

Algoritmos e Sistemas Distribuídos

Aula teórica 5

Ano lectivo 2014/2015

Mestrado Integrado em Engenharia Informática

Última aula: tempo mínimo para resolver o consenso

- Teorema: Não existe nenhum algoritmo que resolva o problema do consenso num sistema síncrono em menos de $f+1$ rounds, na presença de f falhas, usando $n > f+1$ réplicas
- Só demonstrámos para $f=1$
 - Provámos que é impossível resolver em um round

Similaridade


- Dadas duas execuções e_1 , e_2 do mesmo algoritmo, dizemos que elas são similares para o processo i , denominado $e_1 \sim_i e_2$, se $e_1|_i = e_2|_i$
- $e_1 \approx e_2$ se existirem execuções $x_0, \dots, x_k$ tais que: $e_1 = x_0 \sim_i x_2 \sim_j \dots \sim_k x_k = e_2$
- Lema: se $e_1 \approx e_2$ então $\text{dec}(e_1) = \text{dec}(e_2)$

Impossibilidade do consenso num sistema assíncrono

- Resultado fundamental (FLP):
- Não existe nenhum protocolo determinístico para resolver o consenso num sistema assíncrono em que um único processo possa ter uma falha por crash
 - Fisher, Lynch, and Paterson. Impossibility of distributed consensus with one faulty process. JACM, Vol. 32, no. 2, April 1985, pp. 374-382

Hoje: Contornar o FLP

- Enfraquecer a propriedade de terminação
 - Apenas garantir terminação em períodos de sincronia: se a rede entregou as mensagens atempadamente durante um certo intervalo
- Algoritmo: Paxos
 - Usado, por exemplo, por Google, Yahoo!, Microsoft, Amazon, etc



Pressupostos do modelo

- Sistema assíncrono
- Mensagens podem-se perder e ser duplicadas, mas nunca corrompidas
- Processos podem falhar por crash, e depois recuperar
 - Cada processo tem acesso a armazenamento persistente


Especificação (safety)

- CS1 [Validade] Se todos os processos tiverem a mesma proposta v , então v é o único valor que pode ser decidido
- CS2 [Acordo] Dois processos correctos não podem decidir valores diferentes
- CS3 [integridade (+forte)] Se um processo correcto decide v , então v era a proposta de algum processo
 - Notar que $CS3 \Rightarrow CS1$, logo podemos retirar CS1


Separação de papéis

- 3 tipos de processos:
 - Proponentes (proposers)
 - Aceitantes (acceptors)
 - “Aprendedores” (learners)
- Na prática podem correr todos na mesma máquina → um processo com as três funções

Solução trivial: um único acceptor




Tolerar falhas dos acceptors



Quóruns

- Problema: diferentes acceptors podem receber diferentes propostas → quando podemos escolher uma decisão final?
- Ideia base: a escolha só é feita quando uma maioria de acceptors aceitar um valor
- Generalização (quórum) – subconjuntos do conjunto de acceptors tais que quaisquer dois subconjuntos se intersectam


Maiorias / quóruns em acção



Requisitos da solução

- Supondo que é feita apenas uma proposta e não há falhas
- Temos que garantir que essa proposta é aceite
- P1: Um acceptor tem de aceitar a primeira proposta que recebe
- E se houverem propostas diferentes?

P1 + propostas diferentes



Como lidar com propostas diferentes?

- Acceptors têm de poder aceitar mais do que uma proposta/valor
- Cada proposta tem um número de sequência associado que permite distinguir e ordená-las
 - Proposta = (psn, valor)
 - Propostas diferentes têm psn diferente
 - Definição: uma proposta (ou seja, um par (psn,valor)) foi **escolhida** quando foi aceite por uma maioria de acceptors
 - Nessa altura os learners podem declarar a decisão final

Escolher múltiplas propostas?


Yes we can!

- Desde que todas elas tenham o mesmo valor
 - Esse valor é a decisão final do consenso
- Mais um requisito para a solução:
- P2: Se uma proposta com um valor v foi escolhida, então qualquer proposta subsequente (com um psn superior) que seja escolhida tem o valor v

Fortalecer P2

- Vamos definir outro requisito (P2a) que implica P2 e é mais próximo da implementação algorítmica
- P2: Se uma proposta com um valor v foi escolhida, então qualquer proposta subsequente (com um psn superior) que seja escolhida tem o valor v
- P2a: Se uma proposta com um valor v foi escolhida, então qualquer proposta subsequente (com um psn superior) que seja aceite por um acceptor tem o valor v

Dificuldade em conjugar P1 e P2a



Solução: onerar os proposers

- P2b: Se uma proposta com um valor v foi escolhida, então qualquer proposta subsequente (com um psn superior) que seja **emitida por um proposer** tem o valor v
- Notar que P2b implica P2a, que implica P2

Como garantir P2b?

- Supondo que p quer emitir proposta com p_{sn} número n
- Se p puder garantir que não existe $n' < n$ que foi escolhida (ou possa vir a ser escolhida) então pode propor a sua proposta inicial
- Caso contrário tem de propor o valor que foi ou possa vir a ser escolhido. Como determinar tal valor?

Como decidir se existe $n' < n$ que foi escolhida (ou possa vir a ser escolhida)

- Se já foi escolhida $n' < n$, então foi aceite por uma maioria S . Como qualquer outra maioria S' intersecta S , basta encontrar uma maioria que ainda não aceitou nenhum $n' < n$
 - Nesse caso proposer usa a sua proposta inicial
- Mas e se n' ainda vier a ser aceite?

