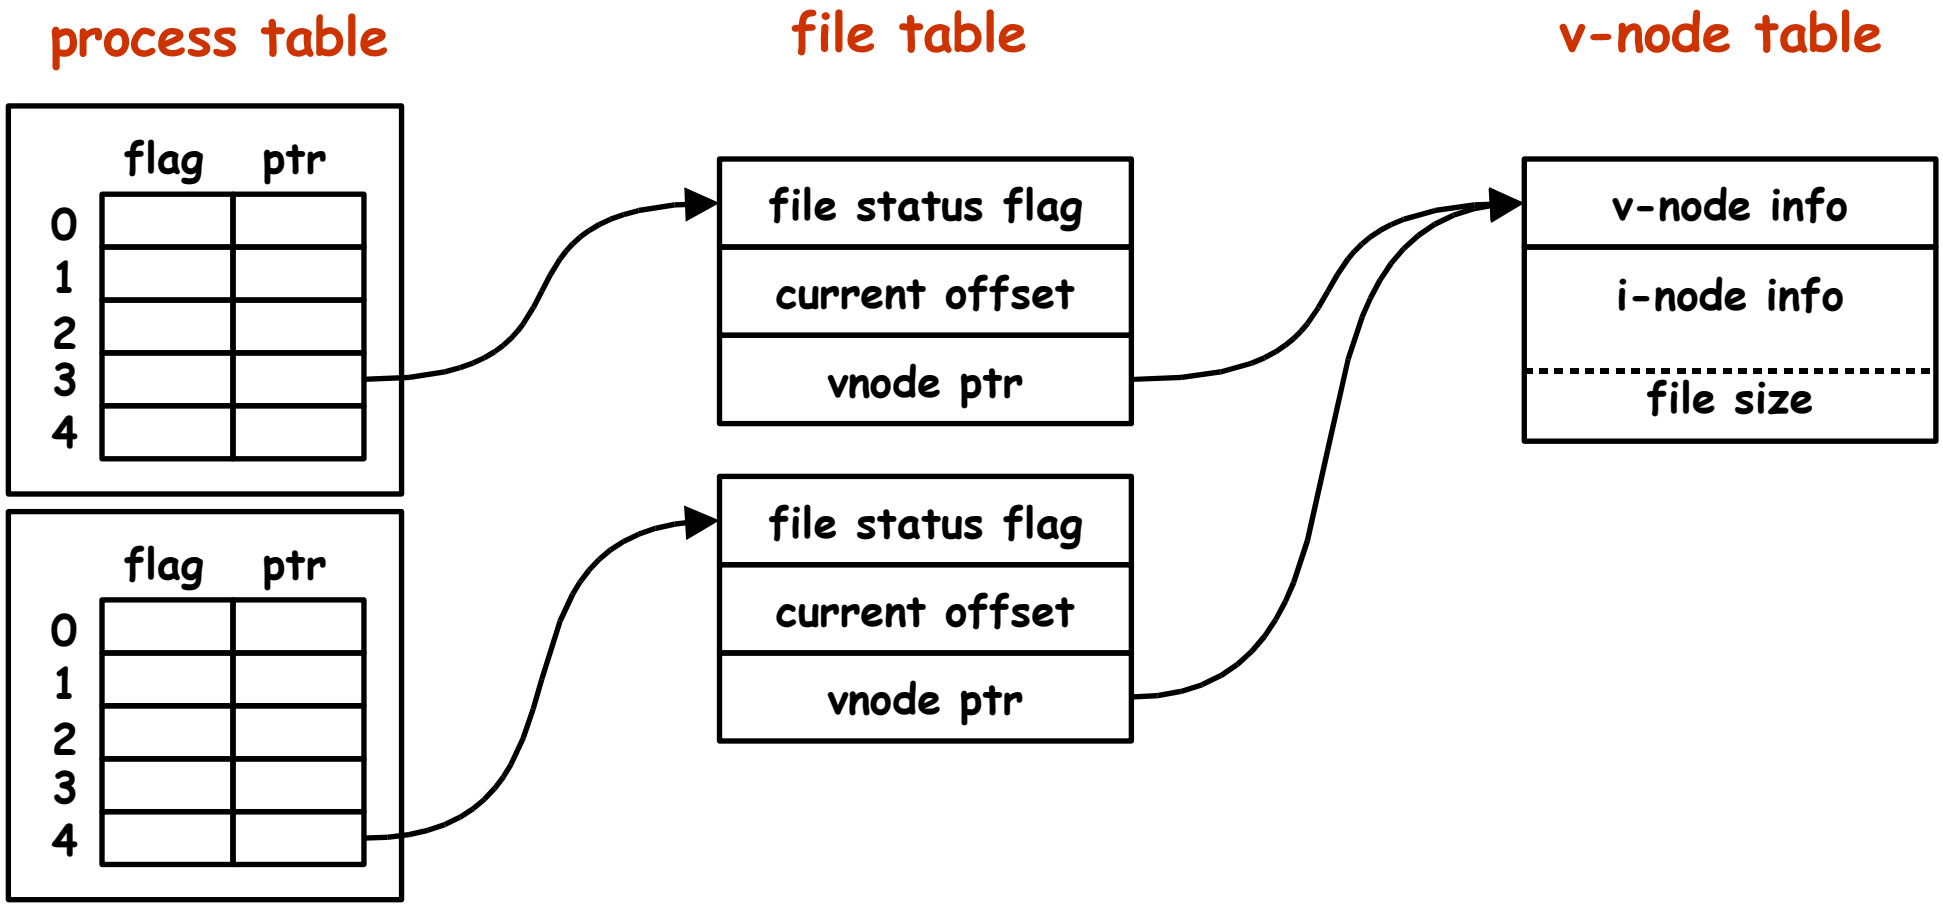

Condivisione di file (VIII)

