Programmazione in rete: i socket

Antonio Lioy
< lioy@polito.it >

Politecnico di Torino
Dip. Automatica e Informatica

Avviso ai programmatori

- **la programmazione di rete è pericolosamente vicina al kernel del S.O. e quindi:**
  - può facilmente bloccare il S.O.
    - sforzarsi di controllare l'esito di tutte le operazioni, senza dare niente per scontato
  - le API possono variare in dettagli minimi ma importanti
    - sforzarsi di prevedere tutti i casi per creare programmi "portabili"
    - cercheremo di usare Posix 1.g

Esercizio - copia dati

- **copiare il contenuto del file F1 (primo parametro sulla riga di comando) nel file F2 (secondo parametro sulla linea di comando)**

`copyfile.c`

Messaggi di errore

- **devono contenere almeno:**
  - [PROG] nome del programma
  - [LEVEL] livello di errore (info, warning, error, bug)
  - [TEXT] segnalazione di errore nel modo più specifico possibile (es. nome di file e riga di input su cui si è verificato il problema)
  - [ERRNO] numero e/o nome dell'errore di sistema (se applicabile)
- **forma suggerita:**

```
( PROG ) LEVEL - TEXT : ERRNO
```

Funzioni di errore

- **conviene definire funzioni di errore standard che accettino:**
  - una stringa di formato per l'errore
  - una lista di parametri da stampare
- **UNP, appendice D.4**

	errno?	terminazione?	log level
err_msg	no	no	LOG_INFO
err_quit	no	exit(1)	LOG_ERR
err_ret	si	no	LOG_INFO
err_sys	si	exit(1)	LOG_ERR
err_dump	si	abort( )	LOG_ERR

`errlib.h`
`errlib.c`

stdarg.h

- **elenco variabile di argomenti (ANSI C)**
- **dichiarato con ellissi (. . .) come ultimo argomento di una funzione**
- **argomenti usabili tutti insieme (ap) in apposite funzioni (vprintf, vfprintf, vsprintf, vasprintf, vsnprintf) oppure uno alla volta (va_arg), ma in questo caso bisogna sapere in altro modo quanti sono**

```
#include <stdarg.h>

void va_start (va_list ap, RIGHTMOST);
TYPE va_arg (va_list ap, TYPE);
void va_end (va_list ap);
```

Esempio uso stdarg.h

- **creo una funzione my_printf**
- **… che si comporti come la printf (e quindi accetti un numero variabile di parametri)**
- **… ma premetta ad ogni stampa "(MY_PRINTF) "**

`va_test.c`

Da 32 a 64 bit: problemi

- **il passaggio dalle architetture a 32 bit a quelle a 64 bit ha modificato la dimensione dei dati**
- **in particolare non si può più assumere che | int | = | puntatore |**
- **attenzione quindi ad usare correttamente i tipi definiti per superare questi problemi (es. `size_t`)**

	ILP32	LP64
`char`	8	8
`short`	16	16
`int`	32	32
`long`	32	64
puntatore	32	64

`datasize.c`

Scambio dati tra nodi eterogenei

- **problema:**
  - quando si scambiano dati complessi (ossia non singoli caratteri ASCII) non si può essere certi che siano codificati allo stesso modo sui diversi nodi
  - codifica dei dati dipende da HW + S.O.
- **soluzione:**
  - usare un formato neutro (di rete)
  - a volte la conversione è fatta automaticamente dalle funzioni …
  - … ma spesso è compito esplicito del programmatore

Sorgenti di incompatibilità dei dati

- **formati floating-point diversi (IEEE-754 / non-IEEE)**
- **allineamento dei campi di una struct sui confini delle word**
- **ordine dei byte negli interi (little-endian o big-endian)**

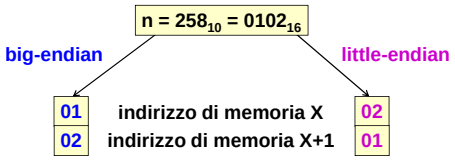

`byteorder.c`

Funzioni "host to network"

- **per il passaggio dei parametri alle funzioni di rete**
- **non pensate per il passaggio dei dati applicativi**

```
#include <sys/types.h>
#include <netinet/in.h>

uint32_t htonl (uint32_t hostlong);
uint16_t htons (uint16_t hostshort);
uint32_t ntohl (uint32_t netlong);
uint16_t ntohs (uint16_t netshort);
```

Note sui tipi interi

- **talvolta si trovano ancora i vecchi tipi:**
  - u_long (= uint32_t)
  - u_short (= uint16_t)
- **in vecchie versioni di cygwin erano definiti:**
  - u_int32_t (= uint32_t)
  - u_int16_t (= uint16_t)
- **consiglio:**
  - scrivere i programmi coi tipi uint32_t e uint16_t
  - se necessario, mapparli con una #define condizionata

Output di tipi interi "speciali"

- **ISO C99 introduce modificatori per:**
  - evitare conversioni / cast non necessari
  - fare output nativo di tipi interi "speciali"
- **nuovi modificatori per tipi interi:**
  - "j" per indicare conversione di intNN_t / uintNN_t
  - "z" per indicare conversione di size_t
- **il supporto di questi nuovi modificatori dipende dalla libc installata insieme al compilatore C**

Indirizzi di rete

- **le reti IPv4 usano direttamente gli indirizzi su 32 bit**
- **... non i nomi (es. www.polito.it), che sono tradotti in indirizzi dal DNS**
- **... e neanche gli indirizzi puntati (es. 130.192.11.51)**
- **... ma il loro valore numerico su 32 bit**

- **esempio: 130.192.11.51**
  - = $130*2^{24} + 192*2^{16} + 11*2^{8} + 51$
  - = (((130*256) + 192)*256 + 11)*256 + 51
  - = 130<<24 + 192<<16 + 11<<8 + 51
  - = 2,193,623,859

Conversione di indirizzi di rete

- **per generalità, le funzioni standard richiedono che l'indirizzo numerico sia espresso in forma di struct**
- **per convertire indirizzi numerici da/a stringhe:**
  - [IPv4] inet_ntoa( ) e inet_aton( )
  - [IPv4 / v6] inet_ntop( ) e inet_pton( )
- **l'uso di altre funzioni (es. inet_addr) è deprecato**

```
#include <arpa/inet.h>

struct in_addr { in_addr_t s_addr };

struct in6_addr { uint8_t s6_addr[16]; };
```

inet_aton ( )

- **converte un indirizzo IPv4 ...**
- **... da stringa in notazione puntata ("dotted notation")**
- **... a forma numerica (di rete)**
- **restituisce 0 in caso di indirizzo non valido**
- **la stringa può essere composta da numeri decimali (default), ottali (inizio con 0) o esadecimali (inizio con 0x) quindi 226.000.000.037 è uguale a 226.0.0.31**

```
#include <arpa/inet.h>

int inet_aton (
  const char *strptr,
  struct in_addr *addrptr
);
```

inet_ntoa ( )

- **converte un indirizzo IPv4 ...**
- **... da forma numerica (di rete)**
- **... a stringa in notazione puntata ("dotted notation")**
- **restituisce il puntatore all'indirizzo in forma di stringa oppure NULL in caso di indirizzo non valido**
- **attenzione! il puntatore restituito punta ad un'area di memoria statica interna alla funzione**

```
#include <arpa/inet.h>

char *inet_ntoa (
  struct in_addr addr
);
```

Esempio: validazione di un indirizzo

Scrivere un programma che:

- **accetti sulla riga di comando un indirizzo IPv4 in notazione puntata**
- **restituisca il suo valore numerico (di rete)**
- **segnali errore in caso di formato errato o indirizzo illegale**

Verifica:

- **si ricordi che A.B.C.D = A<<24 + B<<16 + C<<8 + D**

avrfy.c
avrfy2.c

inet_pton( )

- converte un indirizzo IPv4 / IPv6 …
- … da stringa in notazione puntata ("dotted notation")
- … a forma numerica (di rete)
- restituisce 0 in caso di indirizzo non valido, -1 se la address family è sconosciuta
- address family = AF_INET o AF_INET6

```
#include <arpa/inet.h>

int inet_pton (
  int family,
  const char *strptr,
  void *addrptr
);
```

inet_ntop( )

- converte un indirizzo IPv4 / IPv6 …
- … da forma numerica (di rete)
- … a stringa in notazione puntata ("dotted notation")
- restituisce il puntatore alla stringa oppure NULL in caso di indirizzo non valido

```
#include <arpa/inet.h>

char *inet_ntop (
  int family,
  const void *addrptr,
  char *strptr, size_t length
);
```

Esempio: validazione di un indirizzo

Scrivere un programma che:

- accetti sulla riga di comando un indirizzo IPv4 o IPv6
- indichi se è un indirizzo valido in una delle due versioni di IP

avrfy46.c

Dimensioni degli indirizzi

- per dimensionare la rappresentazione come stringa degli indirizzi v4/v6 usare le macro definite in <netinet/in.h>

```
#include <netinet/in.h>

#define INET_ADDRSTRLEN  16
#define INET6_ADDRSTRLEN 46
```

Indirizzi IPv6

- 128 bit = 8 gruppi da 16 bit, separati da " : "
- forma completa = 1080:0:0:0:8:800:200C:417A
- compressione degli zeri = 1080::8:800:200C:417A

Inizializzazione di strutture (ANSI)

- per trattare strutture dati come sequenze di byte
- … che possono includere NUL e quindi non essere trattabili con le funzioni "str…" (strcpy, strcmp, …)

```
#include <string.h>

void *memset (
  void *dest, int c, size_t nbyte )
void *memcpy (
  void *dest, const void *src, size_t nbyte )
int *memcmp (
  const void *ptr1, const void *ptr2, size_t nbyte )
```

Inizializzazione di strutture (BSD)

- **funzioni pre-ANSI, definite nello Unix BSD**
- **ancora molto usate**

```
#include <strings.h>

void bzero (
  void *dest, size_t nbyte )
void bcopy (
  const void *src, void *dest, size_t nbyte )
int bcmp (
  const void *ptr1, const void *ptr2, size_t nbyte )
```

Gestione dei segnali

- **i segnali sono eventi asincroni**
- **ad ogni segnale ricevuto corrisponde un comportamento di default implicito**
- **per cambiare la risposta ad un segnale:**
  - modificare il comportamento di default
  - intercettarlo registrando un signal handler

Timeout

- **talvolta occorre attivare dei timeout per:**
  - attendere inattivi per una durata di tempo prefissata (sleep)
  - sapere quando è trascorso un certo tempo (alarm)

