SISTEMAS DISTRIBUÍDOS

Capítulo 7

Introdução à replicação e consistência

NOTA PRÉVIA

A apresentação utiliza algumas das figuras livro de base do curso

G. Coulouris, J. Dollimore and T. Kindberg,
Distributed Systems - Concepts and Design,
Addison-Wesley, 5th Edition

SUMÁRIO

- Introdução à replicação
  - Primário-secundário
  - Multi-master
- Caching
  - Sistemas de ficheiros distribuídos
  - Caching NFS
  - Caching CIFS
  - Caching Callback Promise

INTRODUÇÃO À REPLICAÇÃO: MOTIVAÇÃO

Tolerar falhas

Distribuir carga

PRIMÁRIO / SECUNDÁRIO (PASSIVO)

Primário: mantém versão oficial dos dados

Secundário: mantém cópia da versão do primário

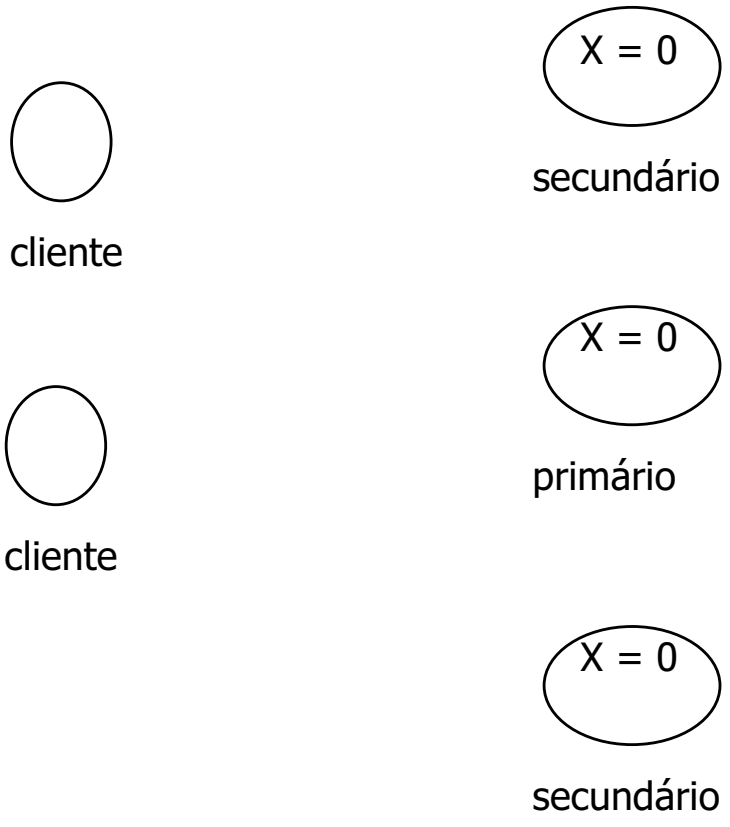

PRIMÁRIO / SECUNDÁRIO : LEITURA

Leitura enviada para qualquer réplicas

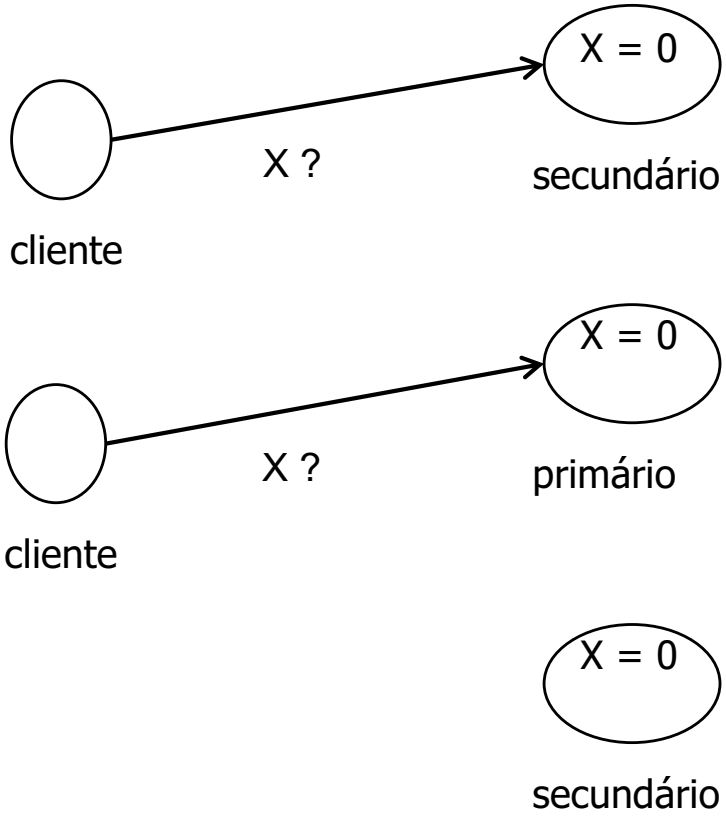

PRIMÁRIO / SECUNDÁRIO : LEITURA

Leitura enviada para qualquer réplicas

Secundário executa operação e devolve resultado

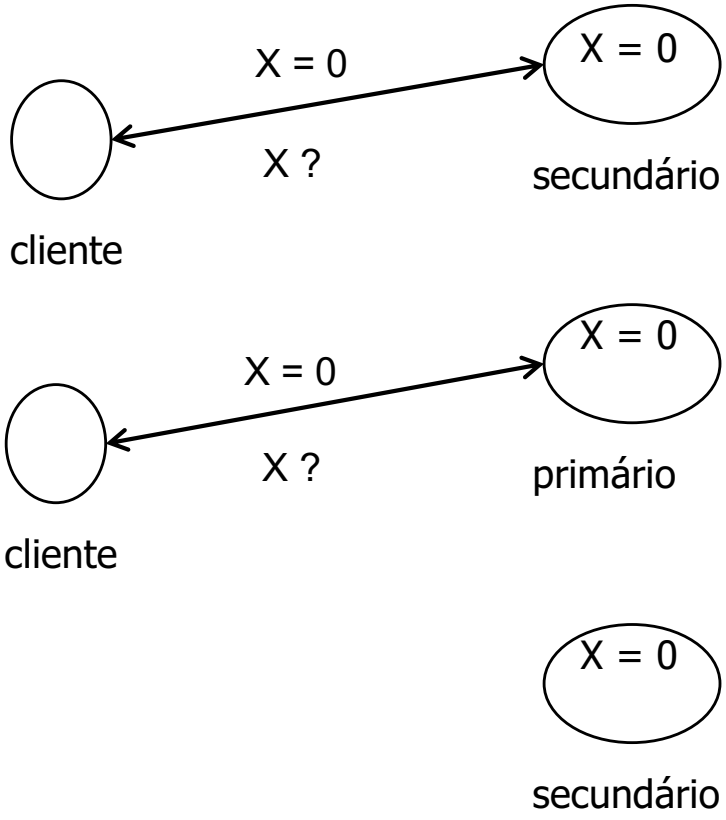

PRIMÁRIO / SECUNDÁRIO : ESCRITA

Escritas enviadas para o primário

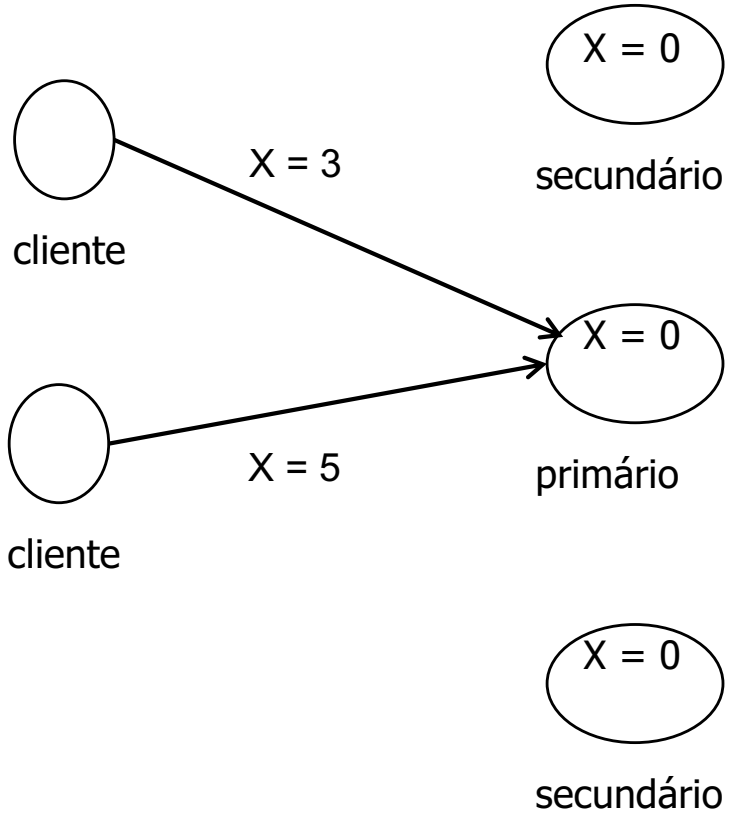

PRIMÁRIO / SECUNDÁRIO : ESCRITA

Escritas enviadas para o primário

Primário ordena escritas e executa-as ordenadamente