- **NOTA**: due processi che aprono lo stesso file ottengono due distinte *file table*, quindi ogni processo ha il proprio *current offset* per il file
- Vista questa organizzazione, possiamo essere più specifici riguardo alle operazioni viste in precedenza:
  - alla conclusione di ogni **`write`**
    - il current offset nella file table entry viene incrementato
    - se il current offset è maggiore della dimensione del file nella v-node table entry, questa viene incrementata
  - se il file è aperto con il flag **`O_APPEND`**
    - un flag corrispondente è settato nella file table entry
    - ad ogni **`write`**, il current offset viene prima posto uguale alla dimensione del file nella v-node table entry
  - **`lseek`** modifica unicamente il current offset nella file table entry corrispondente

Condivisione di file (IX)

- E' possibile che più ***file descriptor*** siano associati a una singola ***file table entry***
  - tramite la funzione **`dup`**, all'interno dello stesso processo
  - tramite **`fork`**, tra due processi diversi
- E' interessante notare che esistono due tipi di flag:
  - alcuni sono associati al ***file descriptor***, e quindi sono particolari del processo
  - altri sono associati alla ***file table entry***, e quindi possono essere condivisi fra più processi
  - esiste la possibilità di modificare questi flag (funzione **`fcntl`**)
- E' importante notare che questo sistema di strutture dati condivise può portare a problemi di concorrenza

Copia del file descriptor

- Un file descriptor esistente viene duplicato da una delle seguenti funzioni:
  - `int dup(int filedes);`
  - `int dup2(int filedes, int filedes2);`
- Entrambe le funzioni “duplicano” un file descriptor, ovvero creano un nuovo file descriptor che punta alla stessa file table entry del file descriptor originario
- Nella file table entry c’e’ un campo che registra il numero di file descriptor che la “puntano”

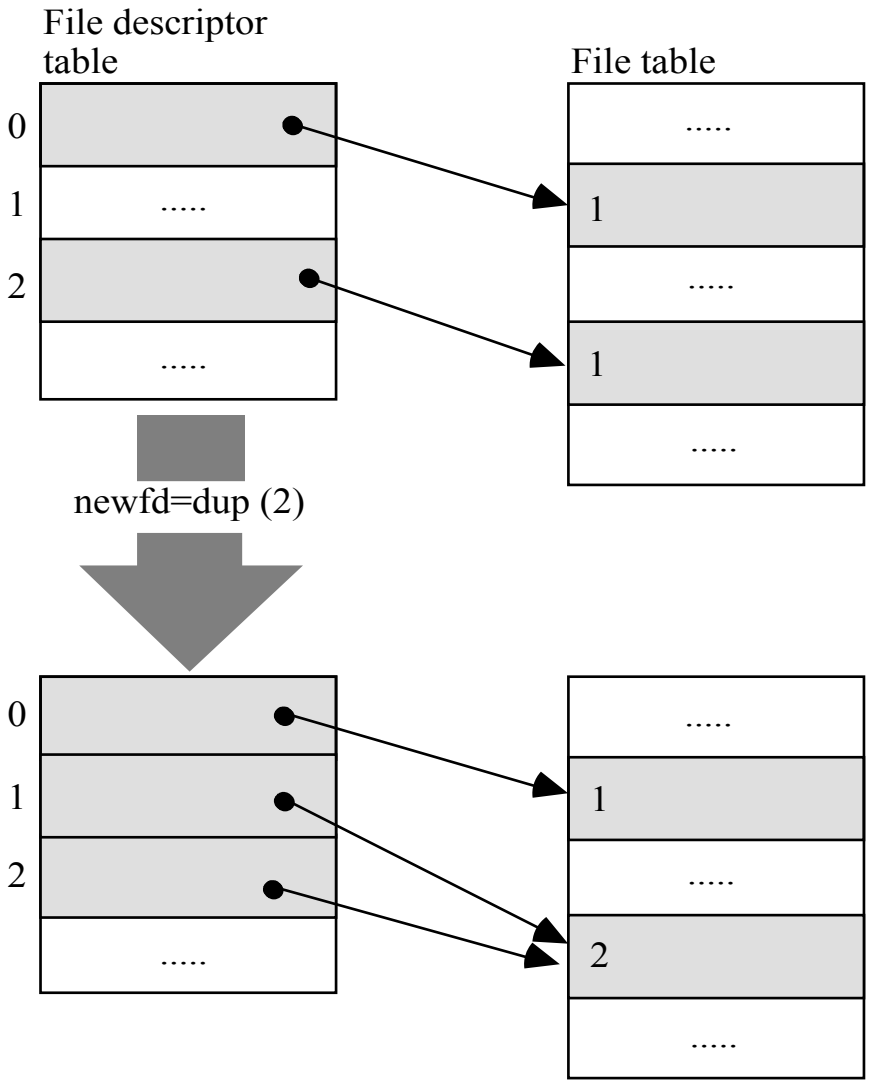

Copia del file descriptor

- Funzione **`dup`**
  - Seleziona il più basso file descriptor libero della tabella dei file descriptor
  - Assegna la nuova file descriptor entry al file descriptor selezionato
  - Ritorna il file descriptor selezionato
- Funzione **`dup2`**
  - Con **`dup2`**, specifichiamo il valore del nuovo descrittore come argomento **`filedes2`**
  - Se **`filedes2`** è già aperto, viene chiuso e sostituito con il descrittore duplicato
  - Ritorna il file descriptor selezionato

Modifica del file descriptor

- La funzione **`fcntl`** permette di esercitare un certo grado di controllo su file già aperti.
  Ha tre forme di chiamata:

```
int fcntl(int fd, int cmd);
int fcntl(int fd, int cmd, long arg);
int fcntl(int fd, int cmd, struct flock *lock);
```

- **`fd`:** è il descrittore del file su cui operare
- **`cmd`:** è il comando da eseguire
- Il terzo argomento, quando presente, è il parametro del comando:
  - **`arg`**: un valore intero (caso generale)
  - **`lock`**: un puntatore (caso di record locking)

- **Comandi:**
  - duplicazione di file descriptor (**`F_DUPFD`**)
  - get/set file descriptor flag (**`F_GETFD, F_SETFD`**)
  - get/set file status flag (**`F_GETFL, F_SETFL`**)
  - get/set async. I/O ownership (**`F_GETOWN, F_SETOWN`**)
  - get/set record locks (**`F_GETLK, F_SETLK, F_SETLKW`**)

