ESD Electronic Systems Design

Synthesis Verification Testing Power Communication

Sistemi operativi distribuiti

Introduzione

- Definizione e collocazione
- Comunicazione in sistemi distribuiti
- Gestione di processi distribuiti
  - Concorrenza
  - Sincronizzazione
  - Deadlock
  - Migrazione
- Gestione di file system distribuiti
- Gestione memoria distribuita

DEFINIZIONE E COLLOCAZIONE

Definizione

- Sistema distribuito:
  - “Un sistema distribuito è un insieme di computer indipendenti che appaiono agli utenti come un singolo computer”
  - “Un sistema distribuito è un insieme di processori che non condividono memoria e clock”
- Termini chiave:
  - “indipendenti”
  - “senza condivisione”

Pro e Contro

- Vantaggi
  - Rapporto prezzo/prestazioni migliore rispetto a mainframe
  - Aumento della potenza di calcolo (load sharing)
  - Condivisione delle risorse (es.: periferiche costose disponibili per molti utenti, file condivisi, …)
  - Affidabilità (tolleranza ai guasti)
  - Scalabilità (incrementare la potenza di calcolo richiede poco sforzo)

Pro e Contro

- Svantaggi
  - Complessità del SW
  - Problemi dovuti alla rete (se la rete satura?)
  - Sicurezza

Collocazione

- Collocazione nello spazio HW/SW
  - HW: scarsamente connesso
  - SW: fortemente connesso

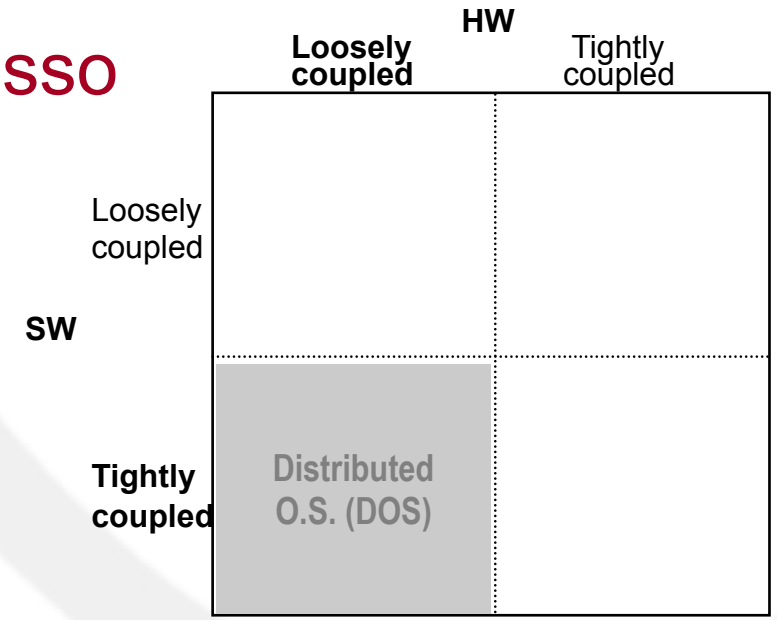

COMUNICAZIONE

Comunicazione distribuita

- Sistemi senza memoria condivisa ➡ il meccanismo della comunicazione richiede schemi alternativi
  - Basati su scambio di messaggi
  - Problema: processi/host spesso remoti (rete)
    - Identificazione richiede conoscenza dell'architettura di rete

Comunicazione distribuita

- Problemi fondamentali
  - Naming: come fanno due processi remoti a “trovarsi” per comunicare
  - Routing: come vengono inviati i messaggi sulla “rete”
  - Connessione: come due processi mandano una sequenza di messaggi
  - Contesa: come vengono risolti conflitti dovuti a richieste multiple della rete

Problematiche

- Struttura fisica: architettura
- Struttura logica: protocolli
- Schemi di comunicazione

Architettura

- Vari modi di collegare i vari “nodi”
- Criteri di confronto
  - Costo di base
    - Quanto costa collegare i vari nodi?
  - Costo della comunicazione
    - Quanto tempo richiede l’invio del messaggio da A a B?
  - Affidabilità
    - Cosa avviene se un collegamento cessa di funzionare?

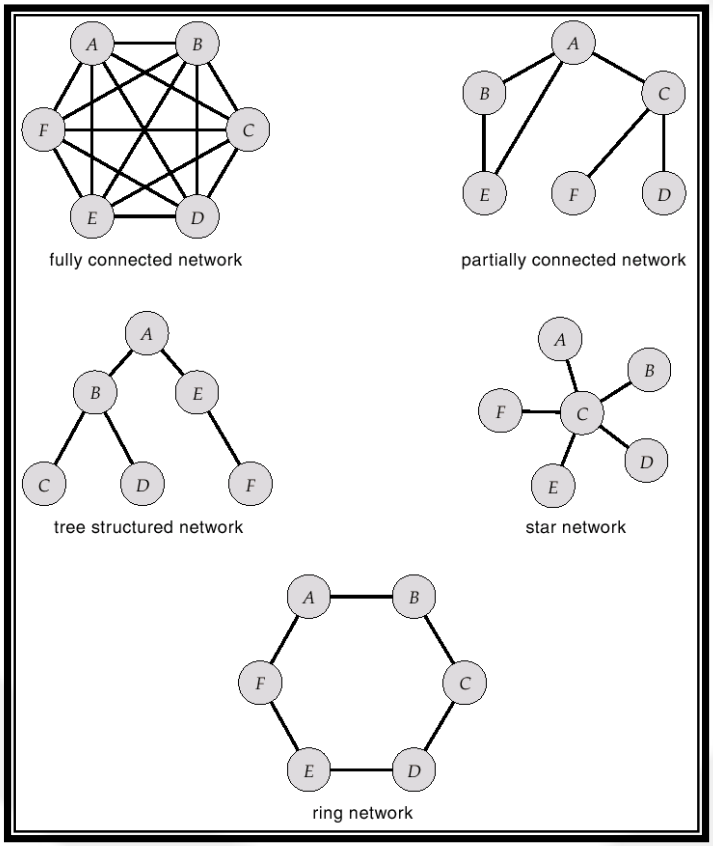

Tipi di rete: LAN

- Local-Area Network (LAN)
  - coprono piccole aree geografiche (<10Km)
- Topologie fisiche
  - bus, anello o stella
- Velocità ≈ 10 Mbps/10Gbps
- Broadcast veloce ed efficiente
- Nodi:
  - Workstation e/o PC
  - Uno o pochi “mainframe”

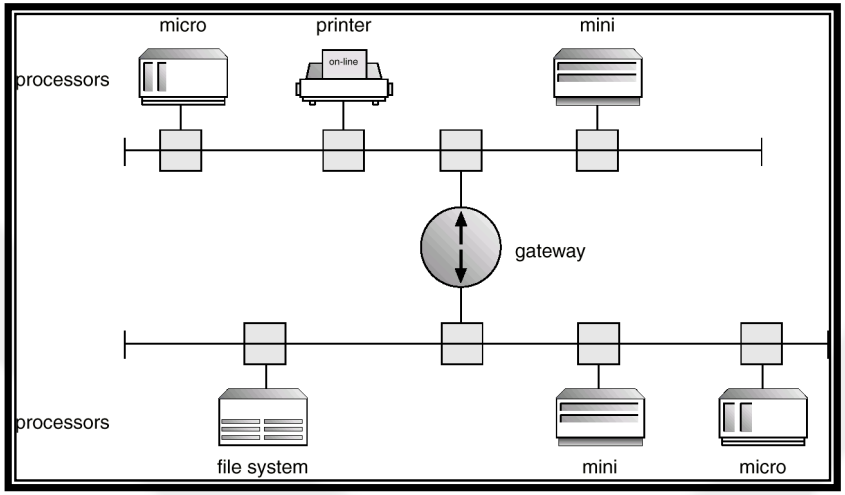

Tipi di rete: WAN

- Wide-Area Network (WAN)
  - collegano siti geograficamente lontani
- Connessioni punto-punto su linee tipicamente affittate da compagnie telefoniche
- Velocità variabile
  - Arpanet originale: 56 kbps
  - Link tipico (T1) = 1.5Mbps
  - Backbone tipico (T3) = 45Mbps
  - Link ATM = 155Mbps
- Broadcast richiede tipicamente messaggi multipli
- Nodi
  - Spesso una serie di “mainframe”

