ESD Electronic Systems Design

Synthesis Verification Testing Power Communication

Sincronizzazione nei sistemi distribuiti

Sommario

- Sincronizzazione dei clock
- Mutua esclusione
- Transazioni
- Deadlock

- Le tecniche adottate per i S.O. tradizionali non vanno bene
  - Suppongono la presenza di memoria condivisa!

Proprietà degli algoritmi distribuiti

- Le informazioni sono distribuite fra molte macchine
- I processi prendono decisioni in base alle informazioni locali
- Evitare la presenza di un “unico punto di fallimento”
- Non esiste clock comune

SINCRONIZZAZIONE DEI CLOCK

Sincronizzazione dei clock

- Quando ogni host possiede un proprio clock, l'ordine degli eventi può essere erroneamente invertito
- Esempio
  - Iterazione editing/compilazione + make

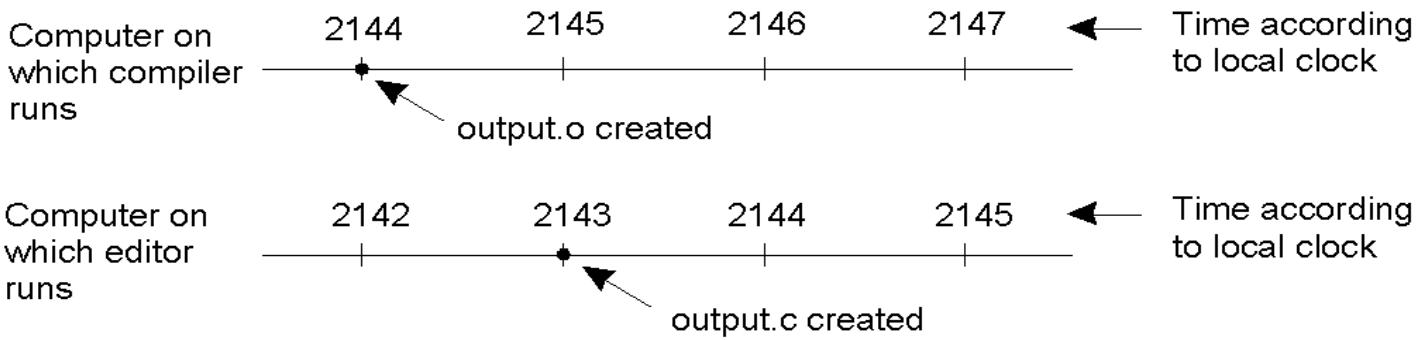

Necessario meccanismo di sincronizzazione

Assunzioni

- Il sistema distribuito è composto da un insieme di processori $P = \{P_1, P_2, \ldots, P_n\}$
  - P_i reagisce ad eventi
    - Eventi esterni: invio, ricezione di messaggi
    - Eventi interni: I/O locale, arrivo di segnali, …
- E = insieme dei possibili eventi nel sistema
- E_{P_i} = insieme dei possibili eventi in P_i
- Vogliamo definire un ordine per E

Sincronizzazione dei clock

- Si possono sincronizzare tutti i clock di un sistema?
  - In linea di principio, NO
    - Necessario un concetto di tempo globale
    - Non realizzabile
      - No clock globale
      - Ritardo di comunicazione (non deterministico) tra nodi
  - Possibile una versione “rilassata” di sincronizzazione
    - Basata sul concetto di tempo logico
      - Sorta di tempo relativo (non assoluto)

Clock logici o virtuali

- Non necessariamente legato al tempo effettivo (reale)
- Sincronizzazione di clock logici è più semplice
  - Idea: l'ordine degli eventi è più importante del tempo esatto in cui gli eventi si verificano
- Modello del sistema
  - Esecuzione dei processi = sequenza di eventi
  - Granularità = evento (istruzione, chiamata a procedura, invio di un messaggio …)

Relazione "→"

- Cattura dipendenze causali tra eventi
- Relazione "è avvenuto prima" (*happened-before*)
- Definizione
  - Se A e B sono eventi nello stesso processore, e A è stato eseguito prima di B, allora A → B
    - Nello stesso processore gli eventi sono totalmente ordinati
  - Se A è l'evento corrispondente a mandare un messaggio da parte di un processore, e B è l'evento corrispondente a ricevere il messaggio da parte di un altro processore, allora A → B
- Evento A ha effetto causale su B se A → B

Relazione "→"

- → è una relazione di ordine parziale irriflessiva
  - Irriflessività
    - ¬ (A → A)
  - Asimmetria
    - se A → B allora ¬ (B → A)
  - Transitività
    - se A → B e B → C e…e V → Z allora A → Z

Relazione "→"

- Sono ammessi eventi concorrenti:
  - A || B se ¬ (A → B) e ¬ (B → A)
  - Quando due processi su processori diversi non si scambiano messaggi
- Per ogni coppia di eventi A e B in un sistema
  - A || B o A → B o B → A

Relazione "→"

- Esempio (diagramma spazio-temporale)
  - $e_{12} \rightarrow e_{23}$
  - $e_{22} \rightarrow e_{13}$
  - $e_{23} \rightarrow e_{24}$
  - $e_{12} \rightarrow e_{24}$
  - $e_{11} \parallel e_{22}$

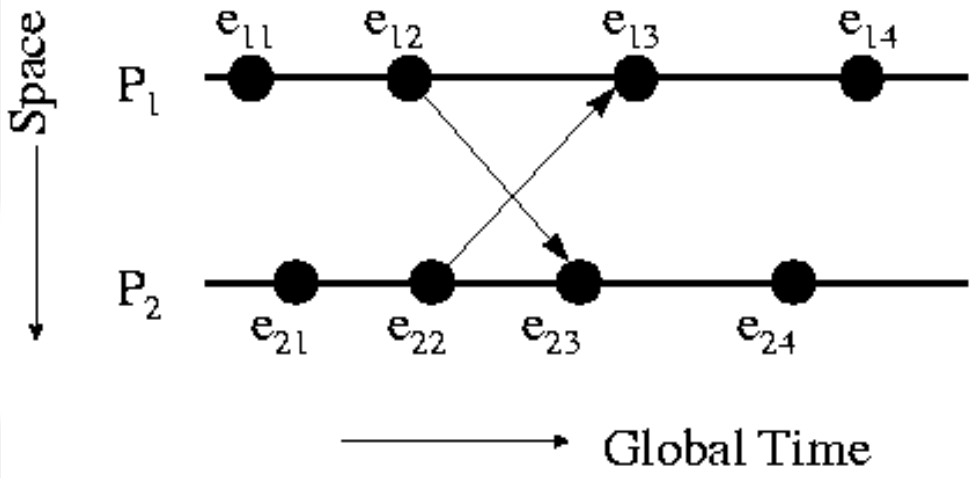

Implementazione di "→"

- Obiettivo:
  - per ogni evento *a*, disporre di un valore di tempo C(*a*) su cui ogni processore è d'accordo
- Sistema di clock logici [Lamport 78]
- Vettori di clock [Fidge 91 / Mattern 88 / Raynal&Singhal 96]

Clock logici di Lamport

- Ogni processore P_i possiede un clock C_i
- C_i assegna dei valori $C_i(a)$ (*timestamp*) ad ogni evento *a* di P_i
- Valori di C_i
  - Nessuna relazione con il tempo reale
  - Monotonicamente crescenti
- Implementazione tramite contatori (locali!)

Clock logici di Lamport

- Condizione affinché un sistema di clock logici sia “corretto”:
  - Se $a \rightarrow b$ allora $C(a) < C(b)$ (indipendentemente da dove *a* e *b* si trovano)
- Realizzabile se sono verificate le seguenti regole:
  - Condizioni di correttezza C1, C2
  - Regole di implementazione IR1, IR2

Clock logici di Lamport

- Condizioni di correttezza
  - [C1] Per ogni coppia di eventi *a* e *b* in P_i , se *a* si verifica prima di *b* allora $C_i(a) < C_i(b)$
  - [C2] Se *a* è l'evento corrispondente a mandare un messaggio *m* nel processore P_i, e *b* è l'evento corrispondente a ricevere il messaggio *m* nel processore P_j allora $C_i(a) < C_j(b)$

Clock logici di Lamport

- Regole di implementazione
  - [IR1] Il clock C_i viene incrementato tra due eventi successivi nel processore P_i come segue:
    - $C_i = C_i + d$ ($d > 0$)
  - [IR2] Se *a* è l'evento corrispondente a mandare un messaggio *m* da parte del processore P_i, allora a *m* viene assegnato un timestamp $t_m = C_i$ (*a*) (dopo l'applicazione di IR1)
    - Quando *m* viene ricevuto dal processore P_j, C_j viene calcolato come segue:
      - $C_j = \max(C_j, t_m) + d$

Esempio

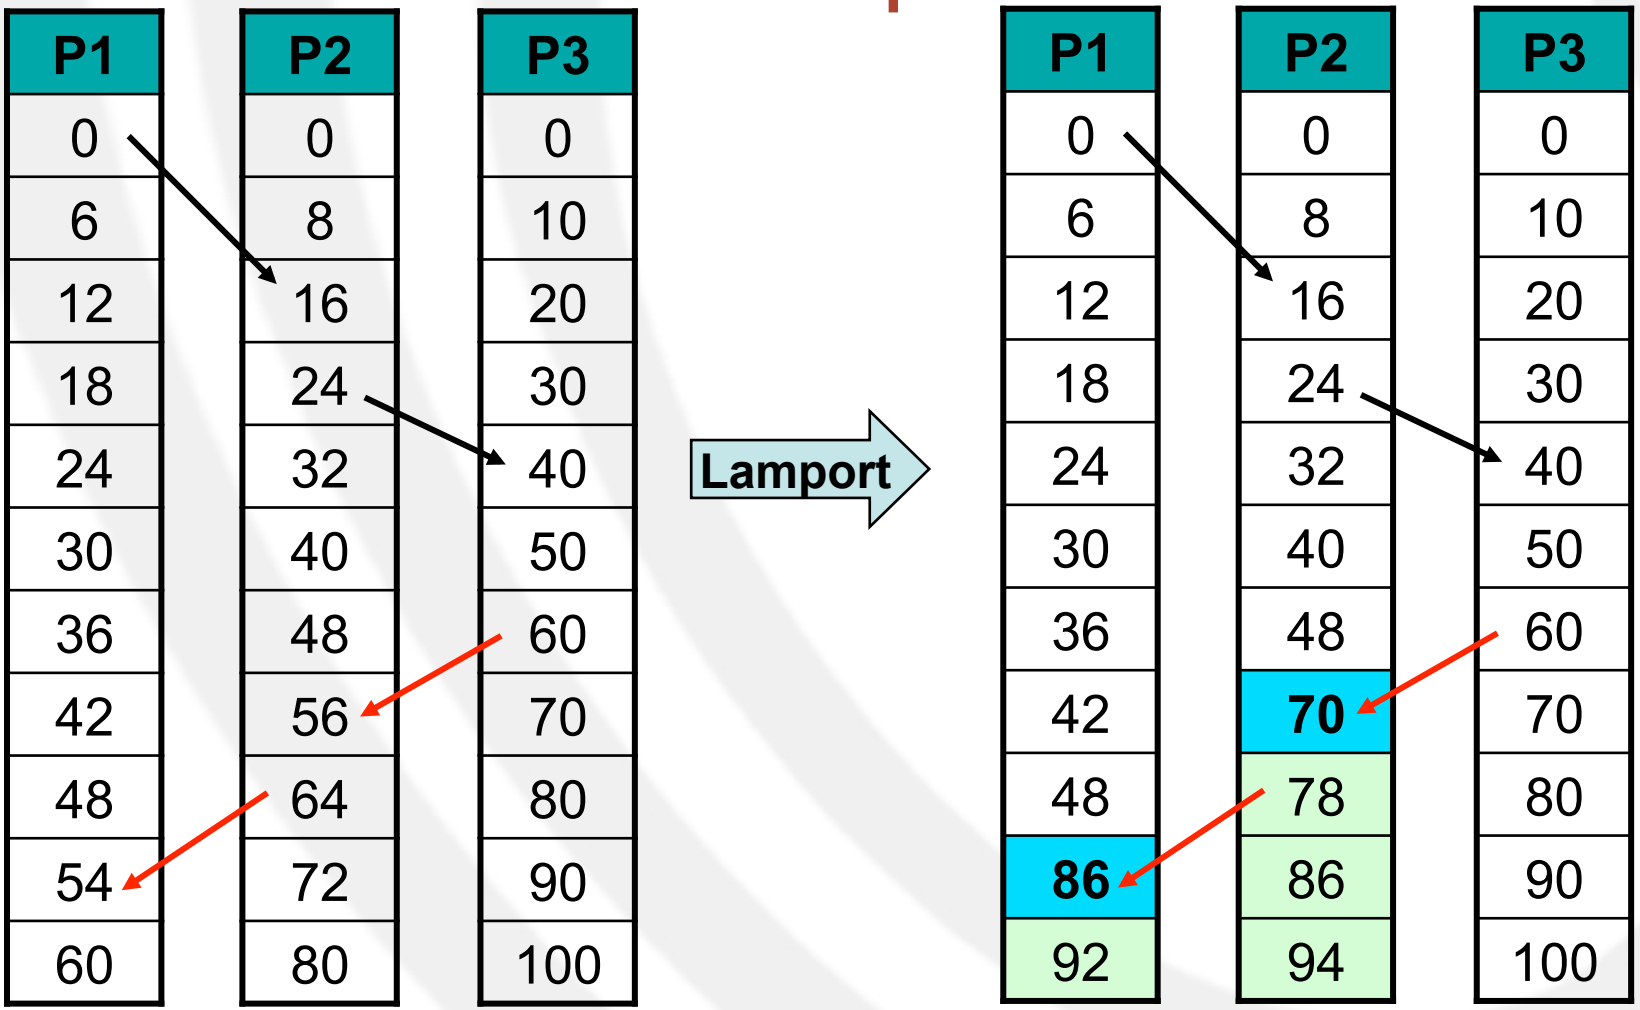
P1
0
6
12
18
24
30
36
42
48
54
60
P2
0
8
16
24
32
40
48
56
64
72
80
P3
0
10
20
30
40
50
60
70
80
90
100
Lamport
P1
0
6
12
18
24
30
36
42
48
86
92
P2
0
8
16
24
32
40
48
70
78
86
94
P3
0
10
20
30
40
50
60
70
80
90
100

Ordine totale?