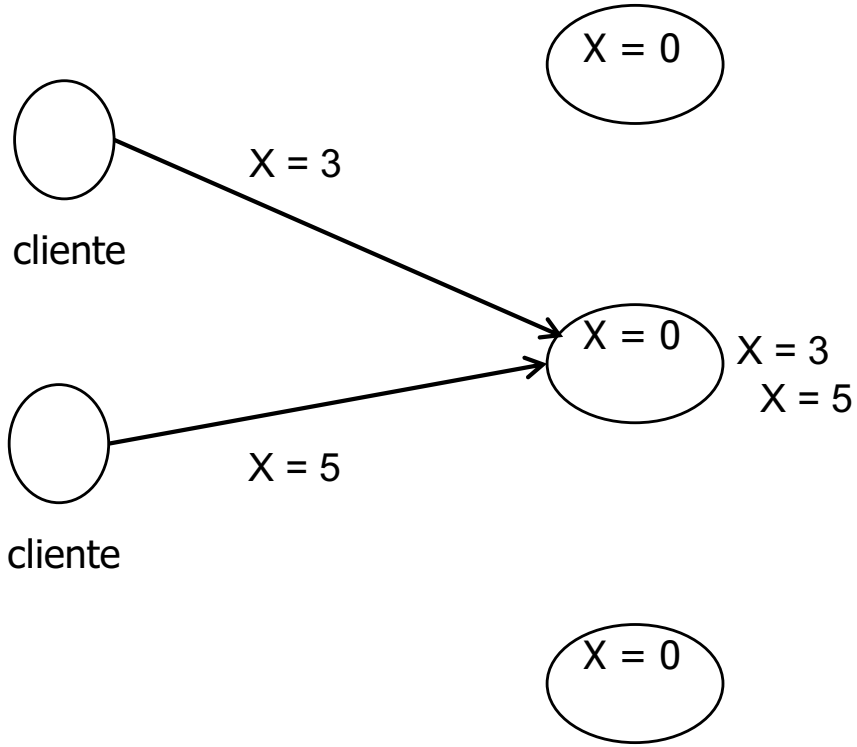

PRIMÁRIO / SECUNDÁRIO : ESCRITA

Escritas enviadas para o primário

Primário ordena escritas e executa-as ordenadamente

Execução de operação

1. Execução no primário
2. Envio da operação para os secundários

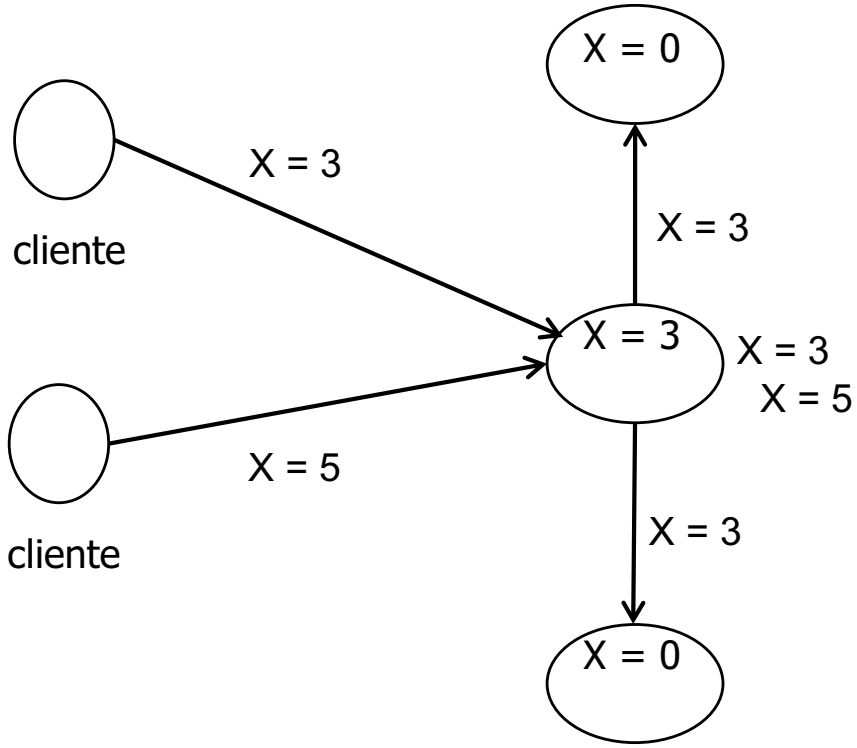

PRIMÁRIO / SECUNDÁRIO : ESCRITA

Escritas enviadas para o primário

Primário ordena escritas e executa-as ordenadamente

Execução de operação

1. Execução no primário
2. Envio da operação para os secundários
3. Secundário executa operação

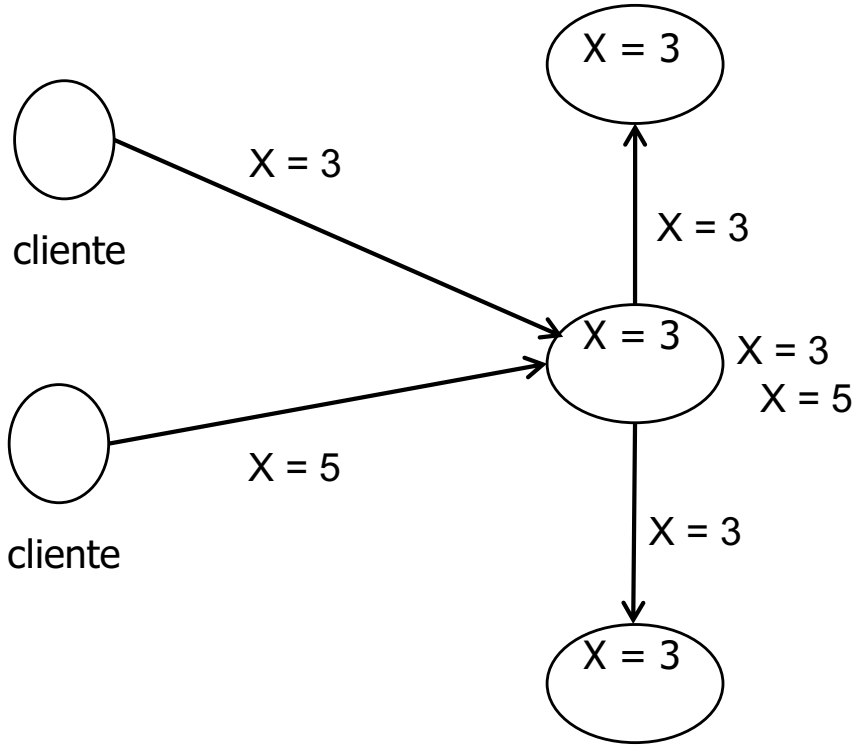

PRIMÁRIO / SECUNDÁRIO : ESCRITA

Escritas enviadas para o primário

Primário ordena escritas e executa-as ordenadamente

Execução de operação

1. Execução no primário
2. Envio da operação para os secundários
3. Secundário executa operação
4. Secundário envia ACK para primário

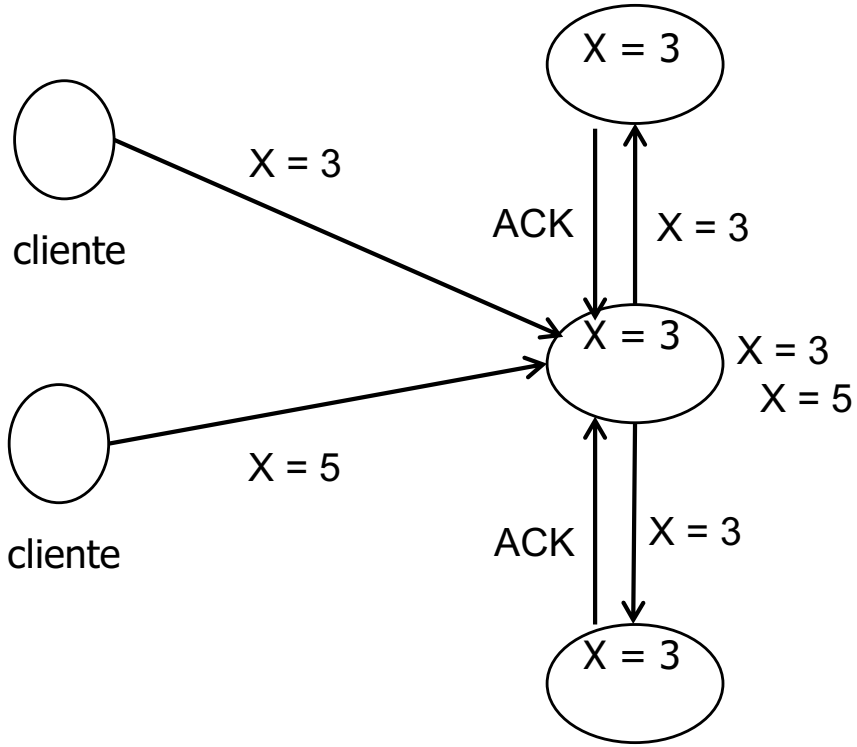

PRIMÁRIO / SECUNDÁRIO : ESCRITA

Escritas enviadas para o primário

Primário ordena escritas e executa-as ordenadamente

Execução de operação

1. Execução no primário
2. Envio da operação para os secundários
3. Secundário executa operação
4. Secundário envia ACK para primário
5. Primário envia ACK para cliente

