TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA

Macroarea di Ingegneria
Dipartimento di Ingegneria Civile e Ingegneria Informatica

Sincronizzazione e Coordinazione nei Sistemi Distribuiti

Corso di Sistemi Distribuiti e Cloud Computing

A.A. 2022/23

Valeria Cardellini

Laurea Magistrale in Ingegneria Informatica

Il tempo nei SD

- In un SD, i processi
  - vengono eseguiti su nodi connessi in rete
  - cooperano per portare a termine una computazione
  - comunicano tramite scambio di messaggi
- Osservazioni*:*
  - Molti algoritmi distribuiti richiedono sincronizzazione
    - Ovvero i processi in esecuzione su diversi nodi del SD devono avere una nozione comune di tempo per poter effettuare azioni sincronizzate rispetto al tempo
  - Molti algoritmi richiedono che gli eventi siano ordinati
    - Nei SD i messaggi arrivano con dei timestamp in modo che si possa sapere in che ordine devono essere eseguiti
- *Conseguenza*: nei SD il tempo è un fattore critico

Il tempo nei SD

- In un sistema centralizzato è possibile stabilire l'ordine in cui gli eventi si sono verificati
  - Memoria comune e clock unico
- In un sistema distribuito è impossibile avere un unico clock fisico comune a tutti i processi
  - Eppure la computazione globale può essere vista come un ordine totale di eventi, se si considera il tempo in cui gli eventi sono stati generati
- Per numerosi problemi nei SD è di vitale importanza risalire a questo tempo, o comunque è importante stabilire l'**ordinamento degli eventi**, ovvero quale evento è stato generato prima di un altro. **Come?**

Il tempo nei SD: soluzioni

- Soluzione 1: **sincronizzazione degli orologi fisici**
  - Il middleware di ogni nodo del SD aggiusta il valore del suo clock fisico in modo coerente con quello degli altri nodi o con quello di un clock di riferimento
- Soluzione 2: **sincronizzazione degli orologi logici**
  - Leslie Lamport ha dimostrato come in un SD non sia necessaria la sincronizzazione degli orologi fisici, ma lo sia solo l'ordinamento degli eventi

Modello della computazione distribuita

- Componenti del SD: *N* processi e canali di comunicazione
- Ogni processo p_i ($1 \le i \le N$) genera una sequenza di eventi
  - Eventi ***interni*** (cambiamento dello stato del processo) ed ***esterni*** (send/receive di messaggi)
  - e_i^k: *k*-esimo evento generato da p_i
- L'evoluzione della computazione può essere visualizzata con un *diagramma spazio-tempo*

  $\rightarrow_i$: relazione di ordinamento tra due eventi in p_i

  $e \rightarrow_i e'$ se e solo se *e* è accaduto prima di *e'* in p_i

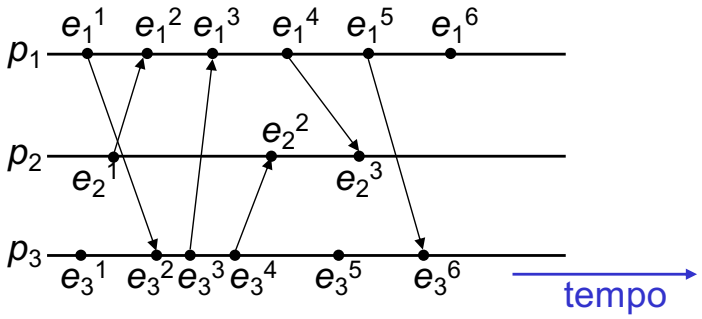

Timestamping

- Ogni processo etichetta gli eventi con un **timestamp**
- Soluzione banale: ogni processo etichetta gli eventi in base al proprio clock fisico
- Funziona?
  - Possiamo ricostruire l'ordinamento di eventi avvenuti su uno stesso nodo
  - Ma l'ordinamento di eventi avvenuti su nodi diversi?
  - In un sistema distribuito è *impossibile* avere un unico clock fisico condiviso da tutti i processi

SD sincroni e asincroni

- Proprietà di un **SD sincrono**
  1. Esistono dei vincoli sulla velocità di esecuzione di ciascun processo
     - Il tempo di esecuzione di ciascuno passo è limitato, sia con lower bound che con upper bound
  2. Ciascun messaggio trasmesso su un canale di comunicazione è ricevuto in un tempo limitato
  3. Ciascun processo ha un clock fisico con un tasso di scostamento (*clock drift rate*) dal clock reale conosciuto e limitato

- In un **SD asincrono**
  - *Non ci sono vincoli* sulla velocità di esecuzione dei processi, sul ritardo di trasmissione dei messaggi e sul tasso di scostamento dei clock

Soluzioni per sincronizzare i clock

- Prima soluzione
  - Tentare di sincronizzare con *una certa approssimazione* i clock fisici dei processi attraverso opportuni algoritmi
  - Ogni processo può etichettare gli eventi con il valore del suo clock fisico (che risulta sincronizzato con gli altri clock con una certa approssimazione)
  - Timestamping basato su tempo fisico (***clock fisico***)

- E' sempre possibile mantenere limitata l'approssimazione dei clock fisici?
  - **No** in un SD asincrono: quindi in un SD asincrono il timestamping non può basarsi sul concetto di tempo fisico
  - Si introduce la nozione di clock basata su tempo logico (***clock logico***)

Clock fisico

- All'istante di tempo reale t, il sistema operativo legge il tempo dal clock hardware $H_i(t)$ del computer e produce il clock software

$$C_i(t) = aH_i(t) + b$$

che approssimativamente misura l'istante di tempo fisico t per il processo p_i

  - Ad es. $C_i(t)$ è un numero a 64 bit che fornisce i nsec trascorsi da un istante di riferimento fino all'istante t
  - In generale il clock non è completamente accurato: può essere diverso da t
  - Se C_i si comporta abbastanza bene, può essere usato per il timestamping degli eventi di p_i
- Quale deve essere la risoluzione del clock per poter distinguere due eventi?

$T_{risoluzione} < \Delta T$ tra due eventi rilevanti

Clock fisici in un SD

- In un SD clock fisici diversi con possibili valori diversi
- *Skew*: differenza istantanea fra il valore di due clock
- *Drift*: i clock contano il tempo con frequenze differenti (a causa di variazioni fisiche), quindi nel tempo divergono rispetto al tempo reale
- *Drift rate*: differenza per unità di tempo di un clock rispetto ad un orologio ideale
  - Ad es. drift rate di 2 μsec/sec significa che il clock incrementa il suo valore di 1 sec+2 μsec ogni secondo
  - Drift rate di normali orologi al quarzo: 10^{-6} s/s (circa 1 s in 11-12 giorni)
  - Drift rate di orologi al quarzo ad alta precisione: 10^{-7} o 10^{-8} s/s
  - A causa del drift rate, dopo un certo intervallo di tempo i clock di un SD saranno di nuovo disallineati → occorre eseguire una sincronizzazione periodica per riallineare i clock

UTC

- Universal Coordinated Time (UTC): riferimento internazionale per il tempo
- Basato sul tempo atomico, occasionalmente corretto utilizzando il tempo astronomico
  - 1 sec = tempo impiegato dall'atomo di cesio 133 per compiere 9192631770 transizioni di stato
- Clock fisici che usano oscillatori atomici sono i più accurati (drift rate pari a 10^{-13} s/s)
- L'output dell'orologio atomico è inviato in broadcast da stazioni radio su terra e da satelliti (es. GPS)
  - In Italia: Istituto Galileo Ferraris
- Nodi con ricevitori possono sincronizzare i loro clock con questi segnali
  - Segnali da stazioni radio su terra: accuratezza nell'intervallo 1-10 ms
  - Segnali da satellite: accuratezza da 0.5 ms fino a 50 ns

Sincronizzazione di clock fisici

- Come sincronizzare i clock fisici con l'orologio atomico oppure tra di loro?
- Sincronizzazione **esterna**

  I clock C_i (per i = 1, 2, … N) sono sincronizzati con una sorgente di tempo S (UTC), in modo che, dato un intervallo I di tempo reale:

  $|S(t) - C_i(t)| \leq \alpha$ per $1 \leq i \leq N$ e per tutti gli istanti in I
  - I clock C_i hanno **accuratezza** α, *con* $\alpha>0$
- Sincronizzazione **interna**

  Due clock C_i e C_j sono sincronizzati l'uno con l'altro in modo che:

  $|C_i(t) - C_j(t)| \leq \pi$ per $1 \leq i,j \leq N$ nell'intervallo I
  - I clock C_i e C_j hanno **precisione** π, *con* $\pi>0$

Sincronizzazione di clock fisici

Sincronizzazione interna

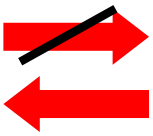

Sincronizzazione esterna

- Clock sincronizzati internamente non sono necessariamente sincronizzati anche esternamente
  - Tutti i clock possono deviare collettivamente da una sorgente esterna sebbene rimangano tra loro sincronizzati entro il bound *D*
- Se l'insieme dei processi è sincronizzato esternamente con accuratezza α, allora è anche sincronizzato internamente con precisione 2α

Correttezza di clock fisici

- Un clock hardware *H* è *corretto* se il suo drift rate è compreso tra $-\rho$ e $+\rho$ con $\rho > 0$
- Se il clock *H* è corretto, l'*errore* che si commette nel misurare un intervallo di istanti reali $[t, t']$ (con $t'>t$) è *limitato*:

$$(1 - \rho)\,(t' - t) \leq H(t') - H(t) \leq (1 + \rho)\,(t' - t)$$

  - Si evitano "salti" del valore del clock
- Per il clock software *C* spesso basta una condizione di monotonicità

$$t' > t \text{ implica } C(t') > C(t)$$

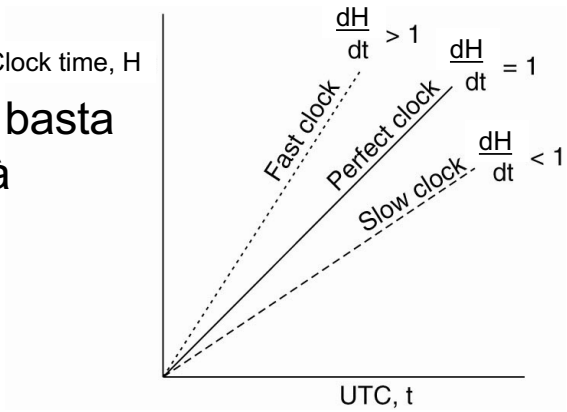

Quando sincronizzare i clock fisici?

- Consideriamo 2 clock aventi lo stesso tasso di scostamento massimo (*maximum clock drift rate*) da UTC pari a ρ
- Ipotizziamo che dopo la sincronizzazione i 2 clock si scostino da UTC in senso opposto
  - Dopo Δt si saranno scostati di $2\rho\ \Delta t$
- Per garantire che i 2 clock non differiscano più di δ, occorre sincronizzarli almeno ogni $\delta/2\rho$ secondi

Sincronizzazione interna in un SD sincrono

- Algoritmo di sincronizzazione **interna** tra due processi in un **SD sincrono**
  1. Un processo p_1 manda il suo clock locale t ad un processo p_2 tramite un messaggio m
  2. p_2 riceve m e imposta il suo clock a $t + T_{trasm}$ dove T_{trasm} è il tempo di trasmissione di m

     T_{trasm} non è noto ma, essendo il SD sincrono, $T_{min} \leq T_{trasm} \leq T_{max}$

     Sia $u = (T_{max} - T_{min})$ l'incertezza sul tempo di trasmissione (ovvero l'ampiezza dell'intervallo)
  3. Se p_2 imposta il suo clock a $t + (T_{max} + T_{min})/2$, il lower bound ottimo sullo skew tra i due clock è pari a $u/2$
- L'algoritmo può essere generalizzato per sincronizzare N processi, con lower bound ottimo sullo skew pari a $u(1\text{-}1/N)$
- In un SD asincrono $T_{trasm} = T_{min} + x$, con $x \geq 0$ e non noto
  - Occorrono altri algoritmi di sincronizzazione dei clock fisici

Sincronizzazione mediante time service

- Un time service può fornire l'ora con precisione
  - Dotato di un ricevitore UTC o di un clock accurato
- Il gruppo di processi che deve sincronizzarsi usa un time service
  - Time service implementato in modo centralizzato da un solo processo (time server) oppure in modo decentralizzato da più processi
- Time service centralizzati
  - Request-driven: algoritmo di Cristian (1989)
    - Sincronizzazione esterna
  - Broadcast-based: algoritmo di Berkeley Unix - Gusella & Zatti (1989)
    - Sincronizzazione interna
- Time service distribuiti
  - Network Time Protocol
    - Sincronizzazione esterna

Algoritmo di Cristian

- Un time server *S* (*passivo*) riceve il segnale da una sorgente UTC (sincronizzazione esterna)
- Un processo *p* richiede il tempo con un messaggio m_r e riceve *t* nel messaggio m_t da *S*
- *p* imposta il suo clock a $t + T_{round}/2$
  - T_{round} è il round trip time (RTT) misurato da *p*

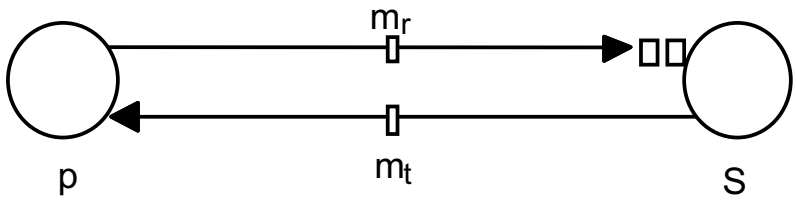

- Osservazioni
  - Singolo time server potrebbe guastarsi
    - Soluzione: usare un gruppo di time server sincronizzati
  - Non gestiti time server maliziosi
  - Accuratezza ragionevole solo se T_{round} è breve → adatto per reti locali con bassa latenza

Algoritmo di Cristian: accuratezza

Caso 1: *S* non può mettere *t* in m_t prima che sia trascorso *min* dall'istante in cui *p* ha inviato m_r
- *min* è il minimo tempo di trasmissione tra *p* e *S*

Caso 2: *S* non può mettere *t* in m_t dopo il momento in cui m_t arriva a *p* meno *min*

- Il tempo su S quando m_t arriva a *p* è compreso in $[t + min, t + T_{round} - min]$
  - L'ampiezza di tale intervallo è $T_{round} - 2\ min$
- Accuratezza: $\alpha \leq \pm (T_{round}/2 - min)$

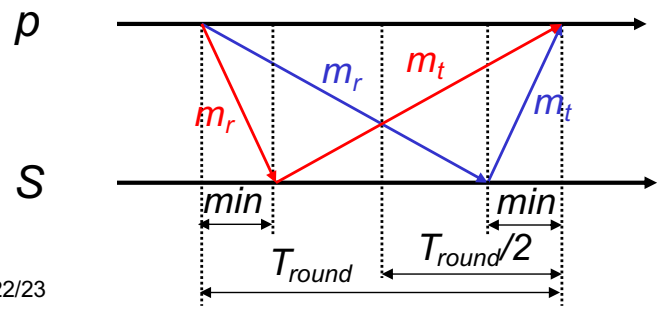

Algoritmo di Berkeley

- Algoritmo per la sincronizzazione interna di un gruppo di macchine
- Il *master* (time server *attivo*) richiede in broadcast il valore dei clock delle altre macchine (*worker*)
- Il master usa i RTT per stimare i valori dei clock dei worker
  - d_i è la differenza tra clock del master *M* e clock del worker *i* (si calcola in modo simile all'algoritmo di Cristian):

    $d_i = (C_M(t_1) + C_M(t_3))/2 - C_i(t_2)$

    dove: $C_M(t_1)$ e $C_M(t_3)$ sono i valori del clock sul master

    $C_i(t_2)$ è il valore del clock sul worker *i*
- Calcola la media delle differenze dei clock
- Invia un valore correttivo ai worker
  - Se il valore correttivo prevede un salto indietro nel tempo, il worker non imposta il nuovo valore ma rallenta il clock