- → è una relazione di ordine parziale
- Per ottenere ordine totale basta aggiungere al timestamp di un evento l'ID del corrispondente processore
- Esempio:
  - Se A accade al tempo 10 su P1, e B al tempo 10 su P2, A → B perché P1 < P2
- Ordine totale usato in molti algoritmi di sincronizzazione

Problema di sincronizzazione

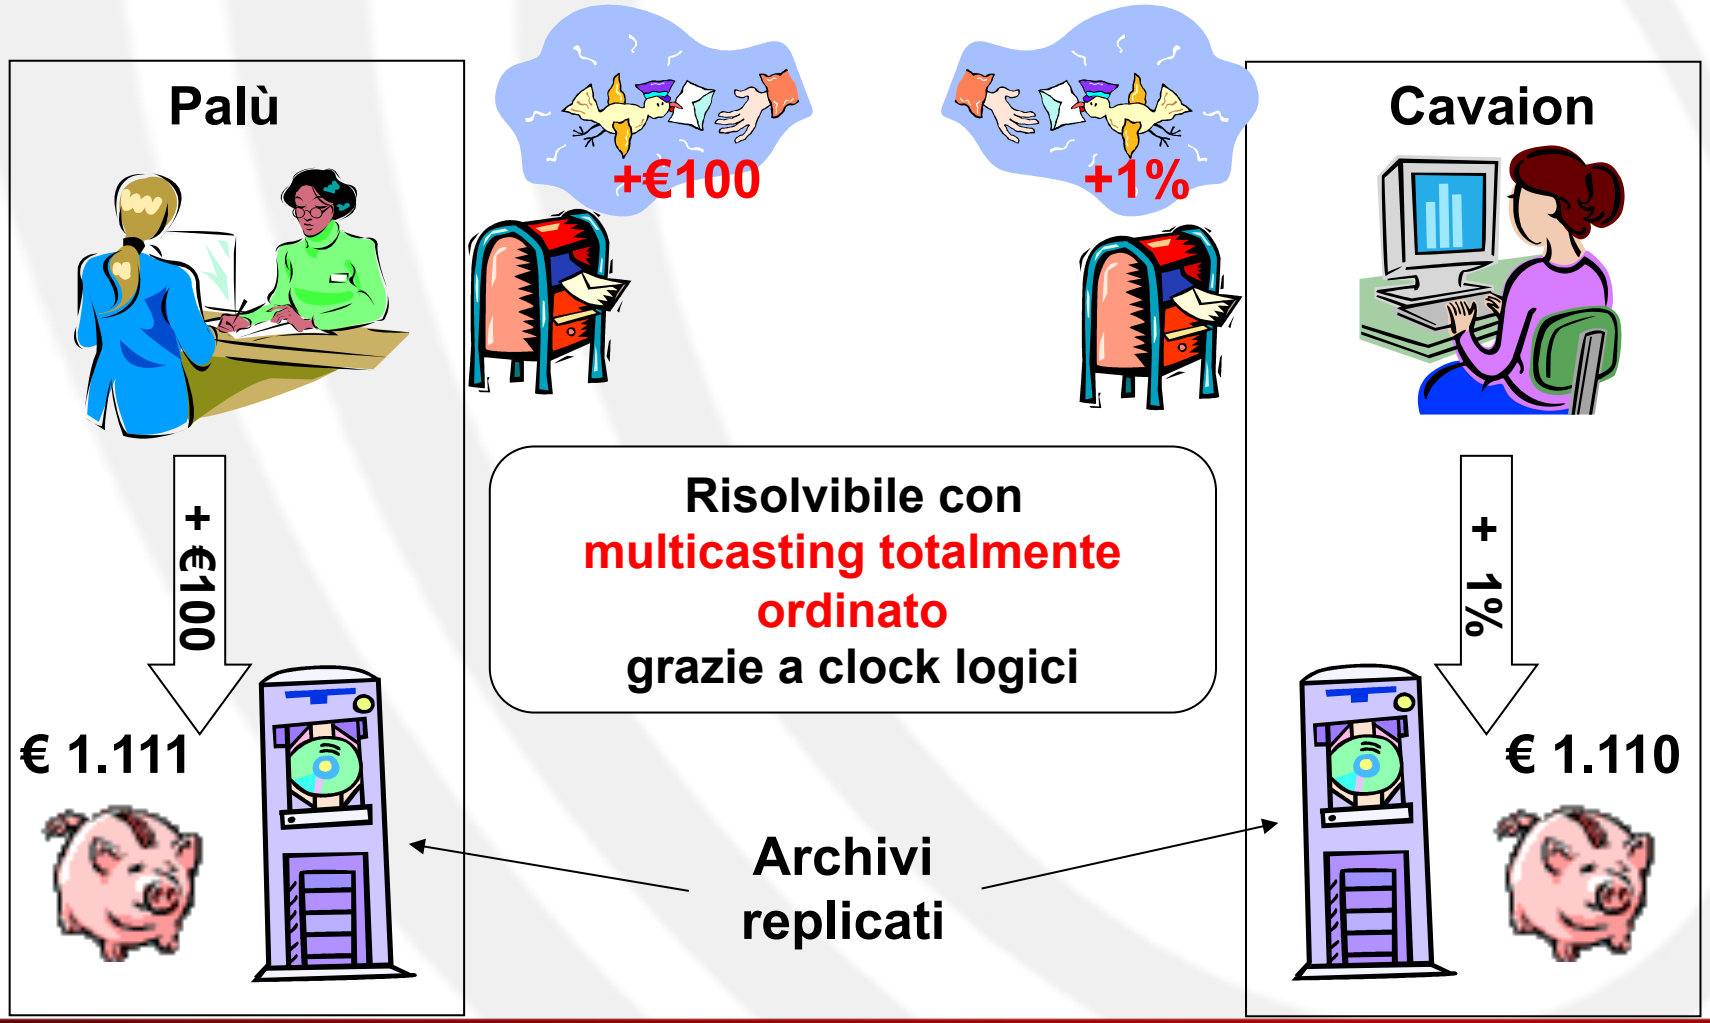

Multicasting totalmente ordinato

- Ogni processo invia messaggi a tutti gli altri processi del gruppo (anche a se stesso)
- Ogni messaggio *m* ha un timestamp t_m corrispondente al clock logico del mittente al momento dell'invio
- I messaggi inviati da un processo arrivano nello stesso ordine di invio e non ci sono perdite
  - Condizione ottenibile tramite *ack* e numerazione dei messaggi
- Quando un processo P_i riceve *m*
  - *m* viene archiviato in una coda totalmente ordinata in base a t_m
  - P_i invia *ack* a tutti ($t_{ack} > t_m$)
- *m* viene rimosso dalla coda ed elaborato da P_i solo quando si trova in testa alla coda e P_i ha ricevuto il relativo *ack* da tutti gli altri processi

N.B: la coda è uguale per tutti i processi

Limitazioni di "Lamport"

- Lamport assicura che se $a \rightarrow b$, allora $C(a) < C(b)$
- L'algoritmo è:
  - completamente distribuito
  - Semplice
  - tollerante ai guasti
- Ma se $C(a) < C(b)$, $a \rightarrow b$?
  - In generale NO! (per eventi su processi remoti)
  - Problema: vogliamo capire anche se 2 eventi sono legati da una relazione di causa ed effetto guardando i timestamp!

Limitazioni di "Lamport"

- Se C(*a*) < C(*b*) allora $a \rightarrow b$?
  - In generale NO!
- Lamport non cattura la seguente relazione di causalità:
  - se $C(e_i) < C(e_j)$ allora $e_i \rightarrow e_j$

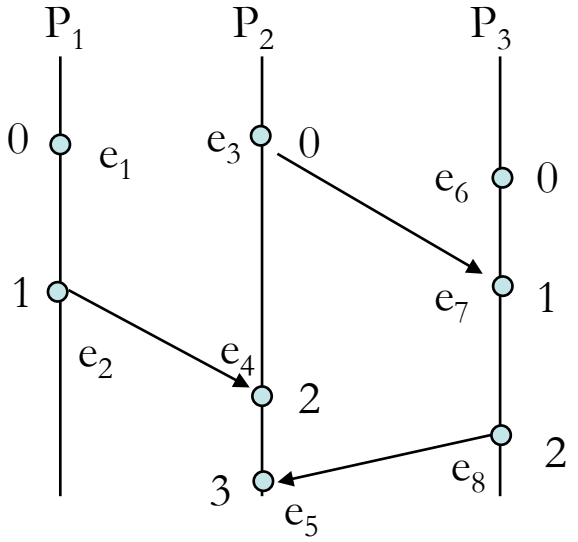

$C(e_3) < C(e_2)$
ma $e_3 \not\rightarrow e_2$!!
In realtà
e_3 ed e_2 sono concorrenti

Relazione di causalità

- Utile perché permette:
  - debugging
  - liveness e fairness per la mutua esclusione
  - consistenza per database replicati
  - rilevazione dei deadlock
  - costruzione di stati globali consistenti per il recovery da crash
  - determinazione del grado di parallelismo tra processi
  - …

Violazione della causalità

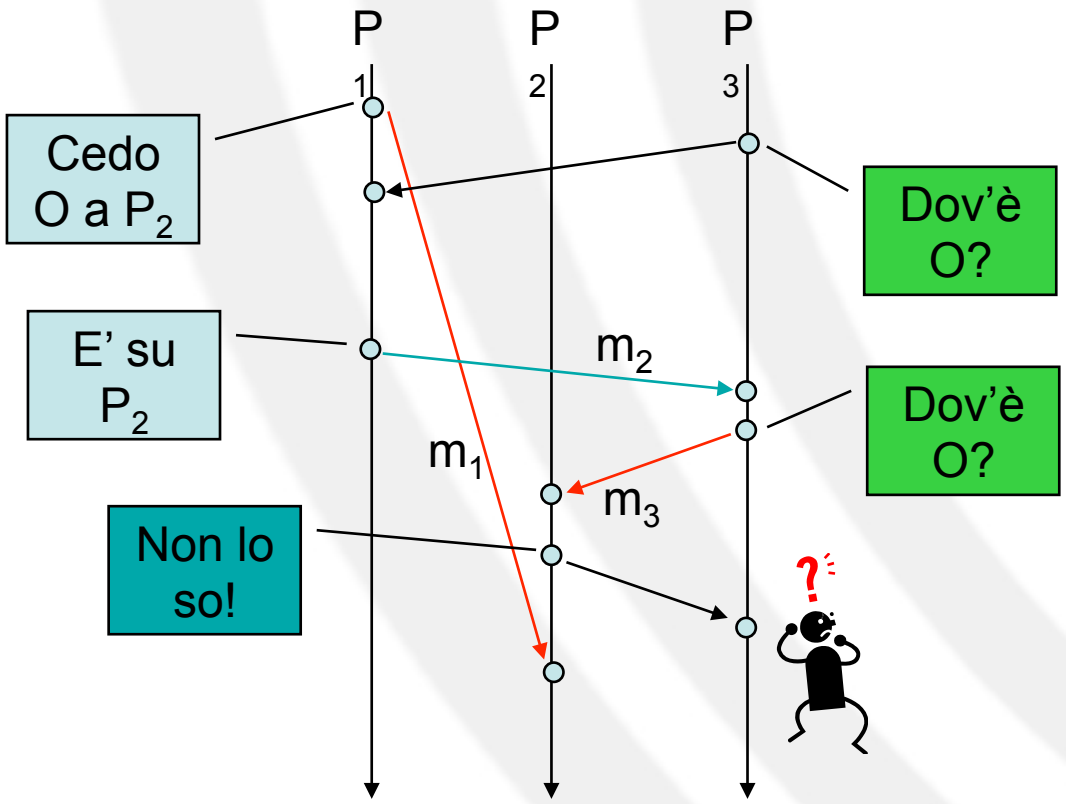

- S(*m*) = evento in cui *m* è spedito
- R(*m*) = evento in cui *m* è ricevuto
- Violazione della causalità:
  - m_1 arriva a destinazione dopo m_3!
  - $S(m_1) \rightarrow S(m_3)$ ma $R(m_3) \rightarrow R(m_1)$

Violazione della causalità

- Esempio tipico
  - Un processore P_i invia due messaggi m_1, m_2
  - Un processore P_j riceve i due messaggi m_1, m_2
  - $S(m_1) \rightarrow S(m_2)$
  - $R(m_2) \rightarrow R(m_1)$
  - In generale, per evitare la violazione della causalità dobbiamo sapere se 2 eventi sono in relazione causale tra loro
  - Soluzione: Vettori di clock logici

Vettori di clock

- [Fidge 91 / Mattern 88 / Raynal&Singhal 96]
- Simili a clock logici, ma più valori (vettore) anziché uno solo
  - *n* processori → *n* elementi del vettore
  - C_i [i] : tempo logico di P_i
  - C_i [j] : la migliore stima del tempo logico di P_j da parte di P_i
    - C_i [j] = tempo dell'ultimo evento in P_j che "è successo prima" del tempo corrente di P_i

Vettori di clock

- Regole di implementazione
  - [IR1] L'elemento *i* del clock C_i viene incrementato tra due eventi successivi nel processore P_i
  - [IR2] Se a è l'evento corrispondente a mandare un messaggio *m* nel processore P_i , allora
    - a *m* viene assegnato vector timestamp $t_m = C_i(a)=(C_i[1], \ldots, C_i[n])$ (dopo aver applicato IR1)
    - quando *m* viene ricevuto dal processore P_j, C_j è calcolato come
    - $\forall k,\ C_j[k] = \max(C_j[k], t_m[k]) + d$

Sistemare la slide per IR2

Vettori di clock - esempio

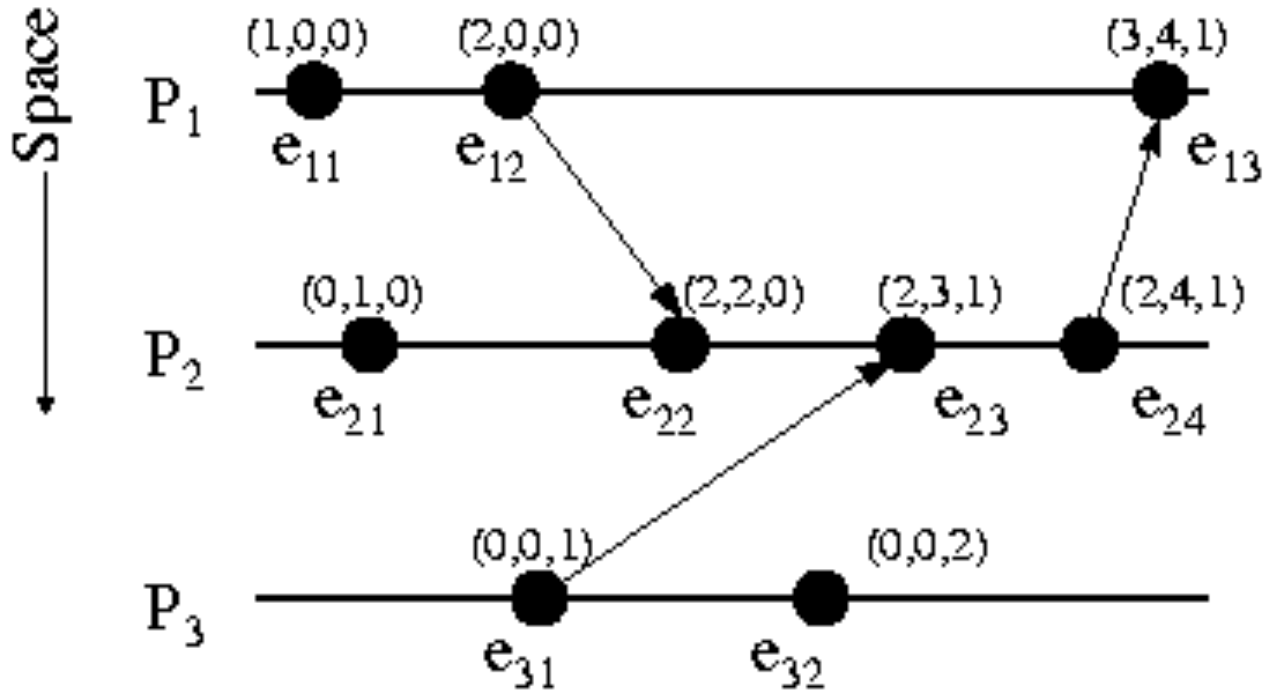

Vettori di clock

- Permette di determinare relazioni causa-effetto tra eventi
  - Non possibile con i clock di Lamport
- Definizione
  - $t_a < t_b$ se e solo se
    - $t_a[i] \leq t_b[i]$ per ogni *i*
    - Esiste *j* tale che $t_a[j] \neq t_b[j]$
- Teorema
  - se $t_a < t_b$, allora $a \rightarrow b$ e viceversa
- Permettono di verificare qualunque tipo di ordine parziale (=, <=, >=, ||)

Esempi
(1,0,3) $\rightarrow$(2,0,5)
(1,1,3) $\not\rightarrow$(1,0,3)
(1,1,3) $\not\rightarrow$(1,1,3)

Se $t_a < t_b$, allora $a \rightarrow b$

- Esempio

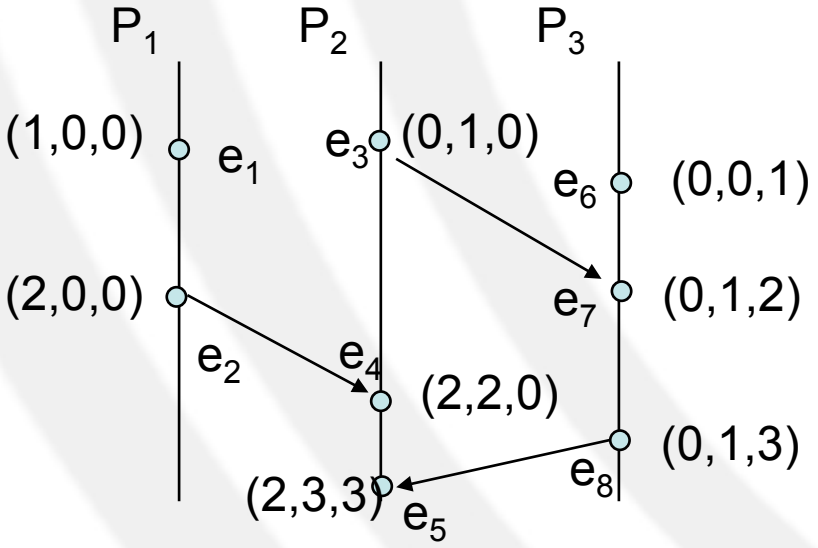

$C(e_3) < C(e_2)$?
NO, infatti
$e_3 \not\rightarrow e_2$!!
e_3 ed e_2 sono concorrenti

