

Algoritmos e Sistemas Distribuídos

Aula teórica 6

Ano lectivo 2014/2015

Mestrado Integrado em Engenharia Informática

Primeiro teste

- 20 de Outubro, 18:00
- Matéria para o teste: Todas as aulas antes do teste (incluindo a de hoje) excepto Paxos
 - Paxos virá para o segundo teste
- Com consulta → apenas são proibidos os dispositivos com funções de comunicação
 - Portáteis, tablets, smartphones, pombo-correio, etc.
- Aula prática / resolução de exercícios-tipo: hoje
- (Terceiro teste prático fica para depois)


Última aula: 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
 - Dois processos correctos não podem decidir valores diferentes
 - Se um processo correcto decide v , então v era a proposta de algum processo

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

Paxos: Exemplo




Aula de hoje

- Atomicidade / linearizibilidade
 - Especificação para um sistema replicado
- Replicação de variáveis de leitura/escrita
 - Interface mais simples do que replicação de máquinas de estados
- Modelo de falhas Bizantinas
 - Falhas arbitrárias

Atomicidade

- Contexto: Sistema replicado com interface genérica
 - Ou seja, replicação de máquinas de estados
 - Clientes invocam pedidos, e obtêm respostas
 - Do ponto do vista dos clientes, sistema replicado é uma “caixa negra”. Como definir o seu comportamento correcto?



Atomicidade

- Condição de correcção para replicação de máquinas de estados, ou para outros sistemas replicados, que define:
- Comportamento do sistema replicado é igual ao de uma invocação instantânea num objecto não replicado
- Também conhecido como linearizabilidade
- Como definir de forma mais precisa?

Definições

- Variável replicada: $(V, v0, \text{invs}, \text{resps}, f)$
 - V : Conj. de valores
 - $v0$: Valor inicial
 - invs : Conjunto de possíveis pedidos (invocações de operações)
 - resps : Conjunto de possíveis respostas (resultados das operações)
 - $f: \text{invs} \times V \rightarrow \text{resps} \times V$
- Execução da especificação sequencial: $v0, a1, b1, v1, a2, b2, v2, \dots$ (a_i = invocação, b_i = resposta)
 - Se finita, tem de terminar com um valor
 - $(b_i, v_i) = f(a_i, v_{i-1})$, $i > 0$.
- Trace da especificação sequencial: $a1, b1, a2, b2, a3, b3, \dots$ (i.e., só a interface)

Especificação: Atomicidade / Linearizibilidade

- Um objecto A é atómico se obedecer às seguintes propriedades:
 - Well-formedness - cada cliente alterna invocações com respostas, começando por uma invocação
 - Atomicidade
 - Progresso - pedidos dos clientes são respondidos a certo ponto, “eventually”
- Como especificar a propriedade da atomicidade?


Atomicidade

- Dado um trace, para cada operação existe um ponto de serialização, entre a invocação e a resposta, tal que se movermos a invocação e a resposta para esse ponto, o trace resultante é igual ao trace da variável replicada (isto é, as operações retornam o mesmo valor)
- Se a última operação de um cliente não tem retorno, ponto de serialização pode ou não ser incluído
- Exemplo: variável replicada == contador com operações de leitura e incremento, valor inicial 0

Exemplos de execuções atômicas



Execuções não atômicas



Replicação de variável de leitura/escrita

- Caso particular de replicação de máquinas de estados
- Máquina de estados a replicar suporta apenas duas operações: read, write(v)
 - Write retorna “ack” quando terminar
 - Read retorna um valor anteriormente escrito (ou v0 – valor inicial)
- Permite uma implementação mais simples do que o Paxos

Algoritmo ABD [Attiya, Bar-Noy, Dolev]

- Pressupõe sistema assíncrono, canais fiáveis
- Usa $2f+1$ réplicas para tolerar f falhas por crash
 - Ou seja, a propriedade de liveness só é garantida em execuções com menos de f falhas
- Vamos descrever a implementação de uma única variável replicada
 - Pode ser generalizado para uma memória com endereços/identificadores, através de várias instâncias do algoritmo a correr em paralelo