Funzione `fcntl` (I)

```
int fcntl(int fd, F_DUPFD, long arg);
```

- Duplica il file descriptor specificato da **`filedes`**
- Ritorna il nuovo file descriptor
- Il file descriptor scelto è uguale al valore più basso corrispondente ad un file descriptor non aperto e che sia maggiore o uguale a **`arg`**

Funzione `fcntl` (II)

```
int fcntl(int fd, F_GETFD);
```

- Ritorna i file descriptor flag associati a **`fd`**
- Attualmente è definito un solo file descriptor flag, **`FD_CLOEXEC`**:
  - se **`FD_CLOEXEC`** è true, il file descriptor viene chiuso eseguendo una **`exec`**

```
int fcntl(int fd, F_SETFD, long arg);
```

- Modifica i file descriptor flag associati a **`fd`**, utilizzando il terzo argomento come nuovo insieme di flag
- Attualmente imposta il flag *close-on-exec* al valore specificato dal bit **`FD_CLOEXEC`** di **`arg`**.

Funzione `fcntl` (III)

```
int fcntl(int fd, F_GETFL);
```

- Ritorna i file status flag associati a **`fd`**
- I file status flag sono quelli utilizzati nella funzione **`open`**

- Esiste la maschera **`O_ACCMODE`** (uguale a 3) che permette di isolare la modalità di accesso, cioè:

  ```
  oflag = fcntl(int fd, F_GETFL) & O_ACCMODE;
  ```

  può essere uguale a uno dei valori:

  `O_RDONLY`, **`O_WRONLY`**, **`O_RDWR`**

- Per determinare gli altri flag, è possibile utilizzare le costanti definite (**`O_APPEND`**, **`O_NONBLOCK`**, **`O_SYNC`**)

Funzione `fcntl` (IV)

```
int fcntl(int fd, F_SETFL, long arg);
```

- Modifica i file status flag associati a **`fd`** con il valore specificato in **`arg`**
- I soli valori che possono essere modificati sono **`O_APPEND`**, **`O_NONBLOCK`**, **`O_ASYNC`** e **`O_DIRECT`**;
  l'access mode deve rimanere inalterato

Esempio 1 d'uso di `fcntl` (I)

```
#include <fcntl.h>

int filestatus(int filedes)
{
    int arg1;
    if((arg1 = fcntl(filedes, F_GETFL)) == -1)
    {
        printf("filestatus failed\n");
        return -1;
    }
    printf("File descriptor %d", filedes);
    switch(arg1 & O_ACCMODE)
    {
        case O_WRONLY:
           printf("write only");
           break;
        /* continua ... */
```

Esempio 1 d'uso di `fcntl` (II)

```
        case O_RDWR:
           print("read write");
           break;
        case O_RDONLY:
           print("read only");
           break;
        default:
           print("No such mode");
           break;
    }
    if(arg1 & O_APPEND) printf(" - append flag set");

    printf("\n");
    return 0;
}
```

- dove **`O_ACCMODE`** è una maschera appositamente definita in **`<fcntl.h>`**.

Esempio 2 d'uso di `fcntl`

- La funzione **`set_fl`** mette a 1 i flag specificati nel parametro **`flags`**
- Per comportarsi correttamente, richiede prima i flag correnti, poi utilizza la maschera con OR, ed infine salva i nuovi flag:

```
void set_fl(int fd, int flags)
   /* flags defines which file status flags to turn on */
{
   int val;
   if ( (val = fcntl(fd, F_GETFL, 0)) < 0)
       err_sys("fcntl F_GETFL error");
   val |= flags;           /* turn on flags */
   if (fcntl(fd, F_SETFL, val) < 0)
       err_sys("fcntl F_SETFL error");
}
```

Il record locking mediante `fcntl` (I)

- Il record locking è un metodo per disciplinare la cooperazione tra processi nell'accesso e modifica dei dati.
- Permette ad un processo di poter accedere ad un file in modo esclusivo.
- E' utile quindi per la gestione di database condivisi.
- Tuttavia l'operazione di lock non è automatica, ma deve essere eseguita esplicitamente dal processo.

Il record locking mediante `fcntl` (II)

- La system call **`fcntl`** offre due tipi di locking:

- 1. Read locking:
  Serve per evitare che i dati vengano modificati da un processo, compreso il processo stesso che ha effettuato il read locking. Tuttavia tutti i processi possono accedere ai dati in lettura. In particolare, il read locking non consente a nessun processo di effettuare un write locking. Più processi possono effettuare un read locking contemporaneamente.

- 2. Write locking:
  Il processo che lo ha effettuato può modificare la parte di file su cui ha effettuato il write locking. Ma nessun altro processo può effettuare un read/write locking su quella parte di file.

Il record locking mediante `fcntl` (III)

```
int fcntl(int fd, int cmd, struct flock *lock);
```

- **`fd`** è un descrittore di file aperto con il parametro:
  - **`O_RDONLY`** oppure **`O_RDWR`** nel caso di un read locking
  - **`O_WRONLY`** oppure **`O_RDWR`** nel caso di un write locking.
- **`cmd`** specifica l'azione da effettuare tramite valori definiti in **`<fcntl.h>`**:
  - **`F_GETLK`** Fornisce la descrizione dei lock in base al contenuto della struttura puntata da **`lock`**. L'informazione restituita descrive il primo lock che blocca il lock descritto in **`lock`**.
  - **`F_SETLK`** Effettua un locking su un file; termina subito se non è possibile. Serve anche per rimuovere un lock.
  - **`F_SETLKW`** Effettua un locking su un file, va in sleep se il lock è bloccato da un lock precedentemente effettuato da un altro processo.