Violazione della causalità

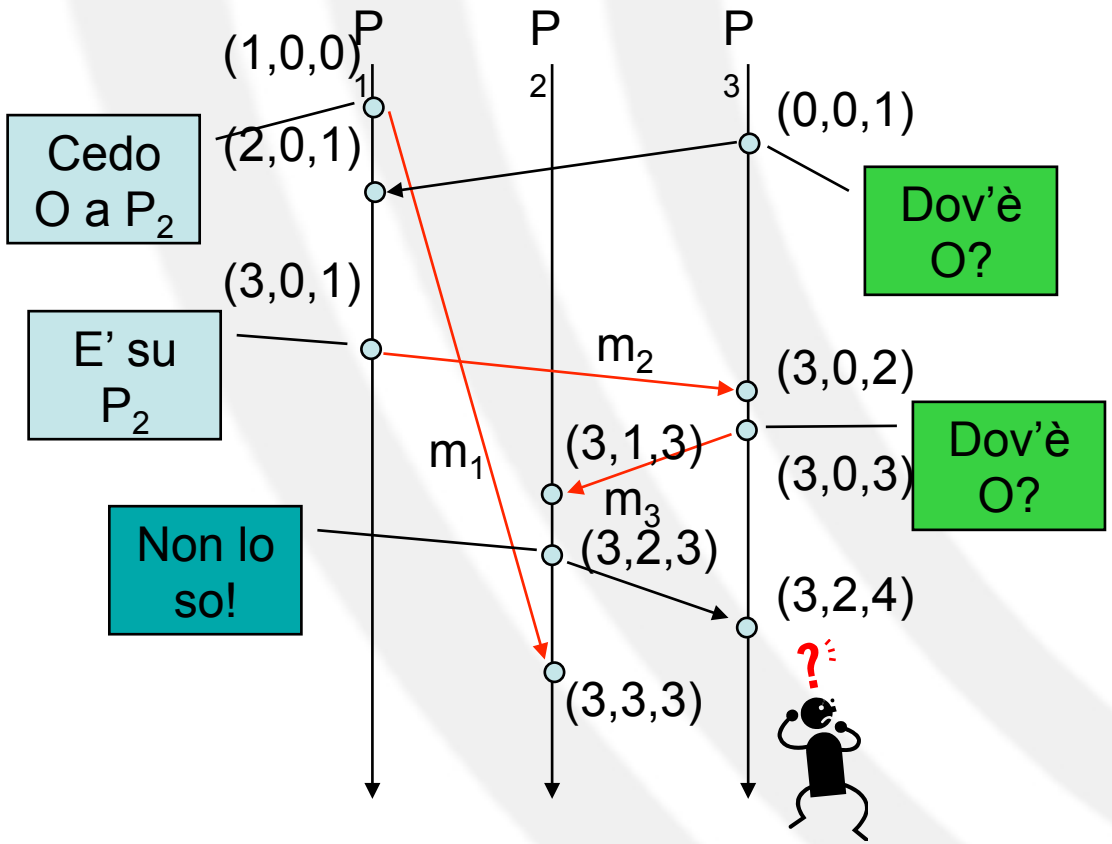

- Quando arriva m_1, P_2 capisce che c'è stata violazione della causalità perché:
  $t_{send}(m_1) < t_{send}(m_3)$
  ma
  $t_{receive}(m_3) < t_{receive}(m_1)$

Clock fisici

- In molti casi è necessario che i singoli clock siano in qualche modo legati al tempo reale
  - Ambienti Real-time!
- Clock fisici vs. logici
- Come garantire la sincronizzazione di clock fisici?
  - Soluzioni centralizzate
  - Soluzioni distribuite

Coordinated Universal Time (UTC)

- Standard internazionale per mantenere il tempo
- Basato su International Atomic Time (TAI)
  - 1s = tempo impiegato da un atomo di cesio 133 per compiere 9.192.631.770 transizioni
  - 50 laboratori calcolano il tempo → media = TAI
  - 86400s TAI durano 3ms meno rispetto al giorno solare medio → richiesta compensazione
- L'output dell'orologio atomico e' inviato in broadcast da stazioni radio e satelliti (GPS) sulla terra
- Segnali da stazioni radio su terra hanno un'accuratezza di circa 0.1-10 ms; segnali da GPS hanno un'accuratezza di circa 1 μs
- Computer con ricevitori possono sincronizzare i loro clock con questi segnali → le altre macchine vanno sincronizzate

Sincronizzazione di clock fisici

- Modello del sistema
  - Ogni host possiede un timer che causa un interrupt H volte al secondo (tick)
  - Quando scatta il timer viene aggiunto 1 a un clock SW C(t)
- Detto t il tempo universale (UTC), idealmente C(t) = t
  - In pratica dC/dt ≠ 1
  - Tolleranza r
    - Maximum drift rate (tasso di scostamento massimo)
  - 1-r < dC/dt < 1+r

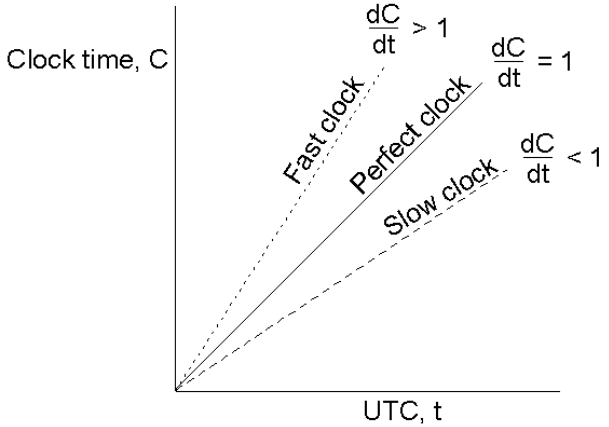

Sincronizzazione di clock fisici

- Assunzione
  - Esiste un processo (time server) che è in grado di fornire un tempo di riferimento
- Periodicamente, gli host dialogano con il time server per sincronizzarsi
- Quanto spesso?
  - Dopo tempo dt, 2 clock possono discordare di 2rdt
  - r = tolleranza del clock
  - Se d = errore max consentito rispetto tempo universale t
    - $2rdt < d \rightarrow dt < d/2r$
  - Allora Dt = distanza tra due sincronizzazioni = d/2r secondi

Sincronizzazione di clock fisici

- Metodi centralizzati
  - Algoritmo di Cristian [Cristian 89]
  - Algoritmo di Berkeley [Gusella&Zatti 89]
- Metodo distribuito

Algoritmo di Cristian

- Host del time server possiede una copia di UTC
- Periodicamente, i processi interrogano il time server
- Difficoltà
  - Processo da sincronizzare può avere clock “veloce”
    - Soluzione: rallentamento progressivo del clock da sincronizzare
  - Va considerato il tempo di propagazione della richiesta
    - La sua misurazione è possibile perché si usa il clock “locale”
    - Stima: (T1 – T0)/2

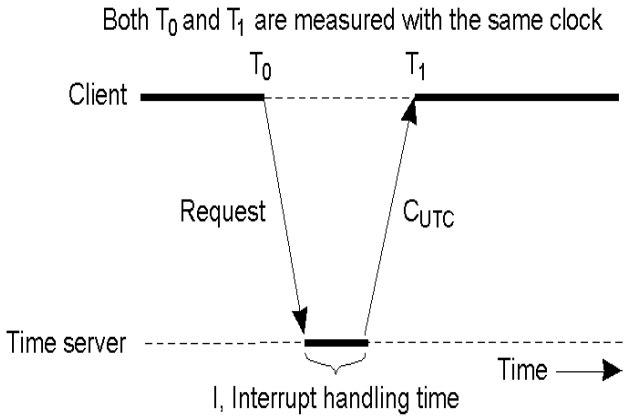

Algoritmo di Berkeley

- Time server (daemon) attivo
  - Chiede ai vari host il tempo e fornisce il proprio
  - Gli host forniscono la differenza tra il loro tempo e quello del server
  - Il daemon dice agli host come regolare i clock
    - Es: facendo una media
- Adatto per sistemi senza riferimento UTC, dove il server viene regolato a mano
- Usato nel Berkeley Unix

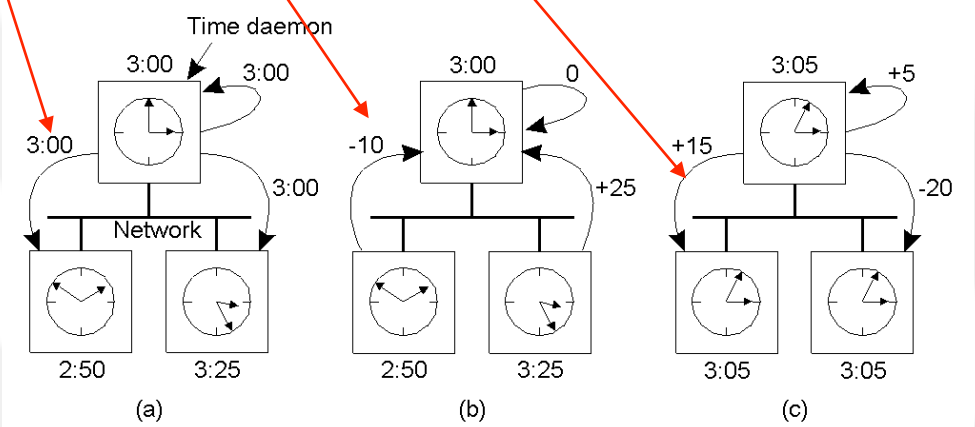

Metodi distribuiti

- Tempo suddiviso in periodi di lunghezza fissa
- Host inviano proprio tempo in broadcast all'inizio di ogni periodo
  - Invii non simultanei a causa di differenze nei vari clock
    - Quindi la ricezione del broadcast rimane attiva per un certo tempo S
  - Quando scade S il clock locale è modificato in base a
    - Media dei valori ricevuti
    - Media dei valori, esclusi n valori estremi
  - E' possibile tener conto anche della stima del tempo di propagazione del broadcast da una data sorgente

DETERMINAZIONE DELLO STATO GLOBALE

Stato globale

- Problemi classici dei S.O. tradizionali si presentano anche nel caso di S.O. distribuiti
  - Mutua esclusione
  - Starvation
  - Deadlock
- Complicazione
  - Non c'è uno stato globale

Stato globale

- Supponiamo di interrompere una computazione distribuita mediante interruzione simultanea di tutti i processi
- Lo stato globale è dato da:
  - stato di ogni singolo processo
  - contenuto di ogni canale di comunicazione
- Osservazione dello stato globale di un sistema distribuito può essere semplice per un osservatore esterno ma difficile all'interno del sistema

Stato globale

- Esempi di casi in cui la conoscenza dello stato globale è importante:
  - Checkpoint per rollback in caso di malfunzionamenti
  - Rilevazione di proprietà stabili
    - La computazione ha terminato
    - Il sistema è in deadlock (tramite RAG)
    - Tutti i token in una rete token-ring sono spariti
  - …

Stato globale (difficoltà)

- Stato distribuito
  - Necessario raccogliere informazioni sparse su macchine diverse
- Conoscenza solo locale
  - Un processo non conosce lo stato di un altro processo!
- Registrazione “istantanea” impossibile
  - No clock globale
    - La registrazione degli stati locali non può essere sincronizzata in base al tempo
    - Conosciamo lo stato locale degli altri processi con un “certo ritardo”
      - Es.: Stelle lontane
- Ci accontentiamo del passato

Stato globale

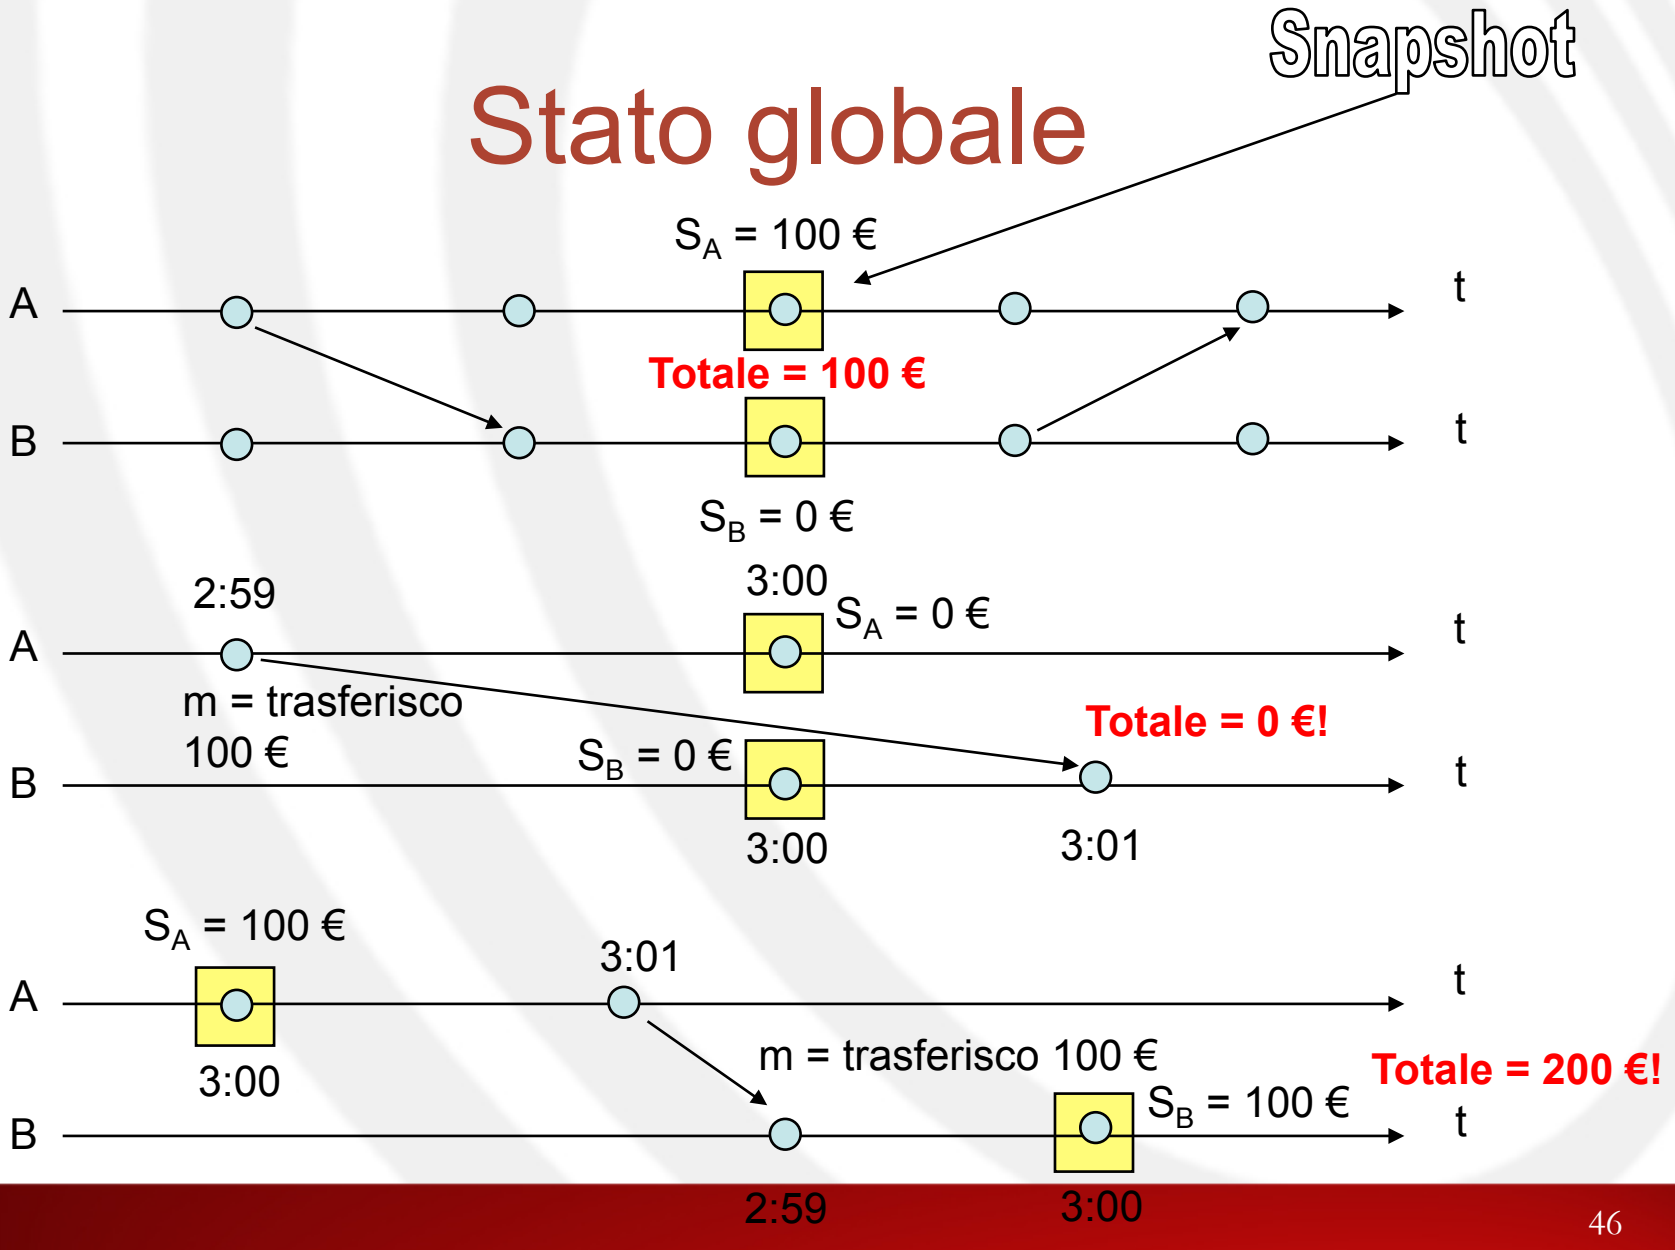

Definizioni

- Canale
  - Tra P1 e P2 esiste un canale se P1 e P2 scambiano messaggi
  - Può essere visto come il cammino tramite cui i messaggi vengono trasferiti
  - È unidirezionale
- Stato locale
  - Lista di *send* e *receive* (di messaggi) in corso
  - Definito per ogni tempo locale (processo locale)
- Snapshot
  - Registra lo stato di un processo
  - Contiene record di tutti i messaggi spediti e ricevuti su tutti i canali dall'ultimo snapshot