Algoritmo di Berkeley: esempio

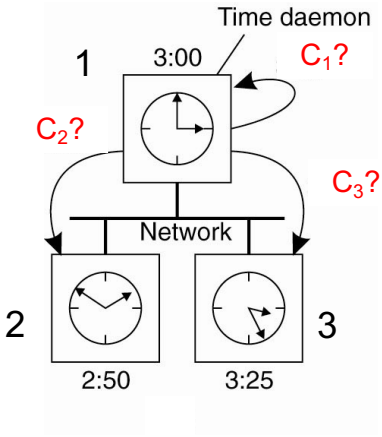

Il master chiede ai worker e a se stesso il valore dei clock

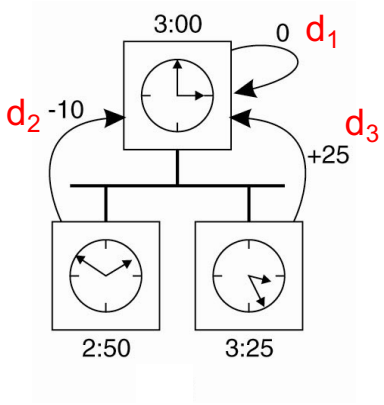

Il master calcola la media delle differenze dei clock pari a
avg = (-10+25+0)/3 = 5

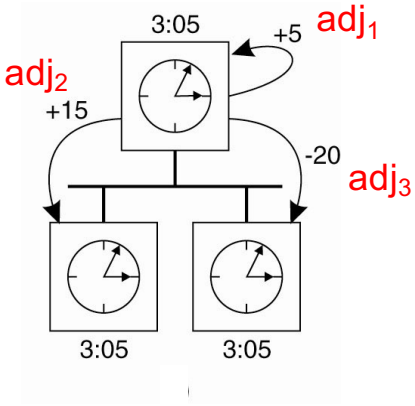

Il master invia ai worker l'aggiustamento dei clock ($adj_i = avg - d_i$)

Algoritmo di Berkeley: caratteristiche

- Precisione dipende da RTT nominale massimo: il master non considera valori di clock associati a RTT superiori al massimo
  - Si scartano gli outlier
- Tolleranza ai guasti
  - Se il master cade, un altro nodo viene eletto come master
    - Tramite un algoritmo di elezione
  - Tollerante a comportamenti arbitrari (worker che inviano valori errati di clock)
    - Il master considera solo quei valori di clock che differiscono tra loro al più per una soglia specificata

Algoritmo di Berkeley: slowdown del clock

- Che cosa significa rallentare un clock?
- Non è possibile imporre un valore di tempo passato ai worker che hanno un valore di clock superiore a quello calcolato come clock comune
  - Ciò provocherebbe un problema di ordinamento causa/effetto di eventi e verrebbe violata la condizione di monotonicità del tempo
- La soluzione consiste nel mascherare una serie di interrupt che fanno avanzare il clock locale in modo da rallentare l'avanzata del clock stesso
  - Il numero di interrupt mascherati è pari al tempo di slowdown diviso il periodo di interrupt del processore

Network Time Protocol (NTP)

- Time service per Internet (standard in RFC 5905)
  - Sincronizzazione esterna accurata rispetto a UTC
  - Servizio configurabile su diversi SO. In GNU/Linux: demone `ntpd`, comando `ntpdate` per sincronizzare manualmente
- Architettura di time service disponibile e scalabile
  - Time server e path ridondanti
- Autenticazione delle sorgenti di tempo

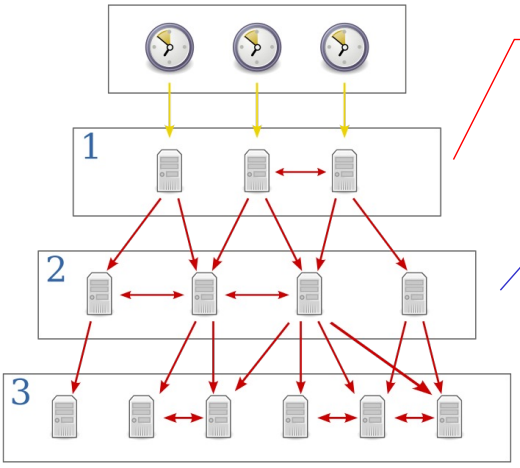

Server primari connessi a sorgenti UTC (livello 1)

Server secondari (livello 2) sincronizzati da server primari

Sottorete di sincronizzazione: server foglia eseguiti su macchine utente

NTP: sincronizzazione

- La sottorete di sincronizzazione si riconfigura in caso di guasti
  - Server primario che perde la connessione alla sorgente UTC diventa server secondario
  - Server secondario che perde la connessione al suo primario (ad es. crash del primario) può usare un altro primario

NTP: modi di sincronizzazione

- Modi di sincronizzazione
  - **Multicast**: server all'interno di LAN ad alta velocità invia in multicast il suo tempo agli altri, che impostano il tempo ricevuto assumendo un certo ritardo di trasmissione
    - Accuratezza relativamente bassa
  - **Procedure call**: un server accetta richieste da altri (come algoritmo di Cristian)
    - Accuratezza maggiore rispetto a multicast
    - Utile se non è disponibile multicast
  - **Simmetrico**: coppie di server scambiano messaggi contenenti informazioni sul timing
    - Accuratezza molto alta (usato per livelli alti della gerarchia)
- Tutti i modi di sincronizzazione usano UDP

NTP: modo simmetrico

- I server A e B si scambiano coppie di messaggi (*m*, *m'*) per migliorare l'accuratezza della loro sincronizzazione
- Ogni messaggio NTP contiene timestamp di eventi recenti:
  - Tempo su B di *send* di *m'* (T_{i-1})
  - Tempo su A di *send* di *m* (T_{i-3}) e tempo su B di *receive* di *m* (T_{i-2})
- Il server A registra in tempo di receive di *m'* (T_i)
- Il tempo tra l'arrivo di *m* e l'invio di *m'* (T_{i-1}-T_{i-2}) può essere non trascurabile

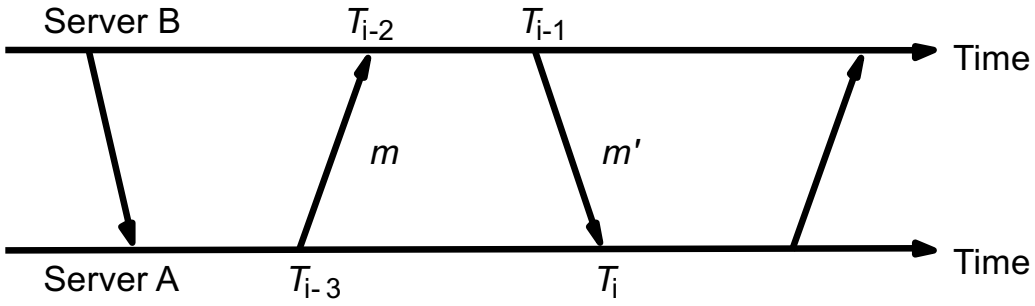

NTP: accuratezza

- Per ogni coppia di messaggi *m* ed *m'* scambiati tra 2 server, NTP stima l'offset o_i tra i 2 clock e il ritardo d_i (pari al tempo totale di trasmissione per *m* ed *m'*)

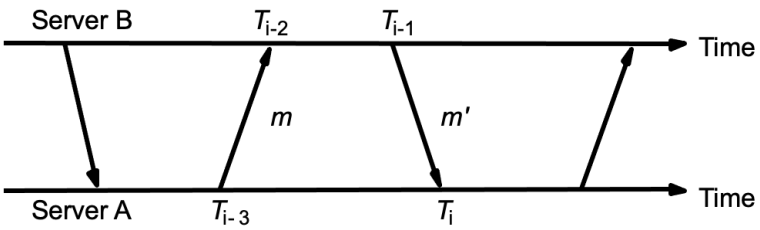

- Indicando con:
  - *o*: offset reale del clock di B rispetto al clock di A ($o = clock_B - clock_A$)
  - *t* e *t'*: tempi di trasmissione di *m* ed *m'* rispettivamente
- si ha

$$T_{i-2} = T_{i-3} + t + o \quad \text{e} \quad T_i = T_{i-1} + t' - o$$
$$d_i = t + t' = T_{i-2} - T_{i-3} + T_i - T_{i-1}$$

- Sottraendo le equazioni e ponendo $o_i = [(T_{i-2} - T_{i-3}) + (T_{i-1} - T_i)]/2$

$$o = o_i + (t' - t)/2$$

- Poiché $t, t' > 0$ si può dimostrare che

$$o_i - d_i/2 \le o \le o_i + d_i/2$$

- Quindi: o_i è la stima dell'offset e $d_i/2$ l'accuratezza di questa stima

NTP: accuratezza

- I server NTP applicano un algoritmo di filtraggio statistico sulle 8 coppie $<o_i, d_i>$ più recenti, scegliendo come stima di o il valore di o_j corrispondente al minimo d_j
- Applicano poi un algoritmo di selezione dei peer per modificare eventualmente il peer da usare per sincronizzarsi www.eecis.udel.edu/~mills/ntp/html/warp.html
- Accuratezza di NTP:
  - 10 ms su Internet
  - 1 ms su LAN

Perfect synchronization over networks is actually impossible

Google's TrueTime (TT)

- Distributed synchronized clock with bounded non-zero error
  - Designed by Google for Spanner, a global-scale distributed NewSQL database
  - Relies on a well-engineered tight clock synchronization available on all Google servers thanks to GPS and atomic clocks
  - Enables applications to generate monotonically increasing timestamps
  - *Cons*: TT requires special hardware and custom-build tight clock synchronization protocol, which is infeasible for many systems
    - Google also relies on its very high throughput, global fiber optic network linking its data centers

Tempo nei SD asincroni

- Gli algoritmi per la sincronizzazione dei clock fisici si basano sulla stima dei tempi di trasmissione
  - Possiamo determinare l'accuratezza conoscendo upper e lower bound del tempo di trasmissione
- Ma in un SD asincrono, no vincoli sui tempi di trasmissione → non possiamo ordinare gli eventi che accadono in nodi diversi usando il tempo fisico
- Tuttavia, di solito ci interessa soltanto che i processi concordino sull'ordine in cui si verificano gli eventi, piuttosto che sul tempo in cui sono avvenuti
  - Il tempo fisico non è più importante, usiamo il tempo logico

Tempo logico

- Idea: ordinare gli eventi in base a 2 osservazioni intuitive:
  1. Due eventi occorsi sullo stesso processo p_i si sono verificati esattamente nell'ordine in cui p_i li ha osservati
  2. Quando un messaggio viene inviato da p_i a p_j, l'evento di *send* precede l'evento di *receive*

- Lamport (1978) introduce il concetto di relazione di ***happened-before*** (anche detta relazione di *precedenza* o *ordinamento causale*)
  - $\rightarrow_i$: relazione di ordinamento tra due eventi occorsi su p_i
  - $\rightarrow$: relazione di happened-before tra due eventi qualsiasi

L. Lamport, Time, Clocks and the Ordering of Events in Distributed Systems, Comm. ACM, 1978

Relazione happened-before

- Due eventi *e* ed *e'* sono in relazione di happened-before (indicata con $e \rightarrow e'$) se è vero uno dei seguenti casi:
  1. $\exists\ p_i \mid e \rightarrow_i e'$
  2. $e = send(m) \wedge e' = receive(m)$

     e è l'evento di invio del messaggio *m*, *e'* è il corrispondente evento di ricezione
  3. $\exists\ e, e', e'' \mid (e \rightarrow e'') \wedge (e'' \rightarrow e')$

     Ovvero la relazione happened-before è transitiva
- Applicando i tre casi è possibile costruire una sequenza di eventi $e_1, e_2, \ldots, e_n$ causalmente ordinati
- *Osservazioni*
  - La relazione happened-before rappresenta un ordinamento parziale (proprietà: *non riflessivo*, *antisimmetrico*, *transitivo*)
  - Non è detto che la sequenza $e_1, e_2, \ldots, e_n$ sia unica
  - Data una coppia di eventi, questa non è sempre legata da una relazione happened-before; in questo caso si dice che gli eventi sono *concorrenti* (indicato da ||)

Relazione happened-before: esempio

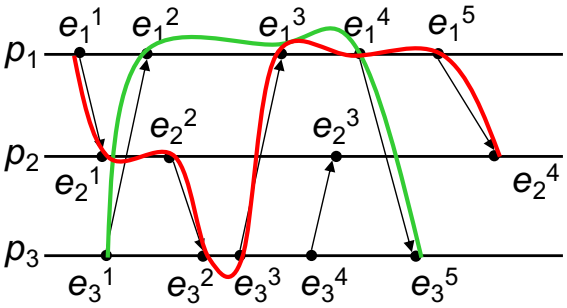

- Sequenza $s_1 = e_1^1, e_2^1, e_2^2, e_3^2, e_3^3, e_1^3, e_1^4, e_1^5, e_2^4$
- Sequenza $s_2 = e_3^1, e_1^2, e_1^3, e_1^4, e_3^5$

- Gli eventi e_3^1 ed e_2^1 sono concorrenti

  $e_3^1 \not\rightarrow e_2^1$ ed $e_2^1 \not\rightarrow e_3^1$

Clock logico scalare

- Il clock logico è un contatore software *monotonicamente crescente*, il cui valore non ha alcuna relazione con il clock fisico
- Ogni processo p_i ha il proprio clock logico L_i e lo usa per applicare i *timestamp* agli eventi
- Denotiamo con $L_i(e)$ il timestamp, basato sul clock logico, applicato dal processo p_i all'evento e
- Proprietà: **se $e \rightarrow e'$ allora $L(e) < L(e')$**
- *Osservazione*:
  - Se $L(e) < L(e')$ non è detto che $e \rightarrow e'$; tuttavia, $L(e) \not< L(e')$ implica che $e \not\rightarrow e'$
  - Happened-before introduce un ordinamento parziale degli eventi: nel caso di eventi concorrenti non è possibile stabilire quale evento avviene effettivamente prima

Clock logico scalare: implementazione

- Algoritmo di Lamport
- Ogni processo p_i inizializza il proprio clock logico L_i a 0 ($\forall\ i = 1, \ldots, N$)
- Prima di eseguire un evento interno, p_i incrementa L_i di 1: $L_i = L_i + 1$
- Quando p_i invia il messaggio m a p_j
  - Incrementa il valore di L_i: $L_i = L_i + 1$
  - Allega al messaggio m il timestamp $t = L_i$
  - Esegue l'evento *send*(m)
- Quando p_j riceve il messaggio m con timestamp t
  - Aggiorna il proprio clock logico $L_j = max(t, L_j)$
  - Incrementa il valore di L_j: $L_j = L_j + 1$
  - Esegue l'evento *receive*(m)