Il record locking mediante `fcntl` (IV)

- La struttura **`ldata`** contiene la descrizione del lock. In particolare, comprende i seguenti campi:

```
short l_type;   /* descrive il tipo di lock */
short l_whence; /* offset */
off_t l_start;  /* offset in byte */
off_t l_len;    /* dimensione del segmento in byte */
pid_t l_pid;    /* definito dal comando F_GETLK */
```

- I campi **`l_whence, l_start, l_len`** specificano il segmento su cui effettuare, controllare o togliere il locking.
- **`l_whence`** determina da dove calcolare l'offset e può essere **`SEEK_SET`** (dall'inizio del file), **`SEEK_CUR`** (dalla posizione corrente), **`SEEK_END`** (dalla fine del file).
- **`l_start`** indica la posizione di partenza del segmento relativamente a **`l_whence`**.
- **`l_len`** è la lunghezza del segmento in byte.
- **`l_type`** fornisce il tipo di lock:
  `F_RDLCK` read locking; **`F_WRLCK`** write locking; **`F_UNLCK`** unlocking
- Il campo **`l_pid`** è rilevante solo solo se il parametro **`cmd`** vale **`F_GETLK`**. Se esiste un lock che blocca il lock descritto dagli altri membri della struttura, a **`l_pid`** viene assegnato l'identificatore del processo che ha effettuato il locking.

Esempio di uso di `fcntl` (I)

Sistema di prenotazione di voli aerei

- La compagnia *ACME Airlines* usa un sistema di prenotazione dei voli basato su Linux. Possiede due uffici per la prenotazione, A e B, ciascuno con un terminale connesso al computer della compagnia.
- Da ciascuno dei terminali si può accedere al database delle prenotazioni, implementato come file Linux, attraverso il programma **`acmebook`**.
- Questo programma permette di leggere e aggiornare il database. In particolare, è possibile decrementare di uno il numero di posti liberi su un determinato volo.

Esempio di uso di `fcntl` (II)

Una situazione critica:

- Supponiamo che sul volo *ACM501* per Londra sia rimasto libero esattamente un posto. Il Sig. Jones e il Sig. Smith entrano rispettivamente nell'ufficio A e B chiedendo un biglietto per quel volo.
- Consideriamo la seguente sequenza di eventi:
- 1. Dall'ufficio A viene lanciato il programma **`acmebook`**. Sia *PA* il processo risultante.
- 2. Dall'ufficio B viene lanciato il programma **`acmebook`**. Sia *PB* il processo risultante.
- 3. *PA* accede al database con una **`read`** e scopre che c'è un posto libero.
- 4. *PB* fa una **`read`** sul database e scopre che c'è un posto libero.
- 5. *PA* azzera il contatore di posti liberi con una **`write`** e consegna il biglietto al Sig. Jones.
- 6. *PB*, non sapendo che l'unico posto rimasto è stato già assegnato, azzera il contatore di posti liberi con una **`write`** e consegna il biglietto al Sig. Smith.

Esempio di uso di `fcntl` (III)

Effetto risultante:

- Come conseguenza è stato assegnato un posto in più rispetto a quelli disponibili.
- Il problema nasce perché più processi possono accedere contemporaneamente ad uno stesso file. Inoltre una singola operazione logica (la prenotazione), costituita da diverse chiamate alle system call **`lseek`**, **`read, write`**, può essere effettuata da più processi concorrenti.
- Una soluzione consiste nel consentire ad un processo di fare il locking della parte di file sulla quale sta lavorando durante la prenotazione. L'utilizzo della system call **`fcntl`** consente di effettuare il locking di (parte di) un file.

Esercizio su system call `fcntl`

1) Scrivere un programma che simuli il sistema di prenotazione di voli *ACME*. Il programma acquisisce da standard input il numero di posti da riservare e procede ad effettuare la prenotazione mediante la funzione **`acmebook,`** che utilizza il meccanismo del locking. Il programma deve essere lanciato due volte (in due *terminal window* diverse), creando quindi due processi *PA* e *PB*, per simulare le richieste provenienti dagli uffici A e B. I processi *PA* e *PB* chiamano ripetutamente la funzione **`acmebook,`** tante volte quanti sono i posti richiesti da standard input. Se ci sono ancora posti liberi, il programma aspetta da standard input un'altro intero, altrimenti termina.

2) Siano *P1* e *P2* due processi che lavorano sullo stesso file. Supponiamo che *P1* esegua un lock sulla sezione *SX* del file e *P2* esegua un lock sulla sezione *SY* dello stesso file. Che cosa succede se poi *P1* tenta di fare un lock su *SY* con **F_SETLKW** e *P2* tenta di fare un lock su *SX* con **F_SETLKW**?

Funzione `ioctl`

```
int ioctl(int fd, int request, …);
```

- La funzione **`ioctl`** raccoglie tutti i comportamenti che non possono essere racchiusi nell'interfaccia standard basata su file
- In generale è usata per manipolare i parametri dei device
- **Categorie di operazioni**
  - disk labels I/O
  - file I/O
  - magnetic tapes I/O
  - socket I/O
  - terminal I/O

Esempio d'uso di `ioctl`

```
int main(int argc, char **argv)
{
  int fd=STDIN_FILENO;
  struct winsize size;

  printf("Calling ioctl with TIOCGWINSZ ...\n");
  if (ioctl(fd,TIOCGWINSZ,(char *)&size) < 0) {
    perror("ERROR");
  }

  printf("%d rows, %d columns\n",size.ws_row,size.ws_col);

  exit(EXIT_SUCCESS);
}
```

Funzione `fsync`

```
int fsync(int fd);
```

- La system call **`fsync`** effettua l'operazione di "flush" dei dati bufferizzati dal kernel per il file descriptor **`fd`**, ovvero li scrive sul disco o sul dispositivo sottostante
- Tale funzione esiste in quanto il gestore del file system può mantenere i dati nel buffer di memoria per diversi secondi (per ragioni efficienza), prima di scriverli su disco
- Ritorna 0 in caso di successo, -1 in caso di errore

Funzione `select`

```
int select(int n, fd_set *readfds, fd_set *writefds,
           fd_set *exceptfds, struct timeval *timeout);
```

- La system call **`select`** permette ad un processo di aspettare contemporaneamente su file descriptor multipli, con un timeout opzionale
- **Parametri di input**
  - **`readfds`** e **`writefds`** sono insiemi di file descriptor, realizzati tramite mappe di bit
  - **`n`** è la dimensione massima di questi insiemi
  - **`timeout`** è il timeout opzionale
- **Parametri di output**
  - ritorna il numero di file descriptor che sono pronti per operazioni di I/O immediate
  - modifica gli insiemi di wait descriptor, ponendo a 1 i bit relativi ai file descriptor pronti per l'I/O