Definizioni

- Stato globale
  - Stato locale di ogni processo + stato dei canali di comunicazione al momento dello snapshot
  - Consistente
    - Per ogni messaggio ricevuto “esiste” la send corrispondente
    - In pratica, ogni evento deve essere preceduto dagli eventi causalmente correlati ad esso
  - Transitless
    - Tutte le send sono state ricevute
  - Fortemente consistente
    - Consistente + transitless

Definizioni

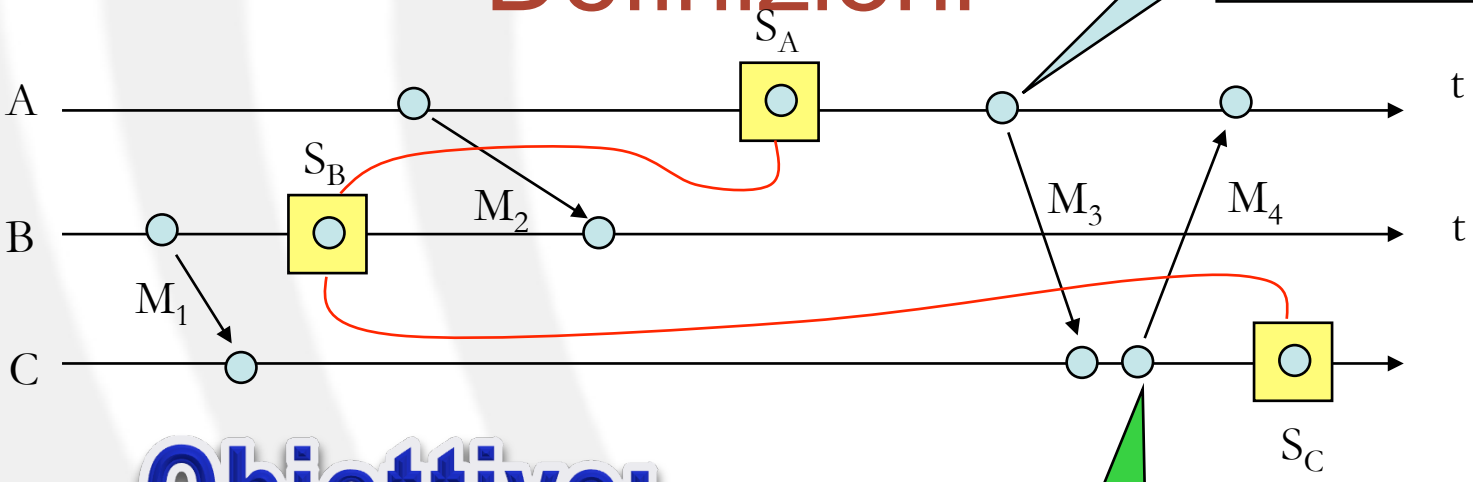

La receive è arrivata ma la send no! → non consistente

Obiettivo: determinare stato globale consistente

La send è stata eseguita prima dello snapshot ma la receive non è ancora arrivata→ non transitless

Tagli (Cut)

- Un taglio è un insieme di eventi, uno per nodo, ciascuno dei quali cattura lo stato del nodo corrispondente
- Frontiera del taglio
  - insieme degli ultimi eventi prima del taglio
  - Suddivide il diagramma in prima e dopo il taglio

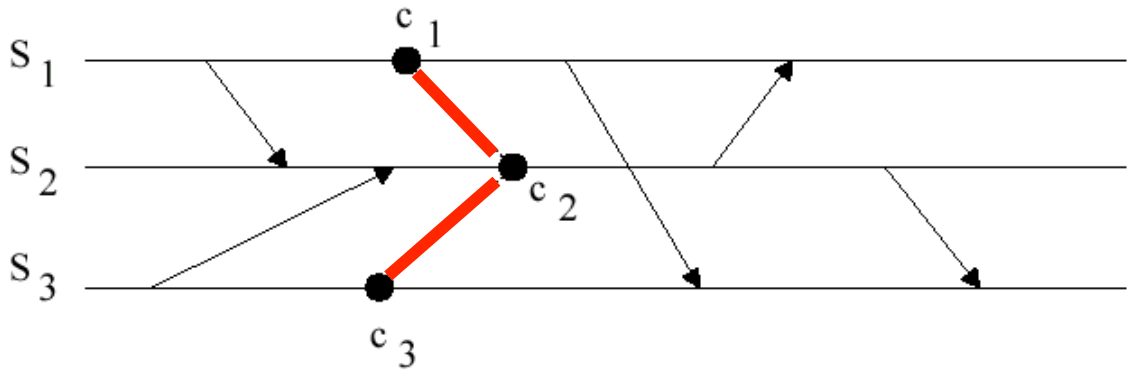

Frontiera del taglio

$C = \{c_1, c_2, c_3\}$

Tagli

- Un taglio C = {c1, c2, c3, … } si dice consistente se per ciascun nodo non esistono due eventi e_i ed e_j per cui $e_i \rightarrow e_j$ AND $e_j \rightarrow c_j$ AND $e_i \not\rightarrow c_i$
- In pratica, un taglio è consistente se quando include un evento, include anche gli eventi che lo precedono
- Esempio di inconsistenza

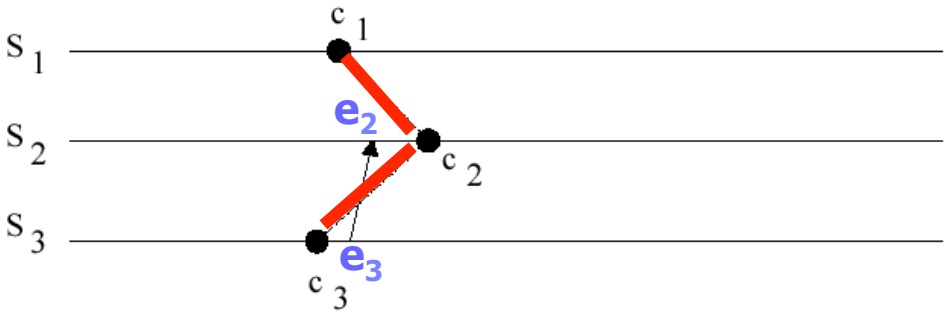

Stato globale

- Uno stato globale è consistente se corrisponde ad un taglio consistente
- I termini stato globale, taglio o snapshot sono intercambiabili

Stato globale: esempio

- GSa = {S1={(m1,R), (m3,S)} S3={(m1,S)}}
- GSb = {S2={(m2,S), (m3,R)} S3={(m2,R)}}

- GSa = {S1={(m1,R)}, S3={(m1,S),(m2,R)}}
- GSb = {S1={(m3,S)}, S2={(m2,S),(m3,R)}}

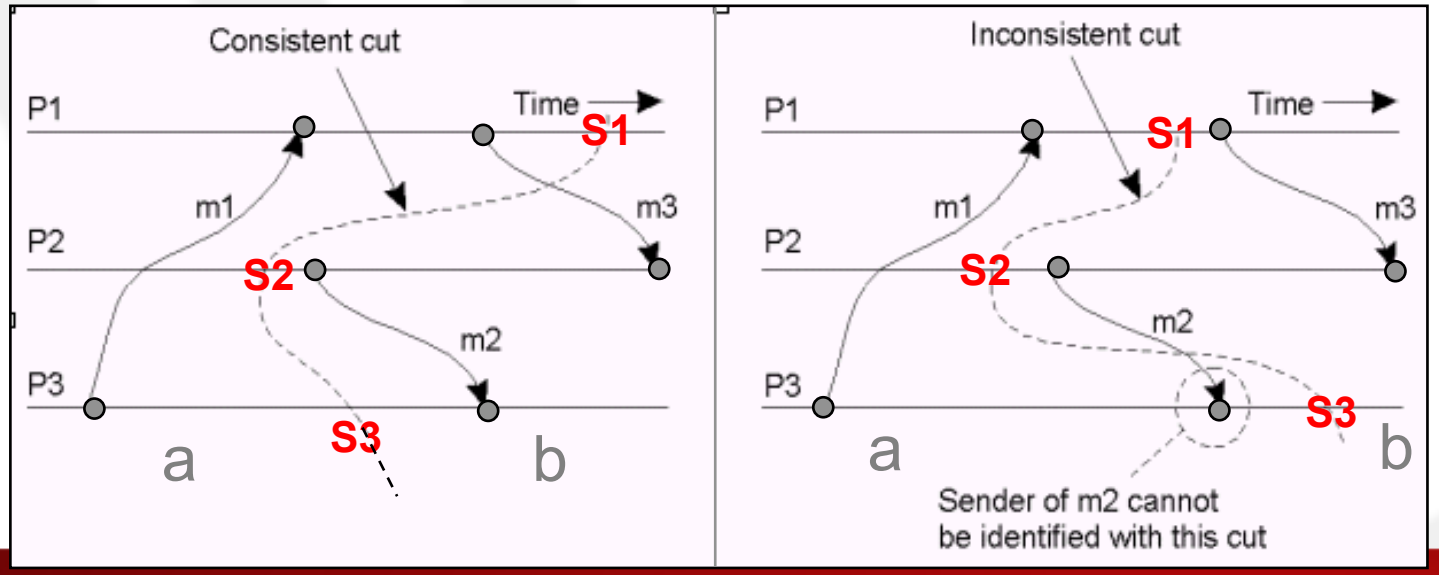

Determinazione dello stato globale

- Necessario un algoritmo specifico
- Chiave
  - Essenziale mantenere lo stato dei messaggi e del canale!
- Esempio
  - Algoritmo banale
    - I processi registrano il loro stato in un istante arbitrario
    - Un processo designato raccoglie i vari stati
  - Semplice, ma non corretto!

Determinazione dello stato globale

- Esempio:
  - produttore-consumatore
    - P registra il suo stato
    - Il messaggio transita sul canale
    - C riceve il messaggio e registra il suo stato

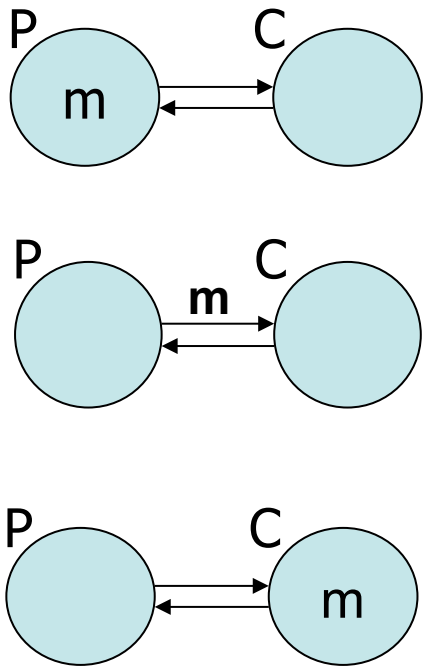

Determinazione dello stato globale

- Stato globale

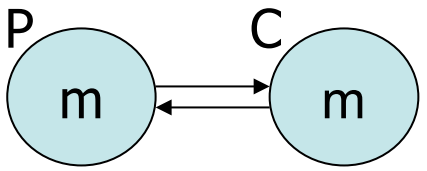

- Cosa abbiamo sbagliato?
  - P registra il suo stato
  - P non ha registrato l'invio di m
  - C ha registrato la ricezione

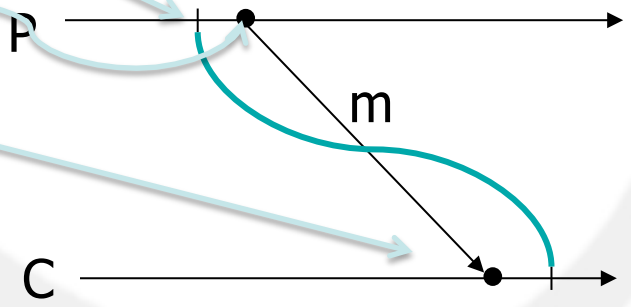

Algoritmo dei distributed snapshot

- Idea [Chandy&Lamport 85]
  - Utilizzare un messaggio speciale (marker) come elemento di sincronizzazione
- Assunzioni
  - Canali FIFO (implica relazioni di precedenza)
  - Nessuna perdita di messaggi
- Algoritmo eseguito inizialmente da un iniziatore
  - Registra il proprio stato (locale)
  - Invia il marker su tutti i suoi canali di uscita

Es.: TCP

atomica

Nessun messaggio ricevuto o spedito durante queste operazioni

Algoritmo dei distributed snapshot

- Comportamento del generico processo:
  - Alla prima ricezione del marker su un canale
    - Registra il suo stato locale
    - Indica come vuoto il canale da cui ha ricevuto il marker
    - Propaga il marker in uscita su tutti i suoi canali
    - Si mette “in ascolto” sui canali di ingresso

    } atomica
  - Alle successive ricezioni del marker su un canale
    - Stato del canale = {sequenza di messaggi ricevuti a partire dalla prima ricezione del marker}
- Algoritmo termina quando:
  - Tutti i processi hanno ricevuto il marker su tutti i canali di ingresso
  - N.B.: raccolta dello stato globale richiede un ulteriore processo
- Garantisce uno stato globale consistente

Distributed snapshot

- Prima ricezione del marker
- Q inizia a registrare il proprio stato ed invia il marker sui suoi canali di uscita
- Q riceve un marker
- Q invia il suo stato S = {a,b,c,d}