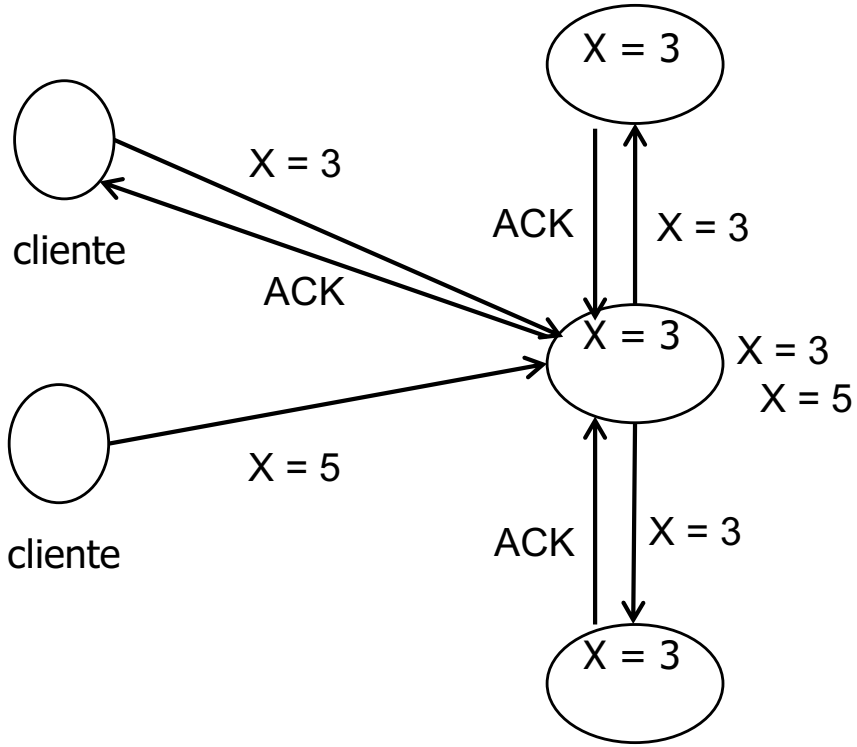

PRIMÁRIO / SECUNDÁRIO : ESCRITA : FALHA DUM SECUNDÁRIO

O que fazer quando um secundário falha (ou a mensagem se perde)?

O primário pode devolver ACK ao cliente sem receber a resposta de todos os secundários

Como é que secundário sabe que está a receber todas as operações?

Operações devem ser numeradas pelo primário (canal FIFO).
Secundário detecta falta de operação na próxima operação (ou por contacto periódico com primário)
NOTA: dependendo das operações, receber a última operação pode ser suficiente

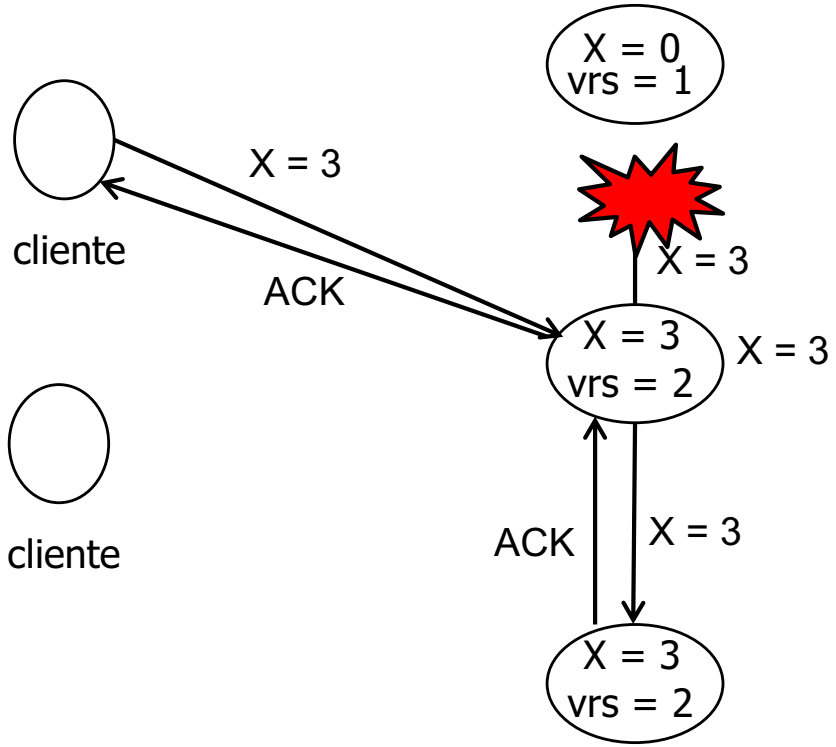

PRIMÁRIO / SECUNDÁRIO : ESCRITA : FALHA DUM SECUNDÁRIO

O que fazer quando um secundário falha (ou a mensagem se perde)?

O primário pode devolver ACK ao cliente sem receber a resposta de todos os secundários

Como é que se garante que cliente não lê versão anterior à sua escrita?

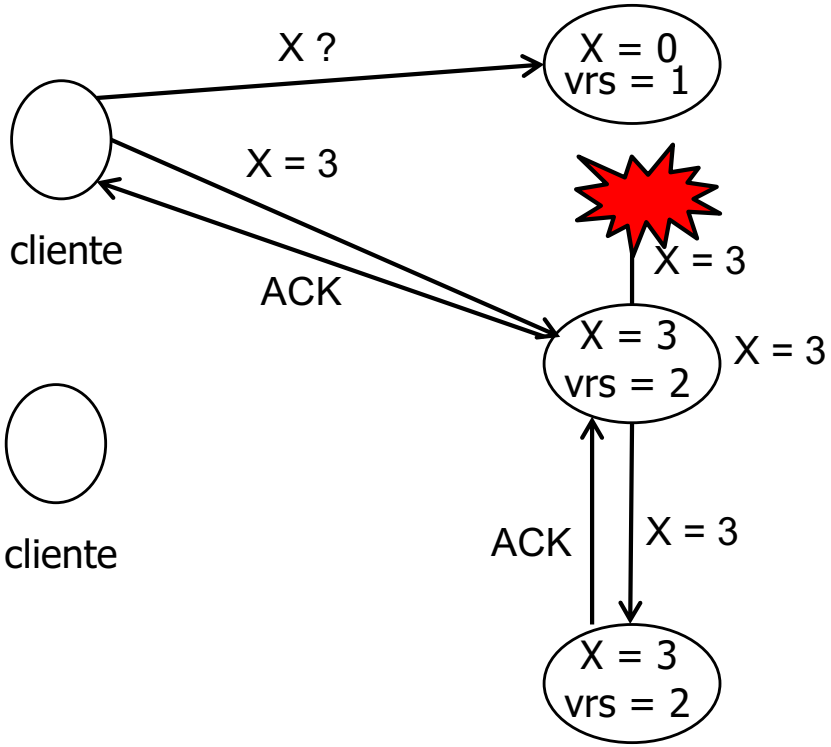

PRIMÁRIO / SECUNDÁRIO : ESCRITA : FALHA DUM SECUNDÁRIO

O que fazer quando um secundário falha (ou a mensagem se perde)?

O primário pode devolver ACK ao cliente sem receber a resposta de todos os secundários

Como é que se garante que cliente não lê versão anterior à sua escrita?

Cliente pode receber versão escrita e enviar essa versão no próximo pedido para que apenas um servidor com uma versão superior responda

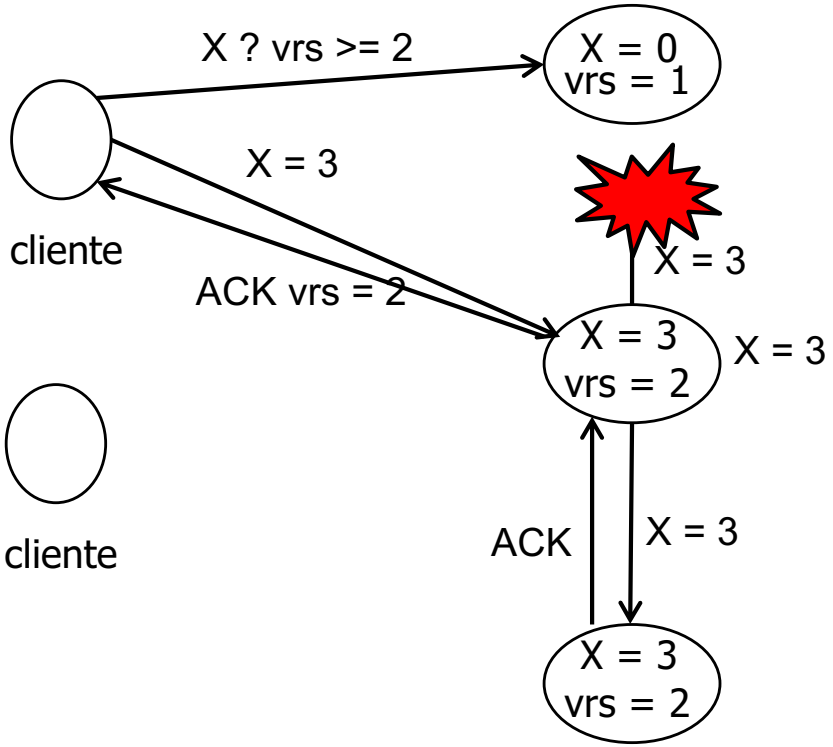

PRIMÁRIO / SECUNDÁRIO : ESCRITA : FALHA DUM SECUNDÁRIO

O que fazer quando um secundário falha (ou a mensagem se perde)?

O primário pode devolver ACK ao cliente sem receber a resposta de todos os secundários

Quantos secundários precisam de responder de forma a que uma escrita não se perca?

