Sincronizzazione

SCD

Anno accademico 2012/13
Sistemi Concorrenti e Distribuiti

Tullio Vardanega, tullio.vardanega@math.unipd.it

Stato del sistema – 1

- **Stato globale di un sistema distribuito**
  - **Lo stato locale di ciascun processo**
    - Non necessariamente tutto
    - Solo ciò che è importante ai fini dello stato globale
  - **L'insieme dei messaggi in transito**
- **Conoscere lo stato globale consente di**
  - **Verificare se il sistema è globalmente attivo oppure no**
    - Nessun messaggio in transito → nessuna attività globale
  - **Se no, quali cause: normale terminazione oppure stallo?**

Stato del sistema – 2

- ***Distributed snapshot***
  - **Riflette uno stato globale consistente come potrebbe essere stato nel recente passato**
    - Esempio di stato inconsistente: P ha ricevuto un messaggio da Q il cui invio non risulta dallo stato globale
  - **Rappresenta un "taglio" (*cut*) nell'evoluzione temporale individuale dei processi del sistema**
    - Fissa ciò che appartiene allo stato globale e ciò che ne è escluso
    - Il "percorso" del taglio (causato dall'algoritmo usato) determina la consistenza dello stato
  - **Algoritmo ideato da K. Chandy e L. Lamport**
    - Distributed Snapshots: Determining Global States of Distributed Systems. ACM Transactions on Computer Systems, 3(1):63-75, 1985

Stato del sistema – 3

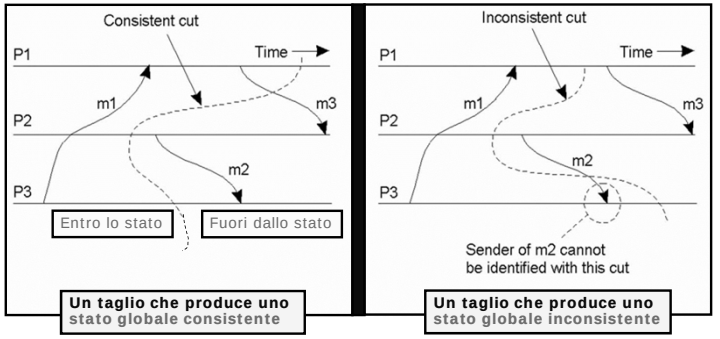

Stato del sistema – 4

- **Situazioni pericolose**
  - **Messaggi inconsistenti**
    - Inviati dal processo M dopo aver salvato il proprio stato (*checkpoint*) ma ricevuti dal processo D prima di aver salvato il proprio stato
    - L'invio di un messaggio inconsistente rischia di essere duplicato in caso di ripristino dello stato
    - Se il suo effetto non è idempotente lo stato di D ne viene corrotto!
  - **Messaggi in transito (*in-flight*)**
    - Inviati da M prima di aver salvato il proprio stato
    - Ricevuti da D dopo aver salvato il proprio stato
- **Uno stato consistente non ammette messaggi inconsistenti**

Distributed snapshot – 1

- **Sistema visto come insieme di processi connessi da canali diretti punto-a-punto**
  - ***Overlay network* sulla topologia fisica**
- **Qualunque processo può iniziare**
  - **Più istantanee possono essere simulatenamente in corso**
- **L'iniziatore salva il suo stato e invia un *marker* sui suoi canali di uscita**
  - **Chiedendo a destinatari di partecipare all'istantanea**
  - **Il *marker* identifica l'iniziatore e la versione di istantanea**

Distributed snapshot – 2

- **Il processo che riceve un *marker* da un suo canale di ingresso C**
  - **Se non ha ancora salvato il suo stato locale lo salva e invia il *marker* su tutti i propri canali in uscita**
  - **Se già lo ha salvato inizia a salvare lo stato del canale C**
    - L'insieme dei messaggi ricevuti su C a partire dall'ultimo salvataggio del sistema
- **Un processo ha fatto la sua parte quando abbia trattato tutti i *marker* ricevuti in ingresso**
- **Quando tutti i processi coinvolti dall'iniziatore hanno completato, l'istantanea è finita**