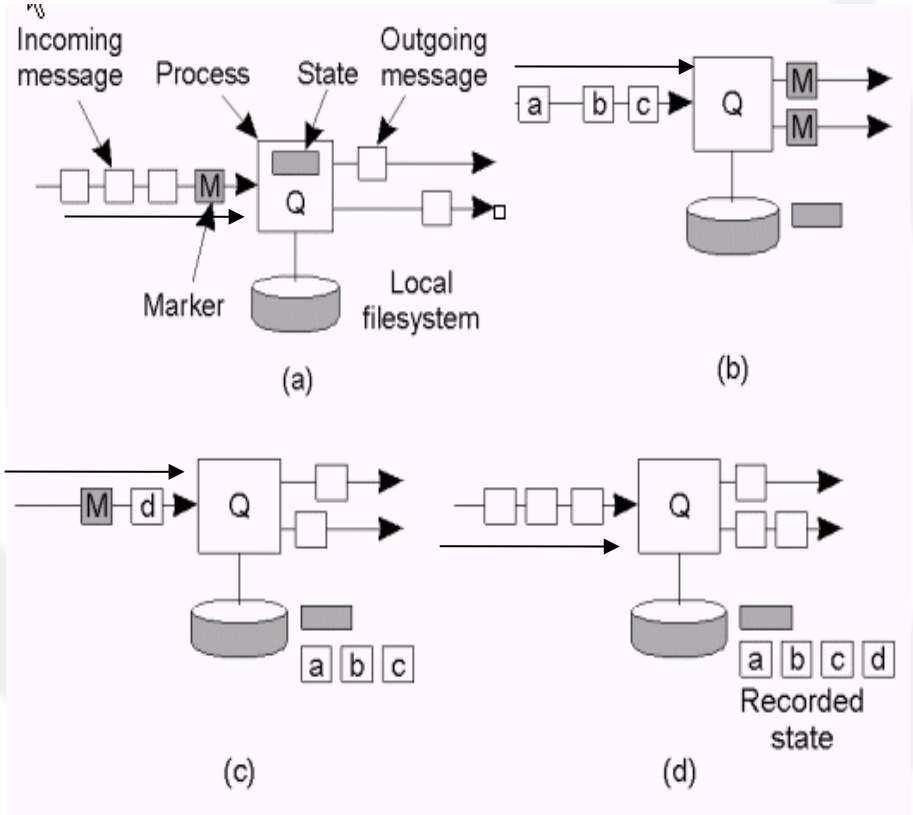

Esempio di esecuzione (1)

Obiettivo:
Determinare uno stato globale consistente

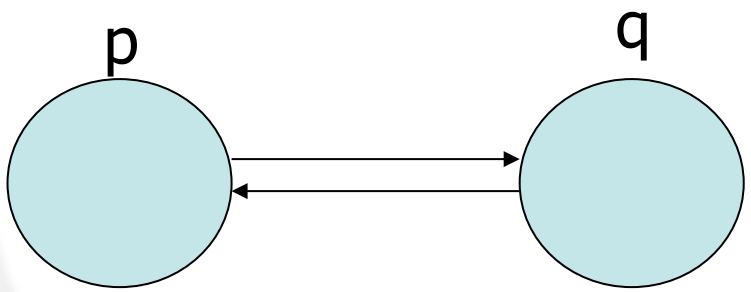

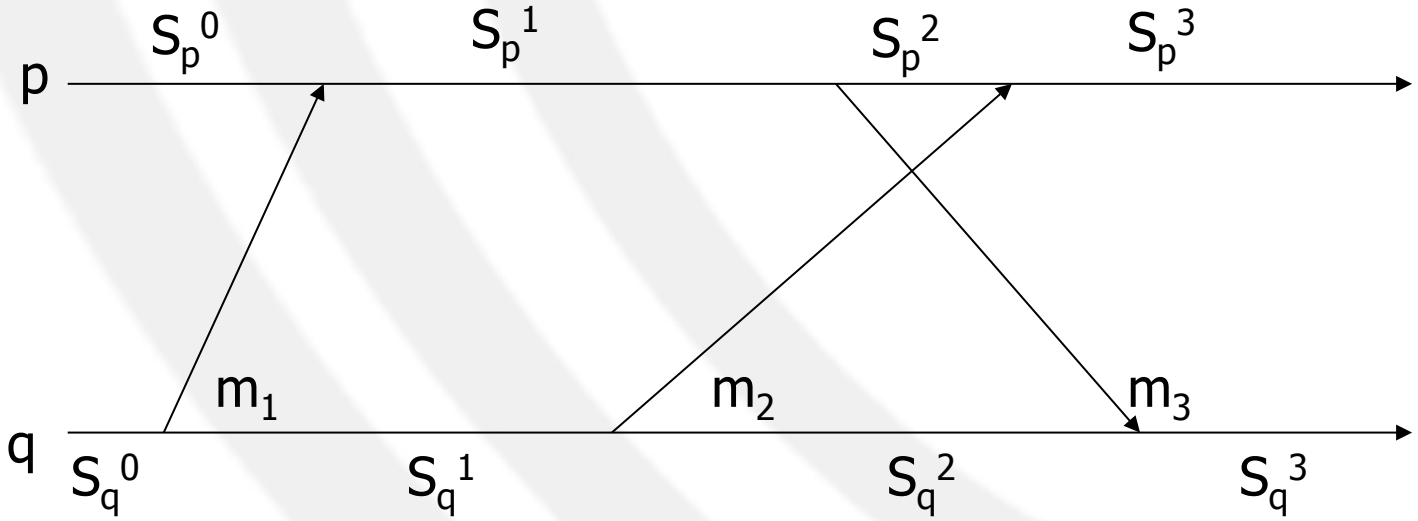

Esempio di esecuzione (2)

- q inizia l'algoritmo e registra lo stato S_q^1
- q invia il marker a p

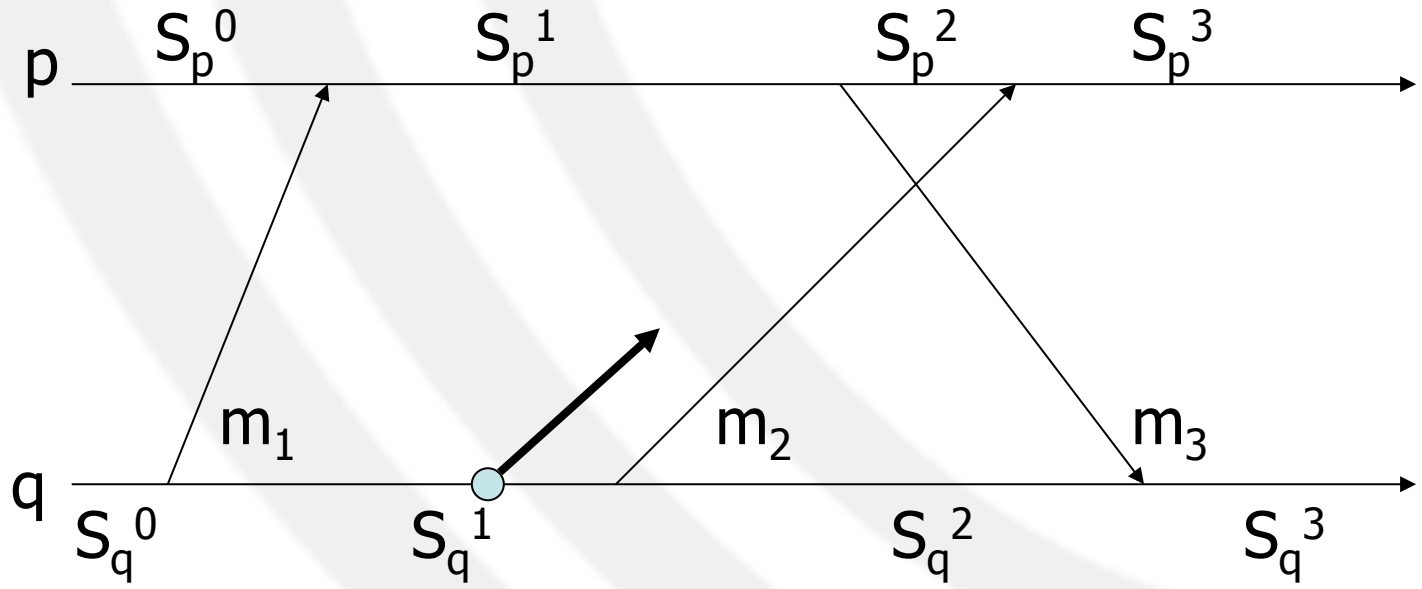

Esempio di esecuzione (3)

- p riceve il marker e registra il suo stato come S_p^2
- Stato del canale = {}
- p rispedisce il marker sul canale di uscita
- nel frattempo il messaggio m_3 viene ricevuto da q

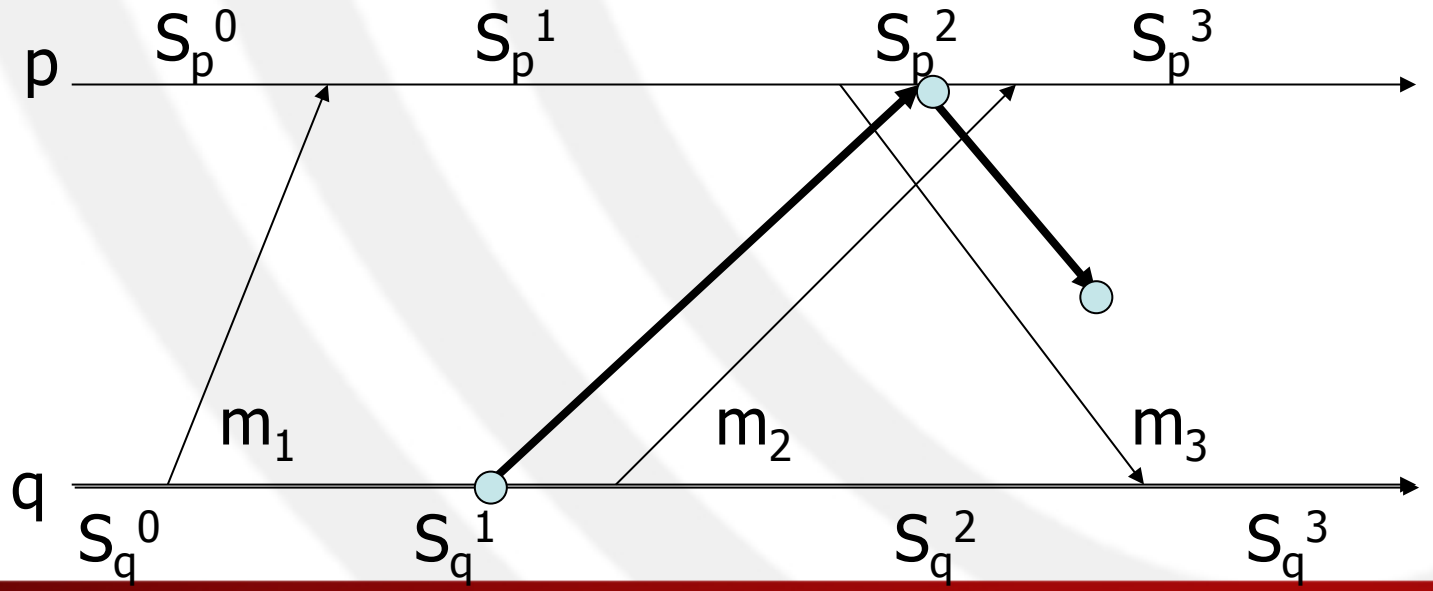

Esempio di esecuzione (4)

- q riceve il marker per la seconda volta
- q registra lo stato del canale = $\{m_3\}$

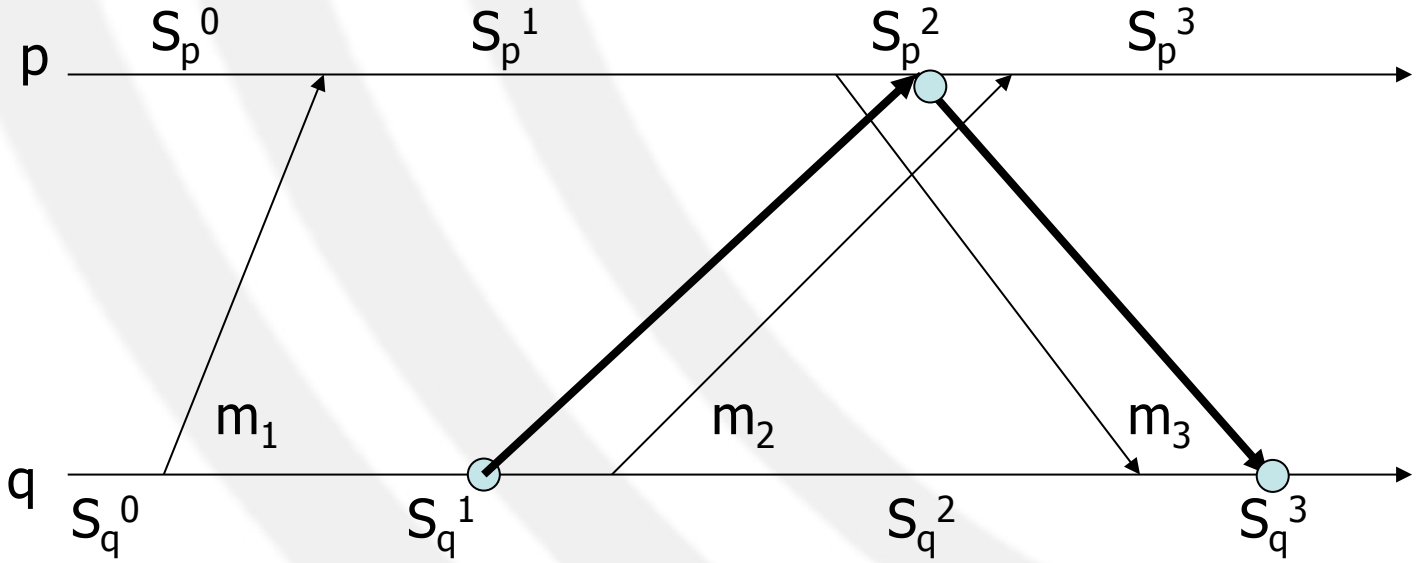

Esempio di esecuzione (5)

- STATO GLOBALE = {(S_p^2, S_q^1), (0,m_3)}
- Consistente:
  - si può dimostrare che se la receive(m) è stata registrata, lo è anche send(m)

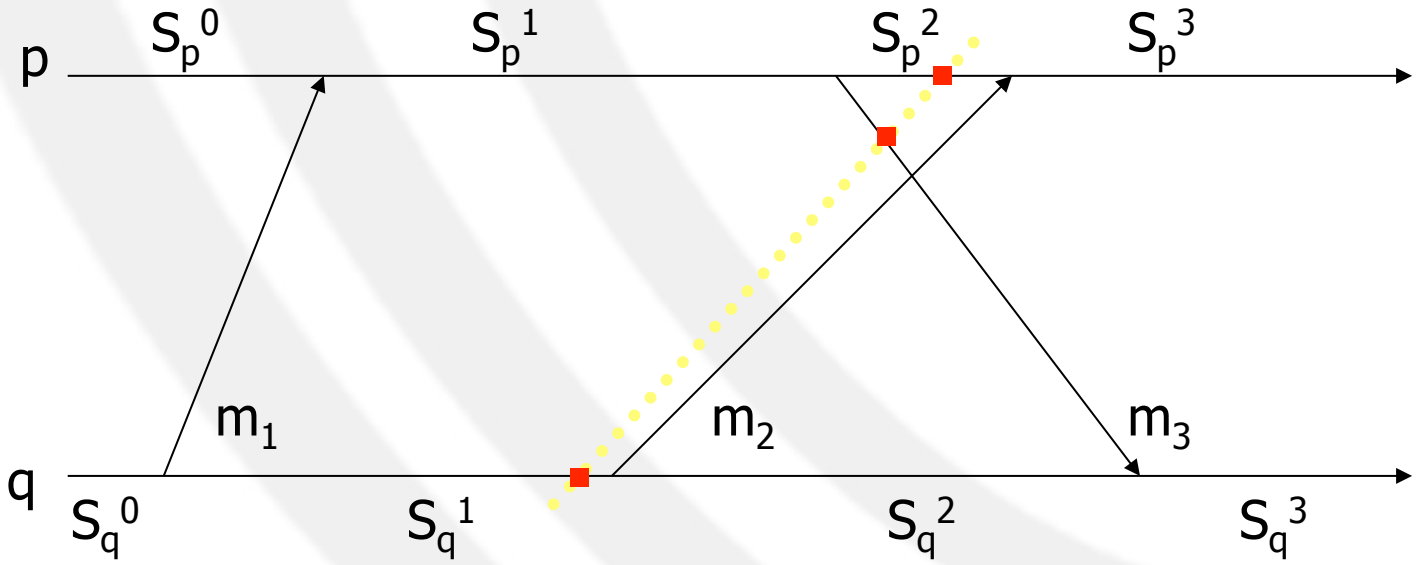

Altro esempio (1)