`sveglia.c`

sleep ( )

- **attiva un timer e sospende il processo per la durata indicata**
- **se termina perché è trascorsa la durata fissata**
  - restituisce zero
- **se termina perché interrotta da un segnale**
  - restituisce il tempo mancante al termine fissato

```
#include <unistd.h>
unsigned int sleep (
  unsigned int seconds
);
```

alarm ( )

- **attiva un timer al cui scadere viene generato automaticamente il segnale SIGALRM**
- **il processo non viene sospeso**
- **nota: la risposta di default a SIGALRM è la terminazione del processo che lo riceve**
- **una nuova chiamata rimpiazza il timer corrente (es. usare `alarm(0)` per cancellare timer corrente)**
- **(!) unico timer per tutti i processi del gruppo**

```
#include <unistd.h>
unsigned int alarm (
  unsigned int seconds
);
```

Gestione dei segnali

- **attenzione alle differenze di semantica nei vari S.O.**
- **usare per signum i nomi logici dei segnali (SIGCHLD, SIGSTOP, ...)**
- **handler può essere:**
  - una funzione definita dall'utente
  - SIG_IGN (ignorare il segnale)
  - SIG_DFL (comportamento di default)

```
#include <signal.h>
typedef void Sigfunc(int);
Sigfunc *signal (int signum, Sigfunc *handler);
```

Note sui segnali

- **SIGKILL e SIGSTOP non possono essere né intercettati né ignorati**
- **SIGCHLD e SIGURG sono ignorati di default**
- **in Unix usare `kill -l` per elencare tutti i segnali**
- **in Unix i segnali si possono anche generare manualmente col comando**

  `kill -`***segnale pid***
- **ad esempio per inviare SIGHUP al processo 1234:**

```
kill -HUP 1234
```

Segnali standard (POSIX.1)

nome	*valore*	*azione*	*note*
HUP	1	term	hangup of controlling terminal or death of controlling process
INT	2	term	interrupt from keyboard
QUIT	3	core	quit from keyboard
ILL	4	core	illegal instruction
ABRT	6	core	abort signal from abort( )
FPE	8	core	floating-point exception
KILL	9	term	kill
SEGV	11	core	invalid memory reference
PIPE	13	term	broken pipe (write to pipe w/o readers)
ALRM	14	term	timer signal from alarm( )
TERM	15	term	termination signal

Segnali standard (POSIX.1) – cont.

nome	*valore*	*azione*	*note*
USR1	16/10/30	term	user-defined signal 1
USR2	17/12/31	term	user-defined signal 2
CHLD	18/17/20	ignore	child stopped / terminated
CONT	25/18/19	cont	continue if stopped
STOP	23/19/17	stop	stop process
TSTP	24/20/18	stop	stop from tty
TTIN	26/21/21	stop	tty input for background process
TTOU	27/22/22	stop	tty output from background process

kill( )

- **per inviare un segnale da processo a processo**
- **restituisce 0 se OK, -1 in caso di errore**
- **(pid=0) invia segnale a tutti i processi del gruppo**
  - spesso usato per inviare segnale a tutti i propri figli
- **(pid<0) invia segnale ai processi del gruppo "–pid"**
- **(signum=0) non invia segnale ma effettua controlli di errore (processo o gruppo inesistente)**

```
#include <sys/types.h>
#include <signal.h>
int kill ( pid_t pid, int signum );
```

Il socket

- **è la primitiva base delle comunicazioni in TCP/IP**
- **è il punto estremo di una comunicazione**
- **adatto per comunicazioni orientate al canale:**
  - socket connessi (una coppia di socket connessi fornisce un'interfaccia bidirezionale tipo *pipe*)
  - modello uno-a-uno
- **adatto per comunicazioni orientate ai messaggi:**
  - socket non connessi
  - modello molti-a-molti

Tipi di socket

- **tre tipi fondamentali:**
  - STREAM socket
  - DATAGRAM socket
  - RAW socket
- **tipicamente:**
  - stream e datagram usati a livello applicativo
  - raw usato nello sviluppo di protocolli (accesso a tutti i campi del pacchetto IP, incluso l'header)

Stream socket

- **octet stream**
- **bidirezionali**
- **affidabili**
- **flusso sequenziale**
- **flusso non duplicato**
- **messaggi di dimensione illimitata**
- **interfaccia di tipo file sequenziale**
- **solitamente usato per canali TCP**

Datagram socket

- **message-oriented**
- **messaggio = insieme di ottetti non strutturato (blob binario)**
- **bidirezionale**
- **non sequenziale**
- **non affidabile**
- **eventualmente duplicato**
- **messaggi limitati a 8 KB**
- **interfaccia dedicata (a messaggi)**
- **solitamente usato per pacchetti UDP o IP**

Raw socket

- **fornisce accesso al protocollo di comunicazione sottostante**
- **tipicamente di tipo datagram**
- **interfaccia di programmazione complessa (e spesso dipendente dal S.O.): non pensata per utenti di applicativi distribuiti**
- **usato per sviluppo di protocolli**

Dominio di comunicazione

- **un socket è definito nell'ambito di un dominio di comunicazione**
- **un dominio è un'astrazione che implica:**
  - una struttura di indirizzamento "Address Family" (AF)
  - un insieme di protocolli che implementano i socket nel dominio stesso "Protocol Family" (PF)
- **per consuetudine si usano quasi sempre solo AF (perché esiste corrispondenza biunivoca con PF)**

Binding

- **un socket viene creato senza un identificativo**
- **nessun processo può referenziare o accedere ad un socket privo di identificativo**
- **prima di poter usare un socket è necessario associargli un identificativo**
  - = indirizzo di rete (per socket di rete)
  - = nome logico (per socket di S.O.)
- **il binding stabilisce l'indirizzo del socket e lo rende accessibile in rete**
- **il binding è legato al protocollo usato**
- **binding esplicito solitamente fatto dai server (per il client indirizzo determinato dal SO in base al routing)**

Associazione (dominio INET)

- **affinché due processi possano comunicare in rete deve esistere tra loro un'associazione**
- **nel dominio AF_INET un'associazione è una quintupla**
- **tutte le quintuple devono essere uniche**

protocollo (TCP, UDP, ...)
indirizzo IP (locale)
porta (locale)
indirizzo IP (remoto)
porta (remota)

Associazione (dominio Unix)

- **due processi sullo stesso nodo Unix possono comunicare tra loro un'associazione locale**
- **nel dominio AF_UNIX un'associazione è una terna**
- **tutte le terne devono essere uniche**

protocollo (channel, msg)
pathname (locale)
pathname (remoto)

Associazioni

- **si creano con la system call bind( ) che crea una metà dell'associazione**
- **l'associazione viene completata:**
  - dal server con accept( ), che elimina la richiesta dalla coda e crea un socket dedicato per la connessione; è una chiamata bloccante
  - dal client con connect( ), che assegna anche la porta locale; è una chiamata bloccante

Socket connessi (stream)

- **la creazione di una connessione è tipicamente un'operazione asimmetrica**
- **ogni processo crea il proprio endpoint con socket( )**
- **il server:**
  - assegna un identificativo al socket tramite bind( )
  - si mette in ascolto sul suo socket tramite listen( )
  - quando arriva una richiesta di collegamento la accetta con accept( ), che elimina la richiesta dalla coda e crea un socket dedicato per la connessione
- **il client si collega al server con connect( ), che effettua implicitamente il binding assegnando anche la porta locale**

Stream socket: pre-connessione

Il client:
1. crea un socket

Il server:
1. crea un socket
2. associa una porta al socket
3. si mette in ascolto sulla coda

Stream socket: richiesta di connessione

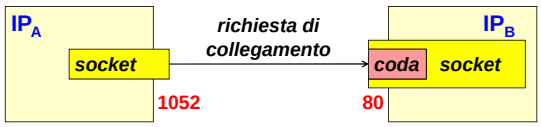

Il client:
1. richiede collegamento alla porta del server

Il server:
1. riceve una richiesta di collegamento

Stream socket: connessione stabilita

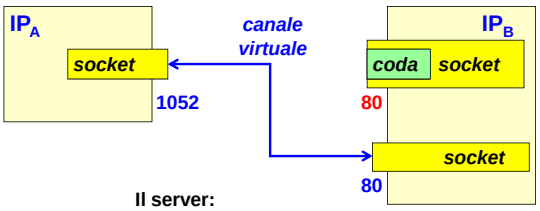

Il server:
1. accetta la richiesta
2. completa il canale con un nuovo socket
3. si rimette in attesa sulla coda del socket originale

Stream socket: flusso logico

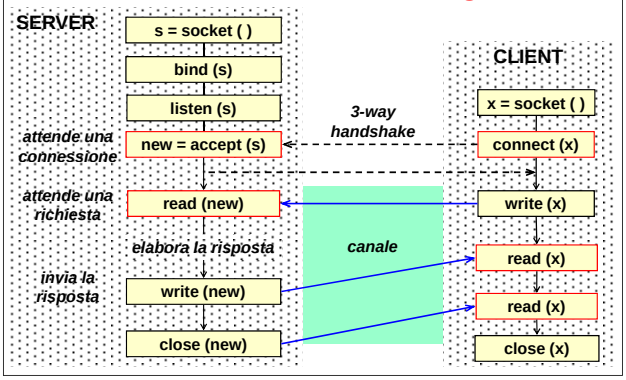

Datagram socket: flusso logico

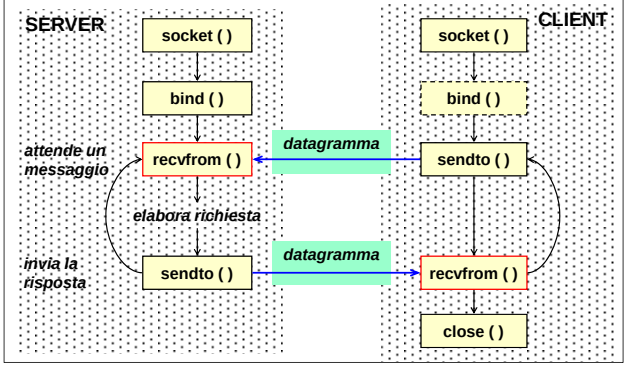

Datagram socket - differenze

- **permettono di:**
  - scambiare dati senza connessione (perché i messaggi contengono l'indirizzo di destinazione e provenienza)
  - inviare da un socket a più destinazioni
  - ricevere su un socket da più sorgenti
- **quindi, in generale, il modello è "molti a molti"**
- **i termini client e server si usano solo nel senso della applicazione**
- **non esistono differenze tra le chiamate effettuate dai vari processi coinvolti nella comunicazione**