Clock logico scalare: esempio

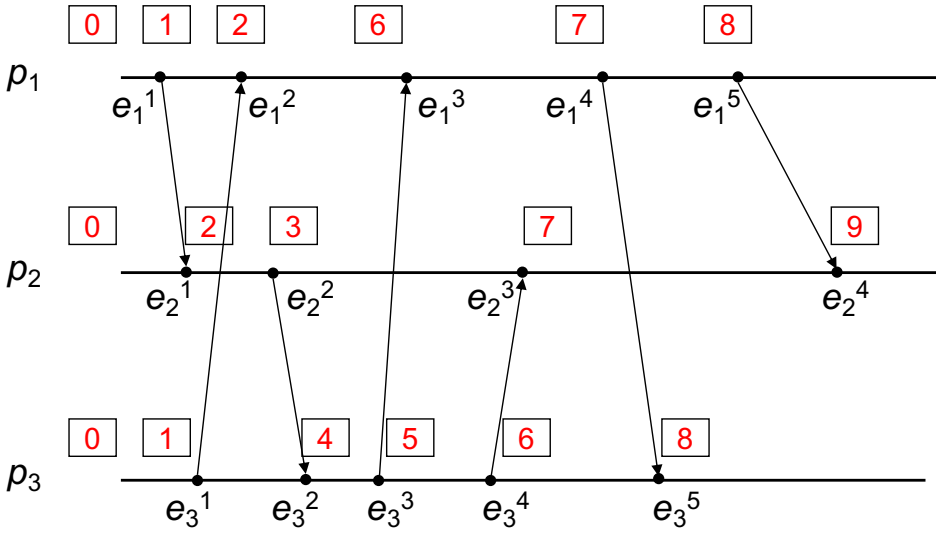

Clock logico scalare: esempio

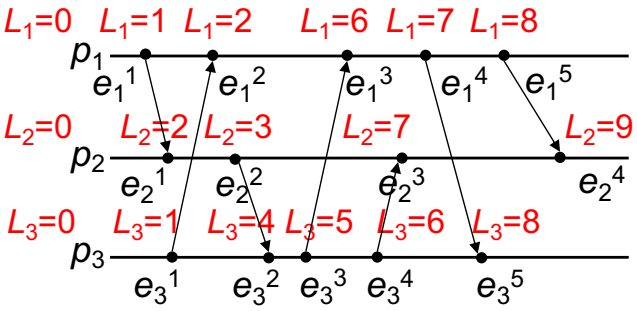

- Osservazioni
  - $e_1^1 \rightarrow e_2^1$ ed i relativi timestamp riflettono questa proprietà (L_1=1 e L_2=2); infatti *if* $e_1^1 \rightarrow e_2^1$ *then* $L(e_1^1) < L(e_2^1)$
  - $e_1^1 \parallel e_3^1$ ed i relativi timestamp sono uguali (L_1=1 e L_3=1); infatti *if* $L(e_1^1) \geq L(e_3^1)$ then $e_1^1 \not\rightarrow e_3^1$
  - $e_2^1 \parallel e_3^1$ ed i relativi timestamp sono diversi (L_2=2 e L_3=1); infatti *if* $L(e_2^1) \geq L(e_3^1)$ then $e_2^1 \not\rightarrow e_3^1$

Relazione di ordine totale

- Usando il clock logico scalare, due o più eventi possono avere stesso timestamp: come realizzare un ordinamento totale tra eventi, evitando così che due eventi accadano nello *stesso tempo logico*?
- Soluzione: usare, oltre al clock logico, il numero del processo su cui è avvenuto l'evento
  - Si stabilisce un ordinamento totale ($\prec$) tra i processi
- Relazione di ordine totale tra eventi (indicata con $e \Rightarrow e'$): se e è un evento di p_i ed e' è un evento di p_j allora $e \Rightarrow e'$ se e solo:
  1. $L_i(e) < L_j(e')$ or
  2. $L_i(e) = L_j(e')$ and $p_i \prec p_j$
- Applicata negli algoritmi di Lamport distribuito e di Ricart-Agrawala per la mutua esclusione distribuita

Relazione di ordine totale: esempio

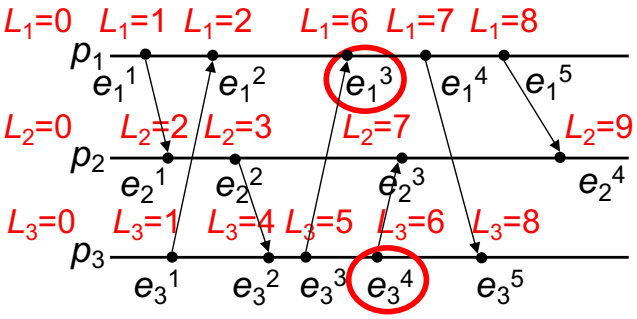

- e_1^3 e e_3^4 hanno lo stesso valore di clock logico: come ordinarli?
- $e_1^3 \Rightarrow e_3^4$ poiché $L_1(e_1^3) = L_3(e_3^4)$ e $p_1 \prec p_3$

Clock logico scalare: limitazione

- Il clock logico scalare ha la seguente proprietà
  - Se $e \rightarrow e'$ allora $L(e) < L(e')$
- Ma non è possibile assicurare che
  - Se $L(e) < L(e')$ allora $e \rightarrow e'$
    Esempio slide 36: $L(e_3^1) < L(e_2^1)$ ma $e_3^1 \parallel e_2^1$
- Conseguenza: non è possibile stabilire, solo guardando i clock logici scalari, se due eventi sono concorrenti o meno

- Come superare questa limitazione?
- Introducendo i clock logici vettoriali: ad opera di Mattern (1989) e Fidge (1991)

Clock logico vettoriale

- Il clock logico vettoriale per un sistema con N processi è un vettore di N interi
- Ciascun processo p_i mantiene il proprio clock vettoriale V_i
- Per il processo p_i $V_i[\,i\,]$ è il clock logico locale
- Ciascun processo usa il suo clock vettoriale per assegnare il timestamp agli eventi
- Analogamente al clock scalare di Lamport, il clock vettoriale viene allegato al messaggio m ed il timestamp diviene vettoriale
- Con il clock vettoriale si catturano completamente le caratteristiche della relazione happened-before

$$e \rightarrow e' \text{ se e solo se } V(e) < V(e')$$

Clock logico vettoriale: significato e confronto

- Dato il clock vettoriale V_i
  - $V_i[\,i\,]$ è il numero di eventi generati da p_i
  - $V_i[\,j\,]$ con $i \neq j$ è il numero di eventi occorsi a p_j di cui p_i ha conoscenza

- Confronto di clock vettoriali
  - $V = V'$ se e solo se $\forall\, j$: $V[\,j\,] = V'[\,j\,]$
  - $V \leq V'$ se e solo se $\forall\, j$: $V[\,j\,] \leq V'[\,j\,]$
  - $V < V'$ (e quindi l'evento associato a V precede quello associato a V') se e solo se
    - $\forall\, i \in [1,\ldots,N]$: $V[\,i\,] \leq V'[\,i\,]$

      and
    - $\exists\, j \in$ in $[1,\ldots,N]$: $V[\,j\,] < V'[\,j\,]$
  - $V \,||\, V'$ (e quindi l'evento associato a V è concorrente a quello associato a V') se e solo se
    - not($V < V'$) and not($V' < V$)

Clock logico vettoriale: implementazione

- Ogni processo p_i inizializza il proprio clock vettoriale V_i

  $V_i[k]=0 \quad \forall\, k = 1, 2, \ldots, N$
- Prima di eseguire un evento interno, p_i incrementa di 1 la sua componente $V_i[i]$

  $V_i[i] = V_i[i] + 1$
- Quando p_i invia il messaggio m a p_j
  - Incrementa di 1 la sua componente $V_i[i]$: $V_i[i] = V_i[i] + 1$
  - Allega al messaggio m il timestamp vettoriale $t = V_i$
  - Esegue l'evento *send*(m)
- Quando p_j riceve il messaggio m con timestamp t
  - Aggiorna il proprio clock logico $V_j[k] = max(t[k], V_j[k]) \;\forall\, k = 1, 2, \ldots, N$
  - Incrementa di 1 la sua componente $V_j[j]$: $V_j[j] = V_j[j] + 1$
  - Esegue l'evento *receive*(m)

Clock logico vettoriale: esempio

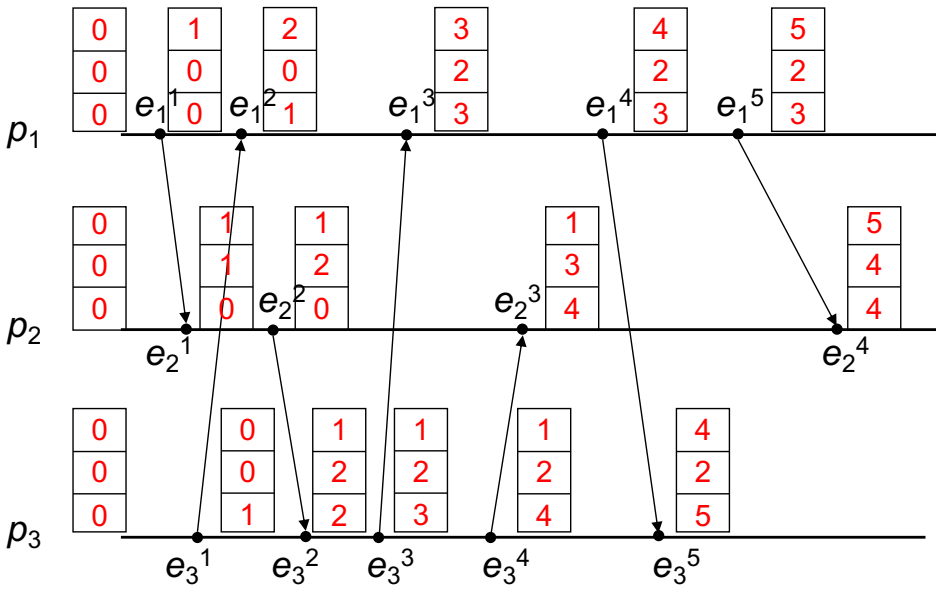

Confronto di clock vettoriali

- Confrontando i timestamp basati su clock vettoriale si può capire se gli eventi sono concorrenti o in relazione happened-before

V	V'
1	1
2	2
0	2

V(e) < V'(e) e quindi e $\rightarrow$ e'

V	V'
1	1
2	0
0	2

V(e) $\neq$ V'(e) e quindi e || e'

Esempi di applicazione del clock logico

- Esaminiamo due applicazioni del clock logico scalare e vettoriale

1. Clock logico scalare per multicasting totalmente ordinato
2. Clock logico vettoriale per multicasting causalmente ordinato

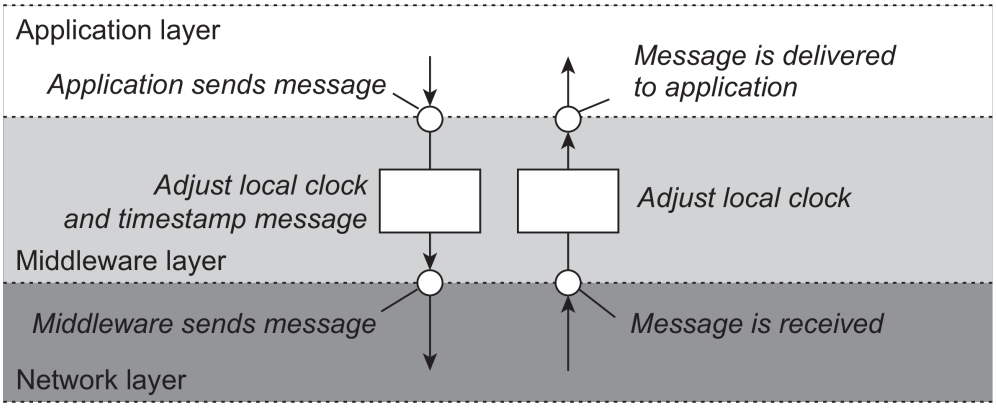

Multicasting totalmente ordinato: problema

- Come garantire che aggiornamenti concorrenti su un database replicato siano visti nello stesso ordine da ogni replica?
  - p_1 aggiunge \$100 ad un conto (valore iniziale: \$1000)
  - p_2 incrementa il conto dell'1%
  - Ci sono due repliche
  - In assenza di sincronizzazione le due operazioni non vengono eseguite sulle due repliche nello stesso ordine
    - Replica #1 ← 1111 (prima p_1 e poi p_2)
    - Replica #2 ← 1110 (prima p_2 e poi p_1)

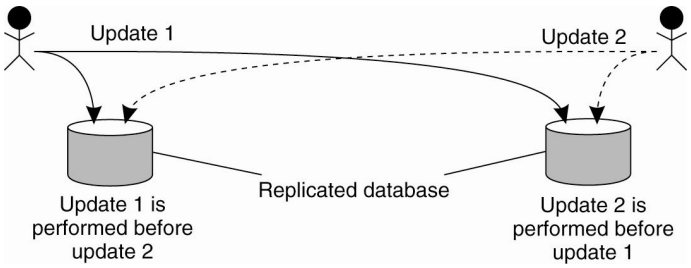

Multicasting totalmente ordinato

- **Multicasting totalmente ordinato**: operazione di multicast con cui tutti i messaggi sono consegnati *nello stesso ordine* ad ogni destinatario

- Assunzioni: comunicazione *affidabile* e *FIFO ordered*
  - Comunicazione affidabile: no perdita di messaggi
  - Comunicazione FIFO ordered: messaggi inviati da p_i a p_j sono ricevuti da p_j nello stesso ordine in cui p_i li ha inviati

Multicasting totalmente ordinato

- Algoritmo centralizzato: coordinatore centralizzato (*sequencer*)
  - Ogni processo invia il proprio messaggio di update al sequencer
  - Il sequencer assegna ad ogni messaggio di update un numero di sequenza univoco e poi invia in multicast il messaggio a tutti i processi, che eseguono gli aggiornamenti in ordine in base al numero di sequenza
  - ✗ Problemi di scalabilità e single point of failure

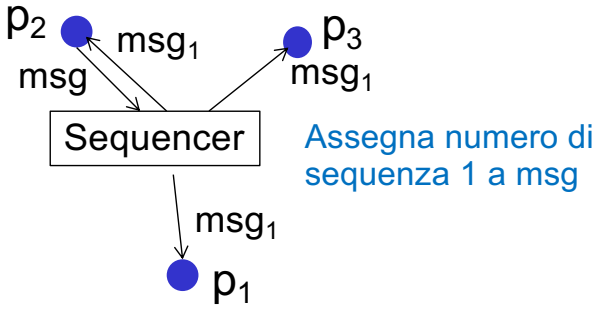

Multicasting totalmente ordinato

- Algoritmo distribuito: applichiamo il clock logico scalare per risolvere il multicasting totalmente ordinato in modo decentralizzato
  - Ogni messaggio è etichettato con il clock logico scalare del processo che lo invia

- p_i invia in multicast agli altri processi (incluso se stesso) il *messaggio di update* msg_i
- msg_i viene posto da ogni processo ricevente p_j in una coda locale $queue_j$, ordinata in base al valore del timestamp
- p_j invia in multicast un *messaggio di ack* della ricezione di msg_i
- p_j consegna msg_i all'applicazione se:
  1. msg_i è in testa a $queue_j$ (e tutti gli ack relativi a msg_i sono stati ricevuti da p_j)
  2. per ogni processo p_k c'è un messaggio msg_k in $queue_j$ *con* timestamp maggiore di quello di msg_i

  Ovvero msg_i viene consegnato solo quando p_j sa che nessun altro processo può inviare in multicast un messaggio con timestamp minore o uguale a quello di msg_i

Multicasting totalmente ordinato

- Costo di comunicazione:
  - N processi e per ogni messaggio ricevuto viene inviato un ack in multicast ➔ N^2 ack
  - ✗ Scalabilità limitata

- Meccanismo alla base della ***state-machine replication***

State machine replication

- Software replication technique applied to services that can be implemented as a deterministic state machine

  Next state of the service =
  f(current state, command executed)

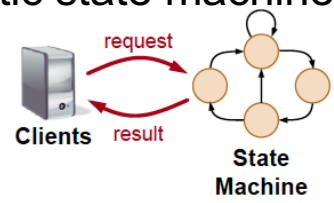

- To achieve fault tolerance, service is replicated on several nodes, all of them running a state machine replication (SMR) middleware
  - Set of replicas behaves as a “centralized” server
- Every replica must execute commands in the same order
- If deterministic and by executing the same commands in the same order, all replicas end up in same state
- Service makes progress as long as any majority of the replicas are up