Como decidir que não existe $n' < n$ que foi (ou possa vir a ser) escolhida

- Se já foi escolhida $n' < n$, então foi aceite por uma maioria S . Como qualquer outra maioria S' intersecta S , basta encontrar uma maioria que ainda não aceitou **e não virá a aceitar** nenhum $n' < n$
 - Nesse caso proposer usa a sua proposta inicial

E se >1 proposta foi aceite?

- Supondo que existem diferentes pares $\langle \text{psn}, \text{valor} \rangle$ aceites por diferentes acceptors
- Se algum foi (ou puder vir a ser) escolhido tem de ser o de psn maior
 - Caso contrário, num algoritmo que garanta P2b, a proposta de psn maior teria de ter um valor igual à proposta que foi (ou possa vir a ser) escolhida

Como garantir P2b?

- Prova-se que para garantir P2b, basta garantir:
- P2c: Para quaisquer v , n , se uma proposta com valor v e psn n é emitida, então existe uma maioria de acceptors S tal que:
 - Ou nenhum acceptor em S aceitou nem virá a aceitar nenhuma proposta com $psn < n$,
 - Ou v é o valor associado à proposta com psn mais alto que foi ou será aceite numa maioria (dentro das propostas com $psn < n$)

Como é que o algoritmo garante P2c?

- Antes de emitir proposta com $psn=n$, proposer contacta uma maioria de acceptors, pergunta qual a proposta com psn mais alto (mas inferior a n) que foi ou virá a ser aceite
- Se a nenhum acceptor aceitou (nem virá a aceitar) valor nenhum $<n$, proposer escolhe a sua proposta inicial
- Caso contrário, propõe o valor associado à proposta de psn mais alto que foi aceite

Dificuldade: prever o futuro

- É difícil prever quais os valores que possam vir a ser aceites
- Ao invés, ao perguntar quais as propostas aceites $< n$, também pedimos uma promessa que o acceptor não virá a aceitar nenhum valor $< n$
- Daí garantirmos que o proposer vai saber qual a proposta com p_{sn} mais alto (mas inferior a n) que foi **ou virá a ser** aceite

Algoritmo do proposer

PROPOSE (v)

choose unique n, higher than any n seen so far

send PREPARE(n) to all nodes

if PREPARE_OK(na, va) from majority then

va = va with highest na (or choose v otherwise)

send ACCEPT (n, va) to all

if ACCEPT_OK(n) from majority then

send DECIDED(va) to all

Algoritmo do acceptor

State: np (highest prepare), na, va (highest accept)
/* This state is maintained in stable storage */

PREPARE(n)

if n > np then

np = n // will not accept anything <n

reply <PREPARE_OK,na,va>

ACCEPT(n, v)

if n >= np then

na = n


va = v

reply with <ACCEPT_OK,n>

Aprendizagem

- Os learners têm de contactar os acceptors (ou ser contactados por eles) para saber quando um valor for escolhido

Liveness não está garantida



- Para garantir progresso, é necessário eleger um proposer único (líder) → só é garantidamente possível em períodos de sincronia


Implementar replicação de máquina de estados (Alternativa #1)

- Correr uma instância do Paxos por cada operação a ser executada
 - instância n usada para determinar a n -ésima operação a ser executada em cada réplica
- Cada réplica corre os 3 papéis do Paxos, e o conjunto de réplicas é fixo
- Clientes enviam operações para o líder, este tenta um número de sequência k e corre a instância k do Paxos
- Eleição de um novo líder traz complicações...


Implementar replicação de máquina de estados (Alternativa #2 – Lab 5)

- Sistema replicado evolui numa sequência de vistas:
 - Conjunto actual de réplicas, uma delas é a réplica primária, restantes são backups
 - Identificador de vista (vid)
- Usar o Paxos para chegar a acordo sobre <primário,backups>
 - vid == número da instância do Paxos a correr

Implementar SMR com o Paxos (Lab 5)




Implementar SMR com o Paxos (Lab 5)




[source: J. Li and M. F. Kaashoek, MIT 6.824 lecture notes]

Implementar SMR com o Paxos (Lab 5)



[source: J. Li and M. F. Kaashoek, MIT 6.824 lecture notes]

Executar operações numa dada vista



Executar operações numa dada vista

- Primário atribui a cada pedido um “viewstamp” $\rightarrow$ tuplo (vid, num_sequência)
- Pedidos dos vários clientes são executados por ordem do viewstamp, por exemplo:
- (0,0) , (0,1) , (1,0) , (1,1) , (1,2) , (2,0) . . .

Desafio: garantir continuidade

- Qualquer réplica, para executar o pedido com viewstamp v , tem de executar toda a sequência de pedidos com viewstamps inferiores a v
 - Se necessário transfere estes pedidos de outras réplicas (transferência de estado)
- Um dos desafios do Lab 5 é garantir que isto acontece no após mudanças de vista

Exercício

- Desenhe o “timeline” de uma execução do algoritmo (original) do Paxos com três acceptors (A1-A3), dois proposers simultâneos (P1,P2), e em que um dos acceptors aceita duas propostas (ou seja, responde positivamente a dois pedidos de “accept”) com valores diferentes.