I socket in C

Il compilatore gcc

- **uno dei migliori compilatori**
- **usare flag "`-Wall -Werror`" per essere certi di non trascurare potenziali sorgenti di errore**
- **attenzione: il warning sull'uso di variabili non inizializzate viene emesso solo se si ottimizza il programma (almeno con `-O1`)**

Note per la compilazione

- **in Solaris > 7 occorre agganciare varie librerie:**
  - libsocket
    - funzioni base dei socket
  - libnsl (name services library)
    - inet_addr (e altro)
  - libresolv (name resolver library)
    - h_errno, hstrerror (e altro)

```
gcc -lsocket -lnsl -lresolv ...
```

make e makefile

- **regole in file di nome "Makefile"**
  - target: dipendenze ...
  - TAB comando_per_creare_il_target
- **$ make [*target*]**
  - il primo target è quello di default
- **esempio:**

```
prova.exe: prova.o mylib.o
     gcc -o prova.exe prova.o lib.o
prova.o: prova.c mylib.h
     gcc -o prova.o -c prova.c
mylib.o: mylib.c mylib.h
     gcc -o lib.o -c lib.c
```

Dipendenze

- **gcc –MM file**
  - analizza il file e ne crea l'elenco delle dipendenze nel formato di make, ignorando gli header di sistema
  - molto utile per creare ed includere automaticamente le dipendenze (col comando "make depend")

```
depend:
  rm -f depend.txt
  for f in $(SRC); do gcc -MM $$f>>depend.txt; done

# dependencies
-include depend.txt
```

Dati applicativi: codifiche

- **codifica ASCII:**
  - sscanf / snprintf per leggere / scrivere dati ASCII (solo se sono stringhe C, ossia terminati da \0)
  - memcpy (se non sono stringhe ma è nota lunghezza)
- **codifica binaria:**
  - hton / ntoh / XDR per leggere / scrivere dati binari
- **esempi (n_{10}=2252):**

```
   ASCII (4 byte)
'2'  '2'  '5'   '2'
0x32 0x32 0x35  0x32
```

```
bin (16 bit)

  0x08 0xCC
```

Dati applicativi: formati

- **formato fisso:**
  - leggere / scrivere il numero di byte specificato
  - convertire i byte secondo la loro codifica
- **formato variabile (con separatori e terminatore):**
  - leggere sino al terminatore, quindi fare la conversione
  - attenzione all'overflow se manca il terminatore
- **formato variabile (TLV = tag-length-value):**
  - leggere il n. di byte dato da length
  - fare la conversione secondo il formato dato dal tag

Unix socket descriptor

- **è un normale descrittore di file riferito ad un socket anziché ad un file**
- **può essere usato normalmente per la lettura o la scrittura con le funzioni di direct I/O**
- **possibile usare le system call operanti su file**
  - close, read, write
  - eccezione: seek
- **disponibili altre system call per funzioni peculiari dei socket (ossia non applicabili a file)**
  - send, recv, …
  - sendto, recvfrom, …

socket( )

- **crea un socket**
- **restituisce il socket descriptor in caso di successo, -1 in caso di errore**
- **family = costante di tipo AF_x**
- **type = costante di tipo SOCK_x**
- **protocol = 0 (ad eccezione nei socket raw)**

```
#include <sys/types.h>
#include <sys/socket.h>
int socket (
  int family, int type, int protocol)
```

socket( ): parametri

- **family:**
  - AF_INET
  - AF_INET6
  - AF_LOCAL (AF_UNIX)
  - AF_ROUTE
  - AF_KEY
- **type:**
  - SOCK_STREAM
  - SOCK_DGRAM
  - SOCK_RAW
  - SOCK_PACKET (Linux, accesso al layer 2)

Combinazioni possibili

	AF_INET	AF_INET6	AF_LOCAL	AF_ROUTE	AF_KEY
SOCK_STREAM	TCP	TCP	yes		
SOCK_DGRAM	UDP	UDP	yes		
SOCK_RAW	IPv4	IPv6		yes	yes

socket( ) : wrapper

- **conviene scrivere una volta per tutte i test invece di ripeterli ogni volta**

```
int Socket (int family, int type, int protocol)
{
  int n;
  if ( (n = socket(family,type,protocol)) < 0)
    err_sys ("(%s) error - socket() failed", prog);
  return n;
}
```

Il concetto di “wrapper”

- **data una funzione da “wrappare”, creare una funzione:**
  - omonima ma iniziante con lettera maiuscola
  - con gli stessi identici parametri
  - di tipo void (a meno che il valore di ritorno sia la risposta della funzione), perché i controlli sono fatti all’interno della nuova funzione
- **non occorre inventare controlli “esotici” ma solo leggere attentamente la descrizione della funzione ed attuare i controlli sul valore di ritorno (o su altri meccanismi di segnalazione d’errore)**

Esempio di wrapper

- **al posto di strcpy( ) si preferisca sempre strncpy( )**
- **… ma anche questa funzione può generare errori:**

```
char *strncpy (char *DST, const char *SRC, size_t LENGTH);

DESCRIPTION
'strncpy' copies not more than LENGTH characters from the
string pointed to by SRC (including the terminating null
character) to the array  pointed  to  by DST.

RETURNS
This function returns the initial value of DST.
```

Wrapper per strncpy

```
void Strncpy (
  char *DST, const char *SRC, size_t LENGTH)
{
  char *ret = strncpy(DST,SRC,LENGTH);
  if (ret != DST)
    err_quit(
      "(%s) library bug - strncpy() failed", prog);
}
```

Uso di funzioni “wrappate”

- se si verifica un errore, tipicamente il wrapper lo segnala e poi termina il processo chiamante
- se il chiamante è un figlio in un server concorrente, non c’è solitamente problema
- se il chiamante è il processo padre in un server concorrente o è un client che deve continuare ad interagire con l'utente, allora terminare il chiamante potrebbe non essere la cosa corretta da fare ...

Indirizzo di un socket

- si usa la struttura sockaddr che è l’indirizzo di un generico socket (Internet, Unix, ...)
- in realtà è solo un overlay per i casi specifici (sockaddr_in, sockaddr_un, ...)
- definita in <sys/socket.h>

```
struct sockaddr {
  uint8_t     sa_len; // non obbligatorio
  sa_family_t *sa_family, // AF_xxx
  char        sa_data[14] // identificativo
}
```

Indirizzo di un socket Internet

- indirizzo di rete di livello 3 (in formato di rete)
- porta di livello 4 (in formato di rete)
- il protocollo di livello 4 è definito implicitamente in base al tipo di socket (STREAM, DGRAM)

```
struct sockaddr_in
{
  uint8_t         sin_len; // non obbligatorio
  sa_family_t     *sin_family; // AF_INET
  in_port_t       sin_port; // porta TCP o UDP
  struct in_addr  sin_addr; // indirizzo IP
  char            sin_zero[8] // non usato
}
```

connect( )

- crea un collegamento tra un socket “locale” ed un socket “remoto”, specificato tramite il suo identificativo (=indirizzo e porta)
- in pratica avvia il TCP 3-way handshake
- il sistema operativo assegna automaticamente un identificativo appropriato al socket locale (indirizzo e porta)
- restituisce 0 se OK, -1 in caso di errore

```
#include <sys/socket.h>
int connect (int sockfd,
  const struct sockaddr *srvaddr, socklen_t addrlen)
```

bind( )

- assegna un indirizzo ad un socket
- restituisce 0 in caso di successo, -1 in caso di errore
- se non si specifica l’indirizzo IP, viene assegnato dal kernel in base al pacchetto SYN ricevuto
- INADDR_ANY per specificare un indirizzo qualunque

```
#include <sys/socket.h>
int bind ( int sockfd,
  const struct sockaddr *myaddr,
  socklen_t myaddrlen )
```

listen( )

- trasforma un socket da attivo in passivo
- specifica la dimensione della coda delle richieste pendenti (= somma delle due code, più talvolta un fattore di aggiustamento 1.5)
- fattore critico per:
  - i server ad alto carico
  - resistere agli attacchi "SYN flooding"
- restituisce 0 in caso di successo, -1 altrimenti

```
#include <sys/socket.h>
int listen ( int sockfd, int backlog )
```

Dimensione di quale coda?

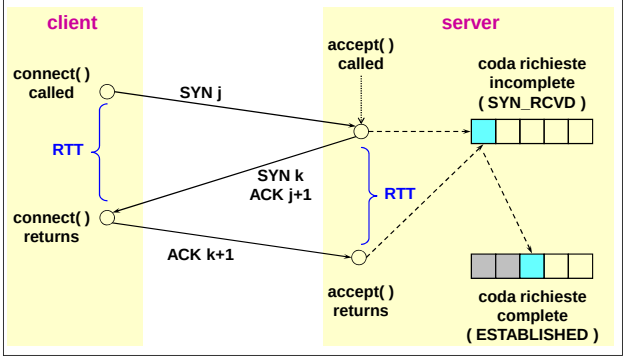

Note sul parametro "backlog"

- **in Linux (a partire dal kernel 2.2) ed in Solaris (dalla 2.9) si usano i SYN_COOKIE e quindi il parametro specifica solo la lunghezza della coda Established**
- **la lunghezza della coda SYN_RCVD è:**
  - dimensionata automaticamente (256-1024 entry) in funzione della RAM disponibile
  - modificabile tramite sysconf o …/ip/…
  - infinita se si attivano i SYN_COOKIE (default da kernel 2.4)

listen( ) : wrapper

- **conviene non fissare la dimensione della coda nel codice ma renderla modificabile (via argomenti o variabili di ambiente)**
- **ad esempio con un wrapper:**

```
#include <stdlib.h> // getenv()

void Listen (int sockfd, int backlog)
{
  char *ptr;
  if ( (ptr = getenv("LISTENQ")) != NULL)
    backlog = atoi(ptr);
  if ( listen(sockfd,backlog) < 0 )
    err_sys ("(%s) error - listen failed", prog);
}
```

Lettura variabili di ambiente in C

- **usare la funzione getenv( )**
- **riceve in input il nome della variabile di environment come stringa**
- **restituisce il puntatore alla stringa relativa al valore**
- **... oppure NULL se la variabile non è definita**

```
#include <stdlib.h>
char *getenv (const char *varname);
```