Multicasting causalmente ordinato

- **Multicasting causalmente ordinato**: un messaggio viene consegnato solo se tutti i messaggi che lo precedono *causalmente* (relazione di causa-effetto) sono stati già consegnati
  - Relazione di causa-effetto tra due eventi: il secondo evento è *potenzialmente* influenzato dal primo evento
    - Obiettivo: consegnare prima la causa e poi l’effetto
  - Indebolimento del multicasting totalmente ordinato
  - Esempio:
    - p_1 invia i messaggi m_A ed m_B
    - p_2 invia i messaggi m_C ed m_D
    - m_A causa m_C
    - Alcune sequenze di consegna compatibili con l’ordinamento causale (e FIFO ordered) sono:

      $m_A\ m_B\ m_C\ m_D$ $m_A\ m_C\ m_B\ m_D$ $m_A\ m_C\ m_D\ m_B$

      ma NON $m_C\ m_A\ m_B\ m_D$

Multicasting causalmente ordinato

- Assunzioni: comunicazione *affidabile* e *FIFO ordered*
- Applichiamo il clock logico vettoriale per risolvere il problema del multicasting causalmente ordinato in modo decentralizzato
  - p_i invia il messaggio m usando come timestamp $t(m)$ il clock logico vettoriale V_i
    - $V_j[i]$ conta il numero di messaggi inviati da p_i a p_j
  - p_j riceve m da p_i e ne ritarda la consegna al livello applicativo (ponendo m in una coda di attesa) finché non si verificano entrambe le condizioni
    1. $t(m)[i] = V_j[i] + 1$
       m è il messaggio successivo che p_j si aspetta da p_i
    2. $t(m)[k] \leq V_j[k] \ \forall \ k \neq i$
       per ogni processo p_k, p_j ha visto almeno gli stessi messaggi visti da p_i

Multicasting causalmente ordinato: esempio

- p_1 invia m a p_2 e p_3
- p_2, dopo aver ricevuto m, invia m^* a p_1 e p_3
- Supponiamo che p_3 riceva m^* prima di m: l'algoritmo evita la violazione della causalità tra m e m^*, facendo sì che su p_3 m^* sia consegnato al livello applicativo dopo m

Aggiornamento clock

p_i invia msg: $VC_i[i] = VC_i[i] + 1$
p_i riceve msg con $t(msg)$: $VC_i[k] = \max\{VC_i[k], t(msg)[k]\}$

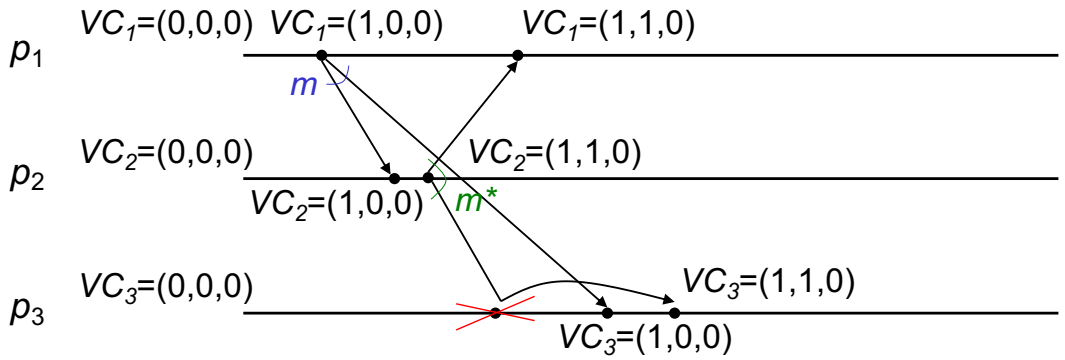

Main properties of algorithms for concurrent and distributed systems

- **Safety**: nothing bad will happen
- **Liveness**: eventually something good will happen

Mutua esclusione

- *N* processi vogliono accedere ad una risorsa condivisa
  - Ogni processo vuole acquisire la risorsa ed usarla in modo esclusivo senza interferenze con gli altri processi
- Ogni algoritmo di mutua esclusione comprende
  - Una sequenza di istruzioni chiamata **sezione critica (CS)**
    - L'esecuzione della sezione critica consiste nell'accesso alla risorsa condivisa
  - Una sequenza di istruzioni che precedono l'entrata in CS, chiamata **trying protocol (TP)**
  - Una sequenza di istruzioni che seguono l'uscita da CS, chiamata **exit protocol (EP)**

Proprietà degli algoritmi di mutua esclusione

- Un algoritmo di mutua esclusione dovrebbe soddisfare le seguenti proprietà:
  - **Mutua esclusione (ME)** o ***safety***: al più un solo processo alla volta può eseguire la CS
  - **No deadlock (ND)**: se un processo rimane bloccato nella sua trying section, almeno un altro processo riesce ad entrare ed uscire dalla CS
  - **No starvation (NS)** o *assenza di posticipazione indefinita*: nessun processo rimane bloccato per sempre nella trying section, ovvero le richieste di entrata in CS sono prima o poi soddisfatte
- Osservazioni:
  - NS implica ND
  - NS è una proprietà di ***liveness*** (no ritardi indefiniti)
  - NS è una condizione di imparzialità (***fairness***) nei confronti dei processi
  - Un ulteriore requisito di imparzialità è ***ordering***
    - Richieste di entrata in CS sono servite secondo l'ordine d'arrivo

Mutua esclusione e sistemi concorrenti

- La mutua esclusione nasce nei sistemi concorrenti
  - La sezione critica è relativa ad una porzione di codice
- Soluzioni basate su variabili condivise per realizzare la mutua esclusione tra *N* processi
  - **Algoritmo di Dijkstra** (1965)
    - Per sistemi a singolo processore
    - Garantisce mutua esclusione ed assenza di deadlock ma non garantisce assenza di starvation
  - **Algoritmo del panificio di Lamport** (1974)
    - Per sistemi multiprocessore a memoria condivisa

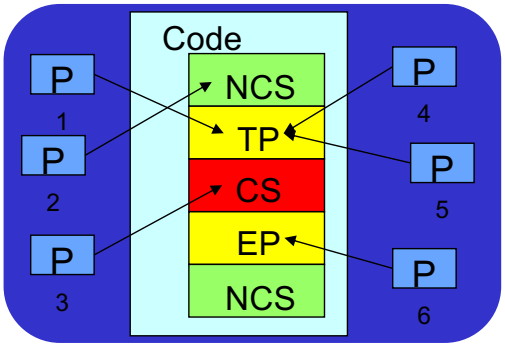

Algoritmo del panificio di Lamport

- Soluzione ispirata ad una situazione reale
  - Attesa di essere serviti in un panificio
- Modello di sistema concorrente per Lamport
  - I processi comunicano leggendo/scrivendo variabili condivise
  - Lettura e scrittura di una variabile non sono operazioni atomiche: un processo può scrivere mentre un altro processo sta leggendo
  - Ogni variabile condivisa è di proprietà di un processo
    - Tutti possono leggere la sua variabile
    - Solo il processo può scrivere la sua variabile
  - Nessun processo può eseguire due scritture contemporaneamente
  - Le velocità di esecuzione dei processi *non* sono correlate tra loro

Algoritmo del panificio di Lamport

- Variabili condivise
  - num[1,…,N] : array di interi inizializzati a 0
  - choosing[1,…,N] : array di booleani inizializzati a *false*
- Variabile locale
  - j: intero compreso in [1,…,N]

Algoritmo del panificio di Lamport

- Ciclo ripetuto all'infinito dal processo p_i

```
// sezione non critica
// prende un biglietto                                   doorway
choosing[i] = true;  // inizio della selezione del biglietto
num[i] = 1 + max(num[x]: 1 ≤ x ≤ N);
choosing[i] = false; // fine della selezione del biglietto
// attende che il numero sia chiamato confrontando il suo biglietto
// con quello degli altri                                          bakery
for j = 1 to N do
    // busy waiting mentre j sta scegliendo
    while choosing[j] do NoOp();
    // busy waiting finché il valore del biglietto non è il più basso
    // viene favorito il processo con identificativo più piccolo
    while num[j] ≠ 0 and {num[j], j} < {num[i], i} do NoOp();
// sezione critica
num[i] = 0;
// fine sezione critica
```

Relazione di precedenza < su coppie ordinate di interi definita da: *(a,b)* < *(c,d)* se a < c, o se *a* = *c* e *b* < *d*

Algoritmo del panificio di Lamport

- Doorway
  - Ogni processo p_i che entra lo segnala agli altri tramite choosing[i]
  - Prende un numero di biglietto pari al massimo dei numeri scelti dai processi precedenti più 1
  - Altri processi possono accedere concorrentemente alla doorway
  - Esempio di esecuzione della doorway

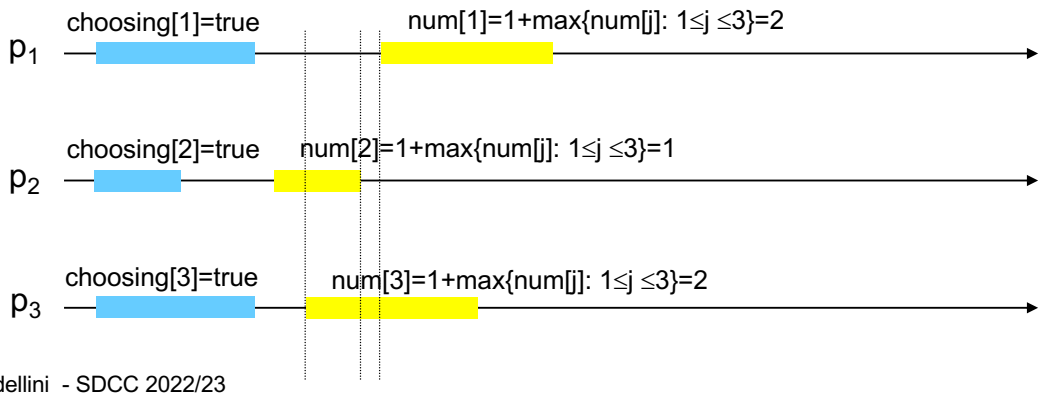

Algoritmo del panificio di Lamport

- Bakery
  - Ogni processo p_i deve controllare che tra i processi in attesa sia lui il prossimo a poter entrare in CS
  - Il primo ciclo permette a tutti i processi nella doorway di terminare la scelta del biglietto
  - Il secondo ciclo lascia p_i in attesa finché:
    - Il suo numero di biglietto non diventa il più piccolo
    - Tutti i processi che hanno scelto un numero di biglietto uguale al suo non hanno identificativo maggiore
  - Osservazione:
    - I casi in cui viene scelto lo stesso numero di biglietto sono risolti basandosi sull'identificativo del processo
  - Esempio di esecuzione del bakery

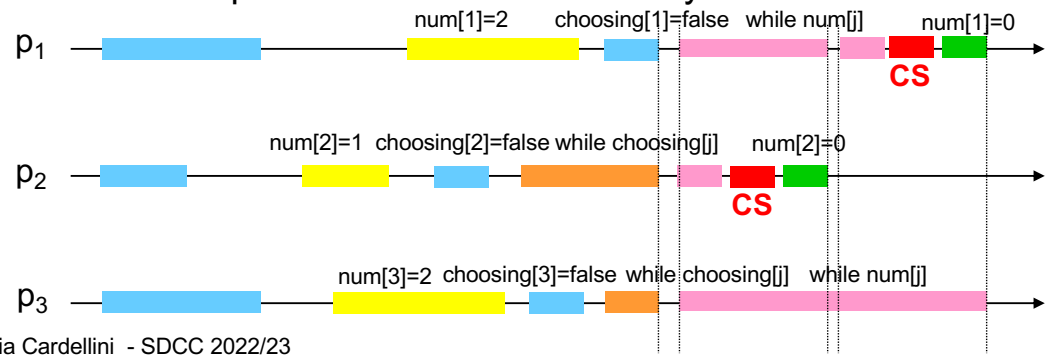

Algoritmo del panificio di Lamport: proprietà

- Proprietà di mutua esclusione
  - Deriva da: *se p_i è nella doorway e p_j è nel bakery allora {num[j], j} < {num[i],i}*
- Proprietà di no starvation
  - Nessun processo attende per sempre, poiché prima o poi avrà il numero di biglietto più piccolo
- L'algoritmo gode anche della proprietà FCFS
  - Se p_i entra nel bakery prima che p_j entri nella doorway, allora p_i entrerà in CS prima di p_j

Mutua esclusione distribuita

- Rispetto al modello di Lamport (slide 60) la comunicazione avviene tramite scambio di messaggi:
  - Un processo non può leggere direttamente il valore di una variabile di proprietà di un altro processo, ma deve inviare un messaggio di richiesta ed attendere un messaggio di risposta contenente il valore
- La comunicazione tra processi avviene in base alle seguenti assunzioni:
  - I processi non hanno variabili condivise ma comunicano tramite scambio di messaggi
  - Il ritardo di trasmissione di un messaggio è impredicibile ma finito
  - I canali di comunicazione tra i processi sono affidabili
    - Un messaggio inviato viene ricevuto correttamente dal suo destinatario
    - Non ci sono messaggi duplicati o messaggi spuri (ricevuti ma mai trasmessi)

Mutua esclusione distribuita: modello del sistema

- Sistema con N processi p_i, $i = 1, \ldots, N$
- Il sistema è asincrono
- I processi non sono soggetti a fallimenti
- La comunicazione è affidabile e FIFO ordered
- I processi trascorrono un tempo finito nella CS

Adattamento dell'algoritmo del panificio

- Adattiamo ai SD l'algoritmo del panificio di Lamport ideato per sistemi concorrenti

> Ogni processo p_i si comporta da server rispetto alle proprie variabili num[i] e choosing[i]
>
> Comunicazione basata su scambio di messaggi
> - Ogni processo legge i valori locali agli altri processi tramite messaggi di richiesta-risposta

Adattamento dell'algoritmo del panificio

- E' una buona soluzione? Funziona, ma…
- Costo di comunicazione per entrare in CS: **6*N*** messaggi
  - Occorre leggere 3*N* variabili (*N* per doorway, 2*N* per bakery)
  - Per ogni lettura vengono scambiati 2 messaggi
- La latenza è determinata dalla combinazione *canale di comunicazione-processo* più lenta

✗ Limitata efficienza e scalabilità
  - I problemi derivano dalla mancanza di cooperazione tra processi

Panoramica sulle algoritmi per ME distribuita

- Algoritmi basati su **autorizzazioni**
  - Un processo che vuole accedere alla risorsa condivisa chiede l'autorizzazione
  - Autorizzazione gestita
    - In modo *centralizzato* (unico coordinatore)
    - In modo completamente distribuito (algoritmo di Lamport distribuito, algoritmo di Ricart e Agrawala)
- Algoritmi basati su **token**
  - Tra i processi circola un messaggio speciale, detto *token*
    - Il token è unico in ogni istante di tempo
    - Solo chi detiene il token può accedere alla risorsa condivisa
  - Algoritmo centralizzato e decentralizzato
- Algoritmi basati su **quorum** (o votazione)
  - Si richiede il permesso di accedere alla risorsa condivisa ad un sottoinsieme di processi
    - Algoritmo di Maekawa

Prestazioni di algoritmi per ME distribuita

- Principali criteri usati per valutare le prestazioni degli algoritmi di ME distribuita:
  - Numero di messaggi per entrare in CS e uscire da CS: misura indiretta della banda di rete consumata
  - Numero di messaggi per entrare in CS: misura indiretta del tempo di attesa

Autorizzazioni: algoritmo centralizzato

- La richiesta di accesso (ENTER) ad una risorsa in mutua esclusione viene inviata al coordinatore centrale
- Se la risorsa è libera, il coordinatore informa il mittente che l'accesso è consentito (GRANTED)
- Altrimenti, il coordinatore accoda la richiesta con politica FIFO e informa il mittente che l'accesso non è consentito (DENIED)
  - Oppure, nel caso di SD sincrono, non risponde (vedi figura)
- Il processo che rilascia la risorsa ne informa il coordinatore (RELEASED)
- Il coordinatore preleva dalla coda la prima richiesta in attesa e invia GRANTED al suo mittente