WAN: esempio

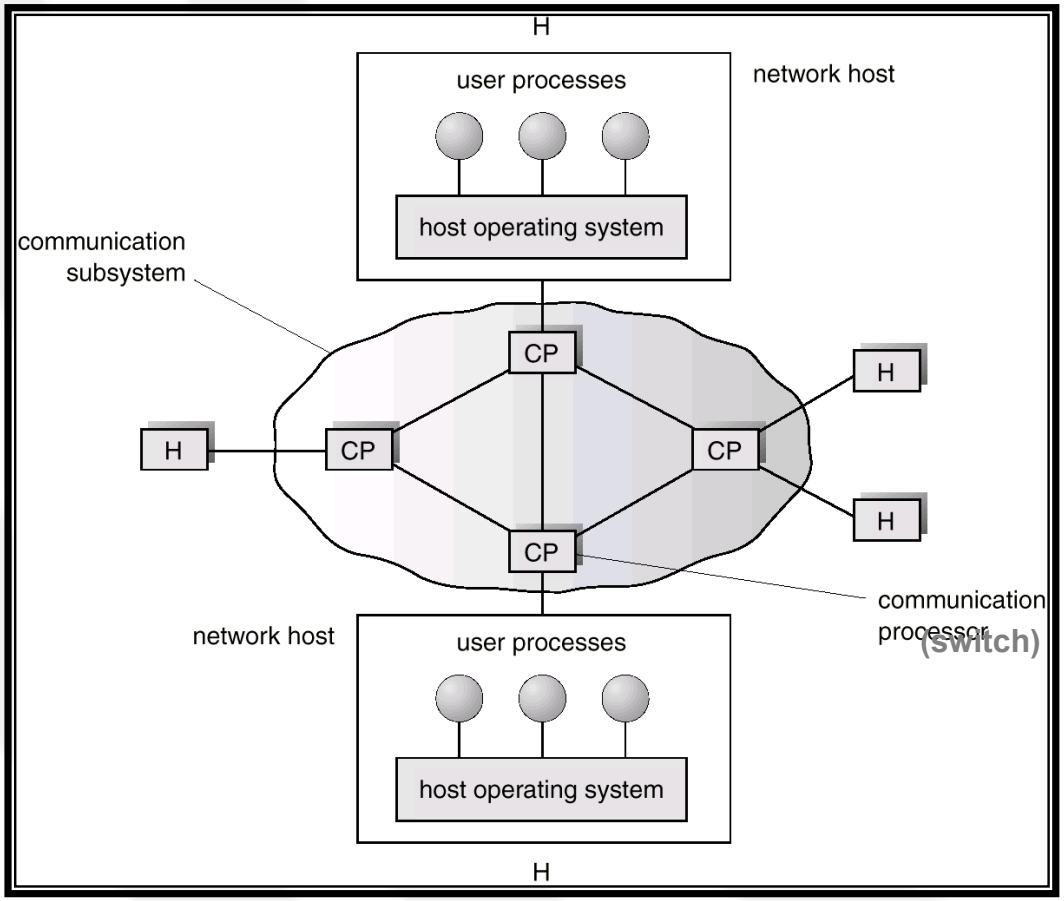
H
user processes
network host
host operating system
communication
subsystem
CP
H
H
CP
CP
H
CP
communication
processor
(switch)
network host
user processes
host operating system
H

Protocolli

- L'operazione di scambio di informazioni tra due macchine va oltre la semplice presenza di un collegamento fisico
- Necessario definire
  - Regole relative al formato dei dati
  - Regole relative alla semantica (informazioni di controllo e gestione errori)
  - Regole relative alla tempistica (velocità)

Protocolli

- Protocollo = insieme di regole
  - Gestione delle regole tipicamente modulare
  - Protocolli a livelli
- Due tipi principali:
  - Protocolli orientati alla connessione
    - Connessione stabilita in modo esplicito
    - Es.: Telefonata
  - Protocolli privi di connessione
    - Dati scambiati senza accordo preventivo
    - Es.: Lettera

Protocolli

- Due “modelli” di protocollo
  - Modello OSI
    - 7 livelli ben definiti
    - Standard ISO
    - Poco utilizzato in pratica
  - Modello TCP/IP
    - Architettura più flessibile
    - 5 Livelli “concettuali”
    - Sviluppato a partire da protocolli esistenti ai vari livelli
    - Standard di fatto