Depende de quantas falhas se toleram e do que se fizer quando o primário falha…

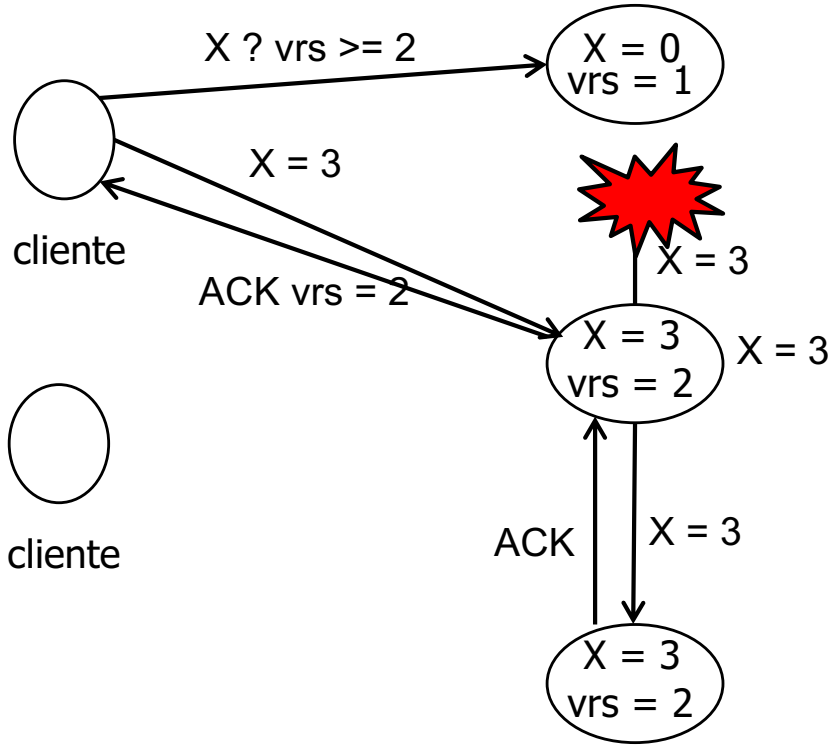

PRIMÁRIO / SECUNDÁRIO : ESCRITA : FALHA DO PRIMÁRIO

O que fazer quando o primário falha?

1. Um secundário deve ser eleito o novo primário
2. Secundários devem concordar em qual a última operação executada

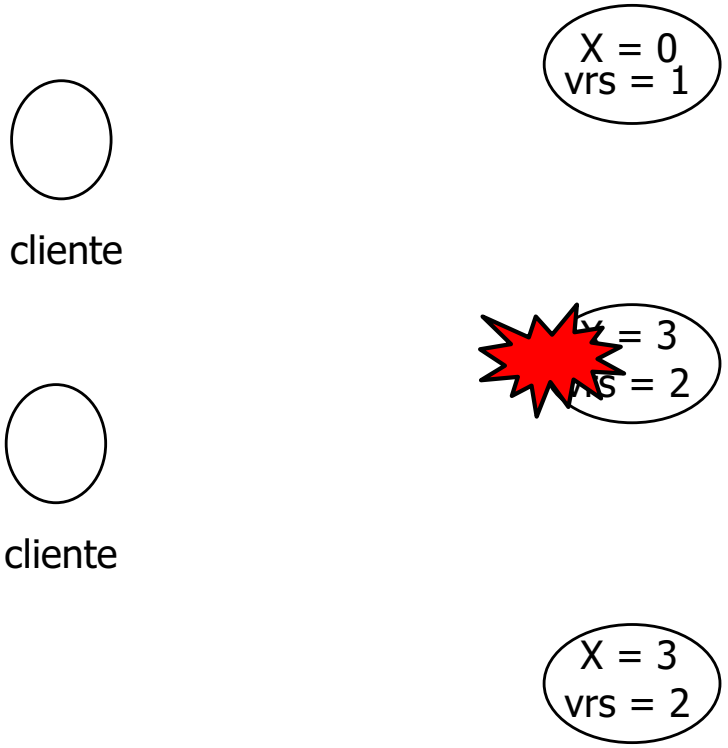

PRIMÁRIO / SECUNDÁRIO : ESCRITA : FALHA DO PRIMÁRIO

O que fazer quando o primário falha?

1. Um secundário deve ser eleito o novo primário
2. Secundários devem concordar em qual a última operação executada

Como garantir que não se perdem mensagens?

1 secundário que participa no protocolo deve ter a última mensagem

Possível solução: maioria de secundários para executar e ler operações

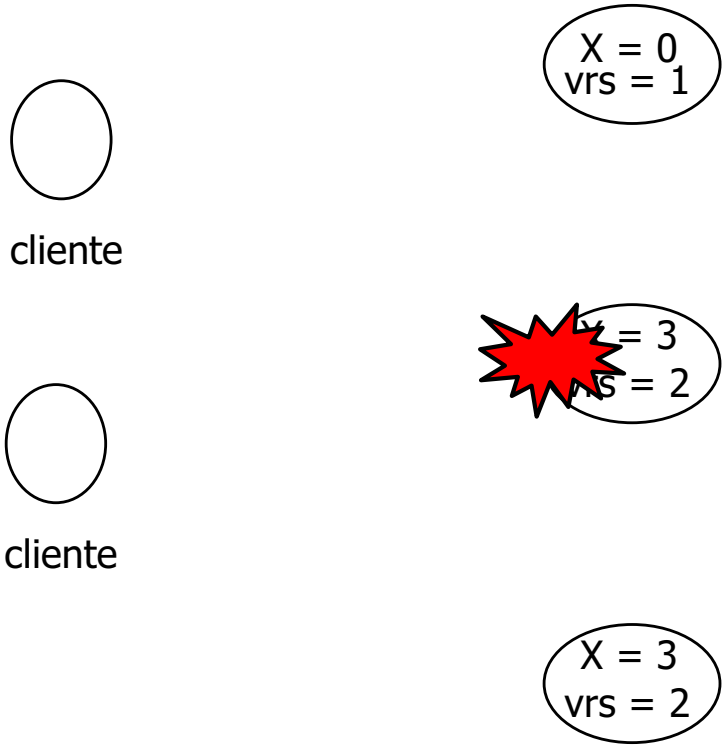

PRIMÁRIO / SECUNDÁRIO : ESCRITA : FALHA DO PRIMÁRIO

O que fazer quando o primário falha?

1. Um secundário deve ser eleito o novo primário
2. Secundários devem concordar em qual a última operação executada

Como garantir que apenas um secundário é eleito?

Algoritmo de eleição / sistema de comunicação em grupo

Detetor de falhas

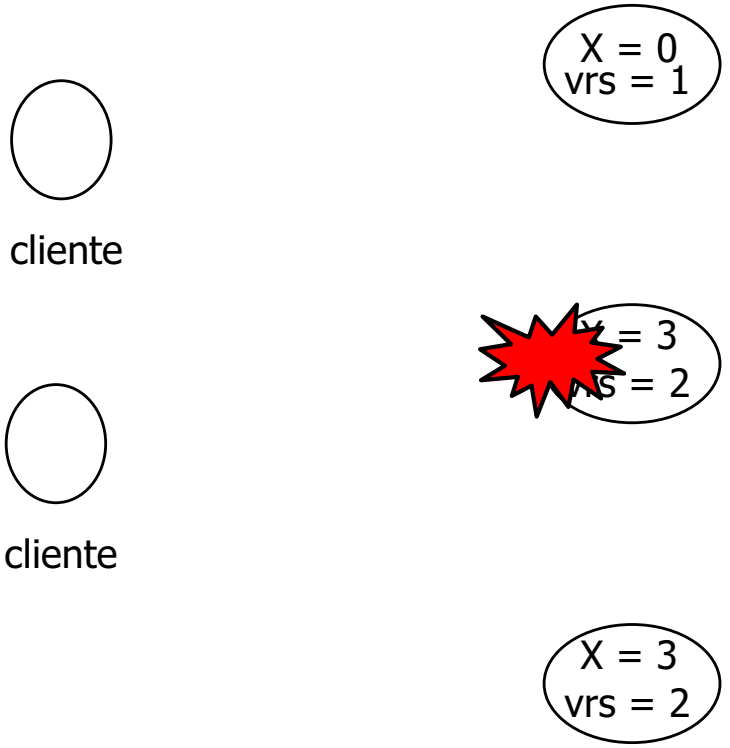

PRIMÁRIO / SECUNDÁRIO : ESCRITA : ELEIÇÃO DE NOVO PRIMÁRIO : OUTLINE

Consideremos 1 primário + N secundários

Primário pode continuar a funcionar desde que receba ACK de K > N/2 secundários

Detecção de primário falhado

- Quando K > N/2 secundários concordam que primário falhou (e concordam em não receber mais pedidos desse primário)

Eleição de novo primário (solução simples)

- Servidores estão ordenados
- Quando o primário falha, o próximo servidor será o novo primário

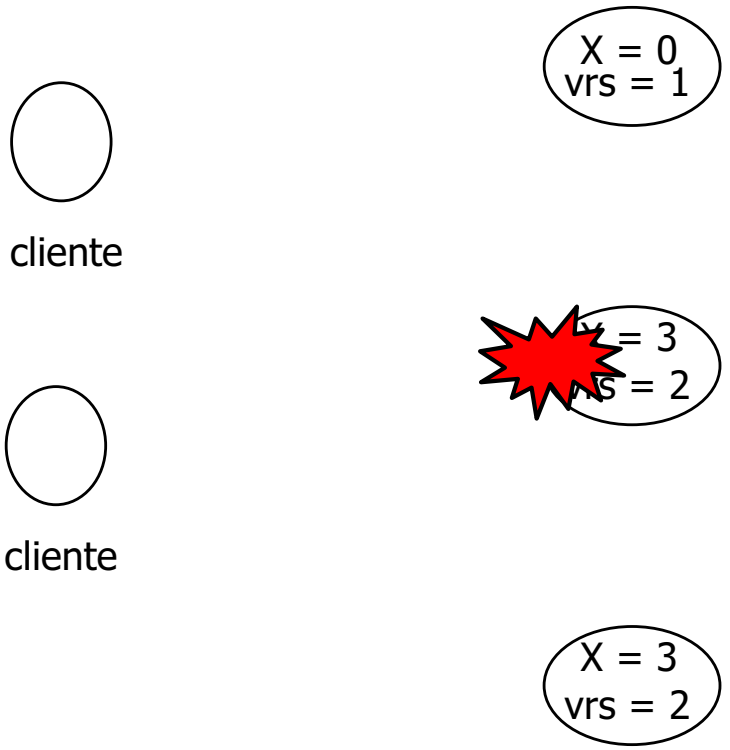

Problemas com esta solução simples?