Elenco variabili di ambiente in C

- **parametro "envp" passato alla funzione main**
  - supportato da MS-VC++ e gcc … ma non è ANSI
- **envp è un array di puntatori a stringhe**
  - ogni stringa contiene la coppia:
    - NOME_VARIABILE=VALORE_VARIABILE
  - ultimo elemento dell'array ha il valore NULL
    - necessario, dato che non c'è un parametro che riporti il numero delle stringhe

```
int main (int argc, char *argv[], char *envp[]);
```

Impostare var. d'ambiente (in BASH)

- **export VARNAME=VARVALUE**
  - aggiunge la variabile all'ambiente di esecuzione
- **export –n VARNAME**
  - rimuove la variabile dall'ambiente di esecuzione
- **env VARNAME=VARVALUE COMANDO**
  - esegue il comando inserendo temporaneamente nel suo ambiente la variabile
- **printenv [VARNAME]**
  - elenca tutte le variabili di ambiente o quella indicata
- **nota: "export" è built-in in bash mentre "env" e "printenv" sono comandi esterni (in /usr/bin)**

Esempi lettura variabili d'ambiente

- **printevar.c stampa il valore della variabile d'ambiente il cui nome è fornito sulla riga di comando**
- **prallenv.c stampa nomi e valori di tutte le variabili d'ambiente definite**

printevar.c
prallenv.c

accept( )

- **preleva il primo collegamento disponibile nella coda delle richieste pendenti**
- **si blocca se non ci sono richieste pendenti (eccezione: se il socket è non bloccante)**
- **restituisce un nuovo socket descriptor, connesso con quello del client**
- **side effect: restituisce l'identificativo del client che si è collegato (a meno che si fornisca NULL)**

```
#include <sys/socket.h>
int accept (int listen_sockfd,
  struct sockaddr *cliaddr, socklen_t *addrlenp)
```

close( )

- **chiude immediatamente il socket**
- **il socket non è più accessibile al processo ma il kernel cercherà di inviare eventuali dati rimasti e poi eseguire la chiusura del canale TCP**
- **comportamento cambiabile con SO_LINGER**
- **restituisce 0 se termina con successo, -1 in caso di errore**

```
#include <unistd.h>
int close ( int sockfd )
```

Comunicazione su stream

- **usare funzioni di I/O non bufferizzato per evitare**
  - di restare indefinitamente in attesa (input)
  - di terminare precocemente in caso di NUL (output)
- **mai la libreria di standard I/O**
- **in particolare usare le system call read( ) e write( ):**
  - operano su file descriptor
  - restituiscono il numero di byte letti o scritti, -1 in caso di errore

```
#include <unistd.h>
ssize_t read (int fd, void *buf, size_t nbyte )
ssize_t write(int fd, const void *buf, size_t nbyte)
```

Risultato di una read su un socket

- **maggiore di zero: numero di byte ricevuto**
- **uguale a zero : socket chiuso (EOF)**
- **minore di zero : errore**

- **attenzione:**
  - a causa della frammentazione e dei buffer …
  - … il numero di dati letti può essere inferiore al numero atteso
  - conviene quindi scrivere funzioni che trattino automaticamente questo problema

Funzioni di lettura / scrittura "sicure"

- **readn( ) e writen( ) leggono e scrivono esattamente N byte, a meno che incontrino errore o EOF**
- **readline( ) legge fino ad incontrare LF oppure a riempire il buffer, a meno di incontrare errore o EOF**
- **riferimento: UNP, figg. 3.14, 3.15, 3.16**
- **nota: readline( ) deve necessariamente leggere un byte alla volta ma usa un'altra funzione (privata) per caricare un buffer in modo più efficiente**

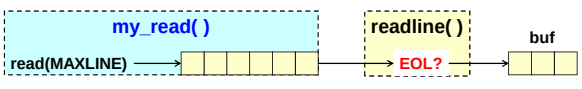

readn, writen, readline

- **le funzioni con iniziale maiuscola controllano automaticamente gli errori**

```
ssize_t readn (int fd, void *buf, size_t nbyte)
ssize_t Readn (int fd, void *buf, size_t nbyte)

ssize_t writen(int fd, const void *buf, size_t nbyte)
void Writen (int fd, const void *buf, size_t nbyte)

ssize_t readline (int fd, void *buf, size_t nbyte)
ssize_t Readline (int fd, void *buf, size_t nbyte)
```

sockwrap.h
sockwrap.c

Uso di errlib e sockwrap

- **sockwrap usa errlib per segnalare gli errori**
- **errlib richiede che esista la variabile "prog" e sia inizializzata al nome del programma in esecuzione**

```
#include "errlib.h"
#include "sockwrap.h"
char *prog;

int main (int argc, char *argv[])
{
  . . .
  prog = argv[0];
  . . .
}
```

Attenzione!

- **poiché my_read usa un buffer locale, le funzioni readline non sono rientranti:**
  - non possono essere usate in ambiente multiprocesso o multithread
  - per questi casi occorre sviluppare funzioni rientranti allocando esternamente il buffer per my_read
- **le chiamate a readline non possono essere mischiate con quelle a normali read perché fanno "read ahead" e perciò "rubano dati" che dovrebbero invece essere consumati da una read diversa**

Esempio: TCP daytime client e server

- **il servizio daytime (tcp/13):**
  - fornisce data e ora correnti in formato comprensibile da un essere umano
  - le risposte sono terminate da CR+LF
- **sviluppare un client che si colleghi al servizio daytime del server specificato sulla riga di comando**
- **sviluppare un server (iterativo) che attende le richieste di servizio e fornisca data e ora, identificando il client che si è collegato**

daytimetcpc.c
daytimetcps.c

Esercizi

- **togliere la listen( ) al server:**
  - cosa capita? perché?
- **lasciare la listen( ) ma togliere la bind( ):**
  - cosa capita? perché?

Informazioni sui socket

- **per conoscere indirizzo e porta**
  - della parte locale: getsockname( )
  - della parte remota: getpeername( )
- **restituiscono 0 se tutto OK, -1 in caso di errore**

```
#include <sys/socket.h>
int getsockname ( int sockfd,
  struct sockaddr *localaddr, socklen_t *addrp )
int getpeername ( int sockfd,
  struct sockaddr *peeraddr, socklen_t *addrp )
```

Informazioni sui socket: esempio

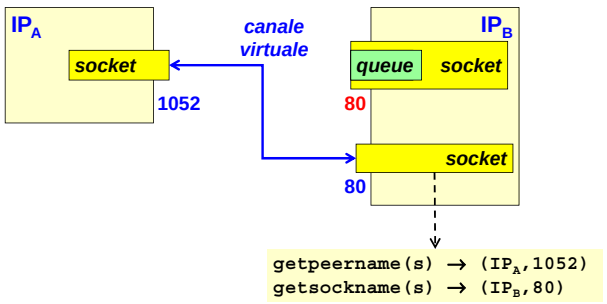

Binding implicito o esplicito?

- **consideriamo il seguente caso:**
  - server web multihomed (N indirizzi di rete)
  - un sito web diverso per ogni indirizzo
- **se il server fa binding a INADDR_ANY:**
  - un solo processo in ascolto
  - demultiplexing fatto dal server
- **se il server fa binding ai singoli N indirizzi:**
  - N processi in ascolto
  - demultiplexing fatto dallo stack TCP/IP

weak-end / strong-end model

- **nel caso di server multihomed …**
- **"strong-end model" = quei kernel che accettano pacchetti su un'interfaccia solo se DST_IP è uguale all'IP dell'interfaccia**
- **"weak-end model" = quei kernel che accettano pacchetti solo se DST_IP è uguale all'IP di una qualunque interfaccia del server**

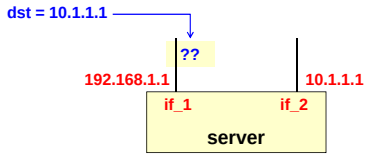

Porte dedicate a server e client

- **IANA**
  - 1-1023 = well-known ports
  - 1024-49151 = registered ports
  - 49152-65535 = dynamic / ephemeral ports
- **UNIX**
  - 1-1023 = riservate solo a processi con EUID=0
  - 513-1023 = riservate a client privilegiati (r-cmds)
  - 1024-5000 = BSD ephemeral ports (poche!)
  - 5001-65535 = BSD servers (non-privileged)
  - 32768-65535 = Solaris ephemeral ports
- **Windows non fa invece nessun controllo**

La porta zero

- **la porta 0 è riservata e non può essere usata per nessun collegamento TCP o UDP**
- **nel caso di uso dell'interfaccia socket sotto Unix il valore zero può essere usato per richiedere al SO una porta dinamica a caso:**
  - solitamente utile solo in UDP
  - il comportamento è diverso con l'interfaccia socket di Windows

recvfrom( ) e sendto( )

- **usate per i socket datagram, pur potendosi usare anche con stream**
- **restituiscono il numero di byte letti o scritti, -1 in caso di errore**
- **il parametro "flags" è di solito zero (maggiori dettagli in seguito)**

```
#include <sys/socket.h>
int recvfrom ( int sockfd,
  void *buf, size_t nbytes, int flags,
  struct sockaddr *from, socklen_t *addrlenp )
int sendto ( int sockfd,
  const void *buf, size_t nbytes, int flags,
  const struct sockaddr *to, socklen_t addrlen )
```

Ricezione dati con recvfrom( )

- ricevere zero dati è OK (=payload UDP vuoto) e non segnala EOF (non esiste in socket datagram!)
- usando NULL come valore di "from" si accettano dati da chiunque … ma poi non si conosce l'indirizzo per rispondere (!), a meno di riceverlo a livello applicativo

Binding con socket datagram

- di solito il client non fa bind( ) ma al socket viene assegnato automaticamente un indirizzo e porta la prima volta che viene usato
- in alternativa il client può fare bind( ) alla porta 0 che indica al kernel di assegnargli una porta effimera a caso

Esempio: UDP daytime client e server

- il servizio daytime (udp/13) fornisce data e ora correnti in formato comprensibile da un essere umano
- il server invia data e ora in un pacchetto UDP ad ogni client che gli invia un qualsiasi pacchetto UDP, anche vuoto
- sviluppare un client che si colleghi al servizio daytime del server specificato sulla riga di comando
- sviluppare un server (iterativo) che attende le richieste di servizio e fornisca data e ora, identificando il client che si è collegato

`daytimeudpc.c`
`daytimeudps.c`

cygwin: problemi noti

- sendto( ) con buffer di dimensione zero non spedisce niente (dovrebbe spedire UDP con payload di lunghezza zero)