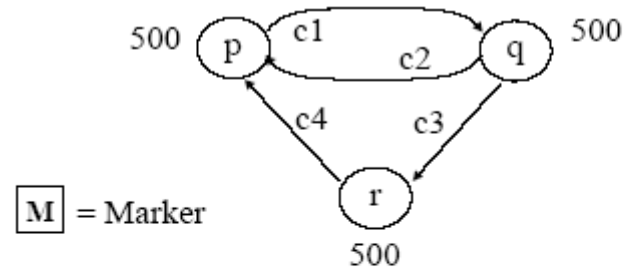

1

Node	Recorded state				
		c1	c2	c3	c4
p			{}		{}
q		{}			
r				{}	

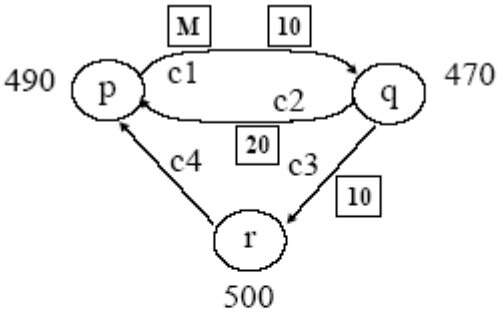

2

Node	Recorded state				
	state	c1	c2	c3	c4
p	490		{}		{}
q		{}			
r				{}	

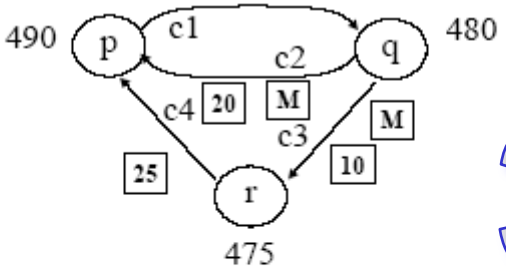

3

Node	Recorded state				
	state	c1	c2	c3	c4
p	490		{}		{}
q	480	{}			
r				{}	

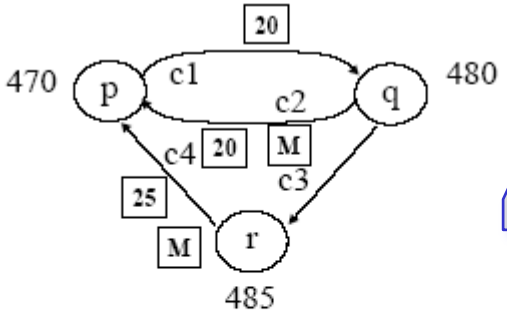

4

Node	Recorded state				
	state	c1	c2	c3	c4
p	490		{}		{}
q	480	{}			
r	485			{}	

Altro esempio (2)

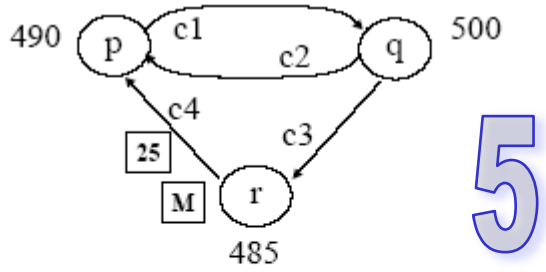

5

Node	Recorded state				
	state	c1	c2	c3	c4
p	490		{20}		{}
q	480	{}			
r	485			{}	

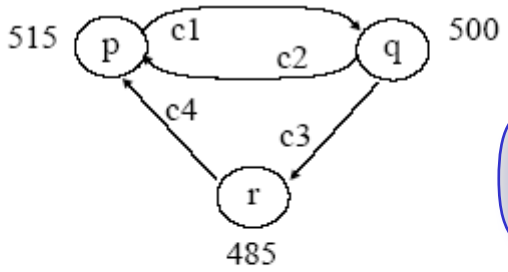

6

Node	Recorded state				
	state	c1	c2	c3	c4
p	490		{20}		{25}
q	480	{}			
r	485			{}	

Proprietà

- Il distributed snapshot garantisce che
  - se S_i e S_j sono gli stati globali al momento dell'inizio e della fine dell'algoritmo, e S* è lo stato globale registrato dall'algoritmo, allora
    - S* è raggiungibile da S_i
    - S_j è raggiungibile da S*

MUTUA ESCLUSIONE DISTRIBUITA

Mutua esclusione

- Assunzioni
  - *n* processi; ogni processo P_i in esecuzione su un diverso processore
  - Ogni processo ha una sezione critica da eseguire in mutua esclusione
- Requisiti
  - Se P_i sta eseguendo la sua sezione critica, nessun altro processo P_j sta eseguendo la sua sezione critica
- Due classi di approcci
  - Centralizzati
  - Distribuiti

Approccio centralizzato

- Uno dei processi nel sistema si occupa di coordinare gli ingressi nella sezione critica
  - Un processo che vuole entrare nella SC invia un messaggio *request* al coordinatore
  - Il coordinatore decide quale processo entra e invia un messaggio *reply*
  - Il processo che riceve la *reply* entra nella SC
  - Quando esce dalla SC, invia un messaggio *release* al coordinatore
- Tre messaggi per ogni ingresso nella SC

Approccio centralizzato - esempio

- P1: request
- Coordinator: reply OK
- P2: request ma il coordinator non invia replay
- P1: release
- Coordinator: reply per P2

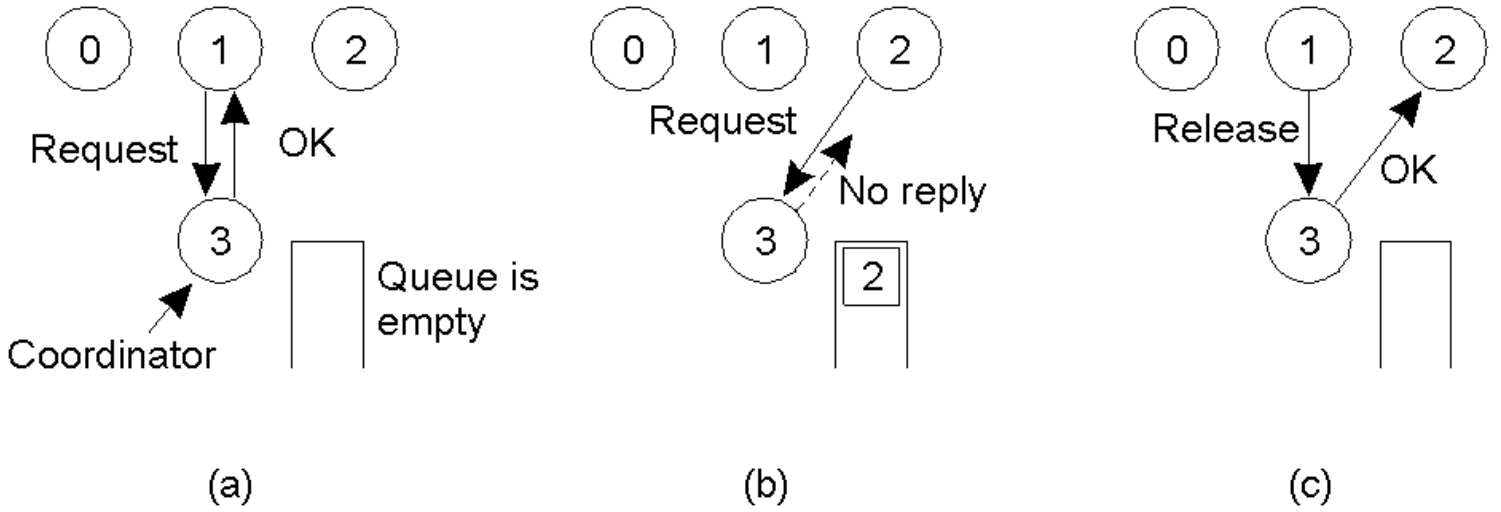

Approccio centralizzato

- Vantaggi
  - Semplice (3 messaggi per richiesta)
  - Garantisce le tre condizioni (mutua esclusione, progresso, attesa limitata) senza deadlock/ starvation
  - Utilizzabile per ogni tipo di risorsa
- Svantaggi
  - Criticità del coordinatore
    - Tolleranza ai guasti (se va in crash?)
    - Prestazioni (possibile collo di bottiglia)

Approccio distribuito

- Basato su broadcast e sull'ordinamento totale degli eventi nel sistema [Ricart & Agrawala 81]
  - Data una coppia di eventi deve essere univocamente definito quale dei due si è verificato prima
  - Utilizzabili timestamp alla Lamport

Approccio distribuito: algoritmo

- Quando un processo P_i vuole entrare nella SC
  - genera un timestamp TS
  - invia il messaggio *request (Pi ,CSk ,TS)* a tutti i processi del sistema
    - invio dei messaggi affidabile (ACK per ogni messaggio)
- Quando un processo P_j riceve un messaggio di *request*,
  - può mandare un messaggio di *reply (OK)*
  - oppure mettere la richiesta in coda
- Quando un processo P_i riceve un messaggio di reply (OK) da tutti gli altri processi
  - può entrare nella SC
- Quando P_i esce dalla SC
  - invia un messaggio di *reply (OK)* a tutte le richieste accodate

Approccio distribuito: algoritmo

- La decisione di replicare o meno in seguito alla ricezione di *request* (P_i , *CSk, TS)* da parte di P_j dipende da tre situazioni:
  - Se P_j è nella SC
    - accoda il messaggio di reply (OK) a P_i
  - Se P_j non è nella SC e non vuole entrare nella SC
    - invia immediatamente un messaggio di reply (OK) a P_i.
  - Se P_j vuole entrare nella SC
    - confronta il timestamp della propria richiesta TS_j con TS
      - Se TS_j>TS invia immediatamente un messaggio di reply (OK) a P_i(P_i ha richiesto prima)
      - Altrimenti, accoda il messaggio di reply (OK) a P_i

Approccio distribuito: esempio

- P0 e P2 richiedono l'accesso alla stessa risorsa
- P0 entra prima (8<12)
- Una volta finito invia OK a P2

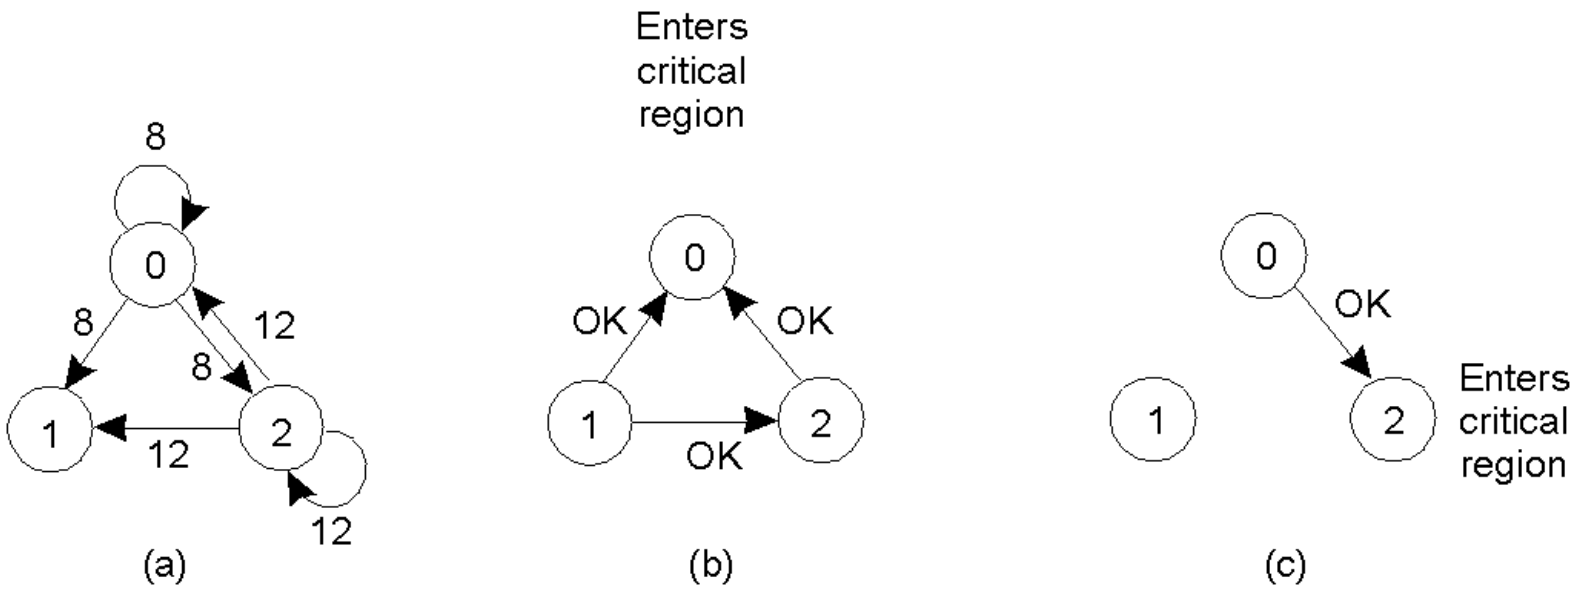

Approccio distribuito

- Vantaggi
  - Mutua esclusione garantita senza deadlock/starvation
  - 2(n-1) messaggi per entrata nella SC
  - Nessun singolo punto di criticità
- Svantaggi
  - n punti di criticità
    - Crash di un processo = divieto di accesso a SC!
  - n colli di bottiglia
  - Necessità di primitive di comunicazione di gruppo
    - I processi devono conoscere l'identità di tutti gli altri
- Variante
  - Modificare l'accodamento con un messaggio di rifiuto
  - Funge da ACK e risolve il problema degli n punti di criticità

Algoritmo token-ring

- Sorta di approccio distribuito
- Assume una specifica organizzazione logica dei processi (ad anello)
- Basato sul passaggio a rotazione di un token tra i vari processi

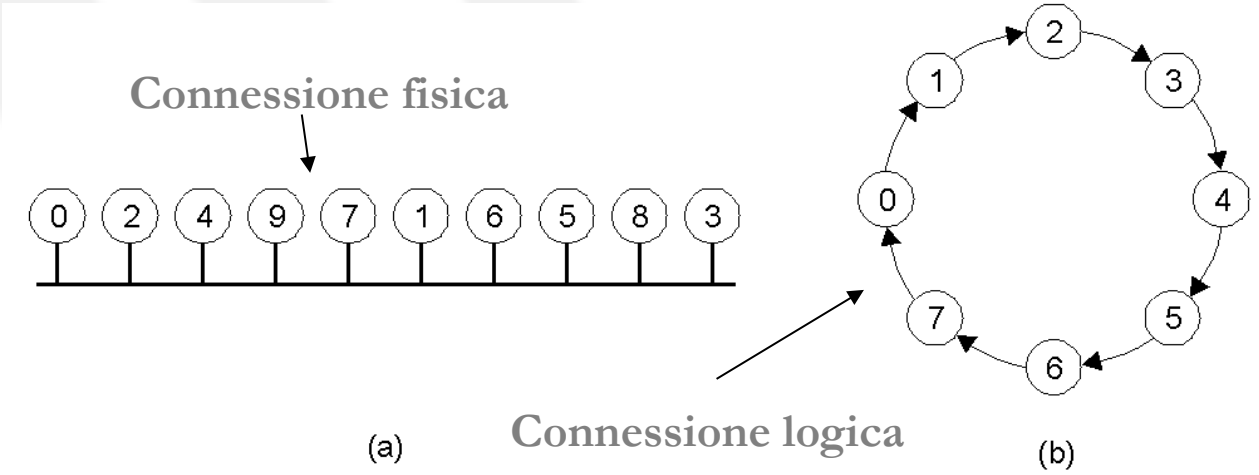

Algoritmo token-ring

- Token originariamente a processo 0
- Passaggio tramite messaggi punto-punto da processo i a i+1 (modulo N)
- Quando un processo riceve il token
  - se vuole entrare nella SC
    - entra nella SC
    - in uscita, passa il token al processo successivo
  - se non vuole entrare
    - passa subito il token

Algoritmo token-ring

- Vantaggi
  - No deadlock/starvation
  - Criticità dei singoli nodi limitata
    - In caso di crash, è sufficiente “bypassare” (aggiornando la struttura della rete)
    - Ci accorgiamo del crash se non arriva ACK del token
- Svantaggi
  - Perdita del token
    - Come individuarla (SC lunga vs. token perso)?