Ulteriori system call per file e directory

- Oltre alle system call per leggere e scrivere file regolari (**`open, read, write, lseek, close`**), esistono system call per effettuare le seguenti operazioni:
  - leggere gli attributi di un file (**`stat`**)
  - modificare gli attributi di un file (**`chmod, chown, chgrp,`** …)
  - creare/eliminare hard link (**`link, unlink, remove`**)
  - creare e leggere le directory (**`mkdir, opendir, readdir, closedir`**)

System call `stat`

```
int stat(const char *file_name, struct stat *buf);
int fstat(int filedes, struct stat* buf);
int lstat(const char *file_name, struct stat *buf);
```

- Le tre funzioni ritornano un struttura **`stat`** contenente informazioni sul file
  - **`stat`** identifica il file tramite un filename
  - **`fstat`** identifica un file aperto tramite il suo descrittore
  - **`lstat`**, se applicato ad un link simbolico, ritorna informazioni sul link simbolico, non sul file linkato

Struttura stat

- `stat` è un puntatore ad una struttura di informazioni sul file specificato

```
struct stat {
    dev_t     st_dev;     // device
    ino_t     st_ino;     // inode
    mode_t    st_mode;    // protection
    nlink_t   st_nlink;   // number of hard links
    uit_t     st_uid;     // user ID of owner
    gid_t     st_gid;     // group ID of owner
    dev_t     st_rdev;    // device type (if node device)
    off_t     st_size;    // total size, in bytes
    blksize_t st_blksize;// best I/O block size
    blkcnt_t  st_blocks; // number of blocks allocated
    time_t    st_atime;  // time of last access
    time_t    st_mtime;  // time of last modification
    time_t    st_ctime;  // time of last status change
}
```

Il campo `st_mode`

- Nel campo **`st_mode`** c'è la codifica sul tipo di file
- Esistono delle macro per agevolare la determinazione del tipo di file a partire dal valore di **`st_mode`**:
  - è un file regolare? **`S_ISREG(m)`**
  - è una directory? **`S_ISDIR(m)`**
  - è un device a caratteri? **`S_ISCHR(m)`**
  - è un device a blocchi? **`S_ISBLK(m)`**
  - è una FIFO? **`S_ISFIFO(m)`**
  - è un link simbolico? **`S_ISLNK(m)`**
  - è un socket? **`S_ISSOCK(m)`**

Il campo `st_mode`

- ***set-user-ID* e *set-group-ID*:**
  - in **`st_mode`**, esiste un bit (*set-user-ID*) che fa in modo che quando questo file viene eseguito, l'*effective user id* prende il valore del campo **`st_uid`**
  - in **`st_mode`**, esiste un bit (*set-group-ID*) che fa in modo che quando questo file viene eseguito, l'*effective group id* prende il valore del campo **`st_gid`**
- **Questi due bit sono utilizzati per risolvere il problema di passwd:**
  - l'owner del comando **`passwd`** è **`root`**
  - quando **`passwd`** viene eseguito, il suo *effective user id* è uguale a **`root`**
  - il comando può modificare in scrittura il file **`/etc/passwd`**

Il campo `st_mode`

- **Costanti per accedere ai diritti di lettura e scrittura contenuti in `st_mode`**
  - **`S_ISUID`** set-user-ID
  - **`S_ISGID`** set-group-ID
  - **`S_IRUSR`** accesso in lettura, owner
  - **`S_IWUSR`** accesso in scrittura, owner
  - **`S_IXUSR`** accesso in esecuzione, owner
  - **`S_IRGRP`** accesso in lettura, gruppo
  - **`S_IWGRP`** accesso in scrittura, gruppo
  - **`S_IXGRP`** accesso in esecuzione, gruppo
  - **`S_IROTH`** accesso in lettura, altri
  - **`S_IWOTH`** accesso in scrittura, altri
  - **`S_IXOTH`** accesso in esecuzione, altri

I campi `st_size` e `st_block`

- Il campo **`st_size`** di **`stat`** contiene la dimensione effettiva del file
- Il campo **`st_block`** di **`stat`** contiene il numero di blocchi utilizzati per scrivere il file
  - dimensione “standard” di 512 byte
  - alcune implementazioni usano valori diversi (non portabile)
- il campo **`st_blksize`** di **`stat`** contiene la dimensione preferita per i buffer di lettura/scrittura

Dimensioni dei file

- **“Buchi” nei file**
  - la dimensione di un file e il numero di blocchi occupati possono non coincidere
  - questo avviene quando in un file c’è un “buco” creato da **`lseek`**
- **Esempio:**

```
$ ls -l core

-rw-r—r- 1 root 8483248 Dec 1 12:20 core

$ du -s core

272 core
```

System call `truncate`

```
int truncate(char* pathname, off_t len);
int ftruncate(int filedes, off_t len);
```

- Queste due funzioni cambiano la lunghezza di un file, portandola alla dimensione specificata:
  - se la nuova dimensione è più corta, tronca il file alla dimensione specificata
  - se la nuova dimensione è più lunga, allunga il file alla dimensione specificata
- Non sono standard POSIX

I campi `st_atime`, `st_mtime` e `st_ctime`

- **Tre valori temporali sono mantenuti nella struttura `stat`**
  - **`st_atime`** (opzione **`-u`** in **`ls`**)
    - Ultimo tempo di accesso
    - Viene aggiornato a seguito di una **`read`**, **`creat/open`** (in caso di creazione di nuovo file), **`utime`** (trattata in seguito)
  - **`st_mtime`** (default in **`ls`**)
    - Ultimo tempo di modifica del contenuto
    - Viene aggiornato a seguito di una **`write`**, **`creat/open`**, **`truncate`**, **`utime`**
  - **`st_ctime`** (opzione **`-c`** in **`ls`**)
    - Ultimo cambiamento nello stato (nell'inode)
    - Viene aggiornato a seguito di una **`chmod`**, **`chown`**, **`creat`**, **`mkdir`**, **`open`**, **`remove`**, **`rename`**, **`truncate`**, **`link`**, **`unlink`**, **`utime`**, **`write`**
  - Attenzione ai cambiamenti su contenuto, inode e accesso per quanto riguarda le directory