ISO-OSI vs. TCP-IP

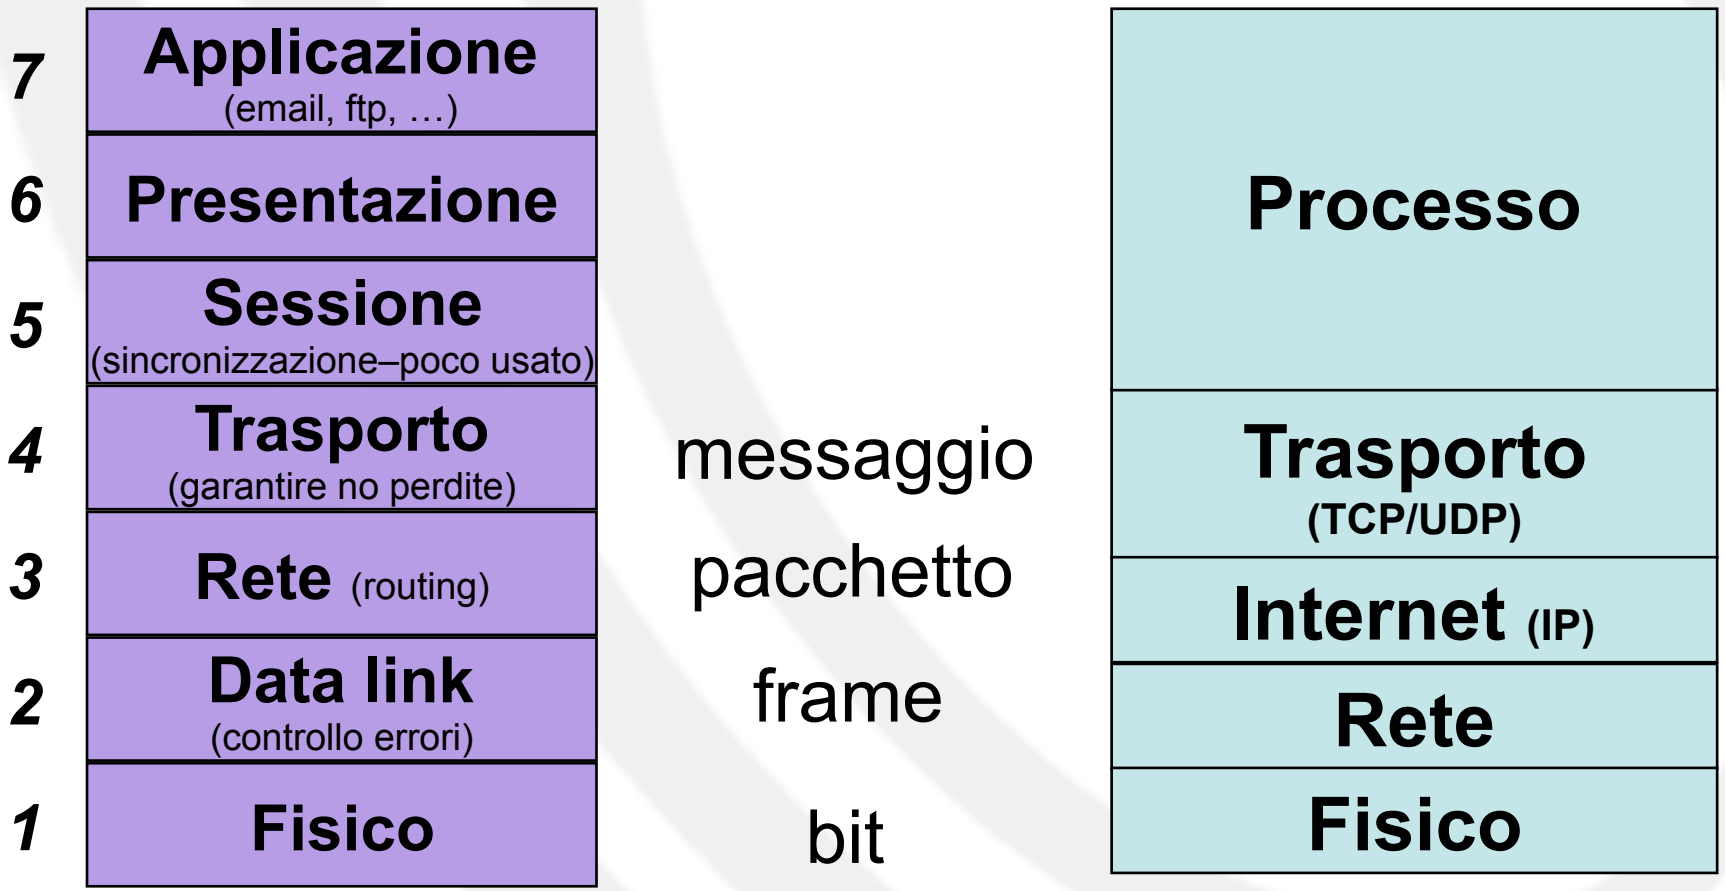

Protocollo TCP/IP: esempio stack

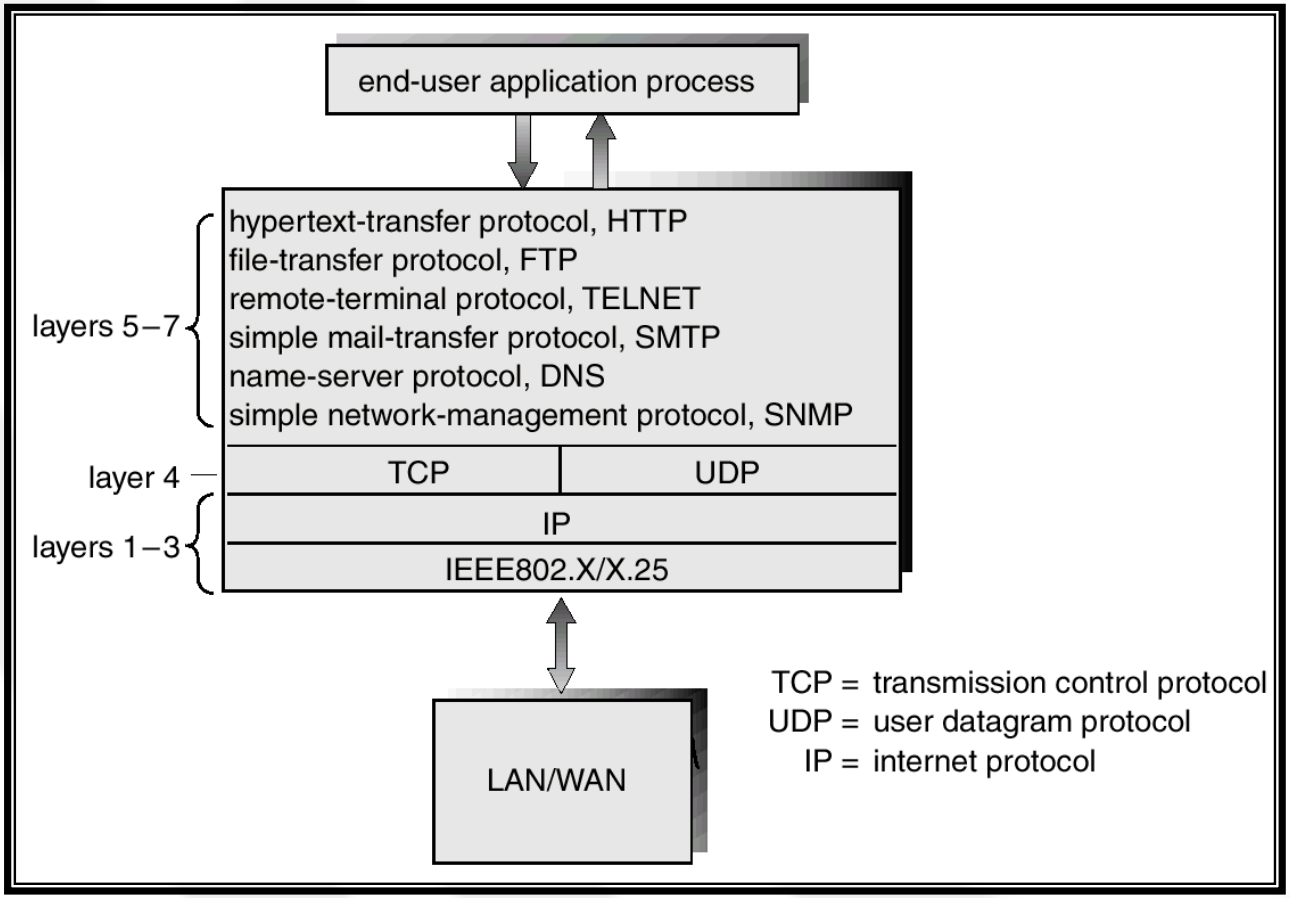

Schemi di comunicazione

- Architettura dei sistemi distribuiti “veri”
  - Tipo WAN
  - Schema basato su protocolli è adatto!
    - Gestione garantita dei vari dettagli
    - Overhead ammortizzato dalle (bassa) velocità della rete

Schemi di comunicazione

- Architettura di sistemi tipo cluster
  - Tipo LAN (esigenze simili)
  - Schema basato su stack (completo) di protocolli è pesante!
  - Necessario uno schema più essenziale (ed efficiente)
    - Overhead non deve penalizzare la velocità della rete
  - Due paradigmi
    - Modello client-server
      (protocollo richiesta/risposta - request/reply)
    - Chiamata di procedura remota
      (RPC e varianti)

Modello client-server

- Server: programma che fornisce un servizio
  - Rende disponibile delle risorse ad altri programmi che sono eseguiti sulla rete
  - Risorse di vario tipo (DB, file system, stampante…)
  - Server esegue sulla macchina alla quale la risorsa è vincolata ed attende passivamente le richieste
  - Spesso lanciati al boot
- Client: programma che usa una risorsa
  - Può essere eseguito sulla macchina alla quale la risorsa è vincolata o su qualunque altra macchina
  - Effettua una connessione attraverso la rete al server