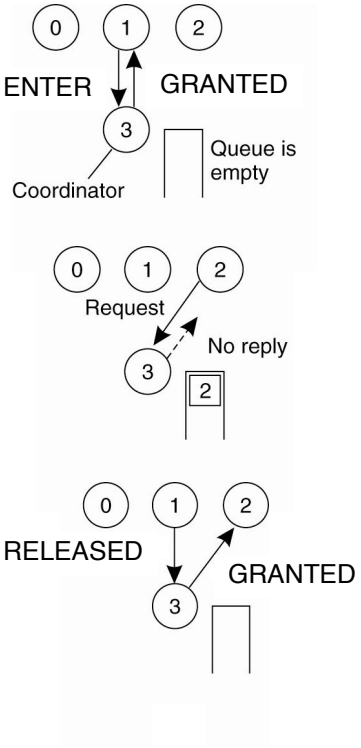

Autorizzazioni: algoritmo centralizzato

- Vantaggi e svantaggi
  - ✓ Garantisce mutua esclusione ed assenza di starvation
  - ✓ Garantisce fairness (coda gestita con disciplina FIFO)
  - ✓ Semplice e facile da implementare
    - Solo **3 messaggi** (richiesta, risposta e rilascio) per entrare e uscire da CS
  - ✗ Il coordinatore è SPoF
  - ✗ Il coordinatore può diventare il collo di bottiglia per le prestazioni
  - ✗ Se un processo fallisce mentre è in CS, si perde il messaggio di rilascio

Algoritmo di Lamport distribuito

- Ogni processo mantiene: clock logico scalare e coda locale (in cui memorizza le richieste di accesso in CS)
  - Si applica anche la relazione di ordine totale $\Rightarrow$
- Regole dell'algoritmo:
  - p_i richiede l'accesso in CS: p_i invia a tutti gli altri processi un messaggio di richiesta avente come timestamp il suo clock scalare ed inserisce <msg. richiesta, timestamp> in coda
  - p_j riceve una richiesta da p_i: p_j inserisce <msg. richiesta, timestamp> in coda ed invia *a* p_i un messaggio di ack
  - p_i entra in CS *se e solo se*:
    - la sua richiesta con timestamp *t* precede tutti gli altri messaggi di richiesta in coda (ossia <*t, i*> è il minimo applicando $\Rightarrow$)
    - p_i ha ricevuto da ogni altro processo un messaggio (di ack o di richiesta) con timestamp maggiore di *t* (applicando $\Rightarrow$)
  - p_i rilascia la CS: p_i elimina la richiesta dalla sua coda ed invia un messaggio di release *a tutti* gli altri processi
  - p_j riceve un messaggio di release: elimina la richiesta corrispondente dalla sua coda

Algoritmo di Lamport distribuito

- Simile ad algoritmo distribuito per multicast totalmente ordinato: perché?
- Soddisfa le proprietà di safety, liveness e fairness
  - Fairness perché richieste servite secondo l'ordine del timestamp e tempo basato su clock logico
- Richiede **3(*N*-1)** messaggi per entrare in CS e uscirne:
  - *N*-1 messaggi di richiesta
  - *N*-1 messaggi di ack
  - *N*-1 messaggi di release

Algoritmo di Ricart e Agrawala

- Estensione ed ottimizzazione dell'algoritmo di Lamport distribuito
  - Basato su clock logico scalare e relazione d'ordine totale

- Un processo che vuole entrare in CS manda un messaggio di REQUEST a tutti gli altri contenente:
  - proprio id
  - *timestamp* basato su clock logico scalare
- Si pone in attesa della risposta da tutti gli altri
- Ottenuti tutti i messaggi di REPLY entra in CS
- All'uscita da CS manda REPLY a *tutti* i processi in coda locale

- Un processo che riceve il messaggio di REQUEST può
  - non essere in CS e non volervi entrare → manda REPLY al mittente
  - essere in CS → non risponde e mette il messaggio in coda locale
  - voler entrare in CS → confronta il suo timestamp e id con timestamp e id ricevuti e vince la coppia minore: se è l'altro, invia REPLY; se è lui, non risponde e mette il messaggio in coda

Algoritmo di Ricart e Agrawala

- Variabili locali per ciascun processo
  - #replies: numero di risposte ricevute (inizializzata a 0)
  - State ∈ {Requesting, CS, NCS} (inizializzata a NCS)
  - Q: coda di richieste pendenti (inizialmente vuota)
  - Last_Req: timestamp del messaggio di richiesta (inizializzata a 0)
  - Num (inizializzata a 0): clock logico scalare
- Ogni processo p_i esegue il seguente algoritmo

Begin
1. State = Requesting;
2. Num = Num+1; Last_Req = Num;
3. for j=1 to N-1 send REQUEST to pj;
4. Wait until #replies=N-1;
5. State = CS;
6. CS
7. ∀ r∈Q send REPLY to r
8. Q=∅; State=NCS; #replies=0;

Upon receipt of REQUEST(t) from pj
1. if State=CS or (State=Requesting and {Last_Req, i} < {t, j})
2. then insert {t, j} in Q
3. else send REPLY to pj
4. Num = max(t, Num)