Distributed snapshot – 3

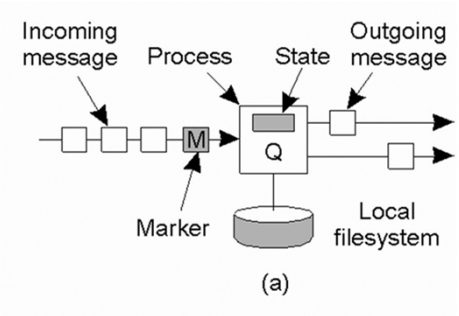

Distributed snapshot – 4

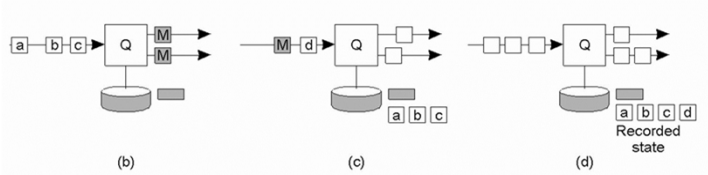

… Salva il proprio stato locale e invia il *marker* su ciascuno dei suoi canali in uscita …

… e comincia a salvare anche lo stato del suo canale in ingresso …

… All'arrivo del successivo *marker* sul suo canale in ingresso ha completato il suo contributo alla cattura dello stato globale

Questo algoritmo produce stati consistenti?

Esempio d'uso: terminazione – 1

- Il processo Q che ha ricevuto un *marker* per la prima volta ne considera il mittente M sul canale in ingresso come suo predecessore
  - Q diventa dunque il successore di M
- Quando Q ha fatto la sua parte invia a M il messaggio "FINITO"
- Lo stato globale per l'iniziatore M' è pronto quando ogni suo successore M abbia ricevuto messaggi "FINITO" da tutti i suoi successori Q'
  - Nel caso generale lo stato globale può includere messaggi in transito
  - Segno di attività non completate

Esempio d'uso: terminazione – 2

- Il processo Q invia il messaggio "FINITO" sse
  - Tutti i suoi successori hanno inviato indietro il messaggio "FINITO"
  - Q non ha ricevuto dai predecessori alcun messaggio successivo al completamento del suo stato
- Altrimenti Q invia il messaggio "CONTINUA" al suo predecessore
  - L'iniziatore allora invia un nuovo *marker* per una nuova istantanea finché non riceva solo messaggi "FINITO" dai suoi successori

Esempio d'uso: terminazione – 3

- Esiste moltissima documentazione su rete che applica, discute, ed estende l'algoritmo di Chandy & Lamport
  - Per un interessante esempio animato, si veda
    - http://www.risc.uni-linz.ac.at/software/daj/snapshot/index.html
    - Perdonando l'inglese ☺
  - Vale la pena fare qualche ricerca e qualche riflessione al riguardo!

Elezione del coordinatore

- La presenza di un coordinatore facilita la costruzione di algoritmi distribuiti
- Eleggere il coordinatore richiede accordo distribuito
  - L'obiettivo dell'algoritmo di elezione è assicurarne la terminazione con l'accordo di tutti i partecipanti
- Prerequisiti
  - Un identificatore ordinale unico per ciascun processo
  - Ogni processo conosce gli identificatori degli altri processi

Algoritmo del «bullo» – 1

- Il processo P che non conosce il coordinatore o ne rileva l'assenza promuove una elezione
  - P invia "ELEZIONE" a tutti i processi di identificatore maggiore
  - Se nessuno risponde P si proclama coordinatore

Algoritmo del «bullo» – 2

- Un processo che riceva "ELEZIONE" da un processo di identificatore minore risponde "OK" e rileva l'elezione
  - Se P riceve "OK" ha finito il suo lavoro
- L'algoritmo designa sempre come coordinatore il processo in vita con identificatore maggiore
  - Il vincente informa tutti i processi del sistema che c'è un nuovo coordinatore

Algoritmo del «bullo» – 3

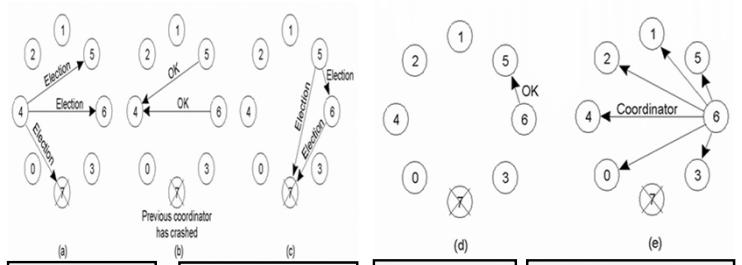

Il processo **4** inizia una nuova elezione

I processi **5** e **6** rilevano l'elezione in parallelo

Il processo **6** rileva l'elezione del processo **5**

Il processo **6** non conosce processi di identificatore maggiore, quindi si proclama coordinatore