Protocollo richiesta/risposta

- Protocollo connectionless
- Basato su due operazioni essenziali

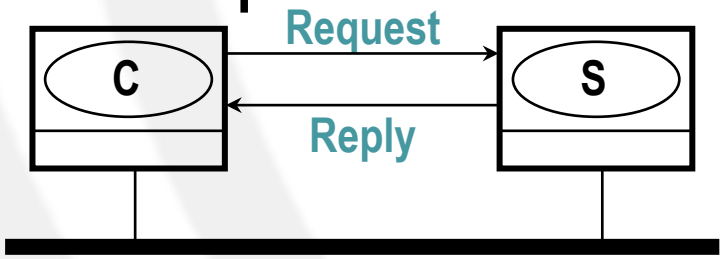

- In termini di protocolli
  - No routing
  - No connessioni
  - No sessione

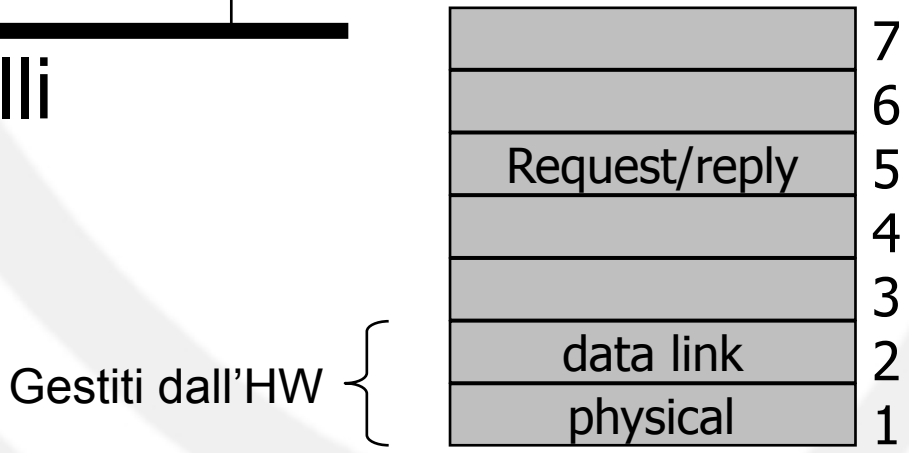

Modello client-server

- Problematiche
  - Tipo di indirizzamento
  - Primitive bloccanti e non
  - Primitive bufferizzate e non
  - Primitive affidabili e non

Indirizzamento client-server

- Per spedire un messaggio, il client deve conoscere l'indirizzo del server
- Tre modi:
  - Cablare indirizzo unico nel codice del client
  - Sfruttare broadcast
  - Lookup dell'indirizzo attraverso un name-server

Indirizzamento client-server

1

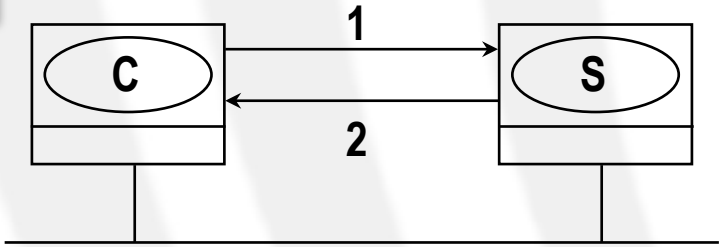

Cablo macchina.processo nel codice del client
1: Richiesta a 234.0
2: Risposta a 199.0

2

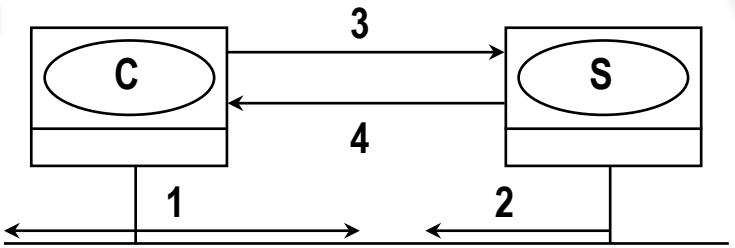

I server scelgono un numero a caso
1: Richiesta broadcast per conoscere # macchina
2: Sono io!!
3: Richiesta
4: Risposta

3

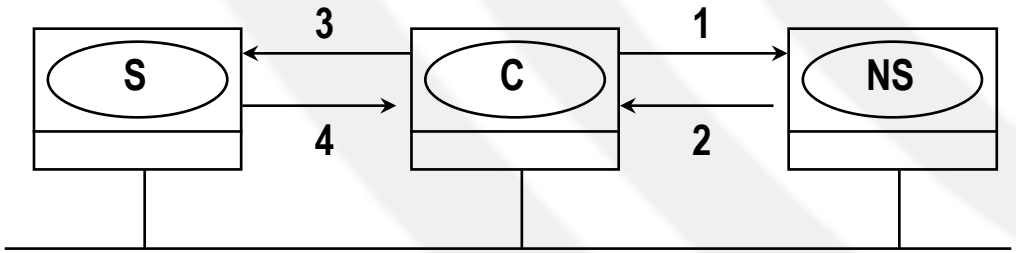

Il client usa il nome del server
Cerca l'indirizzo a run-time
1: Richiesta indirizzo al name-server
2: Risposta del name-server
3: Richiesta al server
4: Risposta dal server

Indirizzamento client-server

- Macchina . Processo (cablato nel codice del client)
  - Non trasparente (Se il server cambia macchina?)
- Broadcast
  - Ogni server sceglie un ID univoco
  - Per sapere l'indirizzo della macchina su cui gira il server, il client invia una richiesta broadcast a tutte le macchine
  - La macchina su cui gira il server risponde fornendo il suo indirizzo
  - Oneroso a causa del broadcast
- Name-server
  - Nome del server cablato nel client
  - Il client chiede l'indirizzo reale ad un particolare name-server

Primitive bloccanti vs. non bloccanti

Bloccante

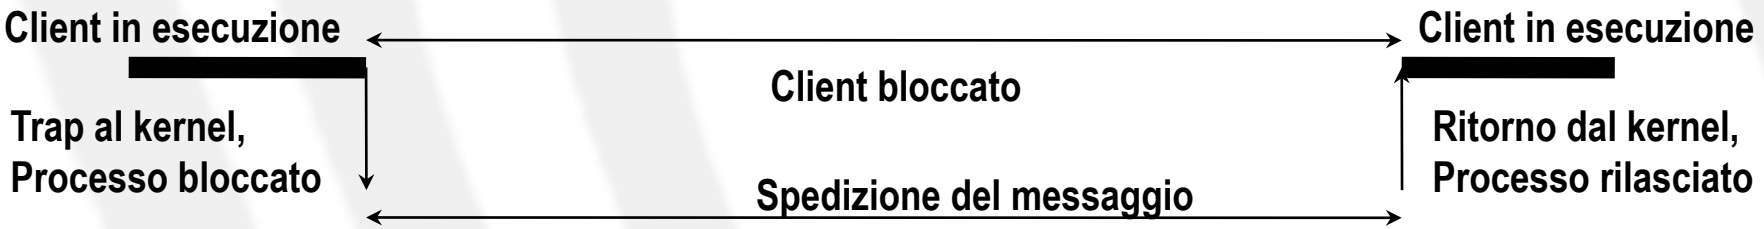

Non bloccante

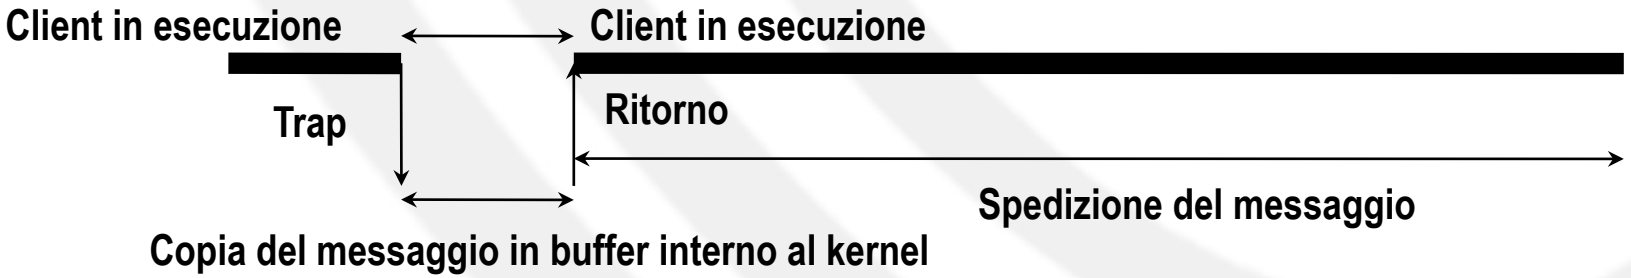

Primitive bloccanti vs. non bloccanti

- Esiste sia SEND che RECEIVE bloccante e non bloccante
- SEND bloccante (sincrona)
  - Problema: CPU “sprecata” durante la trasmissione dei messaggi