Upon receipt of REPLY from pj
1. #replies = #replies+1

Algoritmo di Ricart e Agrawala: esempio

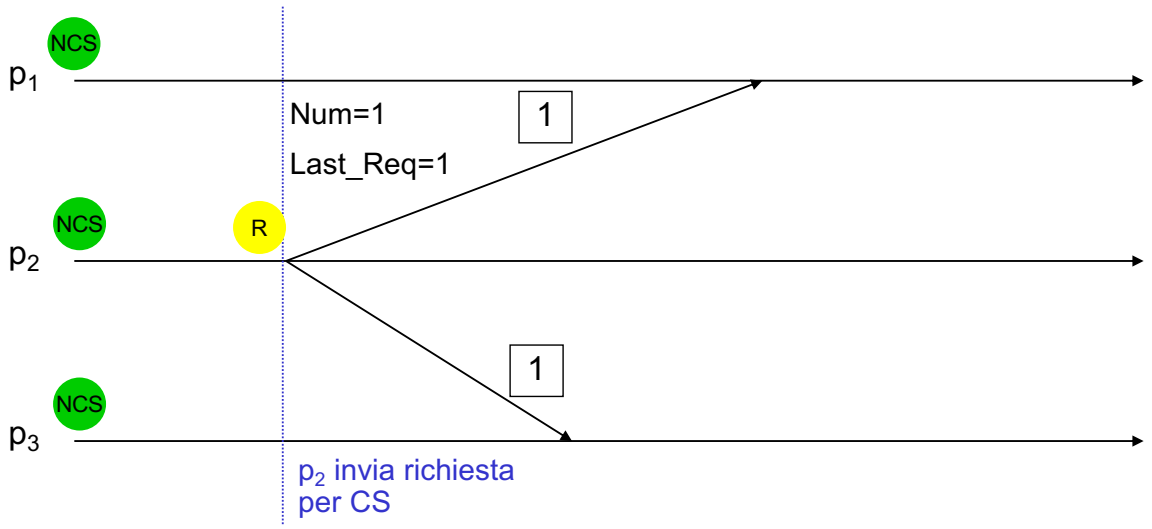

Algoritmo di Ricart e Agrawala: esempio

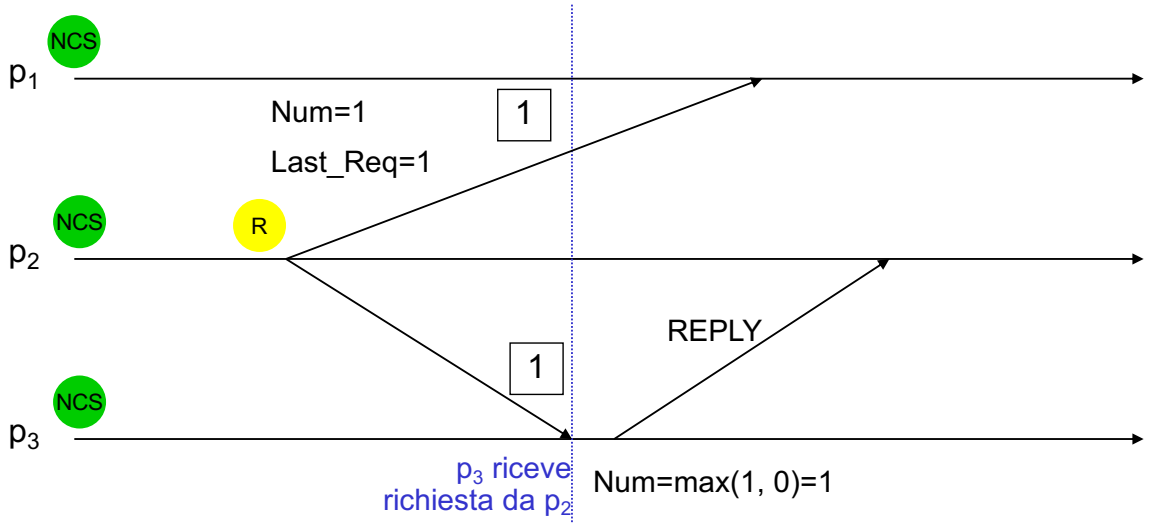

Algoritmo di Ricart e Agrawala: esempio

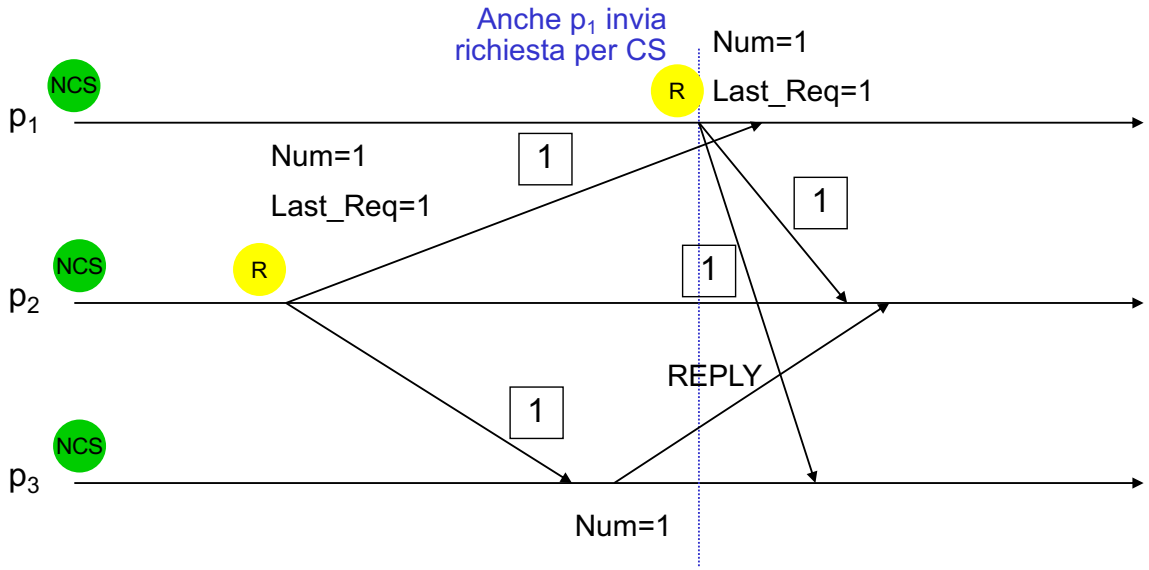

Algoritmo di Ricart e Agrawala: esempio

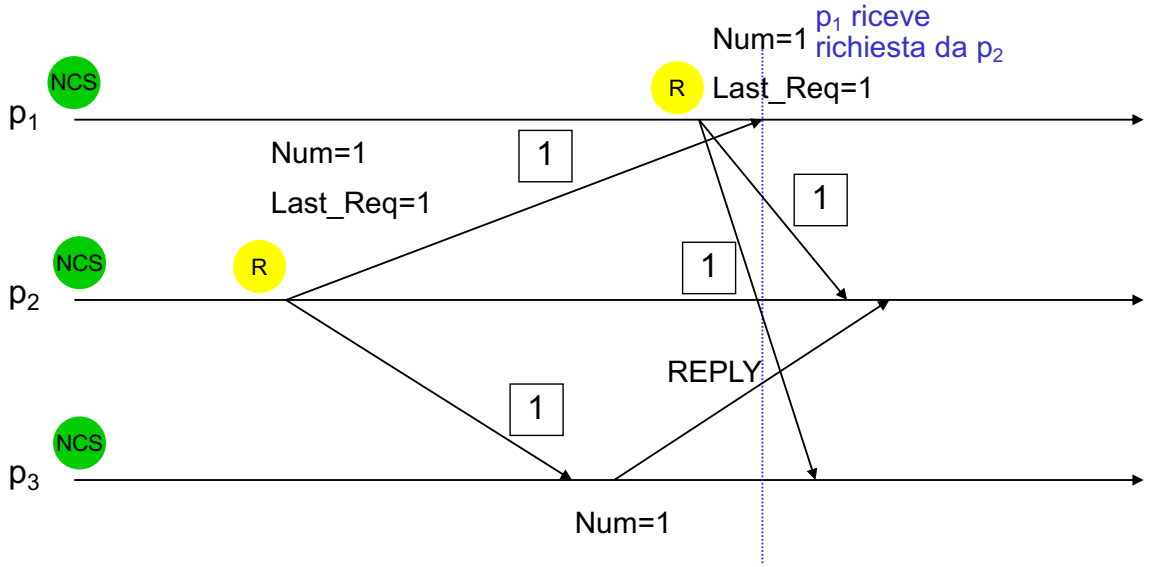

Algoritmo di Ricart e Agrawala: esempio

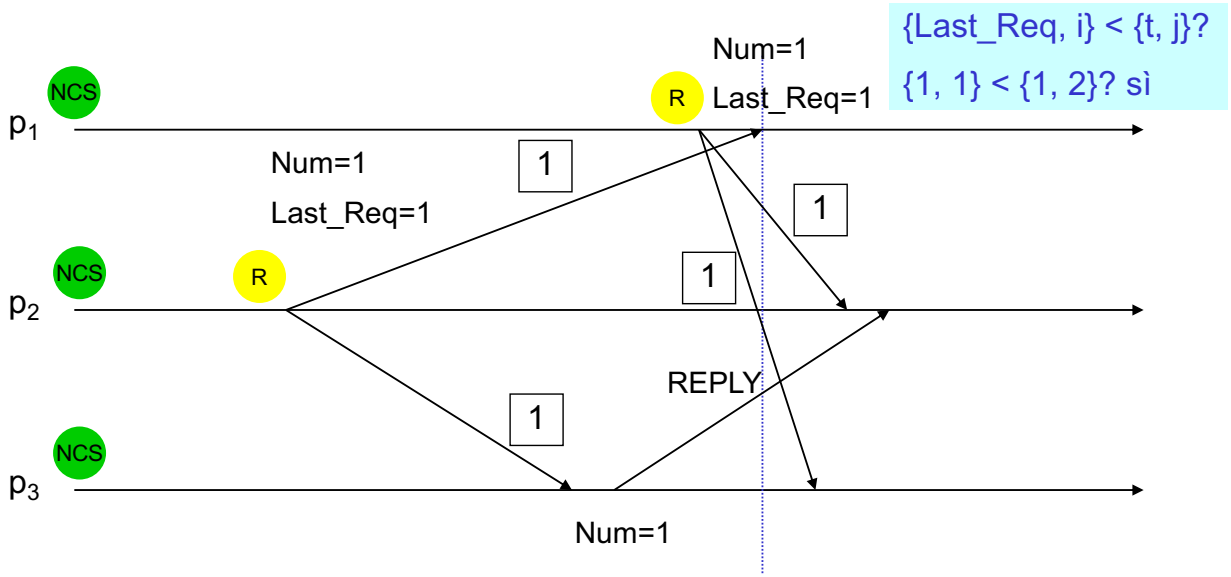

Algoritmo di Ricart e Agrawala: esempio

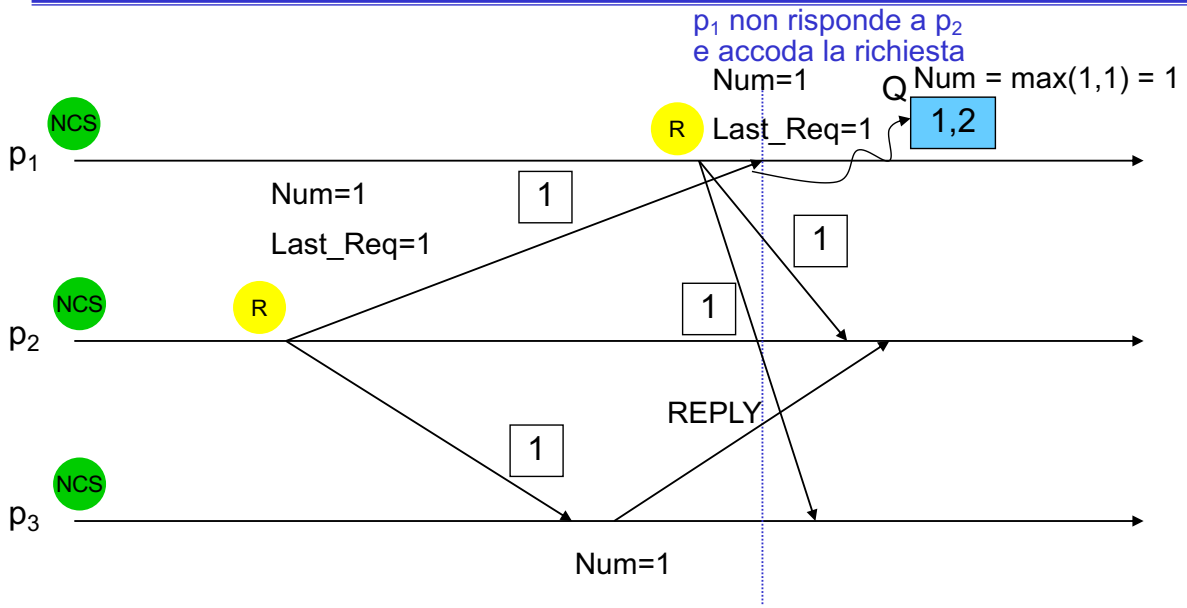

Algoritmo di Ricart e Agrawala: esempio

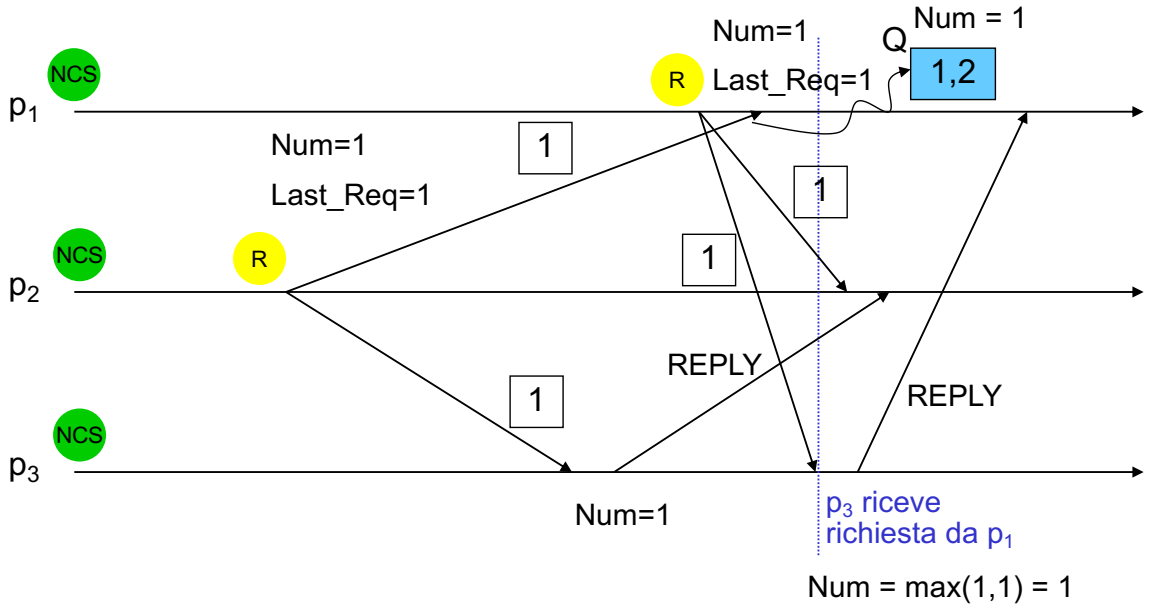

Algoritmo di Ricart e Agrawala: esempio

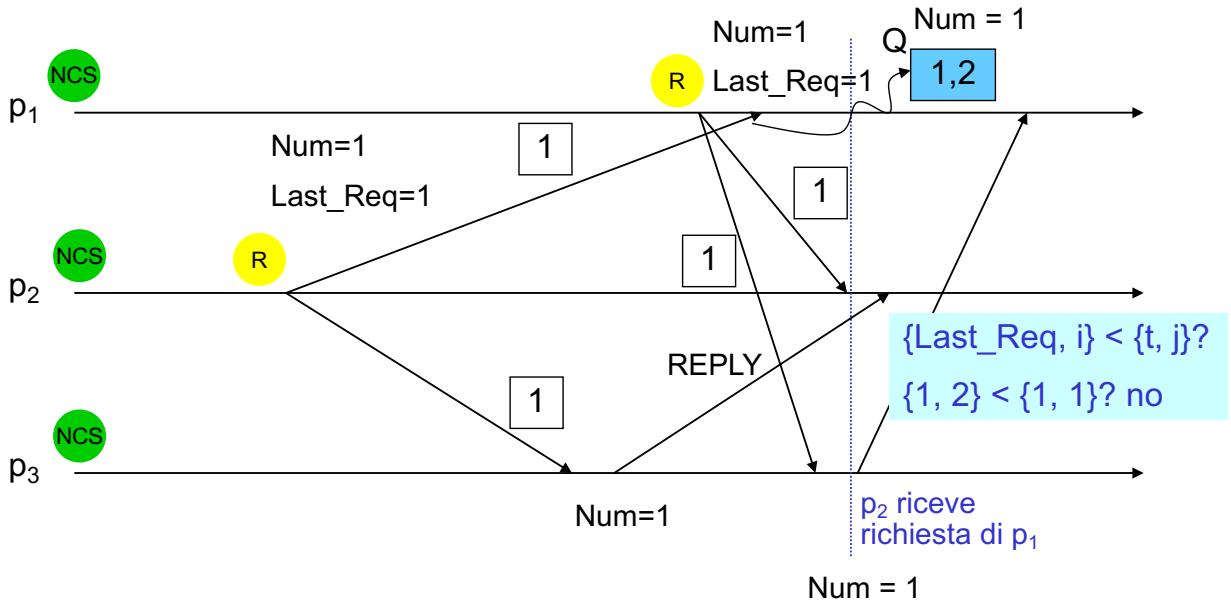

Algoritmo di Ricart e Agrawala: esempio

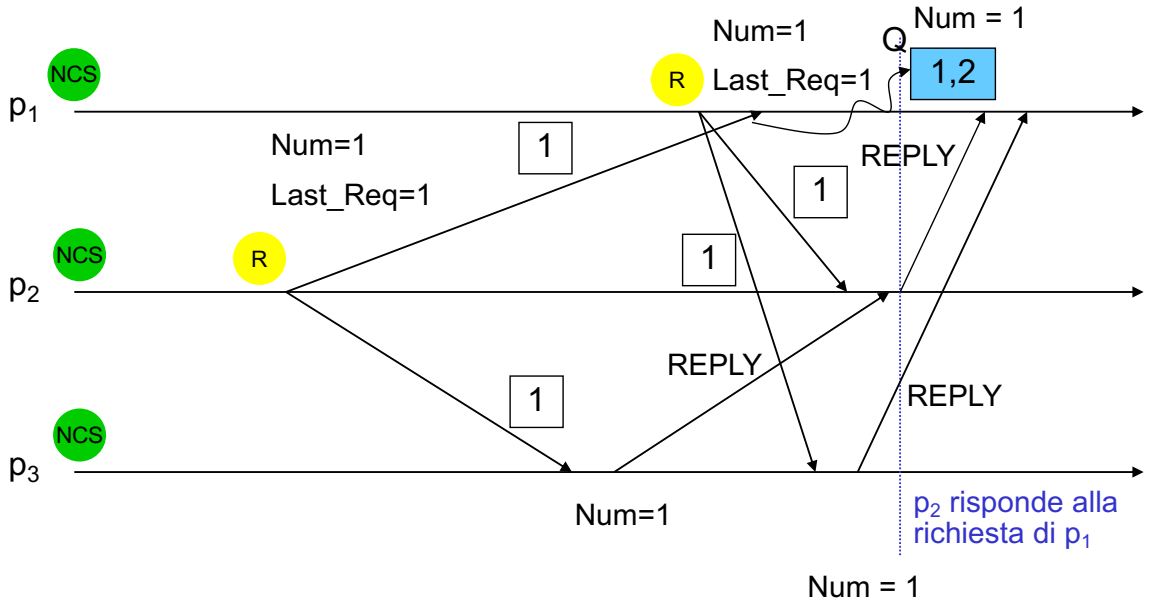

Algoritmo di Ricart e Agrawala: esempio

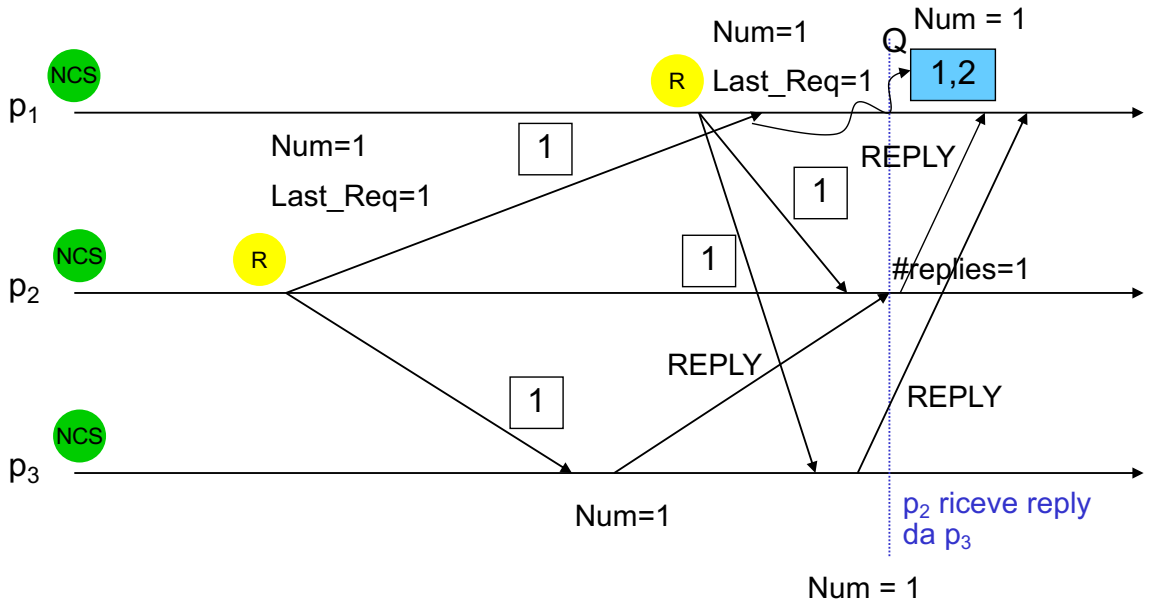

Algoritmo di Ricart e Agrawala: esempio

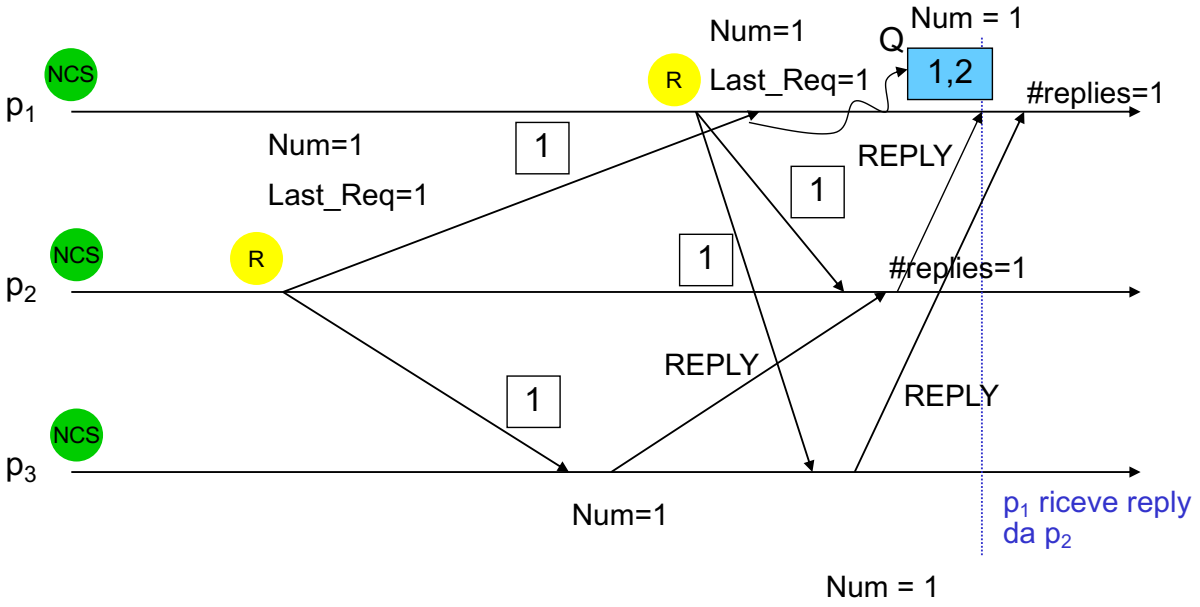

Algoritmo di Ricart e Agrawala: esempio

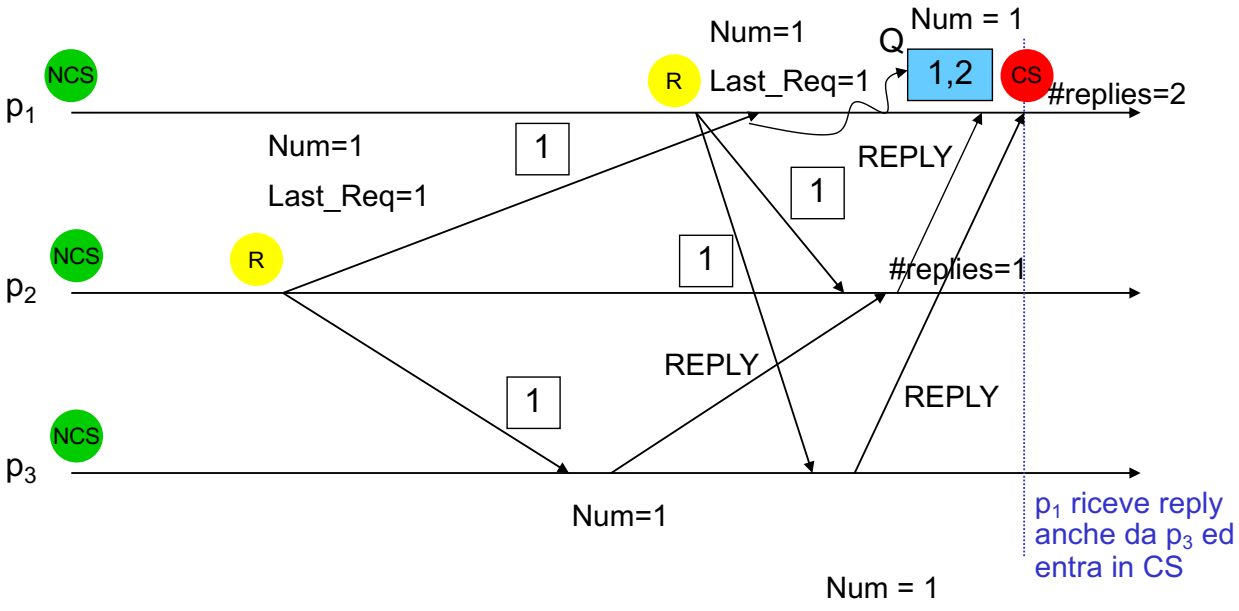

Algoritmo di Ricart e Agrawala: esempio

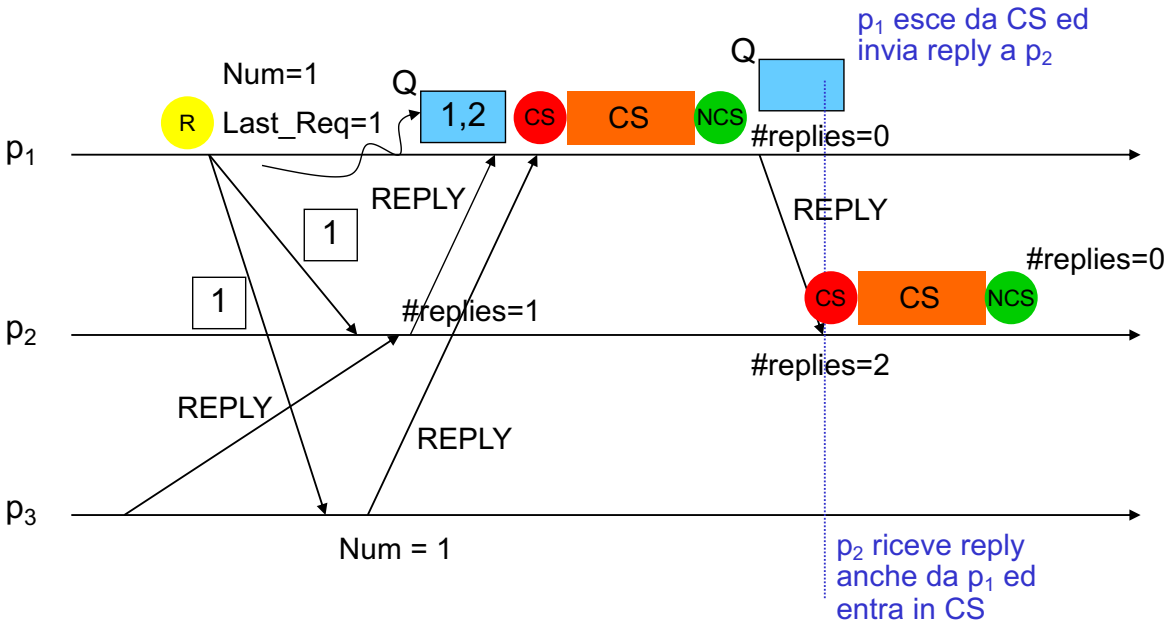

Algoritmo di Ricart e Agrawala

- Vantaggi
  - Come Lamport distribuito, è completamente distribuito
    - Nessun elemento centrale
  - Rispetto a Lamport distribuito, si risparmiano messaggi
    - No messaggio di release, msg di ack differito all'uscita della CS
    - Solo **2(*N*-1)** messaggi per entrare in CS e uscirne: *N*-1 messaggi di richiesta, seguiti da *N*-1 messaggi di reply
  - In letteratura ottimizzazioni (non esaminate) che riducono il numero di messaggi a *N*
- Svantaggi (come Lamport distribuito)
  - Se un processo fallisce, nessun altro potrà entrare nella CS: occorre aggiungere un meccanismo di *failure detection*
  - Tutti i processi possono essere collo di bottiglia
    - Ogni processo partecipa ad ogni decisione

Algoritmi basati su token

- Viene usata una risorsa ausiliaria, chiamata **token**
  - Anche altri algoritmi distribuiti usano il token
- L'algoritmo deve definire: come vengono fatte le richieste per il token, mantenute e servite
- In un algoritmo basato su token in ogni istante esiste un solo possessore di token
  - Si garantisce così la proprietà di safety (mutua esclusione)
- Tipi di algoritmi basati su token:
  - *Centralizzato* (o approccio *token-asking*): gestione centralizzata del token da parte di un coordinatore
  - *Decentralizzato* (o approccio *perpetuum mobile*): gestione decentralizzata del token, che si muove nel sistema

Algoritmo basato su token centralizzato

- Uno dei processi svolge il ruolo di *coordinatore* e gestisce il token
- Il coordinatore tiene traccia delle richieste, in particolare di:
  - Richieste ricevute ma non ancora servite