Problemi dei socket datagram

- problema 1: poiché UDP non è affidabile, il client rischia di rimanere bloccato all'infinito in ricezione
- usare un timeout risolve il problema solo talvolta:
  - OK se rispedire la richiesta non crea problemi
  - inaccettabile in caso contrario (es. transazione di debito o credito)
- problema 2: come si verifica che la risposta arrivi proprio dal server a cui abbiamo fatto la richiesta?
- si devono filtrare le risposte a livello utente oppure a livello kernel

Problema 1

```
enum { normale, la_sveglia_ha_suonato } state;

sveglia (...) {
  state = la_sveglia_ha_suonato;
}

signal (SIGALRM, sveglia);
do {
  sendto (...);
  state = normale; alarm (timeout);
  recvfrom (...);
  alarm (0);
} while (state == la_sveglia_ha_suonato);
```

Problema 1: note

- **la soluzione con alarm è soggetta ad una corsa critica (arrivo dei dati simultaneo con lo scadere del timeout)**
- **con timeout "lungo" è poco probabile che capiti ma non si può escludere**
- **meglio quindi impostare un timeout direttamente sul socket oppure tramite select( )**

Verifica delle risposte datagram

- **confronto binario dell'indirizzo del rispondente con quello del destinatario originale**
- **possibili problemi coi server multihomed**
- **soluzione 1: fare la verifica non sull'indirizzo ma sul nome DNS (funziona solo con server registrati)**
- **soluzione 2: il server fa binding esplicito a tutti i suoi indirizzi e poi aspetta su tutti (select)**

```
n = recvfrom(sfd,*buf,nbyte,0,(SA*)&from,&fromlen);
if ( (fromlen == serverlen) &&
     (memcmp(&servaddr,&from,serverlen) == 0) )
  // risposta accettata
```

Errori asincroni

- **quando si verifica un errore in una trasmissione UDP (es. port unreachable) viene generato un pacchetto ICMP di errore …**
- **… ma la funzione sendto( ) è già terminata con stato OK**
- **… e quindi il kernel non sa a quale applicazione fornire l'errore (ed in quale modo!)**
- **soluzioni possibili:**
  - usare socket datagram connessi (!)
  - intercettare gli errori ICMP con un proprio demone

Socket datagram connessi

- **è possibile chiamare connect( ) su un socket datagram per specificare una volta per tutte il peer con cui si intende comunicare**
- **conseguenze:**
  - non si usa più sendto( ) ma write( ) o send( )
  - non si usa più recvfrom( ) ma read( ) o recv( )
  - gli errori asincroni che si verificano vengono restituiti al processo che controlla il socket
  - il kernel effettua automaticamente il filtraggio delle risposte accettando solo pacchetti dal peer
- **in caso di comunicazione ripetuta con lo stesso peer c'è un buon miglioramento delle prestazioni**

Disconnettere un socket datagram

- **si può fare una seconda connect( ) verso un altro indirizzo per cambiare la connessione**
- **vietato per socket stream**
- **per disconnettere completamente (ossia tornare a socket non connesso) fare connect( ) verso un indirizzo non specificato mettendo AF_UNSPEC**
- **in questo caso si potrebbe ricevere un errore EAFNOSUPPORT che si può però trascurare**

Server concorrenti

Processi in Unix

- sdoppiamento dell'applicazione: fork( )
- eventuale avvio di un nuova immagine: exec( )

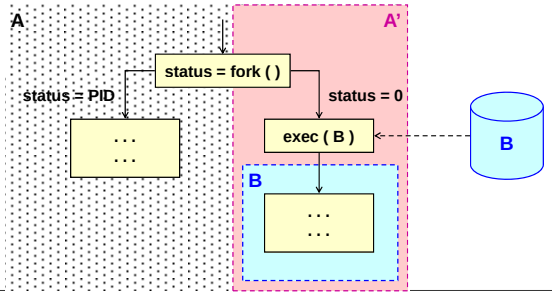

fork( )

- genera un nuovo processo ...
- ... che condivide immagine ed ambiente di esecuzione col processo che ha fatto fork( )
- return status:
  - -1 in caso di errore
  - 0 per il nuovo processo ("figlio" o "child")
  - PID del nuovo processo al "padre" (o "parent")

```
#include <unistd.h>
pid_t fork (void);
```

getpid( ), getppid( )

- il figlio può conoscere il PID del padre tramite getppid( )
- nota: il padre di ogni processo è unico
- per conoscere il proprio PID usare getpid( )
- return status:
  - -1 in caso di errore
  - il PID desiderato

```
#include <unistd.h>
pid_t getpid (void);
pid_t getppid (void);
```

Funzioni exec

- sostituiscono l'immagine in esecuzione con una nuova immagine
- restituiscono -1 in caso di errore
- le funzioni L passano gli argomenti come lista di variabili, terminata da NULL
- le funzioni V passano gli argomenti come vettore di puntatori, con ultimo elemento NULL
- le funzioni P localizzano l'immagine tramite PATH, le altre vogliono il pathname completo
- le funzioni con E ricevono le variabili di ambiente come vettore di puntatori, con ultimo elemento NULL; le altre usano la var. esterna "environ"

Funzioni execv( ) e execl( )

```
#include <unistd.h>
int execv ( const char *filename,
  char *const argv[] );
int execve ( const char *filename,
  char *const argv[], char *const envp[] );
int execvp ( const char *pathname,
  char *const argv[], char *const envp[] );
int execl ( const char *filename,
  const char *arg0, ..., (char *)NULL );
int execle ( const char *filename,
  const char *arg0, ..., (char *)NULL,
  char *const envp[] );
int execlp ( const char *pathname,
  const char *arg0, ..., (char *)NULL,
  char *const envp[] );
```

Funzioni exec

- solitamente solo execve( ) è una system call

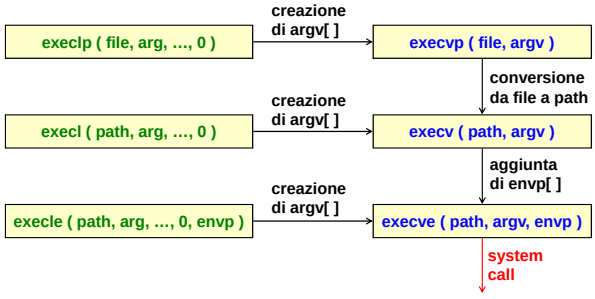

Comunicazione attraverso la exec( )

- **passaggio dei parametri esplicito:**
  - attraverso gli argomenti
  - attraverso le variabili di ambiente
- **i descrittori di file (file e socket) restano aperti, a meno che il chiamante usi fcntl( ) per settare il flag FD_CLOEXEC che li fa chiudere automaticamente quando si esegue una exec**

Scheletro di server concorrente (I)

```
pid_t pid; // PID del figlio
int listenfd; // socket di ascolto
int connfd; // socket di comunicazione

// creazione del socket di ascolto
listenfd = Socket( ... );
servaddr = ...
Bind (listenfd, (SA*)&servaddr, sizeof(servaddr));
Listen (listenfd, LISTENQ);
```

Scheletro di server concorrente (II)

```
// loop di esecuzione del server
while (1)
{
  connfd = Accept (listenfd, ...);
  if ( (pid = Fork()) == 0 )
  {
    Close(listenfd);
    doit(connfd); // il figlio svolge il lavoro
    Close(connfd);
    exit(0);
  }
  Close (connfd);
}
```

Importanza della close( )

- **se il padre dimentica di chiudere il socket di connessione ...**
  - esaurisce in fretta i descrittori
  - il canale col client resta aperto anche quando il figlio ha terminato ed ha chiuso il socket di connessione
- **note:**
  - la funzione close( ) non chiude il socket ma semplicemente ne decrementa il reference count
  - solo quando REFCNT diventa zero, il socket viene chiuso (ossia si invia FIN se è un socket TCP)

Chiusura di una connessione

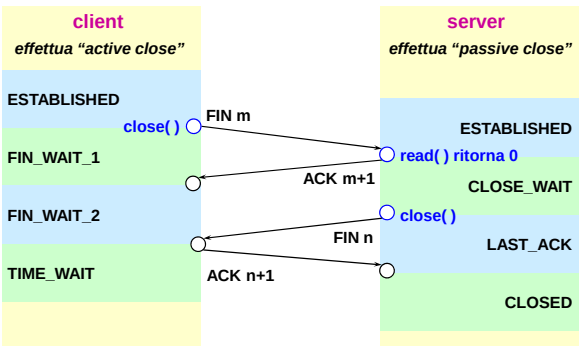

Lo stato TIME_WAIT

- **dallo stato TIME_WAIT si esce solo per timeout:**
  - durata pari a 2 x MSL (Max Segment Lifetime)
  - MSL = 2 minuti (RFC-1122), 30 secondi (BSD)
  - quindi timeout 1…4 minuti
- **esiste per risolvere due problemi:**
  - implementare la chiusura TCP full-duplex
    - l'ultimo ACK potrebbe venir perso ed il client ricevere un nuovo FIN
  - permettere a pacchetti duplicati di "spirare"
    - potrebbero essere interpretati come parte di una nuova incarnazione della stessa connessione

Terminazione dei figli

- **quando un processo figlio termina, viene inviato il segnale SIGCHLD al padre**
- **reazione di default:**
  - ignorato
  - … il che genera un processo "zombie"
- **zombie ereditati ed eliminati dal processo init solo quando il padre termina (ma di solito i server non terminano mai …)**

If we want to avoid zombies, we have to wait for our children.
-- W.R.Stevens

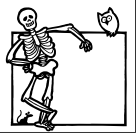

wait( ) e waitpid( )

- **ritornano:**
  - il PID del figlio terminato; 0 o -1 in caso di errore
  - lo status di terminazione del figlio
- **wait( ) è bloccante**
- **waitpid( ):**
  - non si blocca se si usa l'opzione WNOHANG
  - permette di specificare il PID di un figlio specifico (-1 per attendere il primo che termina)

```
#include <sys/wait.h>
pid_t wait (int *status);
pid_t waitpid (pid_t pid, int *status, int options);
```

Intercettare SIGCHLD

- **se più figli terminano "simultaneamente" si genera un solo SIGCHLD, quindi bisogna attenderli tutti**

```
#include <sys/wait.h>
void sigchld_h (int signum)
{
  pid_t pid;
  int status;
  while ( (pid = waitpid(-1,&status,WNOHANG)) > 0)
#ifdef TRACE
    err_msg (
"(%s) info - figlio %d terminato con status %d\n",
      prog, pid, status)
#endif
  ; // occhio a questo punto e virgola
}
```

system call interrotte

- **quando un processo esegue una system call "lenta" (ossia una che può bloccare il chiamante)**
- **… può sbloccarsi non perché la system call è terminata**
- **… ma perché è arrivato un segnale; questo caso è segnalato da errno == EINTR (o ECHILD)**
- **occorre quindi prevedere questo caso e ripetere la system call (azione già svolta in sockwrap)**
- **caso molto rilevante per la accept( ) nei server**
- **ATTENZIONE: si possono ripetere tutte le system call tranne connect( ); in questo caso occorre usare la select( )**