Primitive bloccanti vs. non bloccanti

- SEND non bloccante (asincrona)
  - Problemi
    - Client non ha la certezza di quando il messaggio sia effettivamente arrivato
    - Quando posso cancellare/modificare il buffer usato per memorizzare il messaggio da spedire?
  - Soluzioni
    - Con copia
      - Buffer copiato su buffer interno al kernel
      - Tempo di CPU sprecato per copia
    - Con interrupt
      - Interrupt al mittente quando il messaggio è stato spedito
      - Difficile da programmare

Primitive bufferizzate vs. non bufferizzate

- Non bufferizzate = no memoria locale nel server
  - Indirizzamento al singolo processo
  - Il server esegue receive(address, & message)
  - Problemi in caso di mancato “ascolto” del server
    - Il client deve ritrasmettere nella speranza che il server si metta in ascolto
    - Client potrebbe desistere

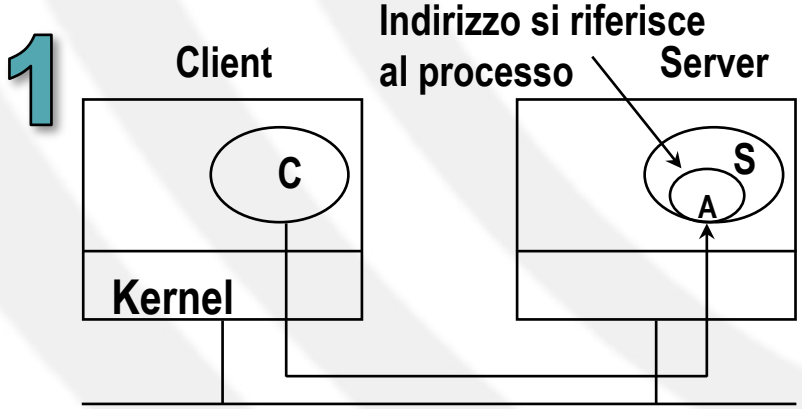

Primitive bufferizzate vs. non bufferizzate

- Bufferizzate
  - Client invia messaggio a mailbox
    - Mailbox simile a una coda limitata
  - Server preleva il primo messaggio dalla mailbox quando desidera
  - Stessi problemi del caso non bufferizzato per mailbox piena

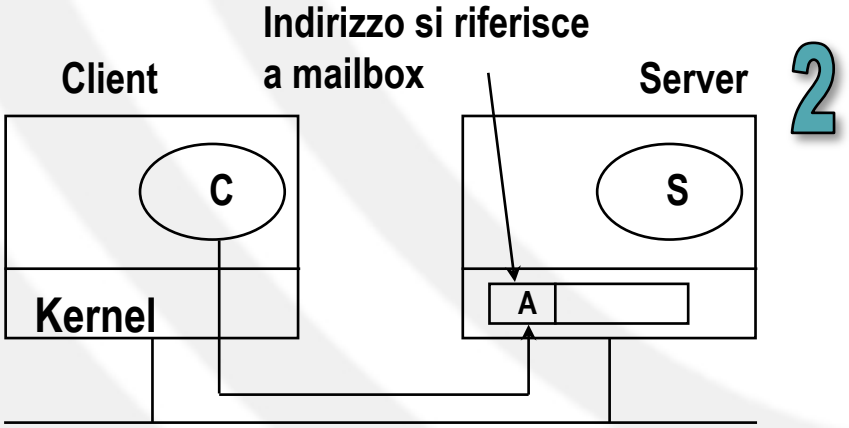

Primitive affidabili vs. non affidabili

- Affidabilità influenza semantica scambio messaggi
  - Send non affidabile (utente deve farsi carico del problema)
  - Send con acknowledgement (ACK) bidirezionale
  - Send con acknowledgement (ACK) unidirezionale
    - Risposta del server come ACK (nessuna garanzia)
  - Varianti intermedie

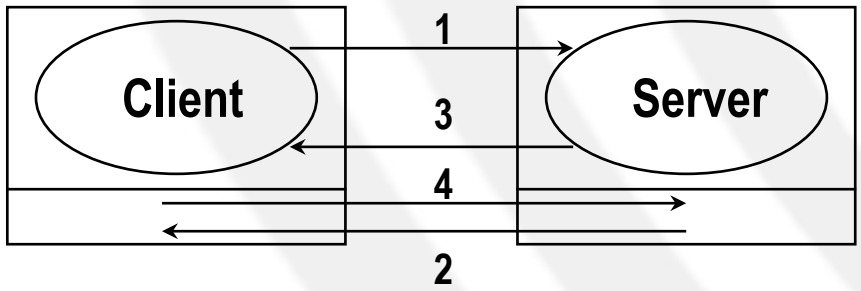

1. Richiesta del client al server
2. ACK del kernel S al kernel C
3. Risposta del server al client
4. ACK del kernel C al kernel S

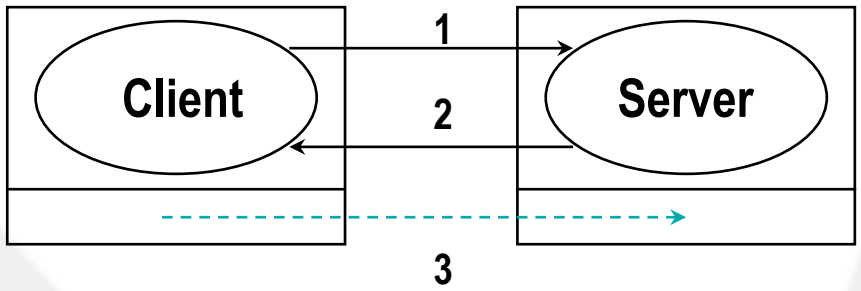

1. Richiesta del client al server
2. Risposta del server al client
3. ACK del kernel C al kernel S (opzionale)

Modello client-server

	Opzione 1	Opzione 2	Opzione 3
Indirizzamento	Macchina.processo	Indirizzo casuale (broadcast)	Name server
Blocco	Primitive bloccanti	Non bloccanti con copia	Non bloccanti con interrupt
Bufferizzazione	NO: Messaggi inaspettati vengono scartati	NO: Messaggi inaspettati conservati per poco tempo	SI: Mailbox
Affidabilità	NO	Req-Ack Reply-Ack	Req-Rep-Ack

Modello client-server

- Paradigma basato su I/O
  - Send e receive
- Diverso rispetto all'uso di servizi su un sistema centralizzato (chiamata a procedura)
- Paradigma alternativo:
  - Chiamate remote a procedura (Remote Procedure Calls)

RPC (Remote Procedure Call)

- Un processo su un sistema (locale) invoca una procedura (remota) in modo trasparente
- Utilizza lo schema classico della chiamata a procedura
  - Richiesta: la chiamata a procedura
  - Risposta: il risultato ritornato dalla procedura stessa