Confronto

Algoritmo	***Msg per entry/ exit***	***Ritardo prima di entrare (in tempi di msg)***	***Problemi***
Centralizzato	3	2	Crash del coordinatore
Distribuito	2 (n – 1)	2 (n – 1)	Crash di ogni processo
Token ring	Da 1 a ∞	Da 0 a n – 1	Perdita del token, crash di un processo

NOTA: (∞ → nessun processo vuole entrare)

TRANSAZIONI

Transazioni atomiche

- Le tecniche precedenti sono da considerarsi “a basso livello”
  - Richiedono la conoscenza da parte del programmatore dei dettagli della mutua esclusione, deadlock, crash, etc.
- Necessario meccanismo più ad alto livello
  - transazioni atomiche (o transazioni)
- Derivate da modello “commerciale”
  - Proprietà tutto-o-niente (all-or-nothing)

Transazioni atomiche: modello

- Esempi di tipiche primitive (offerte da S.O. o da un linguaggio)

Primitiva	Descrizione
BEGIN_TRANSACTION	***Inizio di una transazione***
END_TRANSACTION	***Termine di una transazione e tentativo di conferma (commit)***
ABORT_TRANSACTION	***Cancellazione della transazione e ripristino dei valori iniziali***
READ	***Generica lettura***
WRITE	***Generica scrittura***

- BEGIN/END essenziali
  - delimitano il contesto di una transazione
  - Fondamentali per garantire atomicità

Transazioni atomiche: esempio

- Prenotazione aerea
  - Transazione (a) ok
  - Transazione (b) abortita quando la terza prenotazione non è fattibile

```
BEGIN_TRANSACTION
  reserve WP -> JFK;
  reserve JFK -> Nairobi;
  reserve Nairobi -> Malindi;
END_TRANSACTION
```

(a)

```
BEGIN_TRANSACTION
  reserve WP -> JFK;
  reserve JFK -> Nairobi;
  reserve Nairobi -> Malindi NO
          =>ABORT_TRANSACTION
```

(b)

Transazioni atomiche: proprietà

- Serializzabilità
  - Transazioni concorrenti non interferiscono con altre
    - In pratica, l'esecuzione appare al sistema come se le varie transazioni avvenissero sequenzialmente in un qualche ordine
- Atomicità
  - Transazioni avvengono in modo indivisibile (tutto o niente)
- Permanenza
  - Una volta confermata (commit), le modifiche sono permanenti
- Consistenza
  - Se qualche proprietà invariante è vera prima della transizione, lo deve essere anche dopo

Serializzabilità - esempio

- Esecuzione “seriale”: valore finale dipende dalla sequenza (1, 2 o 3)

```
BEGIN_TRANSACTION
  x = 0;
  x = x + 1;
END_TRANSACTION
```
(a)

```
BEGIN_TRANSACTION
  x = 0;
  x = x + 2;
END_TRANSACTION
```
(b)

```
BEGIN_TRANSACTION
  x = 0;
  x = x + 3;
END_TRANSACTION
```
(c)

Schedule 1	x = 0; x = x + 1; x = 0; x = x + 2; x = 0; x = x + 3	Legale
Schedule 2	x = 0; x = 0; x = x + 1; x = x + 2; x = 0; x = x + 3;	“Legale”
Schedule 3	x = 0; x = 0; x = x + 1; x = 0; x = x + 2; x = x + 3;	Illegale

Transazioni atomiche: implementazione

- Implementazione deve rispettare le 4 proprietà
- Concetto
  - Un processo che esegue una qualunque transazione non deve modificare gli oggetti originali
- Due metodi
  - Utilizzo di uno spazio di lavoro (workspace) privato
  - Write-ahead log

Spazio di lavoro privato

- Uso di uno spazio privato (temporaneo) sul quale operare la transazione
- Commit = copia delle modifiche su spazio comune
- Ottimizzazioni per abbattere il costo
  - No copia per accessi non modificanti
  - Copia di strutture dati (i-node), non di dati
- Esempio:
  - 1,2 = read
  - 0 = write
  - 3 = append

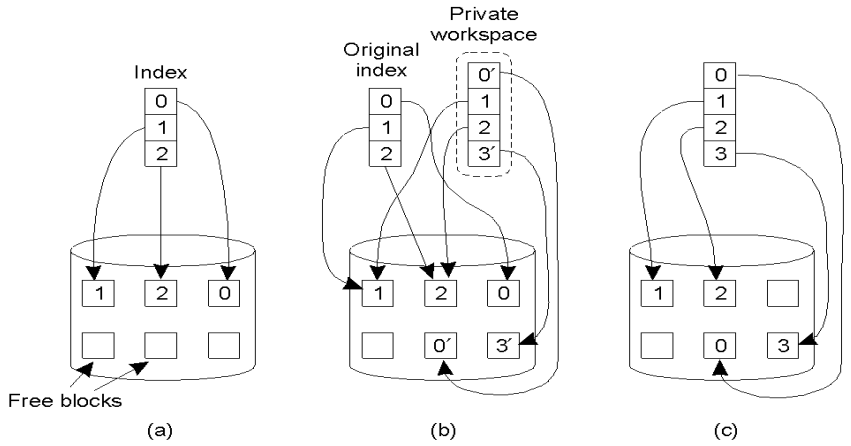

Write-ahead Log

- File di log contenente una sorta di “dichiarazione di intenti”
- Modifiche effettive, ma il log contiene, per ogni transazione, l’effetto della modifica
- Esempio

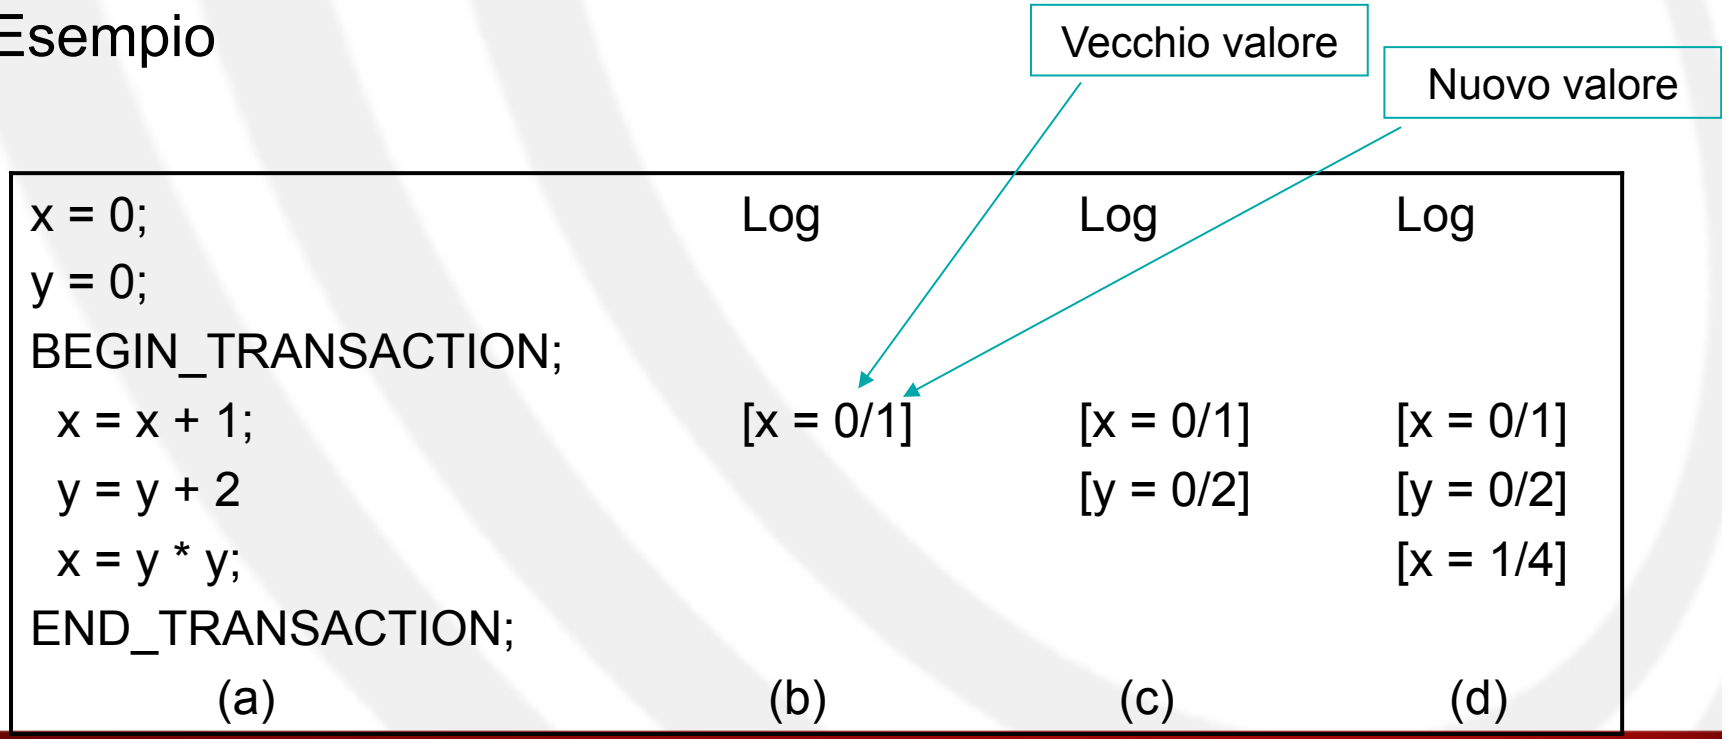

Write-ahead Log

- Al termine delle operazioni
  - Se tutto OK, le modifiche sono già state fatte
  - Se abort, si usa il log (al contrario) per ripristinare (rollback) lo stato precedente alla transazione

Problematiche

- Commit
  - L'operazione di commit deve essere atomica
    - Necessità di opportuno protocollo in ambienti distribuiti
- Controllo della concorrenza
  - Necessario per impedire che transazioni simultanee creino situazioni indesiderate
  - Gestione tramite un transaction manager
    - Two-phase locking, pessimistic timestamp ordering, optimistic timestamp ordering

DEADLOCK IN SISTEMI DISTRIBUITI

Definizione

- Processi utilizzano risorse
- Sequenza di utilizzo
  - Richiesta
    - Se non può essere immediatamente soddisfatta, il processo deve attendere
  - Utilizzo
  - Rilascio
- DEADLOCK
  Un insieme di processi è in deadlock quando ogni processo è in attesa di un evento che può essere causato da un processo dello stesso insieme

Condizioni necessarie

- Mutua esclusione
  - Almeno una risorsa deve essere non condivisibile
- Hold and Wait
  - Deve esistere un processo che detiene una risorsa e che attende di acquisirne un'altra, detenuta da un altro
- No preemption
  - Le risorse non possono essere rilasciate se non "volontariamente" dal processo che le usa
- Attesa circolare
  - Deve esistere un insieme di processi che attendono ciclicamente il liberarsi di una risorsa
- Devono essere vere contemporaneamente
  - Se una non si verifica, non si ha deadlock

Gestione dei deadlock

- Stesse opzioni dei sistemi centralizzati
  - Algoritmo dello struzzo
  - Prevenzione statica
    - Evitare che si possa verificare una delle quattro condizioni
  - Prevenzione dinamica basata su allocazione delle risorse
    - Mai usata: vincolo sulla conoscenza delle richieste di risorse
  - Rivelazione e ripristino
    - Permettere che si verifichino
    - Prevedere metodi per riportare il sistema al funzionamento normale (recovery)

Gestione dei deadlock

- Noi vedremo
  - Rivelazione
    - Centralizzata
    - Distribuita [Chandy&Misra&Haas 83]
  - Prevenzione statica
    - Evitare attesa circolare
    - Distribuita
- Rilevazione e ripristino è accettabile grazie all'uso delle transazioni che permettono di fare rollback

Modello RAG

- Grafo di allocazione delle risorse (RAG) G(V,E)
  - V = nodi
  - E = archi
- Nodi
  - Cerchi = processi (CPU, I/O, memoria)
  - Rettangoli = risorse
    - Nei rettangoli vi sono tanti “ • ” quante sono le istanze della corrispondente risorsa
- Archi
  - Da processi a risorse: processo richiede risorsa
  - Da risorse a processi: processo detiene risorsa

Esempio di RAG

- V = {{P1,P2},{R1}}
- $E_{iniziale}$ = {(R1,P2)} E_{finale} = {(R1,P1),(R1,P2)}

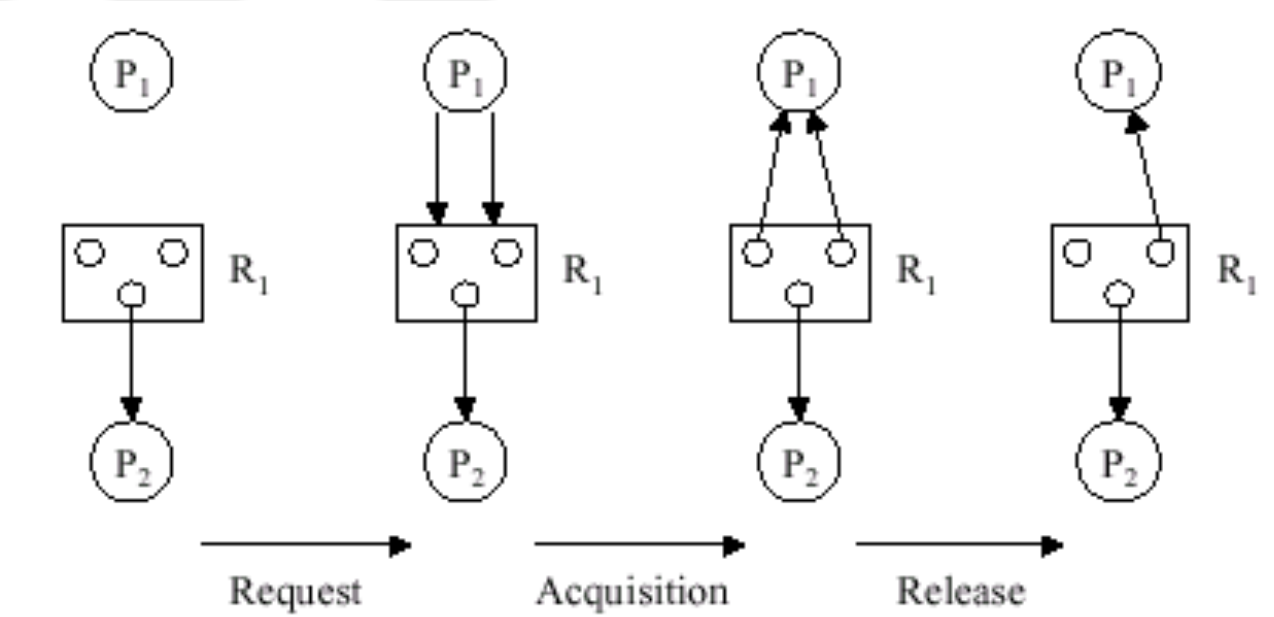

RAG e deadlock

- Se il RAG non contiene cicli, non ci sono deadlock
- Se contiene cicli
  - Se si ha una sola istanza per risorsa → deadlock
  - Se ci sono più istanze, dipende dallo schema di allocazione

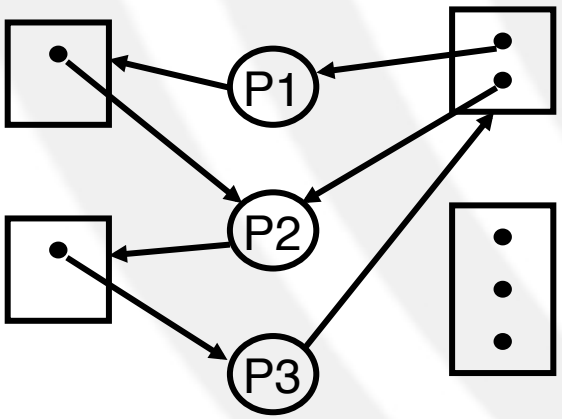

DEADLOCK

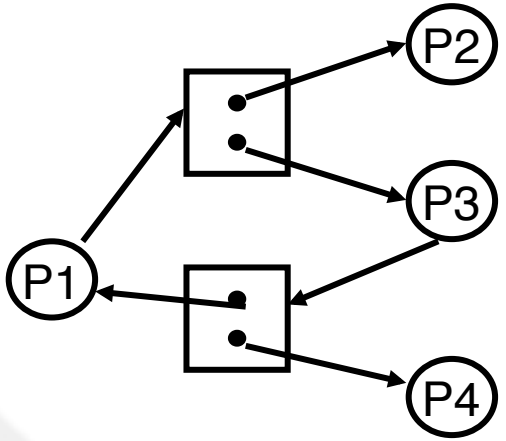

NO DEADLOCK

Rivelazione: approccio centralizzato

- Emulazione del caso non distribuito
- Un coordinatore mantiene un RAG globale
  - Unione dei singoli RAG dei singoli host
  - Se trova un ciclo uccide un processo
- Esempio