Server concorrente: esempio

- **sviluppare un server concorrente in ascolto sulla porta tcp/9999 che riceva righe di testo contenenti due numeri interi e ne restituisca la somma**
- **sviluppare il client che:**
  - legga righe di testo da standard input
  - le invii alla porta tcp/9999 del server specificato sulla riga di comando
  - riceva righe di risposta e le visualizzi su standard output

`addtcps.c`
`addtcpc.c`

Robustezza delle applicazioni

Server lento

- **se un server è lento o sovraccarico …**
- **… il client può completare il 3-way handshake e poi terminare la connessione (RST)**
- **… nel tempo che il server impiega tra listen e accept**
- **questo problema**
  - può essere trattato direttamente dal kernel o può generare EPROTO / ECONNABORTED in accept
  - caso frequente nei server web sovraccarichi

Terminazione del server-figlio

- **quando il server-figlio che comunica col client termina propriamente (exit) viene chiuso il socket e quindi:**
  - si genera un FIN, accettato dal kernel client ma non trasmesso all'applicazione fino alla prossima read
  - se il client esegue una write riceverà un RST
  - a seconda della tempistica, il client riceverà errore sulla write oppure EOF o ECONNRESET sulla prossima read
  - se il client non ha ancora letto i dati inviati dal server quando questi chiude il canale, questi dati potrebbero essere persi (meglio quindi una chiusura parziale lato server con shutdown_write + timeout + exit)

SIGPIPE

- **chi esegue write su un socket che ha ricevuto RST, riceve il segnale SIGPIPE**
  - default: terminare il processo
  - se viene intercettato o ignorato, la prossima write genera l'errore EPIPE
- **attenzione:**
  - se ci sono tanti socket aperti in scrittura …
  - … SIGPIPE non segnala quale ha generato errore
  - meglio quindi ignorare il segnale e ricevere EPIPE sulla write

Crash del server

- **copre anche il caso di server irraggiungibile**
- **le write del client funzionano (non c'è nessuno a rispondere con un errore!)**
- **le read del client andranno in timeout (a volte dopo molto tempo: in BSD 9 m!) generando ETIMEDOUT**
- **read e write potrebbero ricevere EHOSTUNREACH o ENETUNREACH se un router intermedio si accorge del problema e lo segnala tramite ICMP**
- **soluzione: impostare un timeout**
  - direttamente sul socket con le opzioni
  - tramite la select( )
  - tramite la alarm( ) – sconsigliata

Crash e reboot del server

- **sequenza:**
  - crash (= server irraggiungibile)
  - boot (=server raggiungibile ma ha perso conoscenza delle connessioni esistenti: RST)
- **come conseguenza read e write falliscono con ECONNRESET**

Shutdown del server

- **allo shutdown di un nodo Unix, il processo init:**
  - invia SIGTERM a tutti processi attivi
  - dopo 5…20 secondi invia SIGKILL
- **SIGTERM può essere intercettato e quindi i server possono tentare di chiudere tutti socket**
- **SIGKILL non può essere intercettato, termina tutti i processi chiudendo tutti i socket aperti**

Heartbeating

- **se si vuole sapere al più presto possibile se il peer è irraggiungibile o guasto occorre attivare un meccanismo di "heartbeating"**
- **due possibili implementazioni:**
  - mediante l'opzione SO_KEEPALIVE
  - mediante protocollo applicativo di heartbeating

I/O multiplexing

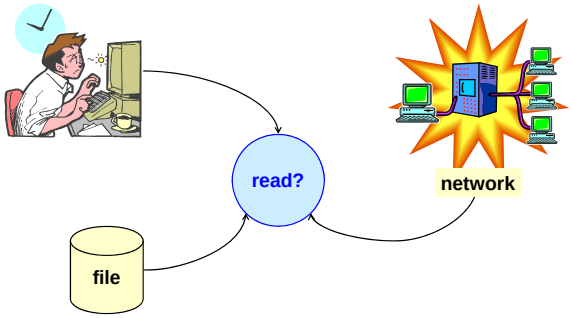

Applicazioni del multiplexing dell'I/O

- **un client che gestisce input da più sorgenti (tipicamente utente da tastiera e server da socket)**
- **un client che gestisce più socket (raro, ma tipico nei browser web)**
- **un server TCP che gestisce sia il socket di ascolto sia quelli di connessione (senza attivare processi separati; es. sistemi embedded)**
- **un server che gestisce sia UDP sia TCP**
- **un server che gestisce più servizi e/o protocolli (raro, ma tipico del processo inetd)**

Modelli di I/O

- **bloccante (read su socket normali)**
- **non bloccante (read su socket non bloccanti)**
- **multiplexing (select, poll)**
- **signal-driven (SIGIO)**
- **asincrono (funzioni aio_xxx)**

- **tutti attraversano due fasi:**
  - attesa che i dati siano pronti
  - copia dei dati da kernel space a user space
- **il problema è sempre in lettura, quasi mai in scrittura**

Modello di I/O multiplexing

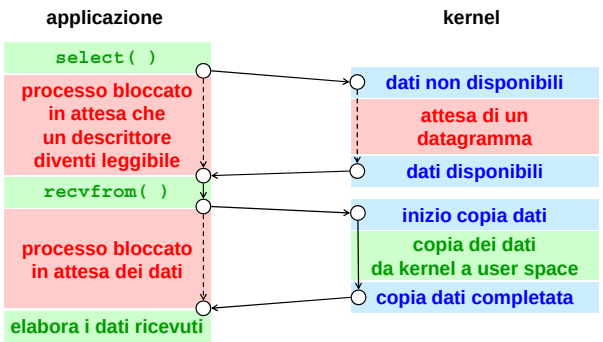

select( )

- **blocca il processo chiamante finché …**
  - uno dei descrittori selezionati diventa "attivo"
  - oppure scade il timeout (se impostato)
- **maxfdp1 (= MAX FD Plus 1) indica il numero del maggiore descrittore di file da osservare, più uno**
- **restituisce il numero di descrittori attivi, 0 se è terminata per timeout, -1 in caso di errore**

```
#include <sys/select.h>
#include <sys/time.h>
int select (int maxfdp1, fd_set *readset,
  fd_set *writeset, fd_set *exceptset,
  struct timeval *timeout);
```

Timeout

- **attesa infinita: timeout == NULL**
- **tempo massimo di attesa: timeout != NULL**
- **nessuna attesa (cioè polling): timeout == {0, 0}**
- **alcuni sistemi modificano il valore del timeout, quindi è meglio re-inizializzarlo ad ogni chiamata**

```
#include <sys/time.h>
struct timeval
{
  long tv_sec;  // seconds
  long tv_usec; // microseconds
};
```

fd_set

- **insiemi di flag per selezionare descrittori di file (ossia un "maschera di bit")**
- **si opera su di essi con le macro FD_xxx**
- **si usa FD_ISSET per sapere su quali descrittori c'è stata attività**
- **attenzione!!! sono da re-inizializzare ad ogni chiamata**

```
#include <sys/select.h>
void FD_ZERO (fd_set *fdset); // azzera la maschera
void FD_SET (int fd, fd_set *fdset); // set(fd)
void FD_CLR (int fd, fd_set *fdset); // reset(fd)
int  FD_ISSET (int fd, fd_set *fdset); // test(fd)
```

Quando un descrittore è "pronto"?

- **readset:**
  - ci sono dati da leggere
  - il peer ha chiuso il canale di lettura (ossia EOF)
  - si è verificato errore sul descrittore
  - c'è un nuovo collegamento ad un socket in ascolto
- **writeset:**
  - c'è spazio per scrivere
  - il peer ha chiuso il canale di scrittura (SIGPIPE/EPIPE)
  - si è verificato errore sul descrittore
- **exceptset:**
  - ci sono dati OOB disponibili

I/O multiplexing: esempio

- **modificare il client addtcpc.c in modo da massimizzare il throughput**
- **soluzione:**
  - non alternarsi tra lettura dell'operazione da standard input e lettura della risposta dal socket ma gestire entrambi gli input tramite select( )
  - vedere i diagrammi nelle prossime slide
- **nota: fare il test sia battendo l'input da tastiera, sia ridirigendolo da un file … si noterà un errore!**

`addtcpc2.c`

Schema di addtcpc.c

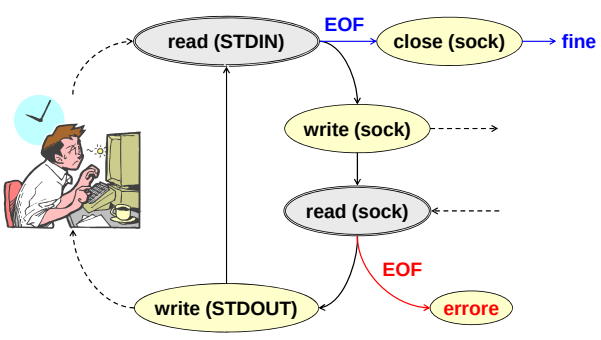

Schema di addtcpc2.c

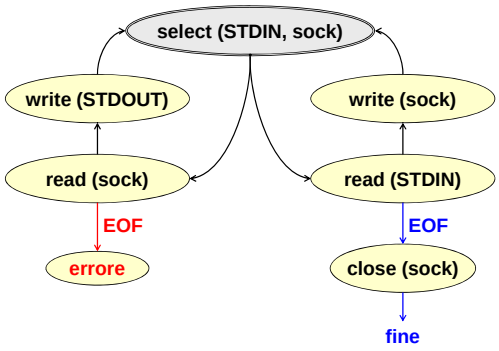

Batch input

- **quando si fornisce input a raffica (come nel caso di lettura da file con un buffer ampio) si rischia di terminare tutto l'input e chiudere il socket senza attendere tutte le risposte**
- **soluzione: non chiudere il socket completamente (close) ma chiudere solo la parte di scrittura (shutdown), aspettando a chiudere la parte in lettura quando si riceverà EOF**

addtcpc3.c

Schema di addtcpc3.c

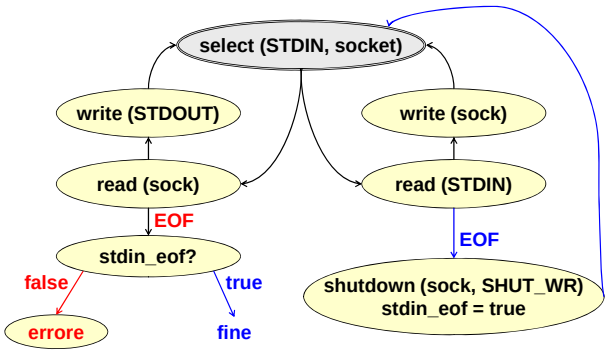

shutdown( )