Schema operativo

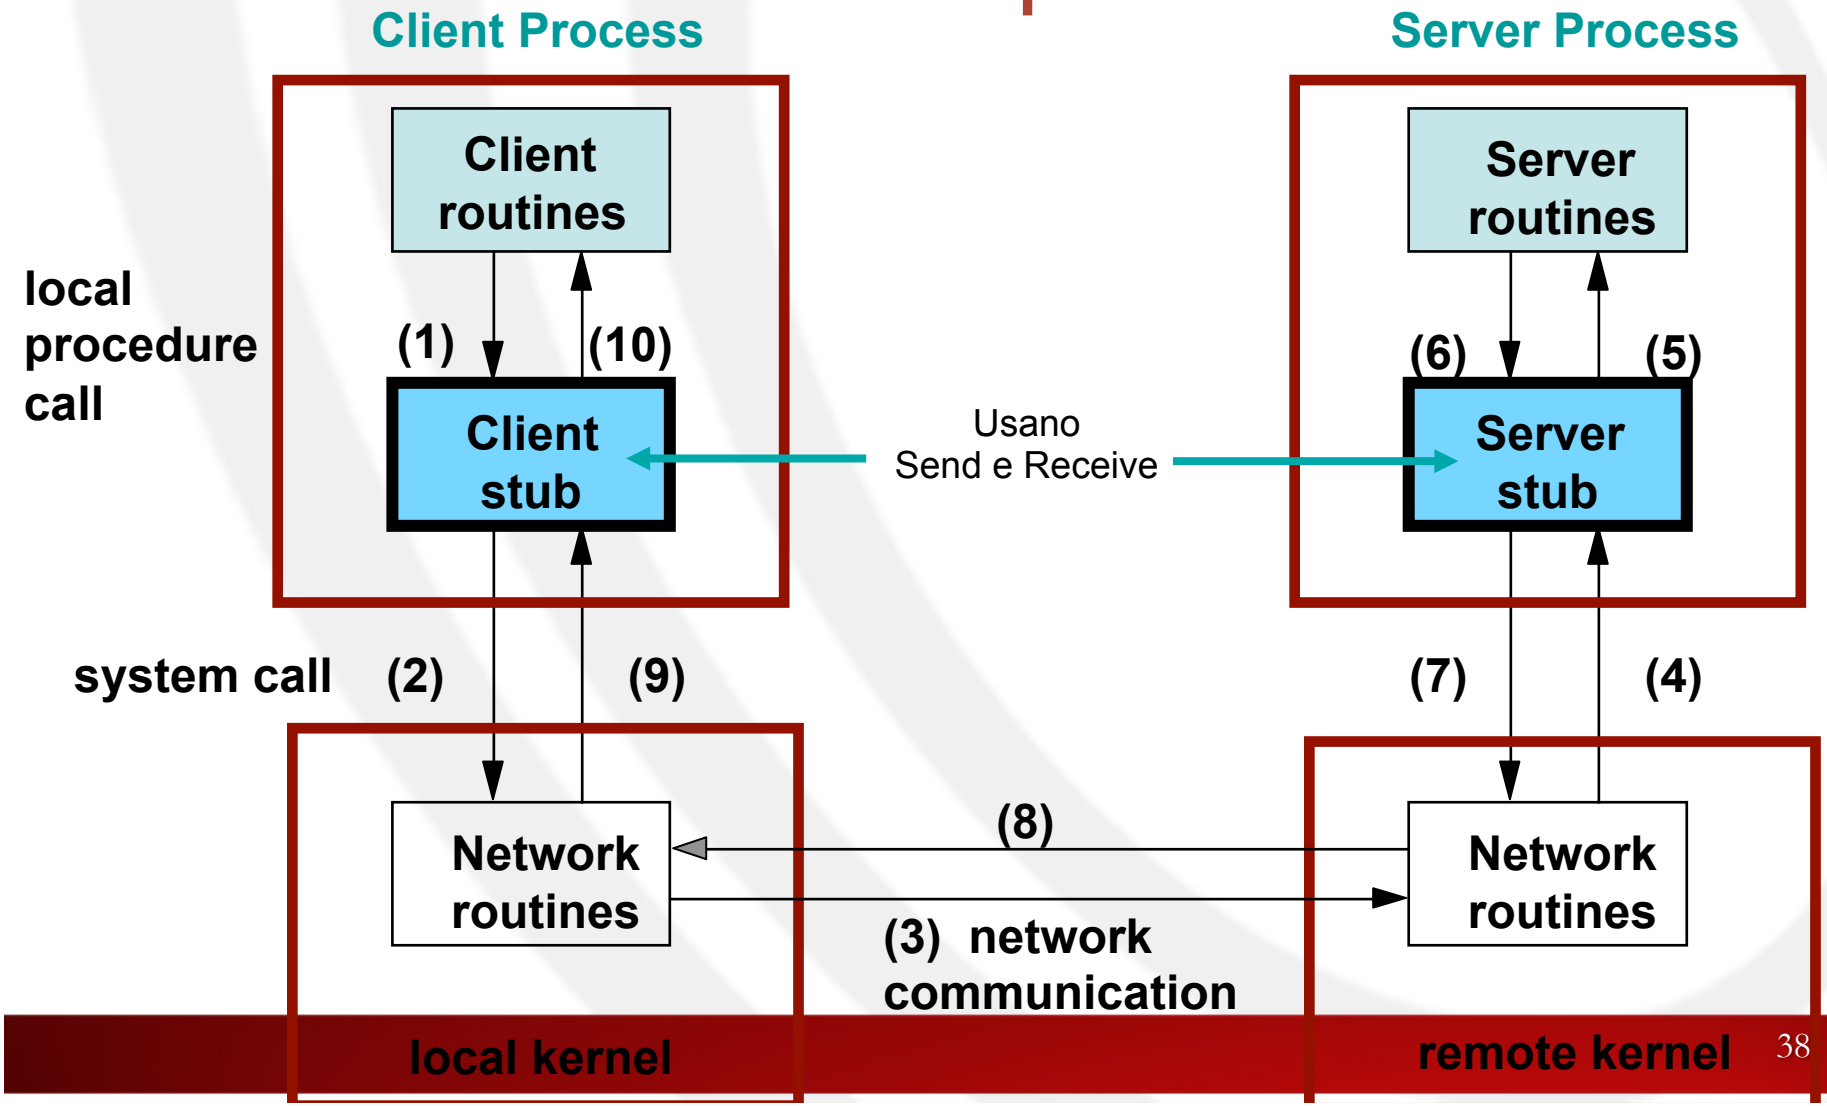

Schema operativo

1. Il client invoca una procedura locale (client stub)
   - apparentemente invoca la procedura remota
     - Stub = procedura remota nello spazio di indirizzamento del client
2. Il client stub:
   - Impacchetta gli argomenti (marshaling) per la procedura remota, trasformandoli in un formato "standard", costruendo uno o più messaggi
   - Chiede al kernel locale (system call) di inviare i messaggi al sistema remoto
   - Esegue *receive* bloccante

Schema operativo

3. Messaggi trasferiti sulla rete al sistema remoto
4. Server stub
   - In attesa, riceve la richiesta remota
   - Disimpacchetta (unmarshaling) gli argomenti dal messaggio e li converte nel formato locale
5. Server stub esegue una procedura locale che invoca l'effettiva funzione sul server
6. Procedura server termina e ritorna al server stub i risultati

Schema operativo

7. Server stub
   - Converte risultati nel formato “standard” e marshal in messaggi di rete da mandare al client stub
   - Chiede al kernel di inviare i messaggi
   - Esegue *receive* bloccante
8. Messaggi trasferiti sulla rete al client stub
9. Il client stub:
   - In attesa, riceve la risposta
   - Unmarshal dei messaggi e conversione nel formato locale
10. Client stub ritorna alla funzione locale

Binding

- Meccanismo con cui il client individua il server
- Binding dinamico
  - Un server che offre servizio RPC si registra presso un binder
  - Binder = server in esecuzione sullo stesso host del servizio RPC
    - Associato ad una specifica porta (111 in Unix)
  - Registrazione = segnalazione di
    - Identificatore (numero del servizio RPC & versione)
    - Indirizzo di trasporto (porta su cui il servizio RPC è in ascolto)
  - Il client che deve fare una chiamata RPC contatta prima il binder del server per ottenere l'indirizzo corretto a cui la richiesta RPC deve essere mandata
- In UNIX ➡ rpcbind

Applicazioni Client-Server via RPC (UNIX)