ABD: Estado e algoritmo de escrita

- Estado
 - $val_i \rightarrow$ valor da variável, inicialmente v_0
 - $tag_i \rightarrow$ par $\langle \text{número de sequência}, id \rangle$ inicialmente $\langle 0, 0 \rangle$
- Algoritmo para o cliente c_1 efectuar escrita:
 $WRITE(v)$
 - Fase 1: Enviar mensagem “read-tag” a todos os processos
 - Esperar por um quórum Q (e.g., maioria) de respostas
 - Seja $seqmax = \max\{sn: \langle sn, id \rangle \in Q\}$
 - Fase 2: Enviar mensagem “write($\langle seqmax+1, c_1 \rangle, v$)”
 - Esperar por um quórum de acks
 - Retornar “ack”

ABD: Algoritmo da réplica i

- Ao receber read-tag:
 - Retornar tag_i
- Ao receber write(new-tag,new-val):
 - Se new-tag > tag_i então
 - $tag_i = \text{new tag}$
 - $val = \text{new-val}$
 - Retornar ack
- Ao receber read:
 - Retornar $\langle tag_i, val_i \rangle$

ABD: Algoritmo de leitura (tentativa 1)

- Algoritmo para o cliente $c1$ efectuar leitura:
READ()
 - Enviar mensagem “read” a todos os processos
 - Esperar por um quórum Q (e.g., maioria) de respostas
 - Seja $\langle \text{tagmax}, \text{valmax} \rangle \in Q$ com a tag mais elevada
 - Retornar valmax
- Será que garante atomicidade?

Tentativa 1 não garante atomicidade

- É possível construir uma execução com o seguinte trace (valor inicial 0):



- Exercício: diagrama temporal desta execução
- Solução: adicionar uma fase (write-back) à leitura

ABD: Algoritmo de leitura

- Algoritmo para o cliente $c1$ efectuar leitura:
READ()
 - Fase 1: Enviar mensagem “read” a todos os processos
 - Esperar por um quórum Q (e.g., maioria) de respostas
 - Seja $\langle \text{tagmax}, \text{valmax} \rangle \in Q$ com a tag mais elevada
 - Fase 2: Enviar mensagem “write(tagmax, valmax)”
 - Esperar por um quórum de acks
 - Retornar valmax

ABD: Correção

- Terminação (se não houverem mais de f falhas) e well-formedness são fáceis de ver
- Atomicidade (ideia geral)
 - Possível encontrar pontos de serialização ordenados pela “tag” associada à segunda fase da leitura e da escrita, com escritas antes das leituras no caso de terem a mesma tag
 - Pela construção do algoritmo, esta serialização comporta-se como uma variável de leitura/escrita (leitura retorna a última escrita, pois esta é a escrita com a mesma tag)
 - Resta demonstrar que este ponto de serialização ocorre entre o início e o fim da operação (ideia geral: demonstrar que pode ser depois do início e pode também ser antes do fim)

Modelo de falhas Bizantino

- Processos que falham podem-se comportar de forma arbitrária
- Modelo engloba causas como bugs de software, corrupção de memória ou de dados em disco
- Também é uma ferramenta de segurança: máquina sob controlo de atacante tem uma falha Bizantina

All bets are off?

- Restrições ao comportamento de um conjunto *limitado* de processos Bizantinos
- Não podem quebrar primitivas criptográficas:
 - Não podem forjar autenticadores (usados para estabelecer canais de comunicação seguros)
 - Não podem provocar colisões de hashes
 - Se assinaturas digitais forem usadas, não podem ser forjadas
- Não podem alterar directamente o estado dos outros processos
- Mas podem fazer “replay” de mensagens antigas autenticadas

Reformulação do consenso

- Condições de correcção:
- C1 [Validade] Se todos os processos **correctos** tiverem $v_i = v$, então v é o único valor do output permitido
- C2 [Acordo] Dois processos **correctos** não podem decidir valores diferentes
- C3 [Terminação] Todos os processos **correctos** têm de decidir a certo ponto (“eventually”)

Resultado fundamental: número mínimo de réplicas para o consenso

- É impossível resolver o problema do consenso com n processos e f falhas Bizantinas, se $n \leq 3f$
- Não vamos demonstrar, por curiosidade devem ver: [N. Lynch] 6.4

Adaptar o ABD para falhas Bizantinas

- Alteração 0: Usar canais de comunicação autenticados
 - Garantir que mensagens provêm do processo certo
- Alteração 1: Mudar as propriedade de intersecção dos quórums
- Propriedade anterior: quaisquer dois quórums intersectam-se numa réplica
 - Garante que a leitura “vê” o último valor que foi escrito
- Qual o problema se usarmos a mesma definição?
- A réplica na intersecção pode ser Bizantina


Quóruns Bizantinos

- Quaisquer dois quóruns intersectam-se numa réplica correcta
- Qual a dimensão necessária para os quóruns ou o número de réplicas?