SUMÁRIO

Introdução à replicação

- Primário-secundário
- Multi-master

Caching

- Sistemas de ficheiros distribuídos
- Caching NFS
- Caching CIFS
- Caching Callback Promise

CODA

Sistema de ficheiros distribuído, descendente do AFS

Servidores replicam volumes (hierarquia de directórios): réplicas principais

Clientes replicam subconjunto de ficheiros: réplica secundária (ou *cache*)

- Ficheiros são replicados completamente

Utiliza aproximação "callback promise"

- Modificações no servidor notificadas aos clientes que replicam ficheiros

Replicação no sistema Coda

Aproximação optimista

- Permite modificação com partições na rede e durante períodos de desconexão

Cada cliente mantém dois conjuntos relativamente a cada volume :

- VSG – conjunto de servidores que replicam o volume
- AVSG – sub-conjunto dos servidores VSG activos

Cada ficheiro tem associado um vector-versão (semelhante a um relógio vectorial), que identifica a sua versão

- No vector-versão existe uma entrada para cada servidor do VSG

REPLICAÇÃO NO SISTEMA CODA: LEITURA

Um cliente obtém uma cópia de um ficheiro a partir de um elemento do AVSG, verificando com todos qual o que tem a versão mais actual

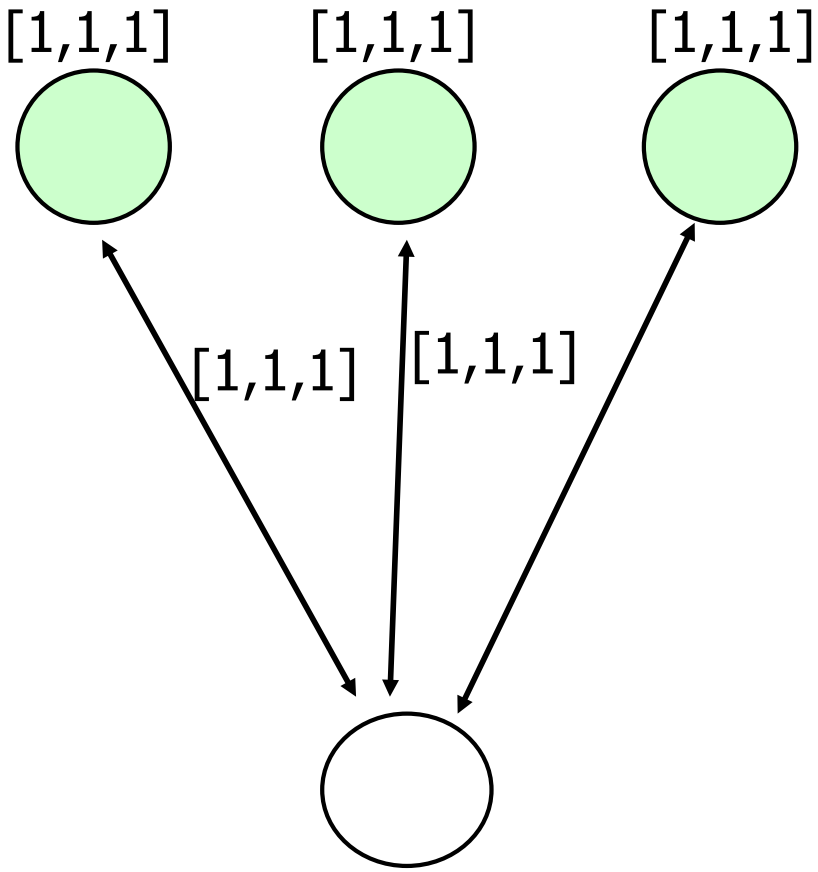

REPLICAÇÃO NO SISTEMA CODA: LEITURA

Um cliente obtém uma cópia de um ficheiro a partir de um elemento do AVSG, verificando com todos qual o que tem a versão mais actual

O cliente obtém a cópia do ficheiro de um dos servidores com a versão mais actual. Fica com uma "callback promise" nesse servidor (e só nesse).

Se existirem diferentes versões, os servidores são informados para se sincronizarem

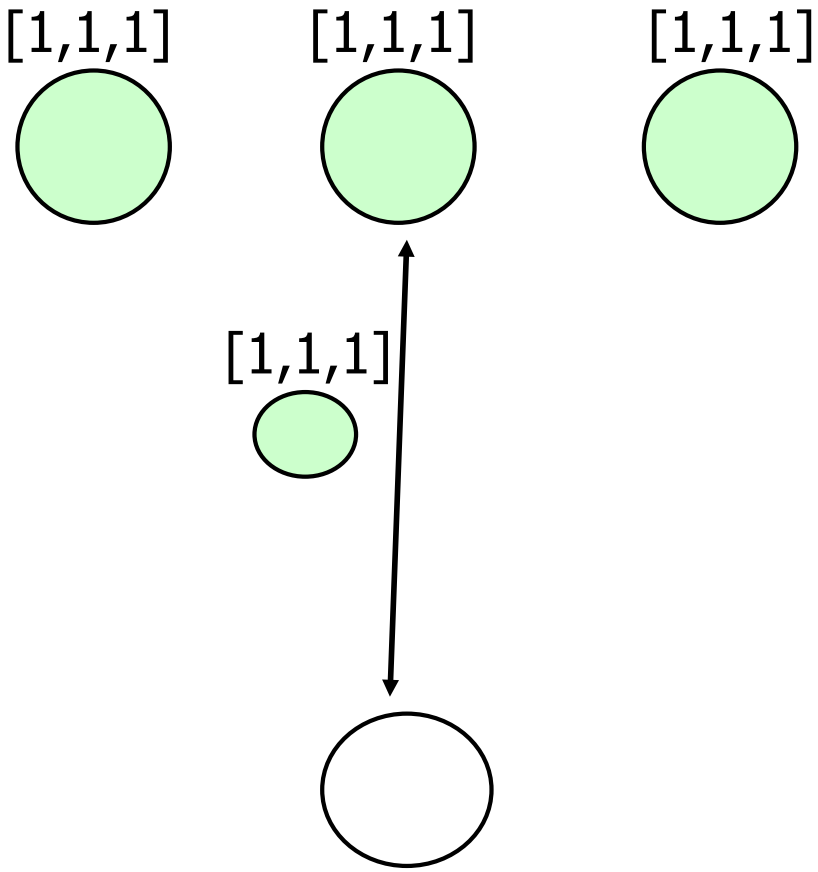

REPLICAÇÃO NO SISTEMA CODA: ESCRITA

Quando o ficheiro é fechado, o cliente escreve a nova versão em todos os servidores do AVSG

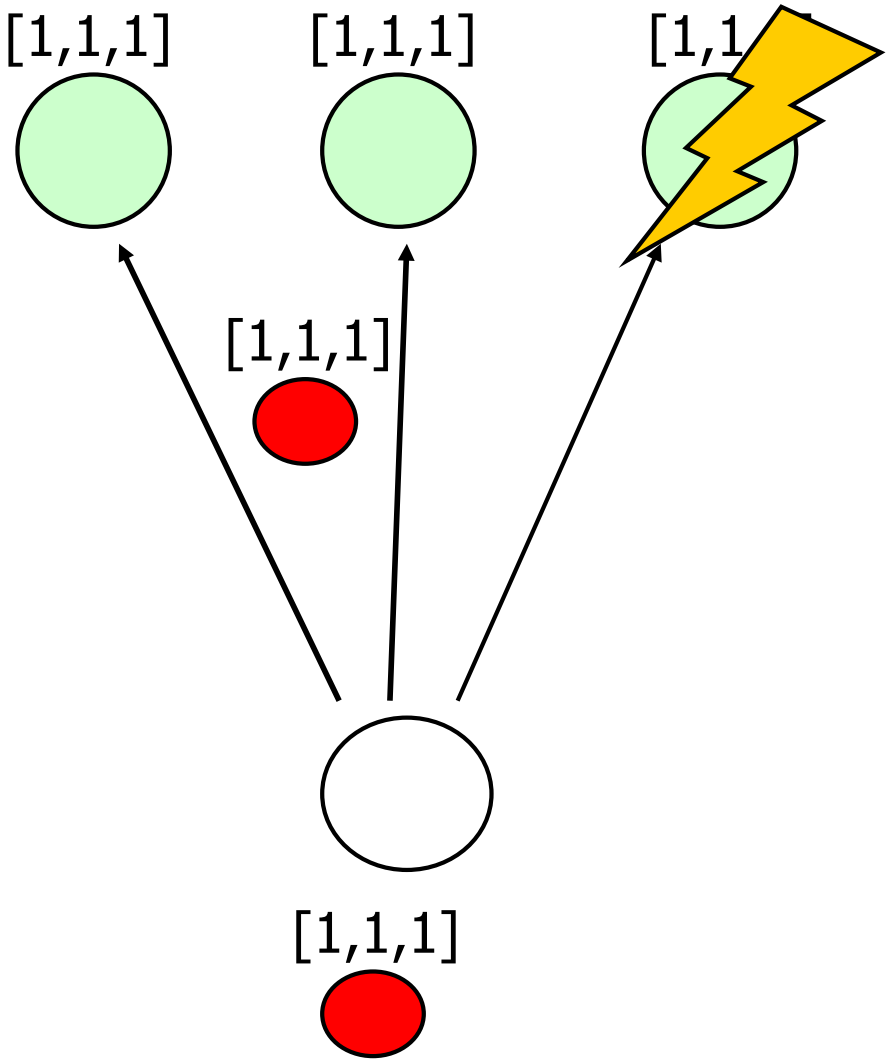

REPLICAÇÃO NO SISTEMA CODA: ESCRITA

Quando o ficheiro é fechado, o cliente escreve a nova versão em todos os servidores do AVSG