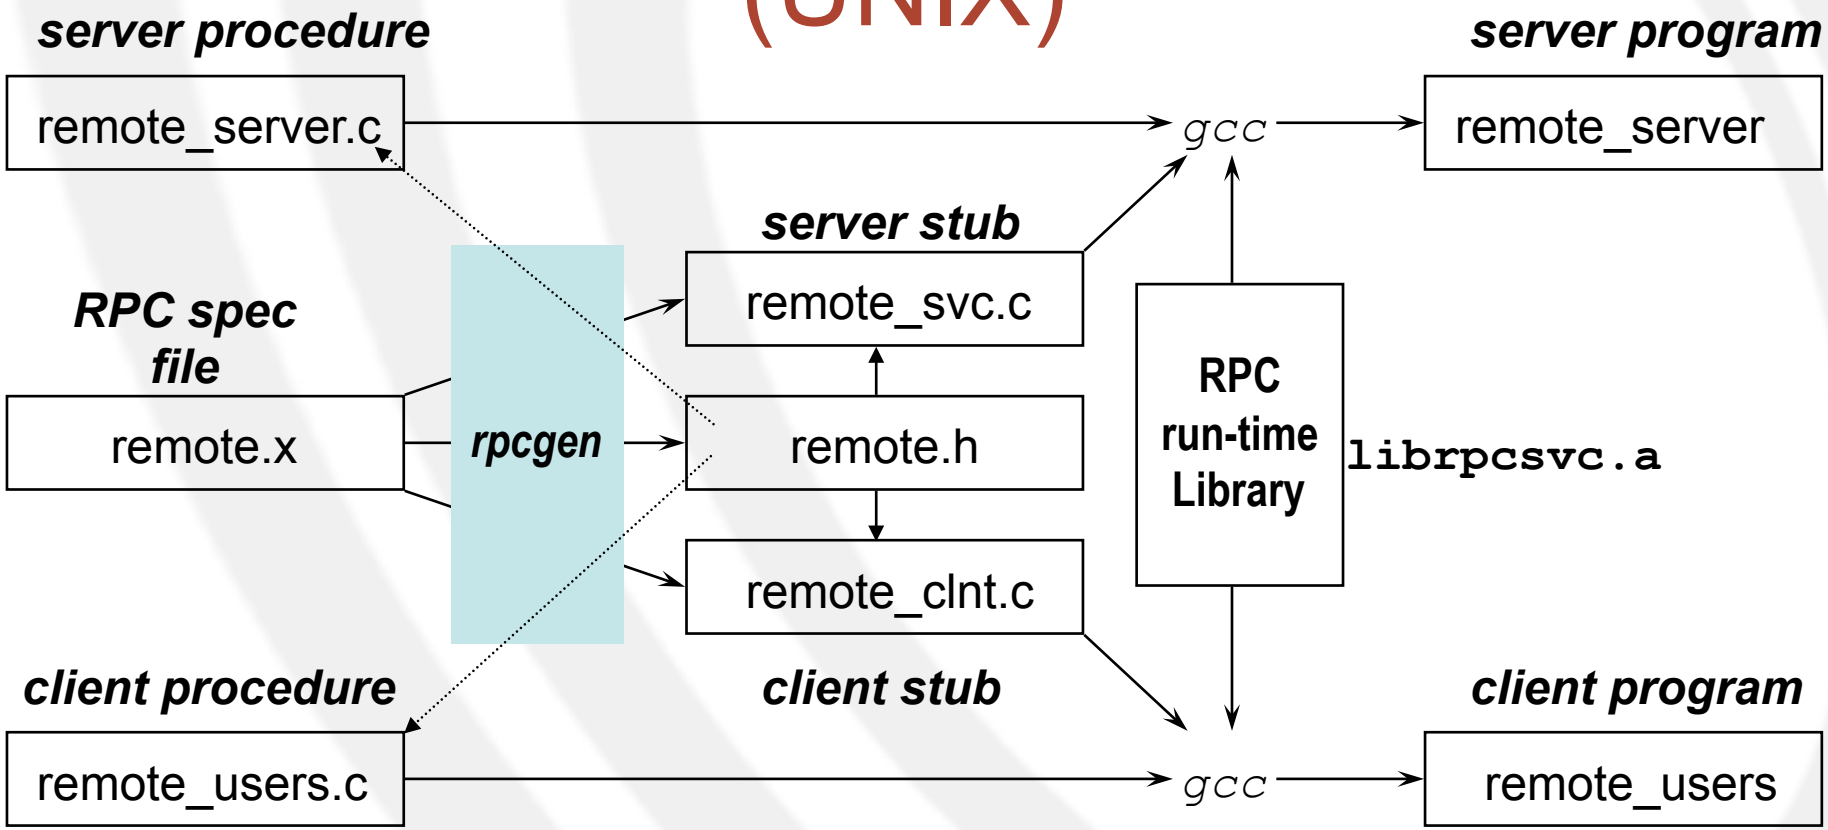

remote.x, remote_server.c

Linguaggio RPC

```
/* remote.x */
program REMOTE_PROG {
    version REMOTE_VERS {
            string REMOTE_USERS(void) = 1;
    } = 1;
} = 0x32345678;
```

- Use `rpcgen` to generate **`remote.h, remote_svc.c, remote_clnt.c`**

  `rpcgen remote.x`
- To compile the server program:

  `gcc -o remote_server remote_server.c remote_svc.c -lrpcsvc`
- To compile the client program:

  `gcc -o remote_users remote_users.c remote_clnt.c -lrpcsvc`

```
/* remote_server.c - remote procedure;
 called by server stub */
#include <stdio.h>
#include <string.h>
#include <utmp.h>
#include <rpc/rpc.h>
#include "remote.h"

char **remote_users_1(void *p, struct svc_req *r)
{
 static char *ptr;
 FILE *fp;
 struct utmp tmp;
 char buffer[1024];
 char tmp_buff[10];

 buffer[0] = '\0';
 fp = fopen("/etc/utmp", "rb");
 while (!feof(fp)){
   fread(&tmp, sizeof(struct utmp), 1, fp);
   if (strlen(tmp.ut_name)){
     sprintf(tmp_buff,"%.8s", tmp.ut_name);
     strcat(buffer, tmp_buff);
   }
 }
 fclose(fp);
 ptr = buffer;
 return(&ptr);
}
```

Info su accessi utenti

remote.h

```
/*
 * Please do not edit this file.
 * It was generated using rpcgen.
 */

#ifndef _REMOTE_H_RPCGEN
#define _REMOTE_H_RPCGEN

#include <rpc/rpc.h>

#define REMOTE_PROG ((unsigned long)(0x32345678))
#define REMOTE_VERS ((unsigned long)(1))
#define REMOTE_USERS ((unsigned long)(1))

extern char ** remote_users_1(void *p, struct svc_req *r);

extern int remote_prog_1_freeresult();

#endif /* !_REMOTE_H_RPCGEN */
```

remote_users.c

```
/* remote_users.c - Client program for the remote users service. */
#include <stdio.h>
#include <rpc/rpc.h>
#include "remote.h"

main(argc, argv)
int argc;
char *argv[];
{
 CLIENT *cl;
 char *server;
 char **sresult;

 if (argc != 2) {
    fprintf(stderr, "usage: %s hostname\n", argv[0]);
    exit(1);
 }
 server = argv[1];

 if ((cl = clnt_create(server, REMOTE_PROG, REMOTE_VERS, "udp")) == NULL){
    clnt_pcreateerror(server);
    exit(2);
 }

 if ((sresult = remote_users_1(NULL, cl)) == NULL){
    clnt_perror(cl, server);
    exit(3);
 }
 printf("Users logging on Server %s\n%s\n", server, *sresult);

 clnt_destroy(cl);
 exit(0);
}
```

Problemi implementativi

- Problemi
  - Passaggio di puntatori e array
    - Puntatore = indirizzo in memoria (quale: server o client?)
    - Soluzione
      - Call by copy/restore
        - » Copy solo per parametri che contengono dati inviati dal client necessari al server
        - » Restore solo per parametri che contegono dati modificati dal server necessari al client
  - Funzioni con numero di argomenti variabile
    - Si usa una struttura