  - Richieste già servite
- Ogni processo p_i mantiene un suo clock vettoriale
- Quando p_i vuole entrare in CS invia un messaggio di richiesta al coordinatore avente come timestamp il proprio clock vettoriale
- Il coordinatore inserisce il msg nella lista delle richieste pendenti
- Quando la richiesta di p_i diventa eleggibile, il coordinatore invia il token a p_i che entrerà in CS
- Uscendo da CS p_i restituisce il token al coordinatore

Algoritmo basato su token centralizzato: coordinatore

- Strutture dati del coordinatore:
  - Reqlist
    - Lista di richieste pendenti, ricevute dal coordinatore ma non ancora servite
  - V
    - Array di dimensione pari al numero di processi
    - V[i]: numero di richieste di p_i già servite
- Regole:
  - All'arrivo della richiesta di token da parte di p_i con timestamp T_{pi}

    Reqlist = Reqlist ∪ {p_i, T_{pi}}
  - Quando la richiesta di p_i diventa eleggibile (ovvero T_{pi} <= V ∀ j≠i) e il coordinatore ha il token

    Invia token a p_i

Algoritmo basato su token centralizzato: processo

- Strutture dati di ogni processo:
  - VC
    - Clock vettoriale per il timestamp dei messaggi
- Regole:
  - All'invio della richiesta di token:

    VC[i] = VC[i] + 1

    Invia msg al coordinatore (con timestamp VC)
  - Alla ricezione del token

    Entra in CS
  - All'uscita da CS

    Invia token al coordinatore
  - All'invio del messaggio di programma

    Invia msg (con timestamp VC)
  - Alla ricezione del messaggio di programma

    VC = max(VC, msg.VC)

Algoritmo basato su token centralizzato: esempio

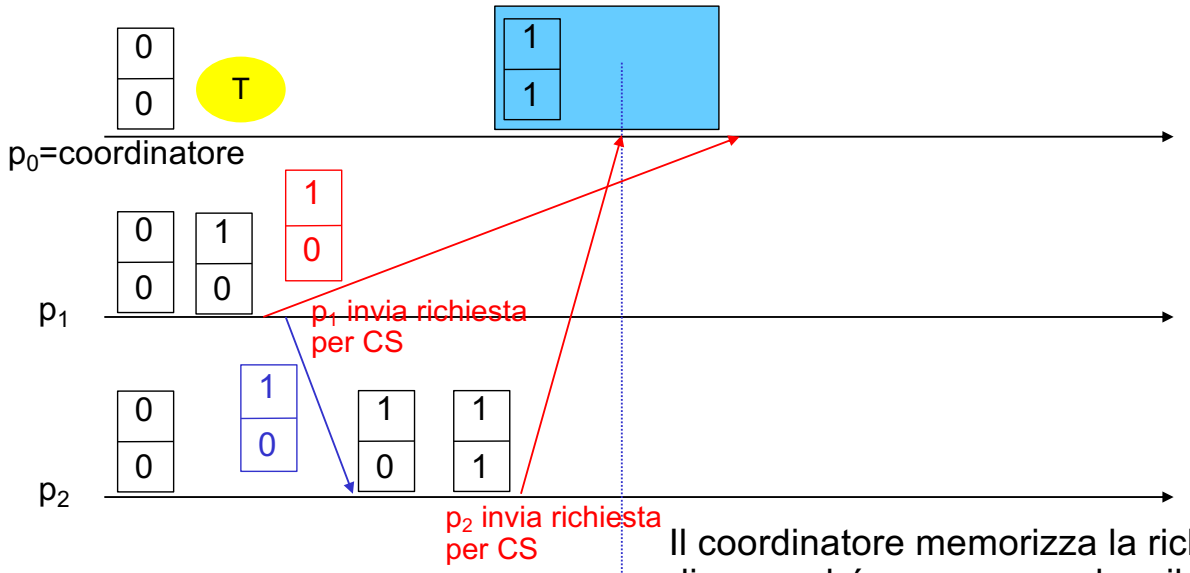

Il coordinatore memorizza la richiesta di p_2 perché non ancora eleggibile (c'è una richiesta "accaduta prima" e non ancora servita)

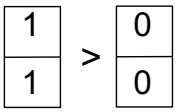

Msg di richiesta token

Msg di programma

Richiesta inviata da p_i *eleggibile* se T_{pi} è al più pari a V $\forall$ j≠i

Algoritmo basato su token centralizzato: esempio

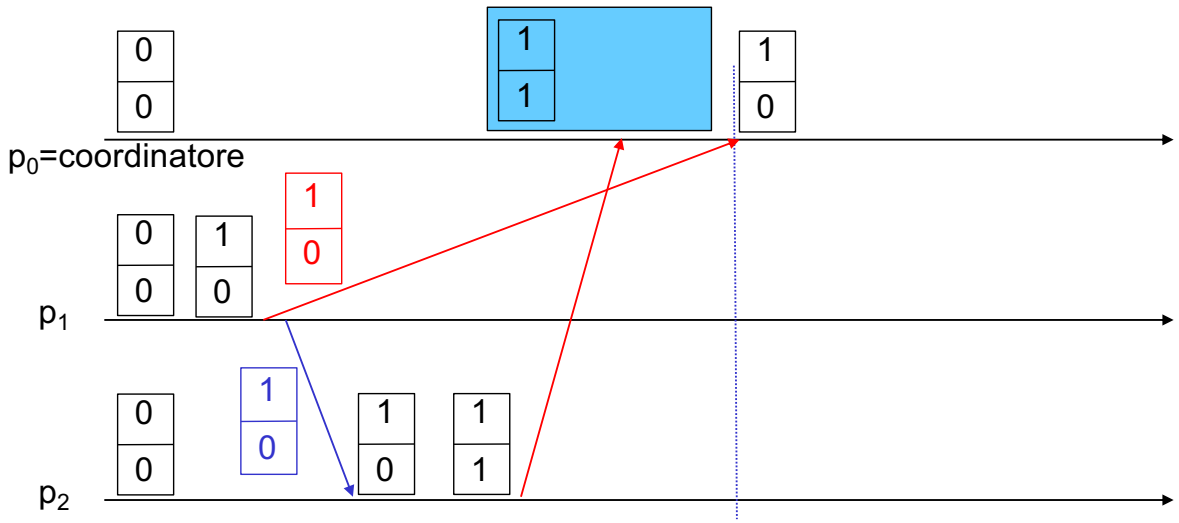

La richiesta di p_1 è eleggibile: il coordinatore invia il token a p_1

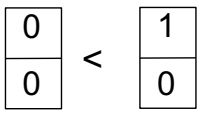

Msg di richiesta token

Msg di programma

Msg con il token

Algoritmo basato su token centralizzato: esempio

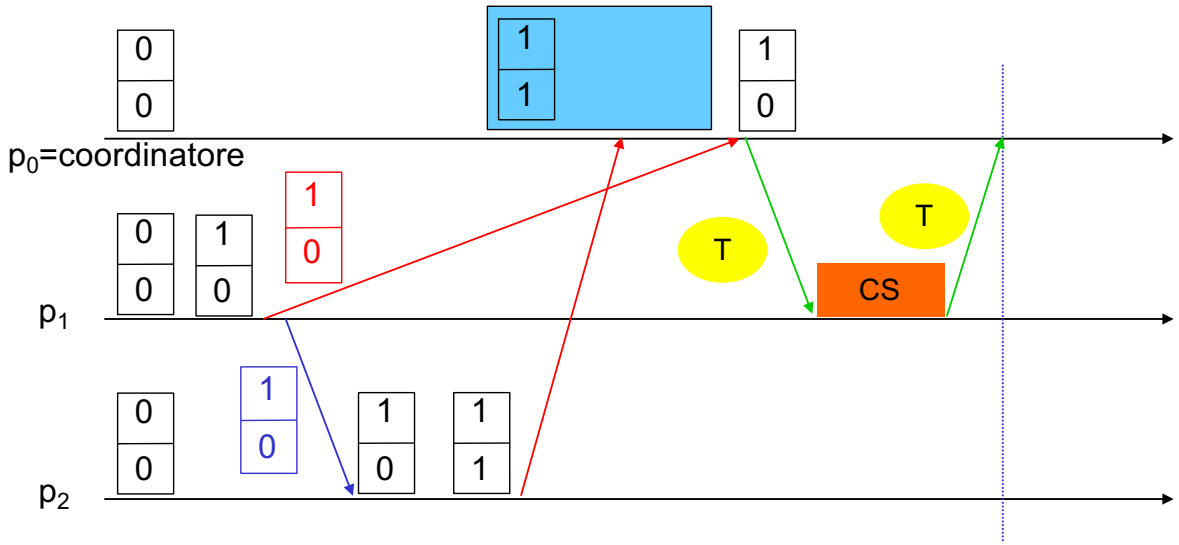

Il coordinatore controlla se la richiesta di p_2 in coda è diventata eleggibile: sì ed invia il token a p_2

1 0 < 1 1

Msg di richiesta token
Msg di programma
Msg con il token

Algoritmo basato su token centralizzato: esempio

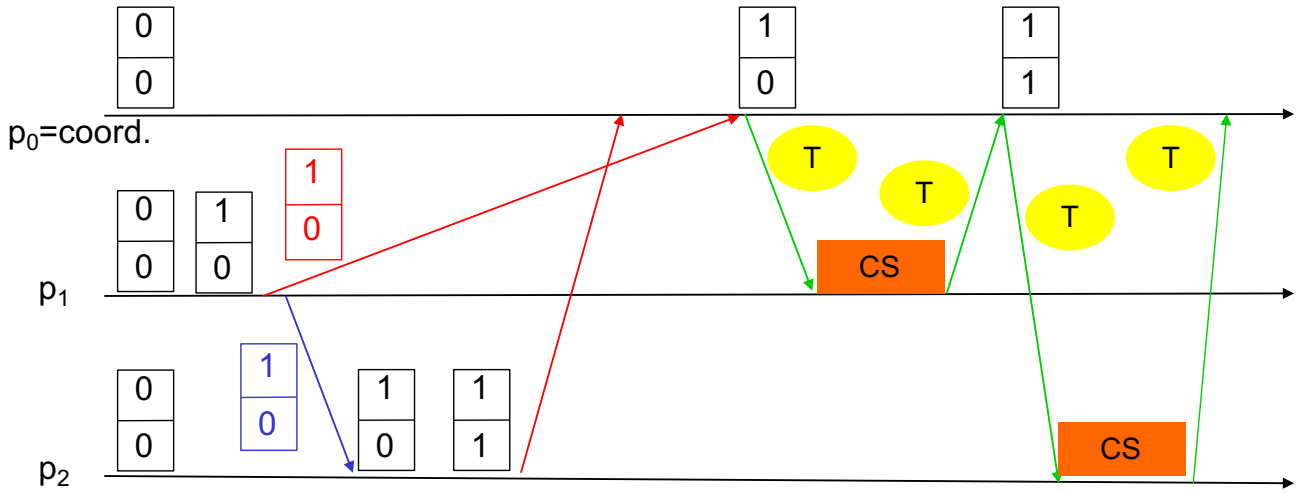

Msg di richiesta token
Msg di programma
Msg con il token

Algoritmo basato su token centralizzato

✓ Prestazioni: N messaggi per entrare in CS (2 msg con coordinatore, N-1 msg di programma)