- **chiude uno dei due canali associati ad un socket**
- **notare che close( ):**
  - chiude entrambi i canali (… ma solo se il reference count del descrittore diventa 0)
  - funzionamento esatto dipende dall'opzione LINGER
- **valori possibili per howto:**
  - SHUT_RD (oppure 0)
  - SHUT_WR (oppure 1)
  - SHUT_RDWR (oppure 2)

```
#include <sys/socket.h>
int shutdown (int sockfd, int howto);
```

Funzionamento di shutdown( )

- **shutdown (sd, SHUT_RD)**
  - read impossibile sul socket
  - contenuto del buffer di read viene eliminato
  - altri dati ricevuti in futuro vengono scartati direttamente dallo stack
- **shutdown (sd, SHUT_WR)**
  - write impossibile sul socket
  - contenuto del buffer di write spedito al destinatario, seguito da FIN se socket stream

Opzioni dei socket

getsockopt( ) e setsockopt( )

- **applicabili solo a socket aperti**
- **"level" indica il livello dello stack di rete: SOL_SOCKET, IPPROTO_IP, IPPROTO_TCP, ...**
- **valori mnemonici per "optname"**

```
#include <sys/socket.h>
#include <netinet/tcp.h>
int getsockopt (int sockfd, int level, int optname,
  void *optval, socklen_t *optlen);
int setsockopt (int sockfd, int level, int optname,
  const void *optval, socklen_t optlen);
```

Alcune opzioni a livello SOCKET

level	optname	get	set	tipo
SOL_SOCKET	SO_BROADCAST	X	X	int (boolean)
	SO_DEBUG	X	X	int (boolean)
	SO_DONTROUTE	X	X	int (boolean)
	SO_ERROR	X		int
	SO_KEEPALIVE	X	X	int (boolean)
	SO_LINGER	X	X	struct linger
	SO_OOBINLINE	X	X	int (boolean)
	SO_RCVBUF	X	X	int
	SO_SNDBUF	X	X	int
	SO_RCVTIMEO	X	X	struct timeval
	SO_SNDTIMEO	X	X	struct timeval
	SO_REUSEADDR	X	X	int (boolean)
	SO_REUSEPORT	X	X	int (boolean)
	SO_TYPE	X		int

Alcune opzioni a livello IP e TCP

level	optname	get	set	tipo
IPPROTO_IP	IP_OPTIONS	X	X	
	IP_TOS	X	X	int
	IP_TTL	X	X	int
	IP_RECVDSTADDR	X	X	int
IPPROTO_TCP	TCP_MAXSEG	X	X	int
	TCP_NODELAY	X	X	int
	TCP_KEEPALIVE	X	X	int

Esempio di lettura opzioni dei socket

- **da UNP, sezione 7.3**
- **note: in CYGWIN i timeout sono interi**

`checkopts.c`

Broadcast, Keepalive, buffer

- **SO_BROADCAST**
  - applicabile solo a datagram socket
  - abilita l'uso di indirizzi broadcast
- **SO_KEEPALIVE**
  - scambio di un pacchetto di "probe" ogni 2 ore (!)
  - intervento a livello kernel per cambiarne il valore
- **SO_SNDBUF, SO_RCVBUF**
  - dimensioni dei buffer locali; impostare prima di connect (per il client) e di listen (per il server)
  - valore >= 3 x MSS
  - valore >= banda x RTT

SO_SNDTIMEO, SO_RCVTIMEO

- **Posix specifica i timeout con una struct timeval**
- **in precedenza erano solo un intero**
- **si applicano solo a:**
  - read, readv, recv, recvfrom, recvmsg
  - write, writev, send, sendto, sendmsg
- **usare altre tecniche per accept, connect, ...**

```
#include <sys/time.h>
struct timeval
{
  long tv_sec;
  long tv_usec;
};
```

SO_REUSEADDR (SO_REUSEPORT)

- **SO_REUSEADDR permette:**
  - di fare bind a porta locale occupata da un processo (un socket di connessione ed uno di ascolto)
  - di avere più server sulla stessa porta (es. IP_A, IP_B, INADDR_ANY)
  - di avere più socket di un singolo processo sulla stessa porta ma con indirizzi locali diversi (utile per UDP senza IP_RECVDSTADDDR)
  - di avere più socket multicast sulla stessa porta (su taluni sistemi si usa SO_REUSEPORT)
- **opzione altamente consigliata per tutti i server TCP**

SO_LINGER

- **cambia il comportamento della close( )**
- **OFF: close non bloccante (ma tenta di inviare i restanti dati)**
- **ON + l_linger == 0: close non bloccante e abort della connessione (=RST, non FIN + TIME_WAIT)**
- **ON + l_linger > 0: close bloccante (tenta di inviare i restanti dati sino al timeout; se non ci riesce, ritorna EWOULDBLOCK)**

```
#include <sys/socket.h>
struct linger
{
  int l_onoff; // 0=off, non-zero=on
  int l_linger; // linger timeout (seconds in Posix)
};
```

IP_TOS, IP_TTL

- **leggono o impostano il valore di TOS e TTL per i pacchetti in uscita**
- **valori per TOS:**
  - IPTOS_LOWDELAY
  - IPTOS_THROUGHPUT
  - IPTOS_RELIABILITY
  - IPTOS_LOWCOST (IPTOS_MINCOST)
- **valori che dovrebbero essere i default per TTL:**
  - 64 per UDP e TCP (RFC-1700)
  - 255 per socket RAW

Librerie di supporto

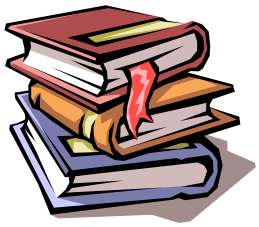

Network libraries

- **libpcap**
  - cattura di pacchetti
  - http://www.tcpdump.org
  - solo per Unix; per Windows vedere winpcap
- **libdnet**
  - raw IP, raw Ethernet, arp, route, fw, if, indirizzi
  - http://libdnet.sourceforge.net
  - per Unix e Windows
- **libnet**
  - http://www.packetfactory.net/projects/libnet/

Event libraries

- **libevent**
  - http://monkey.org/~provos/libevent/
- **liboop**
  - http://liboop.org/

Gestione di nomi e indirizzi

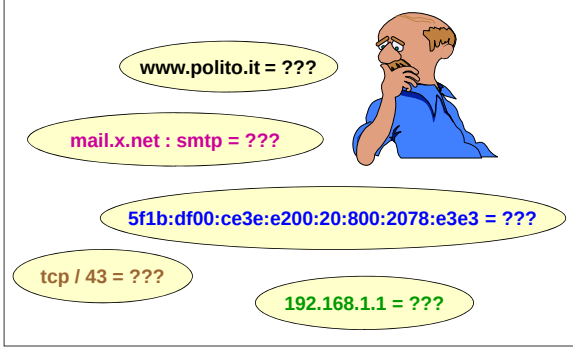

Formati mnemonici e numerici

- **conversione tra nomi mnemonici e valori numerici (nodi, servizi, reti, protocolli, indirizzi di rete)**
- **attenzione! dipendono dall'impostazione locale del sistema**
  - file locali (es. /etc/hosts, /etc/services)
  - lookup service di LAN (es. NIS, LDAP)
  - lookup service globale (DNS)
- **solo nel caso del DNS si può (con qualche sforzo) puntare esplicitamente ad questo servizio**

gethostbyname( )

- **restituisce una struttura dati con la descrizione del nodo il cui nome è specificato come argomento**
- **in caso di errore restituisce NULL e setta la variabile h_errno per specificare l'errore, di cui si può avere una rappresentazione testuale tramite hstrerror(h_errno)**

```
#include <netdb.h>
struct hostent *gethostbyname (
  const char *hostname );
extern int h_errno;
char *hstrerror (int h_errno);
```

struct hostent( )

- **nota: indirizzi rappresentati come 1 char = 1 byte (meglio: 1 unsigned char)**

```
#include <netdb.h>
struct hostent {
  char *h_name; // canonical name
  char **h_aliases; // array of alias names
  int  h_addr_type; // AF_INET or AF_INET6
  int  h_length; // address length (4 or 16 bytes)
  char **h_addr_list; // array of addresses
};
#define h_addr h_addr_list[0] // BSD compatibility
```

struct hostent( )

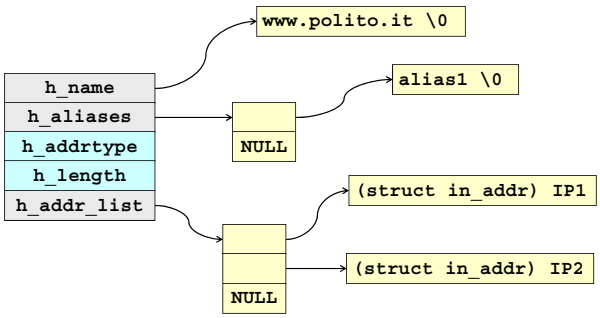

gethostbyaddr( )

- **restituisce una struttura dati con la descrizione del nodo il cui indirizzo è specificato come argomento**
- **in caso di errore restituisce NULL e setta la variabile h_errno per specificare l'errore, di cui si può avere una rappresentazione testuale tramite hstrerror(h_errno)**
- **nota: l'argomento addr in realtà è un puntatore alla struct in_addr o in_addr6**

```
#include <netdb.h>
struct hostent *gethostbyaddr (
  const char *addr, size_t len, int family );
```

uname( )

- **identifica il nodo su cui il programma è in esecuzione**
- **dimensioni e contenuto delle stringhe dipendono dal sistema e dalla sua configurazione sistemistica**
- **restituisce intero negativo in caso di errore**

```
#include <sys/utsname.h>
struct utsname {
  char sysname[...];  // OS name
  char nodename[...]; // network node name
  char release[...];  // OS release
  char version[...];  // OS version
  char machine[...];  // CPU type
};
int uname (struct utsname *nameptr);
```