Mutua esclusione – 1

- **Algoritmo centralizzato: facile ma fragile**
  - **Le richieste "ENTER" di accesso in mutua esclusione a una risorsa condivisa vengono inviate a un coordinatore centrale**
  - **Se la risorsa è libera il coordinatore risponde "GRANTED"**
  - **Altrimenti il coordinatore accoda la richiesta con politica FIFO e risponde ("DENIED")**
  - **L'utente che rilascia la risorsa invia "RELEASED" al coordinatore**
  - **Il coordinatore allora preleva la prima richiesta in attesa e invia "GRANTED" al suo mittente**
- **Il coordinatore è il *Single Point of Failure* (SPF) dell'algoritmo e il collo di bottiglia**

Mutua esclusione – 2

- **Algoritmo distribuito / I**
  - **Il processo P che chiede accesso esclusivo alla risorsa R invia un messaggio M ("GRANT?") con <P, R, C> a tutti i processi del sistema**
    - C = ora locale di P
  - **Il processo che riceva M**
    - Se non sta usando R e non la vuole (per ora) risponde "OK"
    - Se sta usando R non risponde e accoda M presso di sé
    - Se ha chiesto R ma non l'ha ancora ottenuta confronta C di M con la sua ora locale di richiesta: risponde "OK" solo se C è precedente

Mutua esclusione – 3

- **Algoritmo distribuito / II**
  - **P aspetta di ricevere "OK" da tutti i processi**
    - Quando ciò avviene P può accedere a R in mutua esclusione
    - L'accesso avviene con garanzia di assenza sia di *deadlock* che di *starvation*
  - **Quando P rilascia R risponde "OK" a tutti i processi mittenti di richieste accodate presso di sé e le rimuove dalla coda**
    - A quel punto solo un process riceverà "OK" da tutti gli altri
    - Quello la cui richiesta aveva il C "minore"

Mutua esclusione – 4

- **Critica**
  - **Gli SPF aumentano da 1 (il coordinatore) a N (tutti i processi)**
    - Tutti i processi devono sempre rispondere a ogni richiesta
    - La mancata risposta (*time-out*) interpretata come "occupato"
    - Alla ricezione del primo "occupato" il richiedente deve bloccarsi in attesa del primo "OK" successivo
  - **E in più servono una infrastruttura di comunicazione affidabile e orologi coerenti (!)**

Mutua esclusione – 5

- **Algoritmo a *token ring***
  - **Processi collegati in sequenza circolare ordinata e punto a punto**
    - Il gettone transita circolarmente
  - **Il processo in posizione 0 riceve per primo il gettone**
    - Il possesso del gettone il processo può accedere una singola risorsa (senza cumulo)
    - Poi deve passare il gettone al suo vicino
    - Se il processo non ha immediato bisogno di risorse passa subito il gettone al vicino
    - Il vicino conferma la ricezione altrimenti viene rimosso dalla sequenza
  - **Nel caso peggiore un processo richiedente aspetta una intera rotazione del gettone**
- **Il gettone è 1 SPF → se perso va rigenerato**

Mutua esclusione – 6

- **I 3 algoritmi possono essere raffrontati in relazione a 3 criteri fondamentali**
  - **Numero di messaggi necessari al processo per poter operare sulla risorsa richiesta (ingresso e uscita)**
  - **Il tempo necessario perché la richiesta abbia successo**
  - **Le debolezze dell'algoritmo**
- **Questi 3 criteri possono essere applicati a varie classi di algoritmi distribuiti**

Mutua esclusione – 6

Algoritmo	# Messaggi per accesso e rilascio risorsa	Max attesa di accesso spesa per invio messaggi (costo >> lavoro)	Punti deboli (SPF)
Centralizzato	**3** (ENTER, GRANTED, RELEASED)	**2** (ENTER, GRANTED)	**Guasto del coordinatore**
Distribuito	**2 (n – 1)** (GRANT?, RELEASED) da uno a tutti gli altri	**2 (n – 1)**	**Guasto di qualsiasi processo**
Gettone circolante	**1 .. ∞** (se tutti [1] o nessuno [∞] sono interessati alla risorsa)	**0 .. n – 1** (gettone in possesso, gettone all'altro capo)	**Gettone perso Guasto di processo**

Raffronto prestazionale tra gli algoritmi

Argomenti non trattati

- **Argomenti importanti per la problematica di questa lezione non trattati per limiti temporali del corso**
  - **Sincronizzazione degli orologi fisici**
    - Il *middleware* di ogni nodo del sistema distribuito aggiusta il valore del suo orologio fisico in modo coerente con quello degli altri
  - **Sincronizzazione degli orologi logici**
    - Leslie Lamport ha mostrato come l'accordo degli orologi fisici non sia necessario ma lo sia solo l'ordinamento degli eventi (relazione "precede")
  - **Transazioni distribuite**
    - Come ottenere mutua esclusione e **operazioni atomiche** su dati condivisi (***A**tomicity – **C**onsistency – **I**solation – **D**urability*)