Os servidores actualizam o seu vector-versão e enviam-no ao cliente

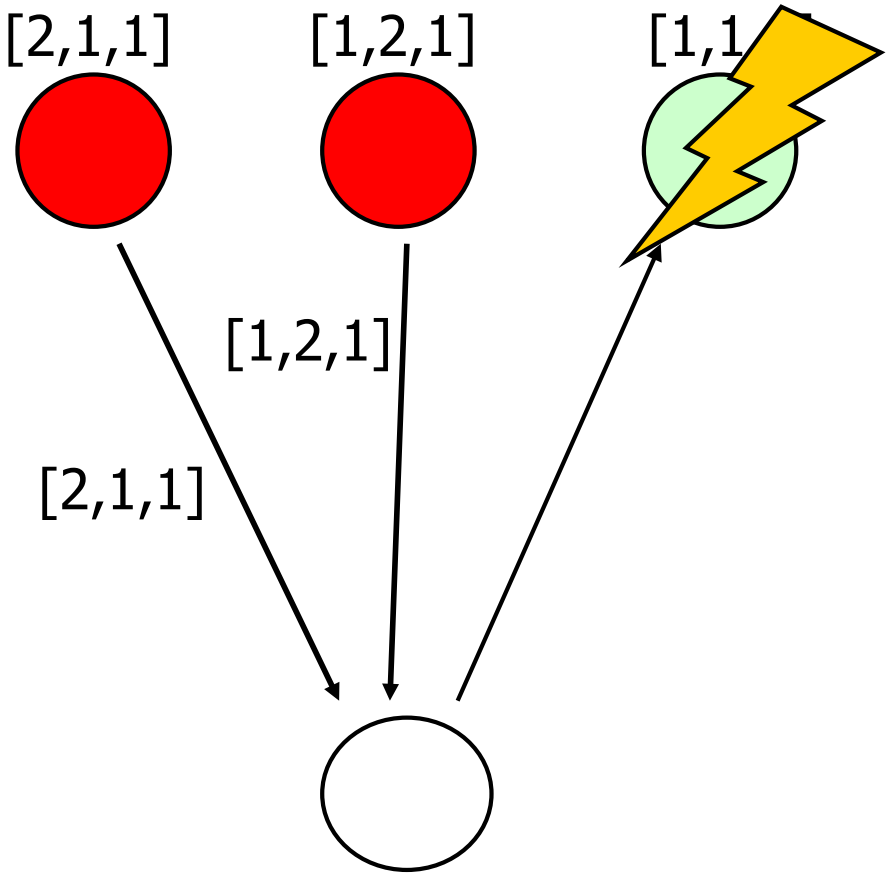

Replicação no sistema Coda: escrita

Quando o ficheiro é fechado, o cliente escreve a nova versão em todos os servidores do AVSG

Os servidores actualizam o seu vector-versão e enviam-no ao cliente

O cliente combina os vectores versão e envia-os aos servidores, que actualizam o ser vector-versão

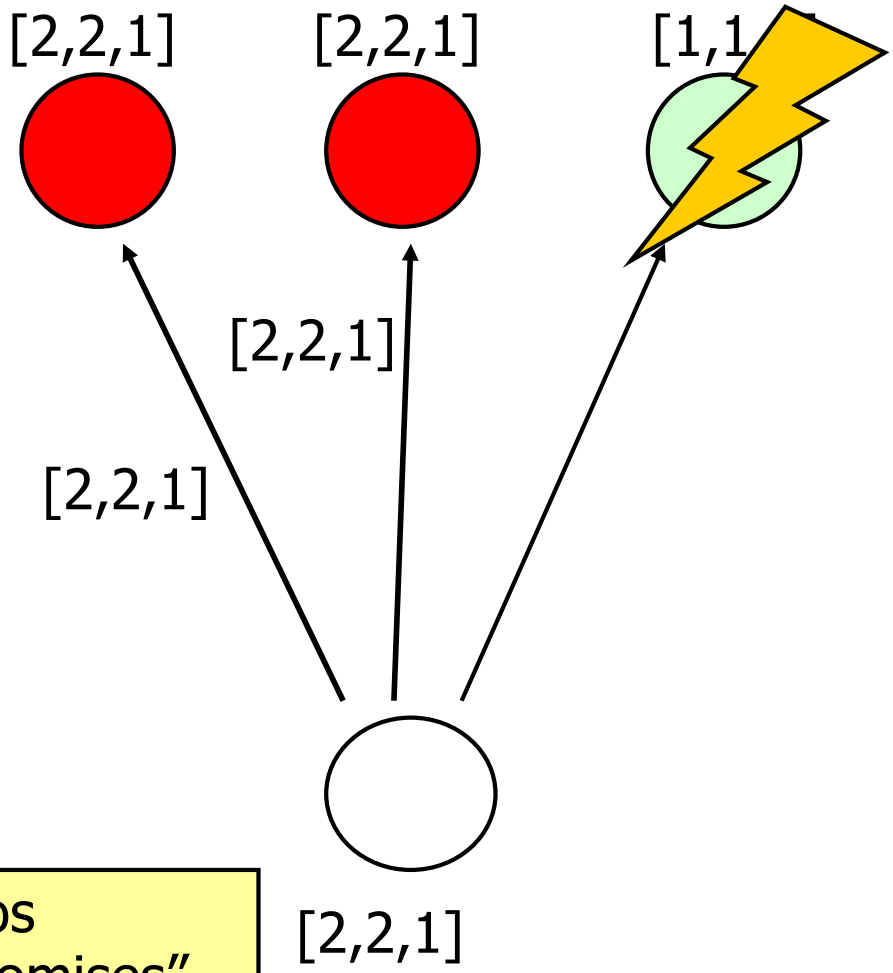

Os servidores notificam os clientes com "callback promises" das alterações nos ficheiros

DETECÇÃO DA INCONSISTÊNCIA: LEITURA

- Se o vector-versão dos vários servidores é diferente
- Dados dois vectores-versão, v1 e v2:
  - Se v2 > v1, v2 é uma versão mais actual
  - Se v2 || v1, existiram escritas concorrentes

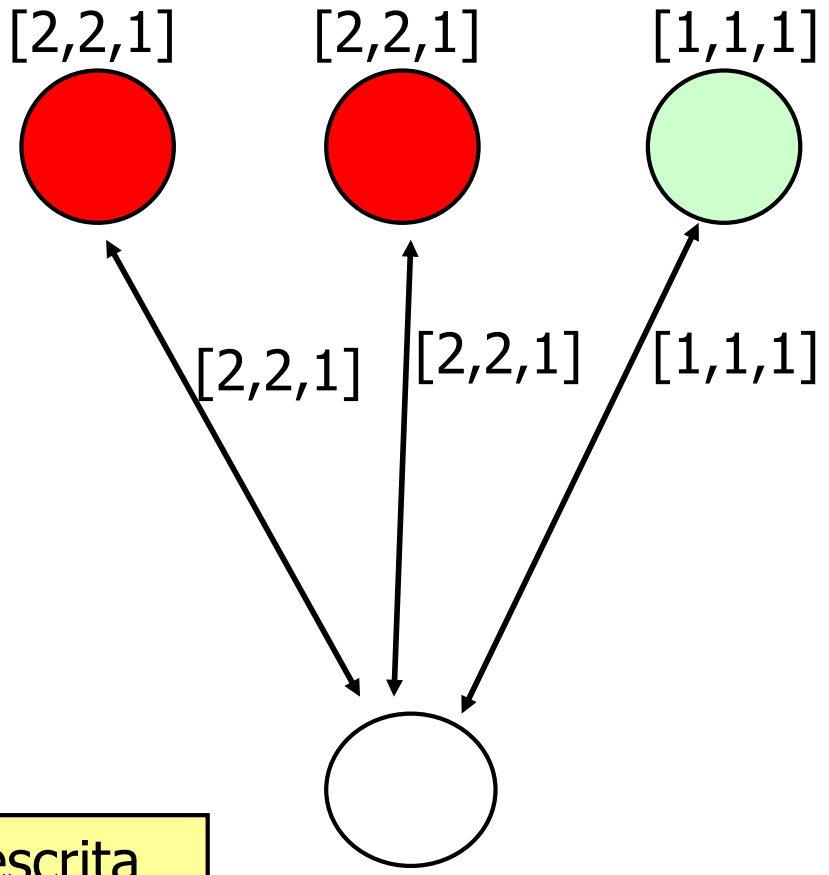

Como poderia surgir uma escrita concorrente?