Esempi

- (info_from_n.c) programma per fornire tutte le informazioni disponibili su un nodo dato il suo nome
- (info_from_a.c) programma per fornire tutte le informazioni disponibili su un nodo dato un suo indirizzo
- (myself.c) programma per fornire tutte le informazioni disponibili sul nodo dove il programma sta eseguendo

info_from_n.c
info_from_a.c
myself.c

getservbyname( ), getservbyport( )

- restituiscono informazioni sul servizio di cui è passato come argomento il nome o la porta
- restituiscono NULL in caso di errore
- attenzione: i numeri di porta sono in network order (OK per programmare, non per visualizzarli)

```
#include <netdb.h>
struct servent *getservbyname (
  const char *servname, const char *protoname );
struct servent *getservbyport (
  int port, const char *protoname );
```

struct servent( )

- nota: errore su UNP (p.251) che dichiara int s_port

```
#include <netdb.h>
struct servent {
  char  *s_name; // official service name
  char **s_aliases; // array of aliases
  short  s_port; // port number (network order)
  char  *s_proto; // transport protocol
};
```

service.c

I “demoni”

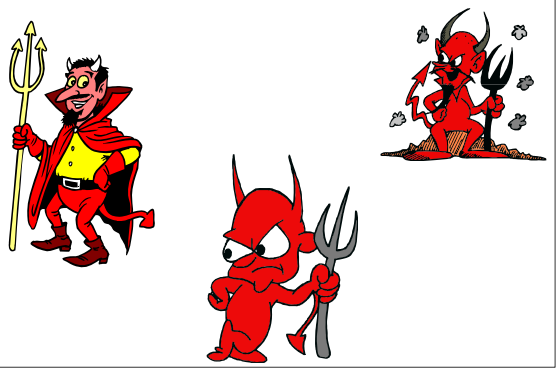

Che cos’è un demone?

- un processo autonomo
- svolge tipicamente il ruolo di un server
- attivato automaticamente al boot
- staccato da qualunque terminale
- scrive informazioni in un file di log
- si configura tramite le informazioni passate sulla riga di comando (sconsigliato!) o contenute in un file di configurazione
- esegue coi diritti di un certo utente e gruppo
- lavora all’interno di un certo direttorio

syslog( )

- non è standard Posix ma è obbligatoria per Unix98
- permette di generare dati nel log di sistema
- destinazione effettiva dei dati dipende dalla configurazione di syslogd (es. /etc/syslog.conf)
- comunicazione aperta in modo implicito o esplicito (openlog + closelog)

```
#include <syslog.h>
void syslog (
  int priority, const char *message , ...);
void openlog (
  const char *ident, int options, int facility);
void closelog (void);
```

syslog priority = level | facility

LEVEL

LOG_EMERG	(priorità massima)
LOG_ALERT	
LOG_CRIT	
LOG_ERR	
LOG_WARNING	
LOG_NOTICE	(priorità di default)
LOG_INFO	
LOG_DEBUG	(priorità minima)

FACILITY

LOG_AUTH	LOG_AUTHPRIV	LOG_CRON
LOG_DAEMON	LOG_FTP	LOG_KERN
LOG_LOCAL0	. . .	LOG_LOCAL7
LOG_LPR	LOG_MAIL	LOG_NEWS
LOG_SYSLOG	LOG_USER	LOG_UUCP

syslog options

OPTIONS

LOG_CONS	log su console se la comunicazione con syslogd fallisce
LOG_NDELAY	apertura immediata del socket, senza attendere la prima chiamata di syslog( )
LOG_PERROR	log anche su stderr
LOG_PID	inserire nel log anche il PID

Inizializzazione di un demone

- **disassociarsi dal terminale di controllo (diventa immune a HUP, INT, WINCH che possono essere usati per altre segnalazioni)**
- **spostarsi nel direttorio di lavoro**
- **chiudere tutti i file ereditati**
- **opzionale, per precauzione verso librerie aliene:**
  - aprire /dev/null ed associarlo a stdin, stdout, stderr
  - aprire un file di log ed associarlo a stdout e stderr
- **aprire syslog**
- **per non sbagliare l'inizializzazione di un demone, usare la funzione daemon_init( ) (UNP, p.336)**

daemon_init( )

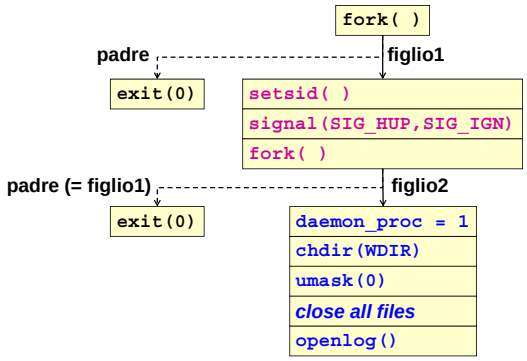

Segnali verso un demone

- **convenzioni molto usate:**
  - SIGHUP per far rileggere il file di configurazione
  - SIGINT per far terminare il demone

inetd

- **se un nodo di rete offre tanti servizi, deve avere tanti demoni in attesa, ognuno dei quali è un processo ed ha del codice associato**
- **per semplificare tutto questo, in Unix si usa spesso il super-server "inetd"**
  - conosce i servizi specificati in /etc/inetd.conf
  - si mette in ascolto su tutti i socket corrispondenti
  - quando riceve una richiesta di collegamento, attiva il server corrispondente

Formato di /etc/inetd.conf

- **ogni riga contiene da 7 a 11 campi:**
  - servizio - nome del servizio in `/etc/services`
  - tipo di socket (`stream`, `dgram`)
  - protocollo (`tcp`, `udp`)
  - flag (`wait`, `nowait`) - server iterativo o concorrente
  - login name (entry in `/etc/passwd`) - nome utente
  - server program (pathname, `internal`)
  - argomenti - massimo 5, incluso `argv[0]`

Esempio di /etc/inetd.conf

```
. . .
echo    stream  tcp  nowait  root    internal
echo    dgram   udp  wait    root    internal
ftp     stream  tcp  nowait  root    /usr/etc/ftpd ftpd
telnet  stream  tcp  nowait  root    /usr/etc/telnetd telnetd
login   stream  tcp  nowait  root    /etc/rlogind rlogind
tftp    dgram   udp  wait    nobody  /usr/etc/tftpd tftpd
talk    dgram   udp  wait    root    /etc/talkd talkd
spawn   stream  tcp  nowait  lioy    /usr/local/spawner spawner
. . .
```

Funzionamento di inetd (I)

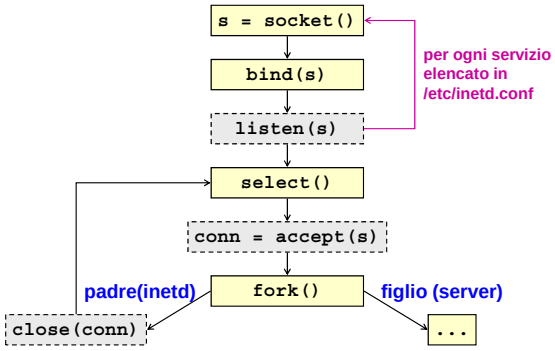

Funzionamento di inetd (II)

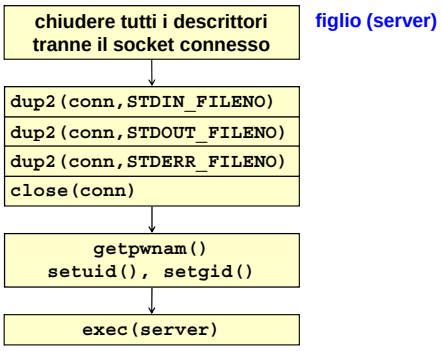

Server attivati da inetd

- **basta un comune "filtro" che:**
  - legga i dati da stdin (descrittore 0)
  - generi i risultati su stdout / stderr (descrittori 1 / 2)
- **problema con dati non ASCII**

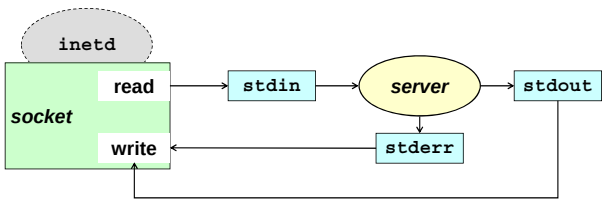

Altre soluzioni per il super-server

- **tcpd è un sistema per attivare in modo sicuro un server da inetd**
- **xinetd è una versione migliorata di inetd che incorpora già le funzionalità di tcpd**
- **tcpserver è un rimpiazzo completo di inetd+tcpd (ma non è un super-server)**

tcpserver

- **opera di D.J.Bernstein (http://cr.yp.to)**
- **è un filtro, in ascolto su una porta TCP**
- **una copia per ogni servizio da proteggere**
  - copie indipendenti = efficienza
  - piccolo = più facile da verificare
- **flessibilità, sicurezza e modularità**
- **meticolosa attenzione ai permessi e alle restrizioni**
- **controllo sul numero di processi concorrenti**
- **controllo d'accesso (indirizzi IP, nomi DNS)**
- **UID e GID impostabili**

tcpserver: attivazione

- **tcpserver rimane in ascolto su una porta (port) di un'interfaccia (host) ed esegue un'applicazione (program) per ogni richiesta ricevuta ...**
- **... se sono superati i controlli eventualmente specificati (-x)**

```
tcpserver [ -qQvdDoOpPhHrR1 ] [ -climit ]
  [ -bbacklog ] [ -xrules.cdb ] [ -ggid ]
  [ -uuid ] [ -llocalname ][ -ttimeout ]
  host port program [ arg ... ]
```

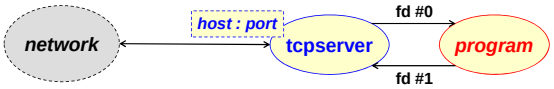

tcpserver: principali opzioni

- **-c*n* (massimo *n* processi simultanei)**
- **-x*r.cdb* (controlla le regole d'accesso in *r.cdb*)**
- **-ggid (imposta il group ID*)***
- **-u*uid* (imposta lo user ID)**
- **-b*n* (consente un backlog di *n* TCP SYN)**

tcpserver: regole di accesso

- **definire le regole secondo il seguente formato:**
  - utente@indirizzo:lista_di_istruzioni
  - lista_di_istruzioni ::= deny | allow , var. di ambiente
- **compilare con tcprules le regole passate, creando un file .CDB (struttura dati hash)**

```
tcprules regole.cdb regole.tmp < regole.txt
```

```
(regole.txt)
130.192.:allow
192.168:allow,CLIENT="private"
:deny
```