System call `utime`

```
int utime(char* pathname, struct utimbuf *times);
struct utimbuf {
    time_t actime;
    time_t modtime;
}
```

- Questa system call modifica il tempo di accesso e di modifica di un file; il tempo di changed-status viene modificato automaticamente al nuovo valore

System call `access`

```
int access(const char* pathname, int mode)
```

- Quando si accede ad un file, vengono utilizzati *effective uid* e *effective gid* per la verifica dei permessi di accesso
- In alcuni casi può essere necessario verificare l'accessibilità in base a *real uid* e *real gid*
- Per fare questo, si utilizza la system call **`access`**
- **`mode`** è un maschera ottenuta tramite bitwise OR delle seguenti costanti:
  - **`R_OK`** test per read permission
  - **`W_OK`** test per write permission
  - **`X_OK`** test per execute permission
  - **`F_OK`** test per esistenza file

System call `umask`

```
mode_t umask(mode_t cmask);
```

- Cambia la maschera di bit utilizzata per la creazione dei file; ritorna la maschera precedente; nessun caso di errore
- Per formare la maschera, si possono utilizzare le costanti **`S_IRUSR`**, **`S_IWUSR`**, ..., viste in precedenza
- Funzionamento:
  - La maschera viene utilizzata tutte le volte che un processo crea un nuovo file
  - Tutti i bit che sono accesi nella maschera, verranno spenti nell'access mode del file creato

System call chmod

```
int chmod (const char* path, mode_t mode);
int fchmod (int fildes, mode_t mode);
```

- Cambia i diritti di un file specificato dal **path** (**chmod**) o di un file già aperto (**fchmod**)
- Per cambiare i diritti di un file, l'effective uid del processo deve essere uguale all'owner del file oppure deve essere uguale a root

Ownership di un nuovo file

- Quando un file viene creato, l'access mode del file viene scelto in base al parametro **`mode`** delle system call **`open`** e **`creat`**
- L'owner del file viene posto uguale allo effective uid del processo
- POSIX permette due possibilità per il group id:
  - può essere uguale allo effective gid del processo
  - può essere uguale al group id della directory in cui il file viene creato
- In alcuni sistemi, questo può dipendere dal bit set-group-id della directory in cui viene creato il file

System call chown

```
int chown(const char* pathname, uid_t owner, gid_t group);
int fchown(int fd, uid_t owner, gid_t group);
int lchown(const char* path, uid_t owner, gid_t group);
```

- **Queste tre funzioni cambiano lo user id e il group id di un file**
  - Nella prima, il file è specificato come **`pathname`**
  - Nella seconda, il file aperto è specificato dal file descriptor **`fd`**
  - Nella terza, si cambia il possessore del link simbolico, non del file stesso
- **Restrizioni:**
  - In alcuni sistemi, solo il superutente può cambiare l'owner di un file (per evitare problemi di quota)
  - Costante POSIX_CHOWN_RESTRICTED definisce se tale restrizione è in vigore