Quóruns Bizantinos

- (i) Quóruns não podem ter mais do que $n-f$ réplicas. Porquê?
- Caso contrário pode ser impossível recolher um quórum: réplicas Bizantinas podem nunca responder
- (ii) Quaisquer dois quóruns intersectam-se em pelo menos uma réplica correcta
- (i) $Q \leq N-f$
- (ii) $N - (N-Q) - (N-Q) \geq f+1$


Solução óptima: $N = 3f+1$, $Q=2f+1$



Será suficiente?

- Supor que não há escritas a decorrer
- Que categorias de valores são retornados num quórum de leitura?
- Resultados correctos e actuais (quantos no mínimo?)
- Resultados correctos e desactualizados
- Resultados retornados por réplicas Bizantinas (incorrectos)

Exemplo



Solução 1: aumentar Q

- Garantir que os valores correctos e actuais têm mais votos do que os incorrectos
- Para tal, os quóruns têm de se intersectar em $2f+1$ réplicas
 - Intersecção contem, no pior caso, $f+1$ réplicas correctas e f Bizantinas
- Requer $n=4f+1$, $Q=3f+1$
- Resultado da leitura é o maior valor retornado por $\geq f+1$ réplicas
- Problema: pode ser impossível encontrar $f+1$ valores coincidentes. Em que situação?
- Torna-se necessário enfraquecer a especificação

Solução 2: clientes assinam as escritas

- No write, o cliente envia assinatura do par <tag,valor>
- Réplicas armazenam e retornam esta assinatura
- Na leitura, o cliente descarta respostas com assinatura inválida
- Necessário enviar nonce com cada pedido/resposta para evitar “replay attacks”

Estado e algoritmo de escrita

- Estado
 - $val_i \rightarrow$ valor da variável, inicialmente v_0
 - $tag_i \rightarrow$ par $\langle \text{número de sequência}, id \rangle$ inicialmente $\langle 0, 0 \rangle$
 - $sig_i \rightarrow$ assinatura de $\langle val_i, tag_i \rangle$
- Algoritmo para o cliente c_1 efectuar escrita: $WRITE(\text{new-val})$
 - Gerar nonce aleatório
 - Fase 1: Enviar mensagem “ $read(\text{nonce})$ ” a todos os processos
 - Esperar por um quórum Q de respostas válidas: correctamente autenticadas e com o nonce enviado; descartar respostas inválidas
 - Seja $t_{max} = \max\{tag: read\text{-}reply(\langle tag, id, sig \rangle) \in Q \wedge válida(sig, \langle tag, id \rangle)\}$
 - Assinar $\langle \langle t_{max}+1, c_1 \rangle, v \rangle$ com chave privada de c_1 , obtem-se a assinatura s
 - Fase 2: Enviar mensagem “ $write(\langle t_{max}+1, c_1 \rangle, \text{new-val}, s, \text{nonce})$ ”
 - Esperar por um quórum de acks válidos (com o nonce enviado)
 - Retornar “ack”

Algoritmo de leitura

- Algoritmo para o cliente $c1$ efectuar leitura: $READ()$
 - Gerar nonce aleatório
 - Fase 1: Enviar mensagem “ $read(nonce)$ ” a todos os processos
 - Esperar por um quórum Q de respostas válidas: correctamente autenticadas e com o nonce enviado; descartar respostas inválidas
 - Seja $\langle tag_{max}, val_{max}, sig_{max} \rangle \in Q$ com a tag mais elevada
 - Fase 2: Enviar mensagem “ $write(tag_{max}, val_{max}, sig_{max}, nonce)$ ”
 - Esperar por um quórum de acks válidos; descartar respostas inválidas
 - Retornar val_{max}

Algoritmo da réplica i

- Ao receber read(nonce):
 - Retornar read-reply(<tag_i,val_i,sig_i,nonce>)
- Ao receber write(new-tag,new-val,sig,nonce):
 - Se válida(sig,<new-val,new-tag>) e new-tag > tag_i
então tag_i = new-tag; val_i = new-val; sig_i = sig
 - Retornar ack(nonce)

Final da matéria para o primeiro teste

- Relembrar que Paxos fica para o segundo teste
- Tudo o resto até esta aula (inclusivé) sai no teste
- Próxima aula: revisão da matéria