DETECÇÃO DA INCONSISTÊNCIA: ESCRITA

Se quando se envia uma escrita, o vector-versão da versão modificado for inferior ao da réplica actual é porque existiu uma modificação concorrente (conflito)

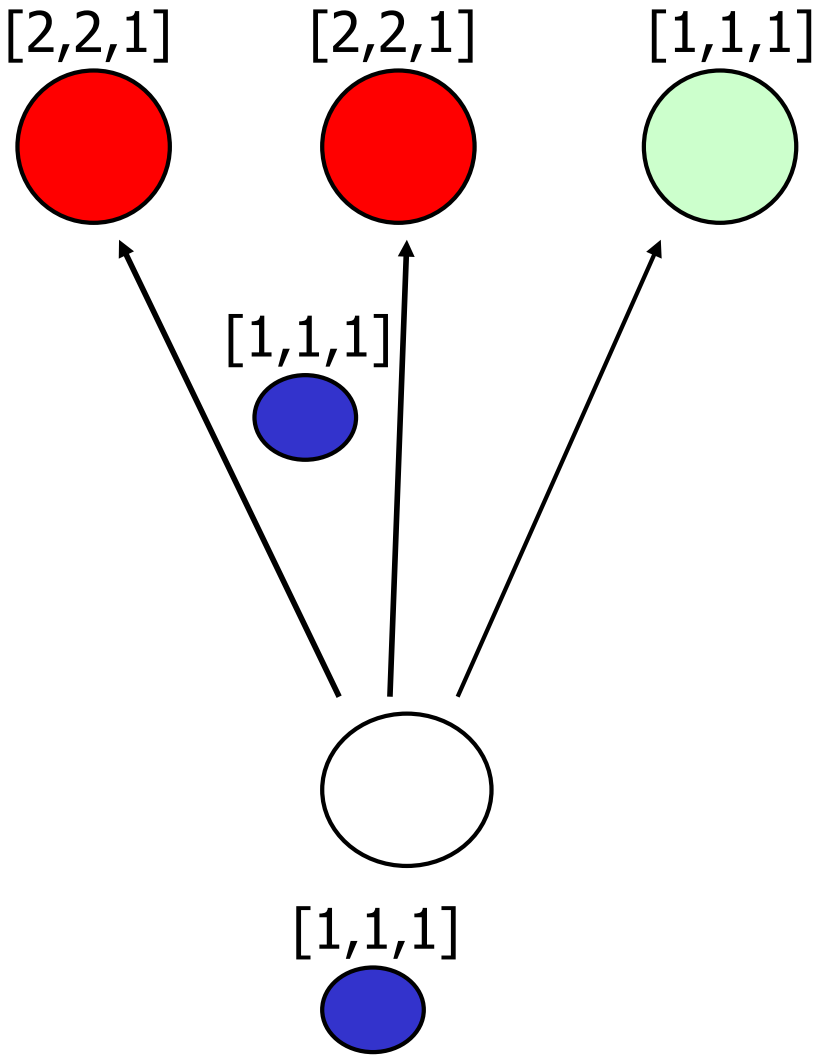

TRATAMENTO DE CONFLITOS

Resolução manual (inicial)

Quando existem modificações concorrentes a um ficheiro, os ficheiros são marcados como em conflito e o acesso é impedido até o conflito ser resolvido por um utilizador

Resolução automática

Podem-se definir programas que, em caso de conflito, são executados para gerar o estado final do ficheiro a partir das diferentes versões

Modificações concorrentes em directorias são resolvidas automaticamente (usando as operações)

SUMÁRIO

Introdução à replicação

- Primário-secundário
- Multi-master

Caching

- Sistemas de ficheiros distribuídos
- Caching NFS
- Caching CIFS
- Caching Callback Promise

MOTIVAÇÃO PARA UTILIZAÇÃO DE SISTEMAS DE FICHEIROS DISTRIBUÍDOS

Acesso a dados a partir de diferentes dispositivos

Partilha de dados por múltiplos utilizadores

Melhor qualidade de serviço do que a disponível localmente

- Melhor tolerância a falhas
- Maior disponibilidade

- Maior dimensão do espaço disponível
- Desempenho semelhante ou superior

SISTEMAS DE FICHEIROS DISTRIBUÍDOS

Um sistema de gestão de ficheiros distribuídos fornece um serviço de acesso a ficheiros semelhante ao de um sistema de ficheiros normal, mas estendido a um conjunto de máquinas ligadas em rede.

ALGUMAS QUESTÕES ENVOLVIDAS NA DISTRIBUIÇÃO

Integração: como integrar no sistema de ficheiro local?

Designação: como designar os ficheiros remotos?

- Externamente: ao nível das aplicações
- Internamente: no sistema

Modelo de acesso: dois extremos: acesso completamente remoto ou acesso completamente local (usando *cache*).

- Partilha de ficheiros: problemas relacionados com o controlo da concorrência e modelo de consistência fornecido

INTEGRAÇÃO NO SISTEMA LOCAL

Os ficheiros dum sistema distribuído de ficheiros devem ser acedidos localmente numa máquina

Problema: Qual a granularidade da partilha?

Solução típica: sub-árvore do sistema de ficheiros

Problema: Como providenciar acesso aos ficheiros?

Solução: integrar a sub-árvore na hierarquia local

- Windows: definindo uma nova *drive*
- Unix-like: através do mecanismo de *mount*

EXEMPLO: *MOUNT* REMOTO E DESIGNAÇÃO NO NFS

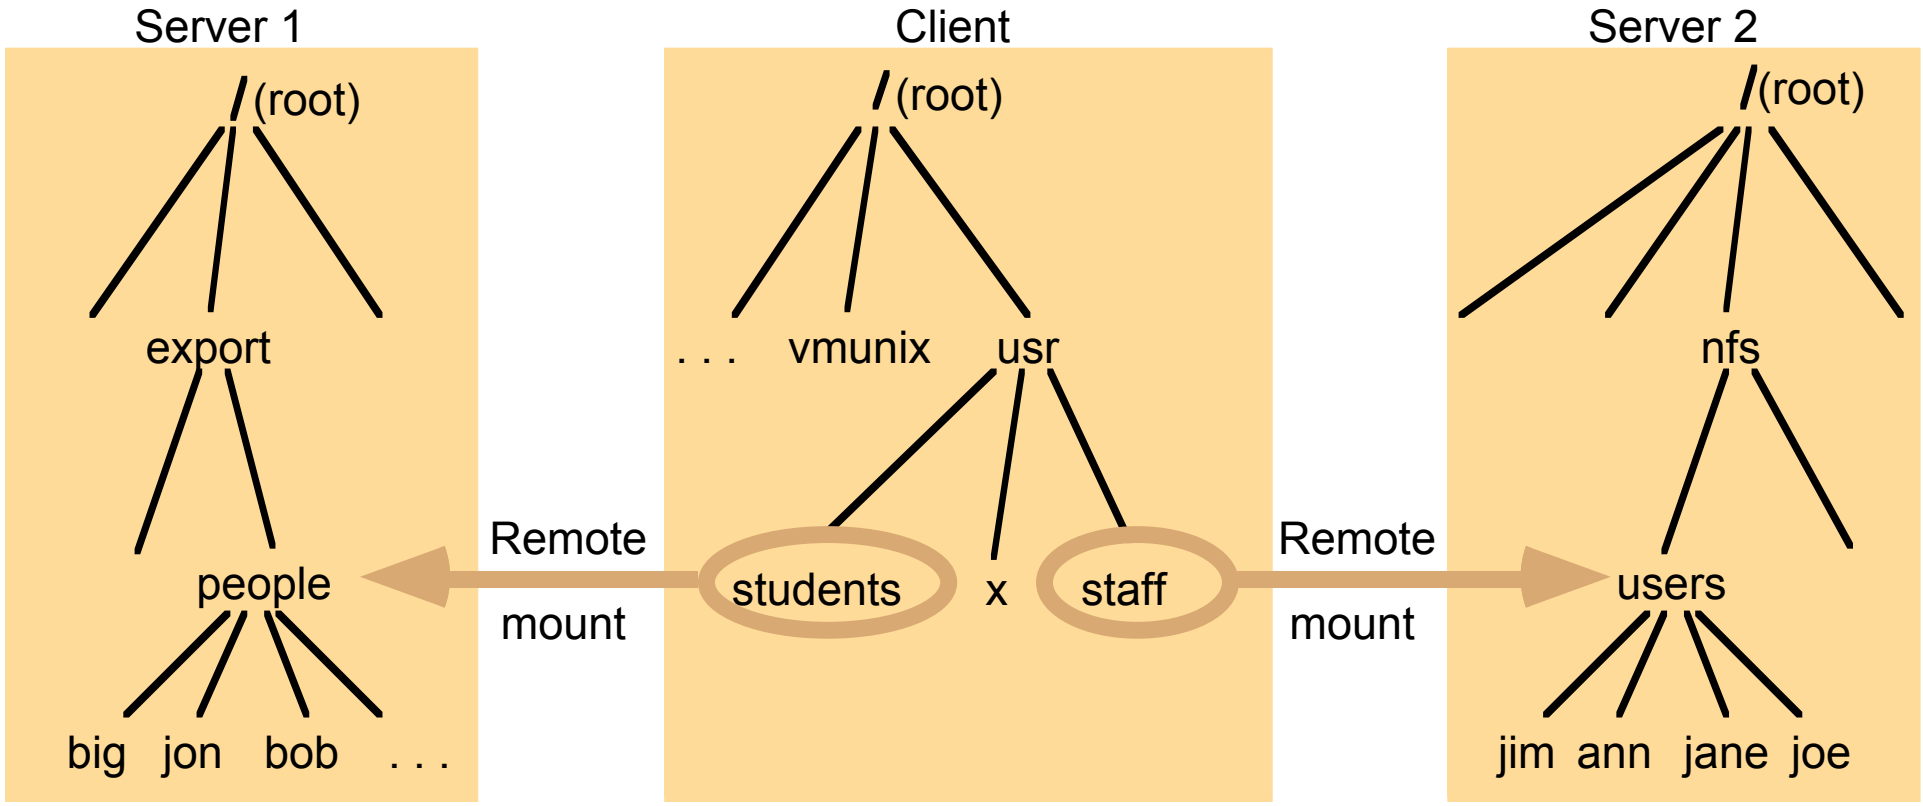

Cada servidor exporta um conjunto de directorias.