Concetto di *hard link*

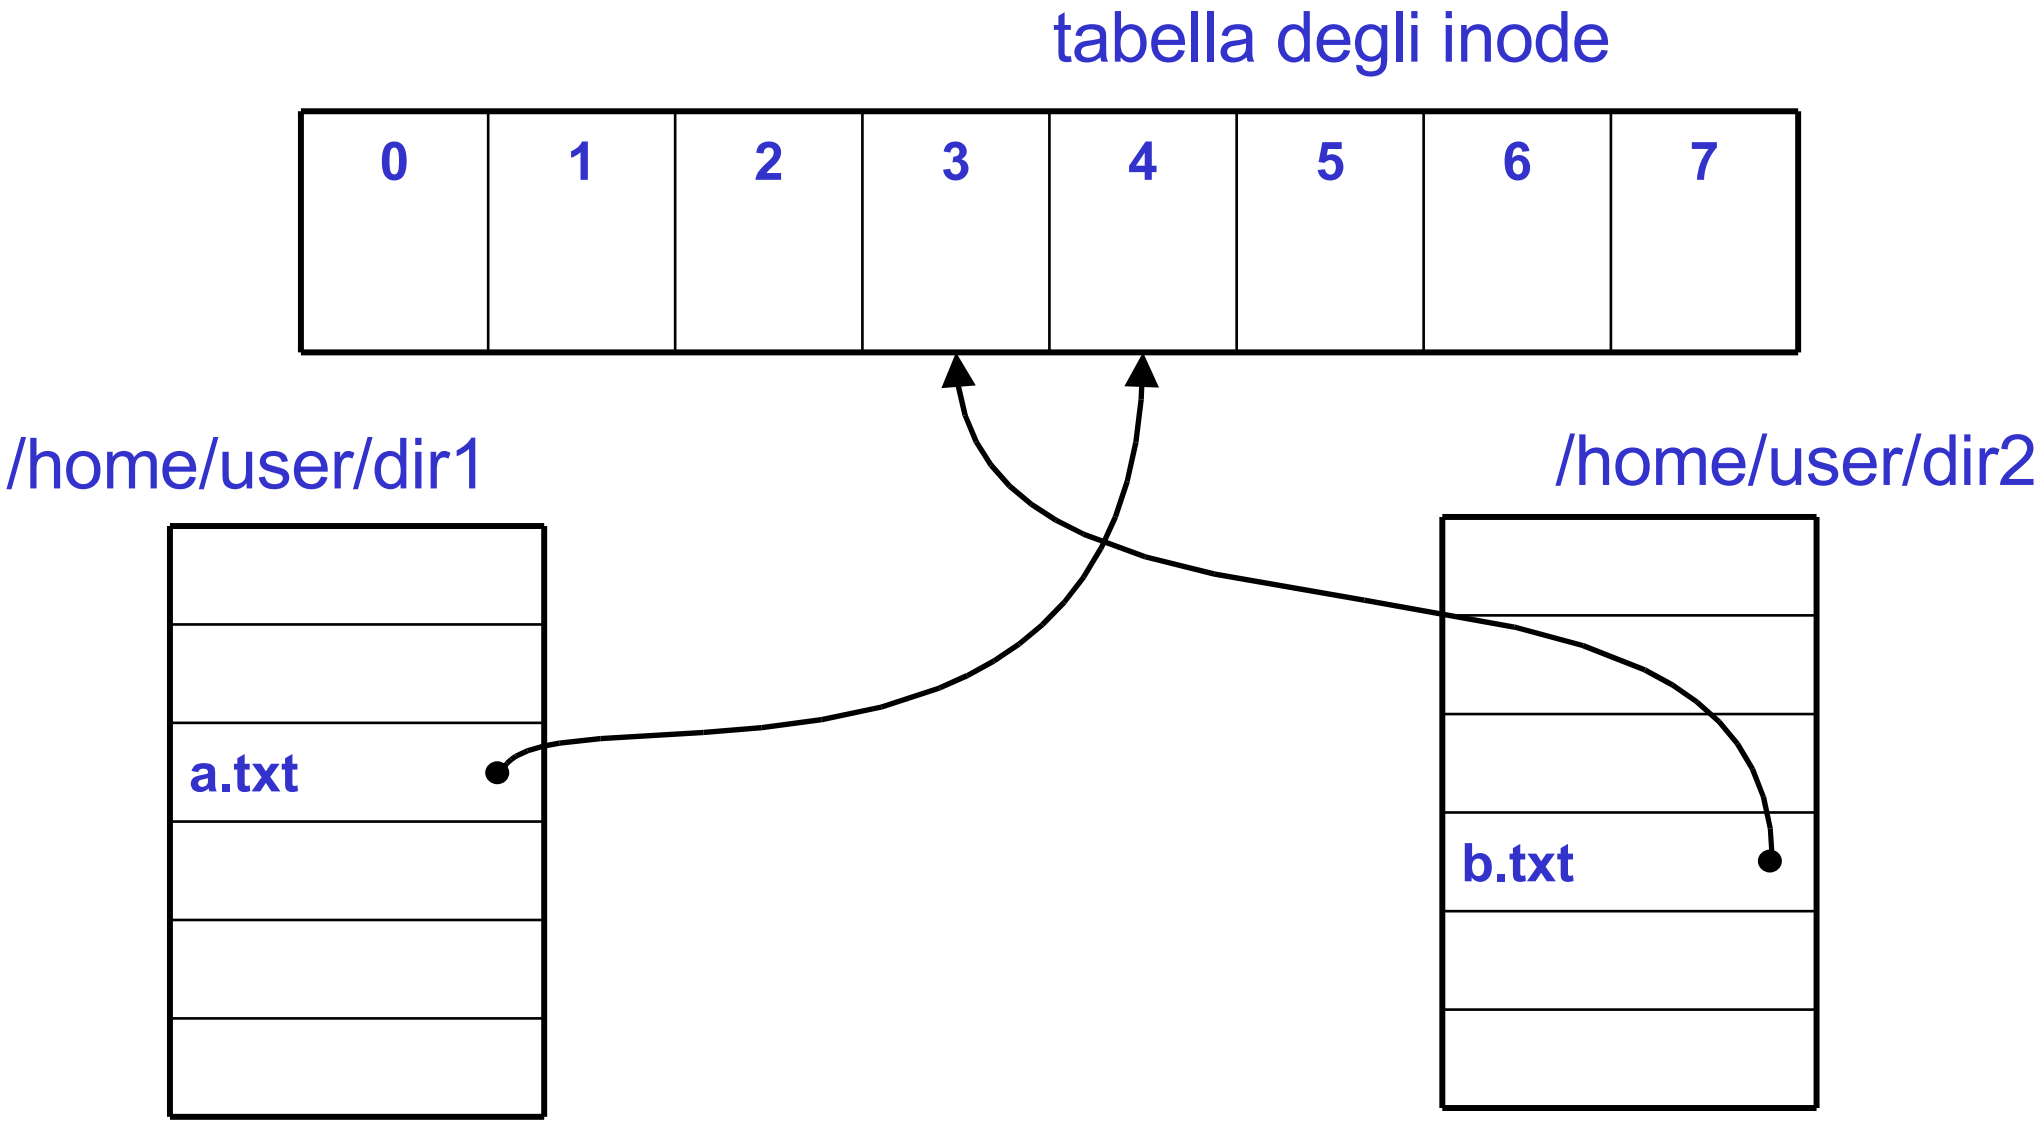

Concetto di *hard link*

- Nella figura precedente, sono mostrate due directory entry che puntano allo stesso i-node (due *hard link*)
- Ogni i-node mantiene un contatore con il numero di directory entry che puntano ad esso (numero di link)
- Operazioni:
  - Linking: aggiungere un link ad un file
  - Unlinking: rimuovere un link da un file
- Solo quando il numero di link scende a zero è possibile rimuovere il file (delete)
- Nella struttura **`stat`**: il campo **`st_nlink`** contiene il numero di link di un file

Concetto di *hard link*

- **Suddivisione delle informazioni:**
  - gli inode mantengono tutte le informazioni sul file: dimensioni, permessi, puntatori ai blocchi dati, etc.
  - le directory entry mantengono un file name e un inode number
- **Limitazioni degli hard-link:**
  - la directory entry contiene un numero di inode sullo stesso file system
  - non è possibile fare hard-linking con file su filesystem diversi
  - in questo caso, si utilizzano *symbolic link*

Hard link per directory

- Ogni directory **`dir`** ha un numero di hard link maggiore uguale a 2:
  - Un hard link esiste perché **`dir`** possiede un link nella sua directory genitore
  - Un'altro hard link esiste perché **`dir`** possiede un'entry "." che punta a se stessa
- Ogni sottodirectory di **`dir`** aggiunge un hard link:
  - Infatti la sottodirectory possiede un'entry ".." che punta alla directory genitore **`dir`**

System call `link`

```
int link(char* oldpath, char* newpath);
```

- Crea un nuovo link ad un file esistente
- E' un'operazione atomica: aggiunge la directory entry e aumenta il numero di link per l'inode identificato da **`oldpath`**
- Cause di errore:
  - **`oldpath`** non esiste
  - **`newpath`** esiste già
  - solo root può creare un hard link ad una directory
    (per evitare di creare loop, che possono causare problemi)
  - **`oldpath`** e **`newpath`** appartengono a file system diversi
- E' utilizzata dal comando **`ln`**