Problemi implementativi

- Necessità della definizione della semantica in caso di errore
  - Impossibilità di trovare il server
  - Richieste perse
  - Risposte perse
  - Crash del server
  - Crash del client
- Soluzioni diverse per ogni tipo di errore

Semantica in caso di errore

- Impossibilità di trovare il server
  - Cause: server down, versioni incompatibili …
  - Codice di errore speciale ➡ ambiguo
    - Es.: -1 può essere confuso con il risultato di un operazione aritmetica
  - Eccezioni/signal ➡ perdita di trasparenza rispetto alle procedure locali
- Risposte perse
  - Uso di timeout associato alla richiesta ➡ possibile solo per richieste idempotenti (ripetibili) (Es.: Non per trasferimenti di denaro!!!)
  - Associazione di numeri progressivi alle richieste se richieste non-idempotenti
- Richieste perse
  - Uso di timeout associato alla richiesta (e ritrasmissione)

Semantica in caso di errore

- Crash del server
  - Equivalente a risposta persa ma …
  - … crash prima o dopo dell' esecuzione richiesta?
  - Semantica diversa a seconda del comportamento del client (allo scadere del timeout)
    - At least once: messaggio viene inviato fino a che non si riceve una risposta (1 o più risposte)
    - At most once: eccezione allo scadere del timeout (al max una risposta, ma anche 0)
    - No promise: (0 o più risposte) facile da implementare
    - Exactly once: ideale, non realizzabile
- ➔ Sistemi isolati ≠ sistemi distribuiti
  - Nei primi macchina server = macchina client!

Semantica in caso di errore

- Crash del client
  - Risposta non trova il client ➡ processo sul server orfano
  - Orfani causano problemi
    - Spreco CPU
    - Blocco risorse (es.: file)
    - Client riparte, esegue la richiesta, arriva risposta orfano precedente!
    - …

Semantica in caso di errore

- Eliminazione degli orfani
  - Basata su log (extermination)
    - Elenco richieste del client mantenuto in un file di log nel client
    - Al reboot del client orfani vengono uccisi
  - Basata sull'utilizzo di "epoche" (reincarnation)
    - Ogni reboot di un client inizia una nuova epoca, inviata a tutti gli host in broadcast
    - Orfani corrispondenti ad altre "epoche" vengono terminati
  - Basata su timeout (expiration)
    - Ad ogni RPC viene associato un tempo massimo di completamento
- Non esiste una soluzione ottima

Varianti di RPC

- RPC = schema base di comunicazione
- Altre varianti
  - RMI (Java): versione ad oggetti di RPC
- Modelli alternativi
  - Basati su tecnologie OO
  - Concetto di object broker (OB)
    - Sorta di elenco di servizi disponibili nella rete
    - Comunicazioni tra client e server passano attraverso l'OB
    - Esempi
      - Microsoft DCOM (OLE)
      - OMG CORBA

Comunicazione di gruppo

- Spesso utile/necessario comunicare non tra processi singoli ma tra gruppi di processi
  - Es.: un gruppo di file server cooperanti che offrono un unico servizio
- Paradigma RPC intrinsecamente 1 a 1!
- Concetto di gruppo è dinamico
  - Processi entrano ed escono dal gruppo
  - Processi possono appartenere a più gruppi
- Gruppo è visto come singola entità

Comunicazione di gruppo

- Problematiche
  - Tipo di comunicazione
  - Struttura dei gruppi
  - Regole di appartenenza al gruppo
  - Indirizzamento di gruppo
  - Atomicità
  - Ordine dei messaggi

Tipo di comunicazione

- Dipende dal supporto HW
- Multicasting
  - Indirizzo di rete su cui più host possono “ascoltare”
  - Comunicazione di gruppo tramite un indirizzo multicast per ogni gruppo
- Broadcasting
  - Indirizzo di rete su cui tutti gli host possono “ascoltare”
  - Comunicazione di gruppo tramite filtraggio dei pacchetti
- Unicasting
  - Assenza di multi-/broadcast
  - Comunicazione di gruppo tramite invio selettivo ai membri

Struttura dei gruppi

- Gruppi chiusi vs. aperti
  - Gruppi chiusi
    - solo i membri possono mandare messaggi al gruppo
    - I non membri possono mandare messaggi a singoli membri
    - Es.: calcolo parallelo – no interazione col mondo esterno
  - Gruppi aperti = non chiusi
    - Es.: gruppo di server replicati
      → client devono poter parlare con il gruppo
      → server devono poter comunicare tra loro

Struttura dei gruppi

- Gruppi paritari (peer) vs. gerarchici
  - Gruppi peer
    - Decisioni “collegiali”, non c’è un capo
    - Vantaggio: robustezza, se cade un processo non è un dramma
    - Svantaggio: complicato prendere decisioni → overhead x votazione
  - Gruppi gerarchici
    - C’è un coordinatore che distribuisce il “lavoro” tra i worker
    - Scarsa tolleranza ai guasti, se cade il coordinatore … dramma
    - Decisioni semplificate (coordinatore può decidere da solo)

Regole di appartenenza al gruppo

- Meccanismo di entrata/uscita da un gruppo
  - Tramite group server
    - Tiene traccia di tutti i gruppi e di chi vi appartiene
    - Semplice ed efficiente ma …
    - … centralizzato → scarsa tolleranza ai guasti, se cade …
  - Gestione distribuita
    - Entrata: messaggio di richiesta
    - Uscita: messaggi di addio a tutti

Regole di appartenenza al gruppo

- Problemi
  - Crash di un membro del gruppo ➔ uscita senza messaggio
    - Gli altri se ne accorgono dopo un pò
  - Sincronizzazione tra entrata/uscita dal gruppo e ricezione dei messaggi
    - Quando P entra deve iniziare a ricevere tutti i messaggi inviati da altri dopo la sua entrata
    - Quando P esce non deve ricevere/spedire + nulla da/per gli altri

Indirizzamento di gruppo

- Tramite il supporto del S.O. e dell'HW
  - Multicast vs. broadcast vs. unicast
  - Trasparente rispetto al sender
- Tramite esplicita lista di destinazioni
  - Lista di indirizzi associata al messaggio
  - Non trasparente (serve conoscere chi appartiene al gruppo)
- Predicate addressing
  - Tipo broadcast, ma selettivo
  - Ogni messaggio contiene un predicato che deve essere valutato dall'host che lo riceve (Vero = accettato, Falso = respinto)
  - Es.: invio di un msg a tutte le macchine per chiedere a quelle con almeno 4MB di memoria libera di eseguire un processo

Atomicità

- Garanzia che un messaggio inviato ad un gruppo sia ricevuto o da tutti o da nessuno (es:. database replicato)
- Difficile da realizzare
  - Utilizzo di acknowledgement efficace solo se gli host del gruppo sono tutti attivi
  - Se il mittente cade e alcuni destinatari hanno perso il msg?
  - Soluzione possibile
    - Il processo manda un messaggio al gruppo e inizializza un timer
    - Ogni processo che riceve un messaggio “non già ricevuto”, lo rimanda a tutti i membri del gruppo

Ordine dei messaggi

- Ordine deve essere uguale per tutti i membri!
- Problema
  - Mezzo di comunicazione spesso non deterministico (es. LAN)
- Soluzioni
  - Ordine di tempo globale: l'ordine vero (difficile)
  - Ordine di tempo consistente: non quello vero, ma uno consistente (uguale per tutti)
  - Ordine causale: ordine consistente solo per messaggi tra i quali esiste una relazione di causalità (irrilevante per gli altri)

Riepilogo

- Sistema operativo distribuito
  - Concetti applicabili a
    - Sistemi distribuiti “veri”
    - Sistemi tipo cluster
- Problematiche
  - Comunicazione basata su “scambio di messaggi”
  - Diverse esigenze tra sistemi con diversi supporti di comunicazione (WAN vs. LAN)
    - Protocolli classici vs. protocolli semplificati
      - Client/server
      - RPC
  - Comunicazione di gruppo