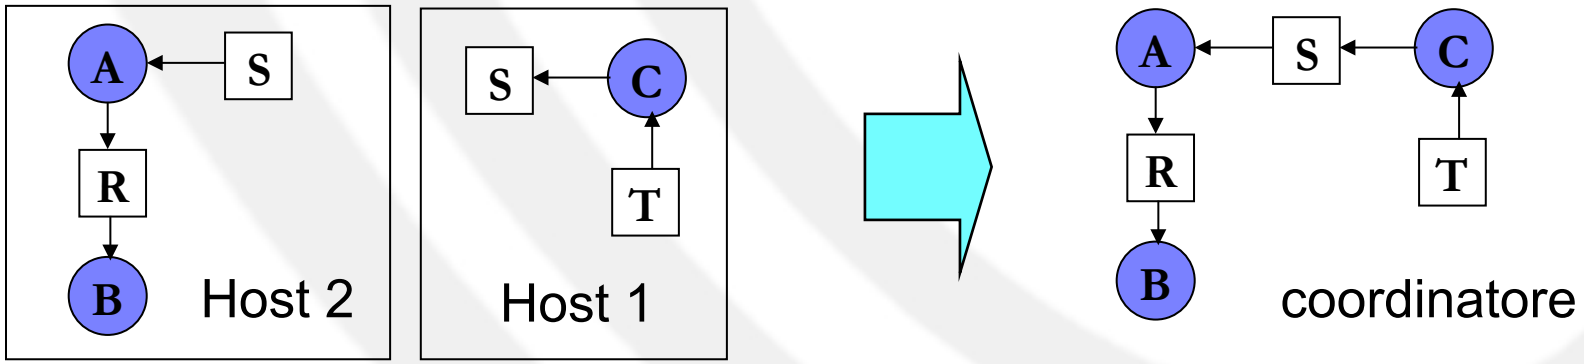

Rivelazione: approccio centralizzato

- Come e quando costruire il RAG globale? (quando trasmettere al coordinatore?)
  - Dopo ogni aggiunta/rimozione di un arco nei grafi locali
  - Periodicamente
  - Su richiesta del coordinatore

Falsi deadlock – Esempio

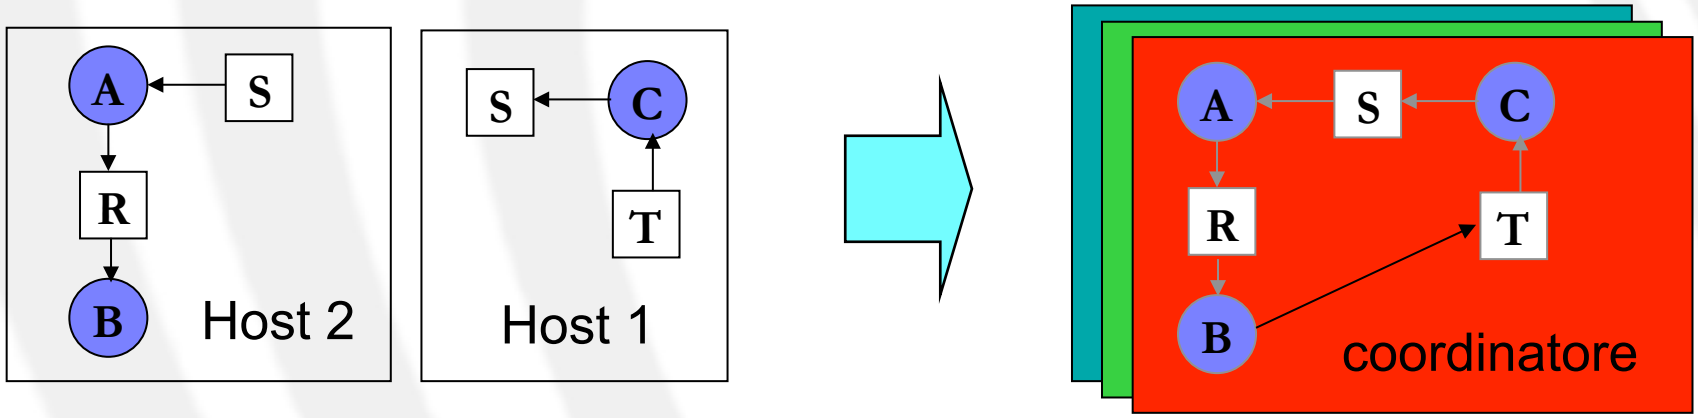

- B rilascia R e richiede T (operazione legale)
- Qual è l'ordine dei messaggi?
  - Msg1: Host 2 annuncia al coordinatore che B lascia R
  - Msg2: Host 1 annuncia al coordinatore che B chiede T
- Se i messaggi arrivano in ordine opposto → falso deadlock

Falsi deadlock – Soluzione

- Aggiornamento del grafo globale deve essere indipendente dall'ordine di ricezione dei messaggi
  - Associazione di timestamp (alla Lamport) alle modifiche dei grafi locali
  - Su ricezione di una modifica con timestamp T, il coordinatore sollecita l'invio di eventuali altre modifiche in corso con timestamp minore di T

Rivelazione: approccio distribuito

- [Chandy&Misra&Haas 83]
  - Invocato quando un processo si mette in attesa per una qualche risorsa
    - Invia messaggi di *probe* ai processi che detengono la risorsa
      - Messaggio = (id proc bloccato, id proc mittente, id proc destinatario)
    - probe propagato a catena ai processi (eventualmente remoti) a loro volta in attesa
      - Se il ricevente è in attesa rispedisce il probe aggiornando mittente e destinatario
    - Se il messaggio raggiunge il mittente → deadlock
  - Recovery
    - Uccisione dell'iniziatore del probe → possibili molte uccisioni se + processi iniziano l'algoritmo contemporaneamente
    - Uccisione del processo con id più altro

Rivelazione: approccio distribuito

- Esempio:
- Il sistema è in deadlock perché il processo 0 (che inizia l'algoritmo) riceve un messaggio (0,8,0) in cui l'id del processo bloccato è proprio 0.

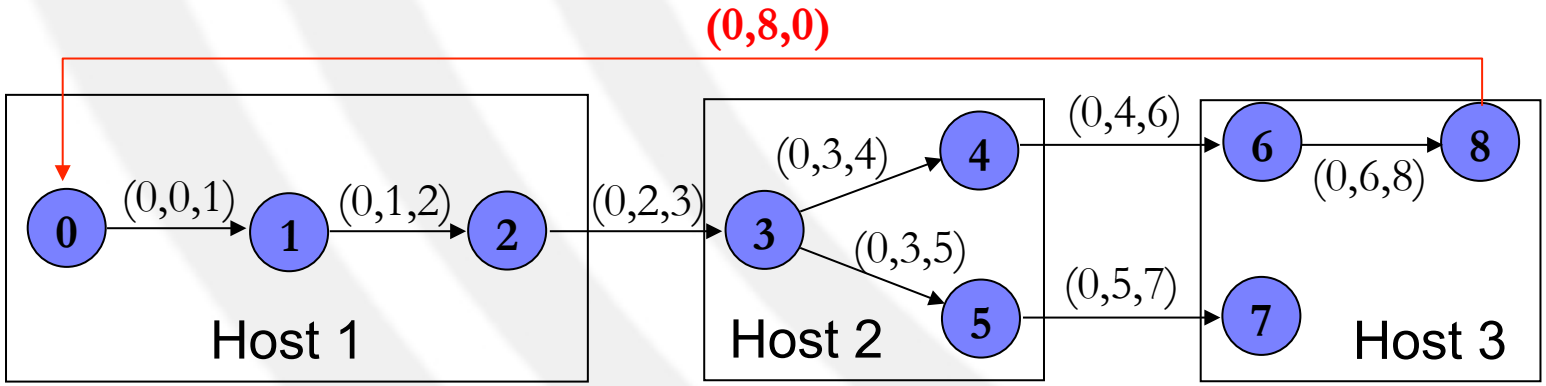

Prevenzione statica

- Prevenzione della condizione di attesa circolare
  - Definizione di un ordine globale tra le risorse del sistema
  - Es: assegnazione di un unico numero ad ogni risorsa
    - Un processo può richiedere una risorsa con un numero n solo se non possiede risorse con numeri più alti di n
    - In tal modo è impossibile che si verifichi attesa circolare
  - Implementazione semplice e a basso costo

Prevenzione statica

- In presenza di:
  - Transazioni atomiche
  - Ordinamento globale del tempo (Lamport)
- possibili altri schemi:
  - Wait-die (aspetta-muori)
  - Wound-wait (ferisci-aspetta)

Prevenzione statica basata su timestamp

- Timestamp usato come valore di priorità di ogni processo
- Uso dei timestamp per regolare l'attesa di un processo
  - Schema non-preemptive (wait-die)
  - Schema preemptive (wound-wait)
- L'uso dei timestamp previene starvation

Schema Wait-Die

- Se un processo P_i necessita di una risorsa detenuta da un processo P_j
  - se $TS(P_i) < TS(P_j)$ ➡ P_i si mette in attesa (wait)
  - se $TS(P_i) > TS(P_j)$ ➡ rollback di P_i (die)

Wait-die – esempio

wait

TS = 10

TS = 99

die

TS = 110

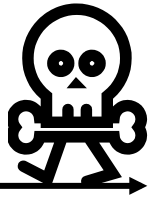

TS = 10

→ **Sempre nella direzione di timestamp crescenti**

Schema Wound-Wait

- Se un processo P_i necessita di una risorsa detenuta da un processo P_j
  - se $TS(P_i) < TS(P_j)$ ➡ P_j viene ferito e ucciso (wound)
  - se $TS(P_i) > TS(P_j)$ ➡ si mette in attesa (wait)

Wound-wait – esempio

wound

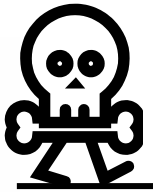

TS = 10

TS = 110

wait

TS = 99

TS = 10

Sempre nella direzione di timestamp decrescenti

Prevenzione statica basata su timestamp

- Rollback possibile grazie a transazioni ➡ possibile sottrarre risorse senza danni!
- Wait-die tende ad ammazzare tanti processi giovani
  - Vecchio rispettoso aspetta
  - Giovane presuntuoso viene ripetutamente ucciso
- Wound-wait ammazza una sola volta
  - Vecchio saggio prelaziona il giovane
  - Il giovane riparte e attende pazientemente

ALGORITMI DI ELEZIONE

Algoritmi di elezione

- Alcuni algoritmi distribuiti richiedono la presenza di un processo speciale (es.: coordinatore, iniziatore)
- Necessità di algoritmi specifici per stabilire chi eleggere (o rieleggere)
- Assunzioni:
  - Un valore unico di priorità *i* associato ad ogni processo P_i del sistema (solitamente PID)
  - Corrispondenza uno a uno tra host e processo (1 processo/1 host)
- Coordinatore = processo con valore di priorità più alto

Algoritmo del bullo

- [Garcia-Molina 82]
- Applicabile a sistemi in cui ogni processo può mandare un messaggio ad ogni altro processo
- Schema
  - Iniziato da un processo P_i nel caso di richiesta non risposta dal coordinatore entro un tempo T
  - P_i assume che il coordinatore non è attivo e cerca di eleggere se stesso come coordinatore

Algoritmo del bullo

- Processo di elezione
  - P_i manda un messaggio (ELECTION) ad ogni processo con un valore di priorità più alto, ed attende una replica entro un tempo T
  - Se non riceve risposta entro T, assume che tutti i processi destinazione non siano attivi; P_i elegge se stesso come coordinatore
  - Se riceve risposta (OK), i processi che hanno ricevuto il messaggio lanciano a loro volta un'elezione
    P_i resta in attesa di una messaggio da parte del nuovo coordinatore (COORDINATOR)
    - Attesa legata a timeout (T´)
    - Se non riceve messaggi entro T´, P_i rilancia un'elezione

Algoritmo del bullo

- L'algoritmo "favorisce" processi che ripartono dopo un crash
  - Il processo esegue l'algoritmo
  - Se non ci sono processi con valori più alti, il processo ripartito (bullo) obbliga tutti i processi con valori più bassi a farlo diventare il coordinatore
  - Generalmente il processo che riparte ha un PID maggiore rispetto a quello dei processi già esistenti

Algoritmo del bullo: esempio

1. P7 crash
2. P4 lancia un'elezione
3. P5 e P6 rispondono a P4 (OK)
4. P5 e P6 lanciano un'elezione
5. P6 risponde a P5 (OK)
6. P6 comunica a tutti che e' il nuovo coordinatore

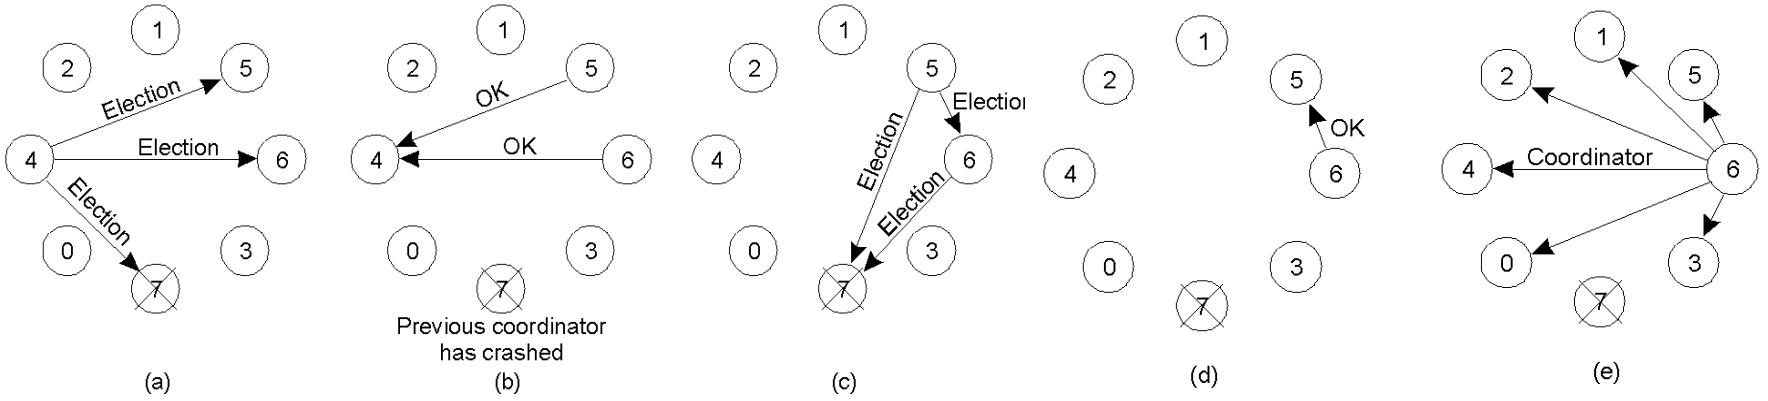

Algoritmo dell'anello

- Applicabile a sistemi organizzati ad anello (logico)
- Assunzioni
  - Link unidirezionali
  - Processi mandano messaggi al processo adiacente
  - Ogni processo mantiene una lista di tutti i valori di priorità di tutti i processi nel sistema
- Se il processo P_i osserva un problema nel coordinatore, lancia un'elezione a cascata
  - Messaggio ELECTION al primo successore attivo
  - Aggiunge il valore *i* (la propria priorità) alla lista

Algoritmo dell'anello

- Prima o poi, P_i riceverà un messaggio contenente il proprio numero
- A questo punto P_i è in grado di decidere chi è il coordinatore
  - Fa circolare lo stesso messaggio, stavolta di tipo COORDINATOR
  - Tutti i processi, analizzando la lista, determinano il nuovo coordinatore (processo con priorità massima)
  - Quando i vari messaggi COORDINATOR sono circolati una volta, vengono eliminati
- Messaggi ridondanti!

Algoritmo dell'anello: esempio

- P7 crash
- P5 e P2 lanciano un'elezione simultaneamente
- Quando P5 e P2 ricevono un messaggio contenente 2 e 5 rispettivamente, lanciano un messaggio COORDINATOR
- P6 diventa nuovo coordinatore