System call `unlink` e `remove`

```
int unlink(char* path);
int remove(char* path);
```

- Rimuove un hard link per il file specificato da **`path`**
- E' un'operazione atomica: rimuove la directory entry e decrementa di uno il numero di link del file
- Cause di errore:
  - Il file **`path`** non esiste
  - un utente diverso da root cerca di fare **`unlink`** su una directory
- E' utilizzata dal comando **`rm`**
- Un file può essere effettivamente cancellato dall'hard disk solo quando il numero di hard link raggiunge 0

System call `unlink` e `remove`

- **Cosa succede quando un file è aperto?**
  - Il file viene rimosso dalla directory
  - Il file non viene rimosso dal file system fino alla sua chiusura
  - Quando il file viene chiuso, il sistema controlla se il numero di hard link è sceso a zero; in tal caso rimuove il file

System call `unlink` e `remove`

- **Come utilizzare questa proprietà:**
  - per assicurarsi che i file temporanei non vengano lasciati in giro in caso di crash del processo
  - sequenza di operazioni:
    - viene creato un file temporaneo
    - viene aperto dal processo
    - si effettua una operazione di unlink
  - Il file non viene cancellato fino al termine/crash del programma, che causa la chiusura di tutti i file temporanei

System call `rename`

```
int rename(char* oldpath, char* newpath);
```

- Cambia il nome di un file da **`oldpath`** a **`newpath`**
- Casi:
  - se **`oldpath`** specifica un file regolare, **`newpath`** non può essere una directory esistente
  - se **`oldpath`** specifica un file regolare e **`newpath`** è un file regolare esistente, questo viene rimosso e sostituito
  - sono necessarie write permission su entrambe le directory
  - se **`oldpath`** specifica una directory, **`newpath`** non può essere un file regolare esistente
  - se **`oldpath`** specifica una directory, **`newpath`** non può essere una directory non vuota

Link simbolici

- Un link simbolico è un file speciale che contiene il pathname assoluto di un altro file
- E' un puntatore indiretto ad un file (a differenza degli hard link che sono puntatori diretti agli inode)
- Introdotto per superare le limitazioni degli hard link:
  - hard link possibili solo fra file nello stesso filesystem
  - hard link a directory possibili solo al superuser
- **Nota:** questo comporta la possibilità di creare loop
  - i programmi che analizzano il file system devono essere in grado di gestire questi loop

Link simbolici

- Quando si utilizza una funzione, bisogna avere chiaro se:
  - segue i link simbolici (la funzione si applica al file puntato dal link simbolico)
  - non segue i link simbolici (la funzione si applica sul link)
- Funzioni che non seguono i link simbolici:
  - lchown, lstat, readlink, remove, rename, unlink
- Esempio (tramite shell):

```
$ ln -s /no/such/file myfile
$ ls myfile
myfile
$ ls -l myfile
lrwx------ penguin  myfile -> /no/such/file
$ cat myfile
cat: myfile: No such file or directory
```

System call `symlink` e `readlink`

```
int symlink(char* oldpath, char* newpath);
```

- crea una nuova directory entry **`newpath`** con un link simbolico che punta al file specificato da **`oldpath`**
- **Nota**: **`ldpath`** e **`newpath`** non devono risiedere necessariamente nello stesso file system

```
int readlink(char* path, char* buf, int size);
```

- poiché la open segue il link simbolico, abbiamo bisogno di una system call per ottenere il contenuto del link simbolico
- questa system call copia in **`buf`** il valore del link simbolico

System call `mkdir` e `rmdir`

```
int mkdir(char* path, mode_t);
```

- Crea una nuova directory vuota dal path specificato
- Modalità di accesso:
  - I permessi specificati da mode_t vengono modificati dalla maschera specificata da umask
  - E' necessario specificare i diritti di esecuzione (search)

```
int rmdir(char* path);
```

- Rimuove la directory vuota specificata da path
- Se il link count della directory scende a zero, la directory viene effettivamente rimossa; altrimenti si rimuove la directory

System call `chdir` e `getcwd`

- Ogni processo ha una directory corrente a partire dalla quale vengono fatte le ricerche per i pathname relativi

```
int chdir(char* path);

int fchdir(int filedes);
```

- Cambia la directory corrente associata al processo, utilizzando un pathname oppure un file descriptor

```
char* getcwd(char* buf, size_t size);
```

- Legge la directory corrente e riporta il pathname assoluto nel buffer specificato da **`buf`** e di dimensione **`size`**

Leggere e scrivere directory

- Le directory possono essere lette da chiunque abbia accesso in lettura
- Solo il kernel può scrivere in una directory per evitare problemi di consistenza
- I diritti di scrittura specificano la possibilità di utilizzare uno dei seguenti comandi: **`open`**, **`creat`**, **`unlink`**, **`remove`**, **`symlink`**, **`mkdir`**, **`rmdir`**
- Esistono delle funzioni speciali per leggere il contenuto di una directory

Operazioni su directory

```
DIR *opendir(const char *pathname);
```

- Apre una directory; ritorna un puntatore se tutto è ok, **NULL** in caso di errore

```
struct dirent *readdir(DIR *dir); // POSIX std function
```

- Ritorna un puntatore ad una struttura dati contenente informazioni sulla prossima entry, **NULL** se fine della directory o errore

```
void rewinddir(DIR *dp);
```

- Ritorna all'inizio della directory

```
void closedir(DIR *dp);
```

- Chiude la directory

File e Directory: info su directory

- La struttura **`dirent`** ritornata da **`readdir`** è definita in **`dirent.h`**:

```
struct dirent {
  ino_t d_ino;                  // i-node number
  char  d_name[NAME_MAX+1];// null-terminated name
}
```

- **Note:**
  - la struttura **`DIR`** è una struttura interna utilizzata da queste quattro funzioni come "directory descriptor"
  - le entry di una directory vengono lette in un ordine non determinato a priori