✓ Garantite anche proprietà di fairness e ordering

✗ Coordinatore: SPoF e collo di bottiglia per scalabilità

✗ In caso di crash del coordinatore occorre eleggerne uno nuovo

Algoritmo basato su token decentralizzato

- Processi organizzati logicamente ad anello (unidirezionale)
  - Nessuna relazione tra topologia dell'anello e interconnessione fisica tra i nodi
- Il token viaggia da un processo all'altro
  - Passa dal processo p_i al processo $p_{(i+1) mod\ N}$
- Il processo in possesso del token può entrare in CS
- Se un processo riceve il token ma non vuole entrare in CS, passa il token al processo successivo

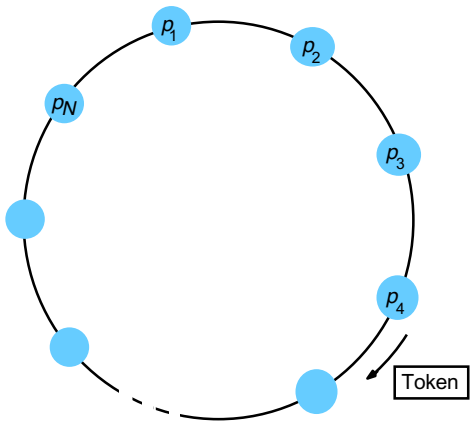

Algoritmo basato su token decentralizzato

- ✓ Se l'anello è unidirezionale, viene garantita anche fairness
- ✓ Rispetto a token centralizzato, la gestione del token è condivisa
- ✗ Consumo di banda di rete per trasmettere il token anche quando nessuno vuole entrare in CS
- ✗ In caso di perdita del token occorre rigenerarlo
- ✗ Guasti temporanei possono portare alla creazione di token multipli
- In caso di crash di singoli processi
  - Se fallisce un processo, occorre riconfigurare l'anello
  - Se fallisce il processo che possiede il token, occorre rigenerare il token ed eleggere il prossimo processo che avrà il token

Algoritmi basati su quorum

- Idea: per entrare in CS occorre raccogliere voti solo da un sottoinsieme di processi (quorum), non da tutti
- Votazione all'interno del sottoinsieme
  - I processi votano per stabilire chi è autorizzato ad entrare in CS
  - Un processo può votare per un solo processo
- Insieme di votazione V_i: sottoinsieme di $\{p_1, \ldots, p_N\}$, associato ad ogni processo p_i

- Un processo p_i per entrare in CS
  - Invia *request* a tutti gli altri membri di V_i
  - Attende *reply* da tutti i membri di V_i
  - Ricevute tutte le *reply* dai membri di V_i entra in CS
  - All'uscita da CS invia *release* a tutti gli altri membri di V_i

- Un processo p_j in V_i che riceve *request*
  - Se è in CS o ha già risposto dopo aver ricevuto l'ultimo *release,* non risponde e accoda la richiesta
  - Altrimenti risponde subito con *reply*

- Un processo che riceve *release* estrae ***una*** richiesta dalla coda e invia *reply*

Algoritmo di Maekawa

- Ogni processo p_i esegue il seguente algoritmo:

Inizializzazione

```
state = RELEASED;
voted = FALSE;
```

Protocollo di entrata in CS per p_i

```
state = WANTED;
invia in multicast request a tutti i processi in V_i (incluso se stesso);
wait until (numero di reply ricevute = K);
state = HELD;
```

Alla ricezione di *request* da p_j ($i \neq j$)

```
if (state = HELD or voted = TRUE) then
        accoda request da p_j senza rispondere;
else
        invia reply a p_j;     // vota a favore di p_j
        voted = TRUE;
end if
```


Algoritmo di Maekawa

Protocollo di uscita da CS per p_i

```
state = RELEASED;
invia in multicast release a tutti i processi in V_i;
if (coda di richieste non vuota) then
        estrai la prima richiesta in coda, ad es. da p_k;
        invia reply a p_k;      // vota a favore di p_k
        voted = TRUE;
else
        voted = FALSE;
end if
```

Alla ricezione di un messaggio di release da p_j ($i \neq j$)

```
if (coda di richieste non vuota) then
        estrai la prima richiesta in coda, ad es. da p_k;
        invia reply a p_k;
        voted = TRUE;
else
        voted = FALSE;
end if
```

Algoritmo di Maekawa: insieme di votazione

- Come è definito l'insieme di votazione V_i per p_i?

1. $V_i \cap V_j \neq \varnothing \quad \forall\, i, j$
   - Insiemi di votazione ad intersezione non nulla
2. $|V_i| = K \quad \forall\, i$
   - Tutti i processi hanno insiemi di votazione con stessa cardinalità K (stesso *sforzo* per ogni processo)
3. Ogni processo p_i è contenuto in K insiemi di votazione
   - Stessa *responsabilità* per ogni processo
4. $p_i \in V_i$
   - Per ridurre il numero di messaggi trasmessi

- Si dimostra che la soluzione ottima che minimizza K è $K \approx \sqrt{N}$
  - Essendo N = K(K-1) + 1

Esempio: N=3

V_1={1,2}
V_3={1,3}
V_2={2,3}

Esempio: N=7

V_1={1,2,3}
V_4={1,4,5}
V_6={1,6,7}
V_2={2,4,6}
V_5={2,5,7}
V_7={3,4,7}
V_3={3,5,6}

Algoritmo di Maekawa

- Come scegliere quali sono i processi a cui inviare la richiesta?
  - Si costruiscono gli insiemi di votazione in modo tale che abbiano intersezione non vuota
  - Se un quorum autorizza l'accesso in CS ad un processo, nessun altro quorum potrà accordare lo stesso permesso
- Proprietà
  - Soddisfa safety ma non liveness
    - Si può verificare deadlock
    - Si può rendere l'algoritmo deadlock-free con messaggi aggiuntivi
- Prestazioni
  - Per entrare in CS e uscirne occorrono **$3\sqrt{N}$** messaggi ($2\sqrt{N}$ per entrata e $\sqrt{N}$ per uscita)
    - Più efficiente di Ricart-Agrawala per reti a larga scala essendo $3\sqrt{N} < 2(N-1)$ per $N > 4$

Algoritmo di Maekawa: esempio di deadlock

$P = \{p_1, p_2, p_3\}$
$V_1 = \{p_1, p_2\}$, $V_2 = \{p_2, p_3\}$, $V_3 = \{p_3, p_1\}$

Situazione di deadlock

- p_1, p_2 e p_3 richiedono contemporaneamente l'entrata in CS
- p_1, p_2 e p_3 impostano ognuno voted=TRUE ed aspettano la risposta dell'altro

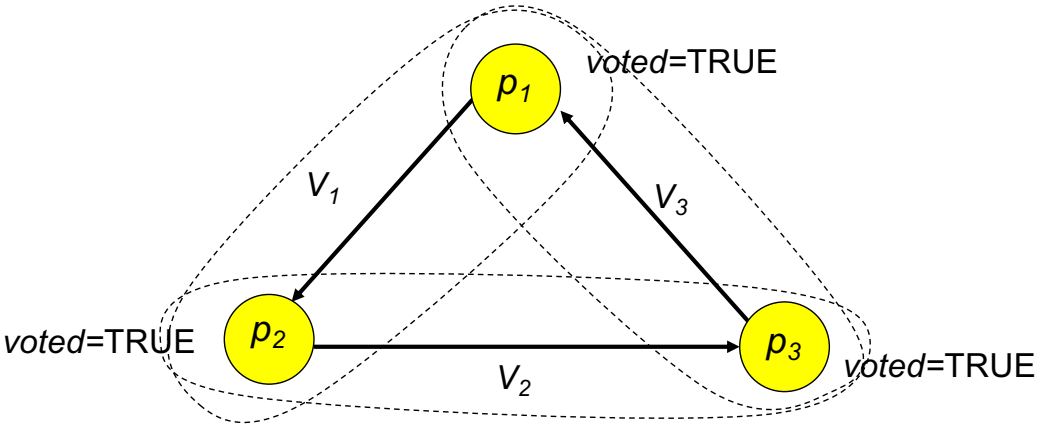

Confronto tra algoritmi per ME distribuita

Algoritmo	#msg per entrata/uscita in/da CS	#msg per entrata in CS	Problemi
Autorizzazione centralizzato	3	2	Crash del coordinatore
Ricart-Agrawala	2(*N*-1)	2(*N*-1)	Crash di un qualunque processo
Token centralizzato	3 + (N-1) inclusi msg di programma	2 + (N-1) inclusi msg di programma	Crash del coordinatore
Token decentralizzato	Da 1 a ∞ (se anello bidirezionale)	Da 0 a *N*-1	Perdita del token Crash di un qualunque processo
Maekawa	$3\sqrt{N}$	$2\sqrt{N}$	Possibile deadlock

Distributed election algorithms

- Many distributed algorithms require that a process acts as *coordinator* (or *leader*), e.g.,
  - Sequencer in totally ordered multicast
  - Coordinator in mutual exclusion
- How to elect the coordinator at runtime?
  - Existing coordinator can crash
  - Election requires to reach a distributed consensus
- Let's study the following election algorithms
  - **Bully algorithm**
  - **Ring election algorithm** by Fredrickson & Lynch

Distributed election: system model

- System with N processes p_i, $i = 1, \ldots, N$
- Processes can crash
- Communication is reliable
- Each process does not hold more than one election at time
- Each process has a unique id and the non-faulty process with the highest id is elected

Distributed election: properties

- *Safety*: only the non-faulty process with the highest id is elected as leader
  - The election result does not depend on the process that started the election
  - When multiple processes start an election at the same time, only a single winner will be announced
- *Liveness*: at any time, some process is eventually leader

Bully algorithm

- Idea: "Node with highest ID bullies its way into leadership" (Garcia-Molina)
- Process p_i notices that coordinator is no longer responding and initiates an election
  - p_i sends an ELECTION message to all processes with higher id (p_{i+1}, p_{i+2}, …, p_N)
  - If no one responds, p_i wins the election and becomes coordinator, announces the victory by sending all processes a message
  - If p_k (with $k>i$) receives the ELECTION message from p_i, it answers sending OK message, takes over and holds an election
  - If p_i receives the OK message, it sits back
- This algorithms always selects as new leader the non-faulty process with the highest id
- A new process (or a process that restarts after crash) does not know the coordinator and therefore holds an election

Bully algorithm: example

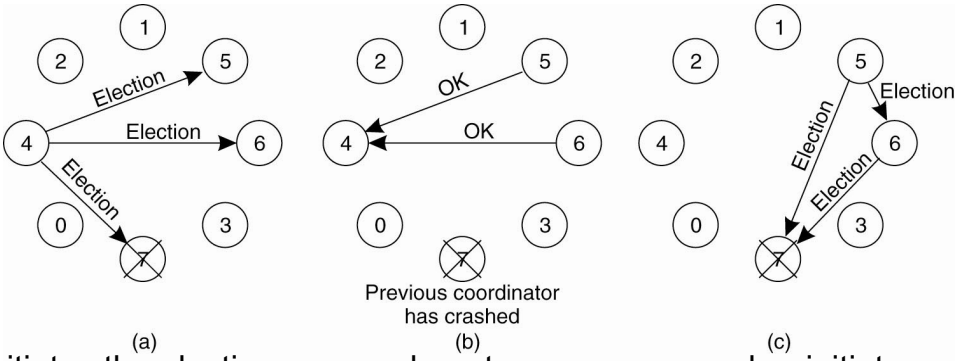

p_4 initiates the election — p_5 and p_6 stop p_4 — p_5 and p_6 initiate a new election

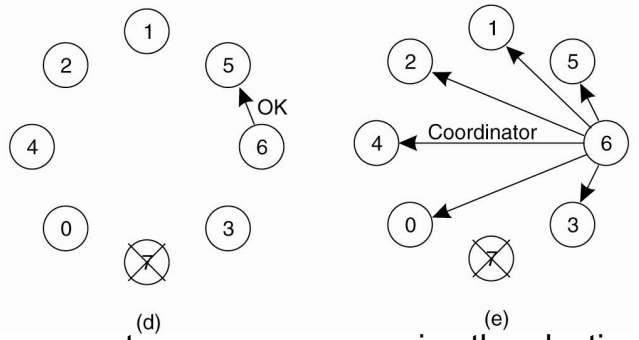

p_6 stops p_5 — p_6 wins the election and becomes the new coordinator

Which is an important assumption?

Synchronous DS and we use a timeout-based mechanism to identify a faulty process

Bully algorithm: communication cost

- Which is the communication cost in terms of exchanged messages?
- Best case: the process with the second highest identifier notices the coordinator's failure
  - It can immediately select itself as coordinator and then send N-2 coordinator messages ⇒ O(N) messages
- Worst case (assuming no process fails during election): the process with the lowest id initiates the election
  - It sends N-1 election messages to processes, which themselves initiate each one an election

    ((N-1) + (N-2) + … + 1) + N-1 ⇒ $O(N^2)$ messages

Ring algorithm by Fredrickson & Lynch

- Processes are organized in a logical ring (unidirectional)
  - Each process knows at least its successor
- Process p_i notices that coordinator is no longer responding and initiates an election
  - p_i sends an ELECTION message to $p_{(i+1) mod\ N}$ with its own id
  - If $p_{(i+1) mod\ N}$ *is* faulty, p_i skips over it and goes to the next process along the ring, until a non-faulty process is located
  - At each step, the receiver adds its own id to the list in the ELECTION message and forwards the message
- Eventually, the ELECTION message gets back to p_i, which identifies the highest id in the list and circulates the COORDINATOR message to inform everyone else who the coordinator is

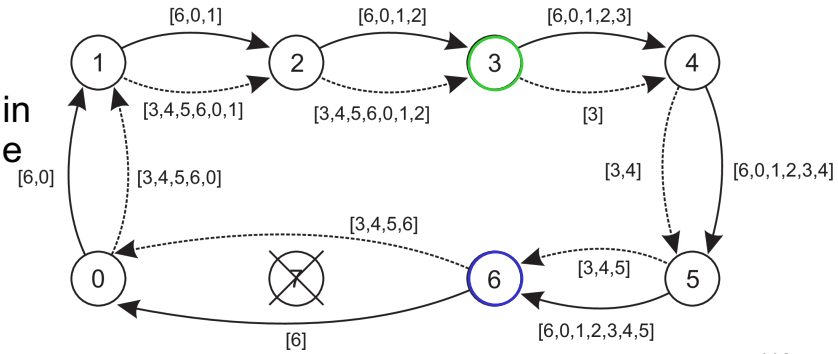

Election algorithms: cost

- Communication cost as number of required messages
- Bully:
  - $O(N^2)$ in the worst case
  - O(N) in the best case
- Fredrickson & Lynch ring:
  - O(2N)
  - But requires larger messages than Bully

Election algorithms: properties

- Common assumption
  - Communication is reliable (messages are neither dropped nor corrupted)
- Ring election algorithm:
  - Works both for synchronous and asynchronous communications
  - Works for any N and does not require any process to know how many processes are in the ring
- Fault tolerance with respect to process failure
  - What happens if a process crashes during election? It depends on the algorithm and the crashed process
  - Additional mechanisms may be needed, e.g., ring reconfiguration
- Something to consider:
  - What happens in case of network partition?
  - Multiple nodes may decide they are the new leader