O cliente pode montar uma directoria remota (caso tenha permissões) numa directoria local (ex.: /usr/students no cliente monta a árvore /export/people no Server 1)

Integração no sistema local (cont.)

Como fazer a integração ?

Solução: os sistemas de operação normalmente suportam mecanismos para definir novos sistemas de ficheiros

- Unix-like: VFS
- Windows: IFS

ARQUITECTURA

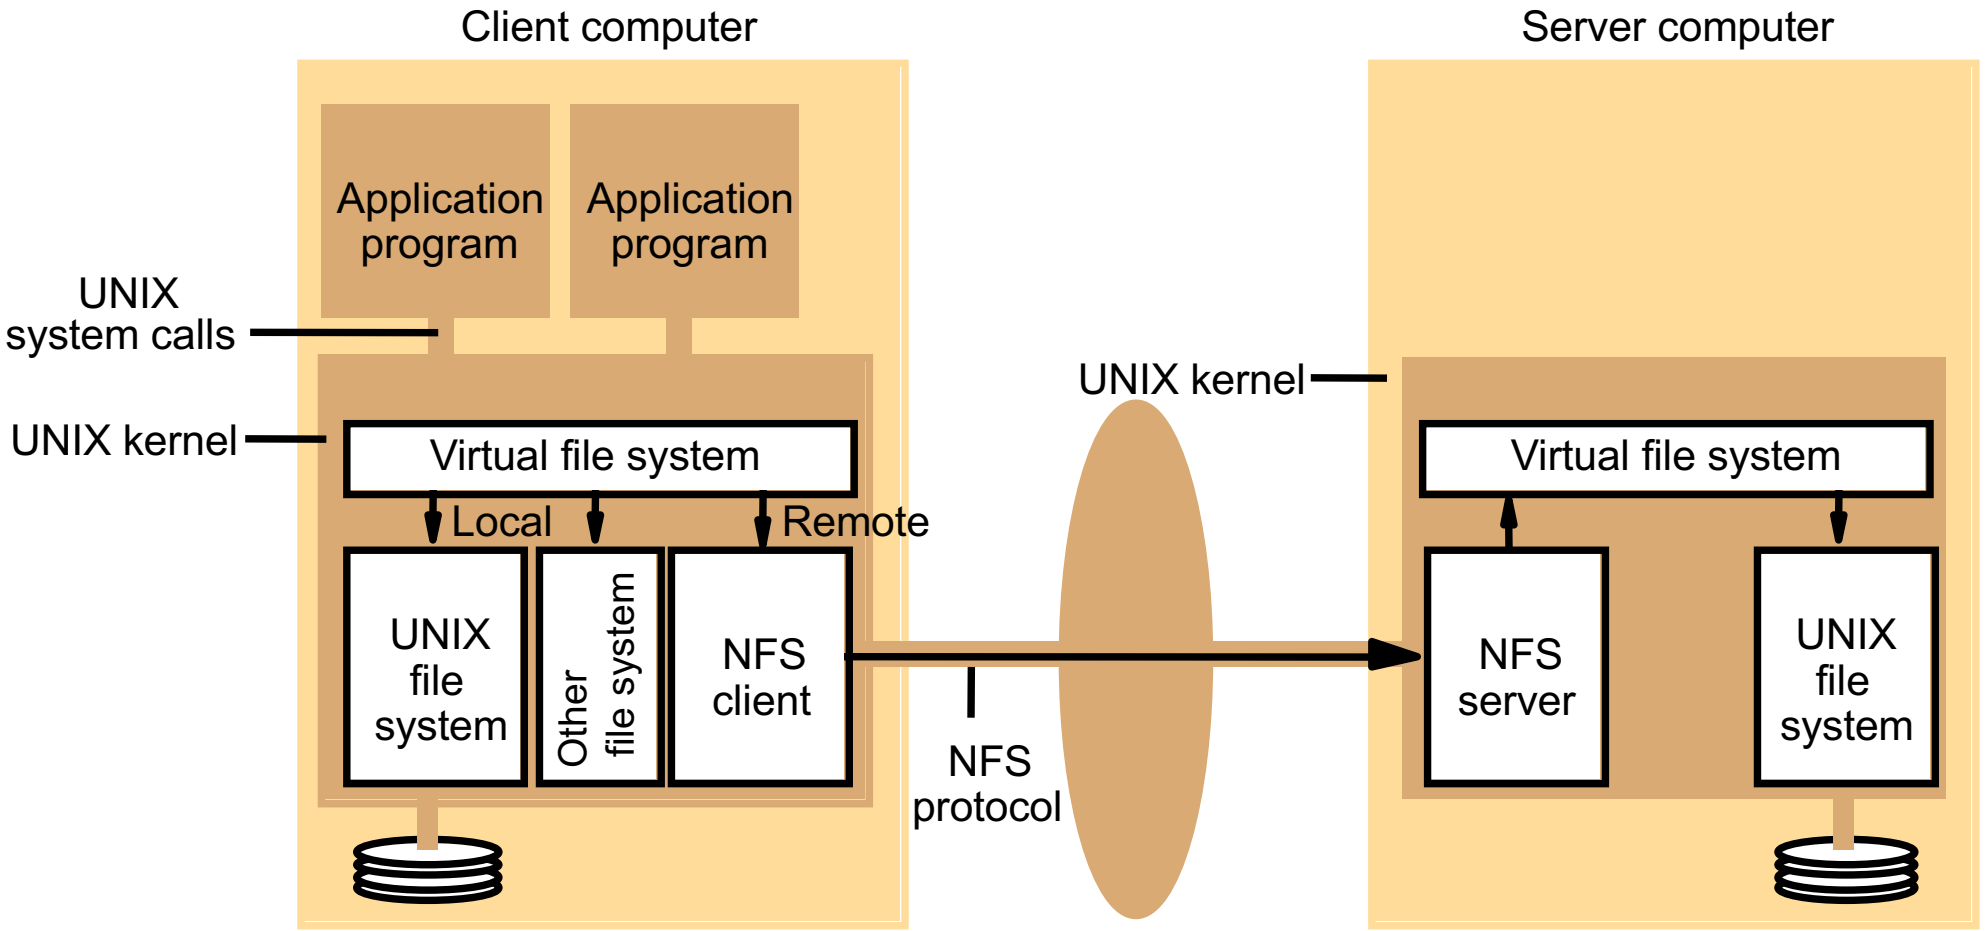

DESIGNAÇÃO DOS FICHEIROS

Tipos dos nomes dos ficheiros:

Nomes simbólicos

(exemplo: /x/y/p/q)

Nomes internos ou sistema

(exemplos: FileId, File-handles, UFIDs)

TIPOS DOS NOMES SIMBÓLICOS

Nomes globais. Podem ser passados entre máquinas mas implicam a introdução de uma super-raiz do *file system*.
Uma forma popular é: "//servername/ficheiro"

Exemplo: //asc.di.fct.unl.pt/home/foobar

Nomes contextuais. Todos os nomes são interpretados a partir de um *file system* local.

Fáceis de implementar mas mais difícil passar um nome entre duas máquinas

Ligações (mounts)

Um mesmo nome em duas máquinas pode referir o mesmo ou diferentes ficheiros
Nomes diferentes em duas máquinas podem referir o mesmo ficheiro

CARACTERÍSTICAS DOS NOMES INTERNOS

Para que os clientes e os servidores possam memorizar UFIDs (ou *file handles*) sem que os mesmos possam dar origem a ambiguidades, estes devem ser:

- únicos no tempo
- únicos no espaço

Que propriedades tem um NFS *file handle* ?
[file system number, file i-node, i-node generation number], endereço IP do servidor, porta do servidor

SUMÁRIO

Introdução à replicação

- Primário-secundário
- Multi-master

Caching

- Sistemas de ficheiros distribuídos
- Caching NFS
- Caching CIFS
- Caching Callback Promise

MODELOS DE *CACHING* : INFORMAÇÃO REPLICADA

Quase todos os sistemas de ficheiros distribuídos mantêm uma cache que pode ter diferentes características

Modelo *caching* por blocos. Guarda blocos de ficheiros (geralmente da dimensão do bloco dos discos e com dimensão idêntica à usada na transferência entre o cliente e o servidor).

Modelo *Caching* de Ficheiros "inteiros". Guarda ficheiros completos na cache – sempre que é necessário aceder a um ficheiro, este é transferido para a máquina do cliente. Nota: caching efectuado normalmente em disco.

Modelo Serviço Remoto ou sem Cache. Cada vez que é necessário aceder a um ficheiro, o cliente invoca o servidor.

Eficiência?

Depende da fracção de operações que podem ser servidas pelos valores guardados na cache.

MODELOS DE *CACHING* : INFORMAÇÃO REPLICADA

Quase todos os sistemas de ficheiros distribuídos mantém um cache que pode ter diferentes características

Modelo *caching* por blocos. Guarda blocos de ficheiros (geralmentes da dimensão do bloco dos discos e com dimensão idêntica à usada na transferência entre o cliente e o servidor).

Modelo *Caching* de Ficheiros "inteiros". Guarda ficheiros completos na cache – sempre que é necessário aceder a um ficheiro, este é transferido para a máquina do cliente. Nota: caching efectuado normalmente em disco.

Modelo Serviço Remoto ou sem Cache. Cada vez que é necessário aceder a um ficheiro, o cliente invoca o servidor.

Coerência?

Depende do modo como é verificada a validade da cache
Sem caching > caching blocos e caching fich. inteiros

SEMÂNTICA DO ACESSO NUM SISTEMA DE FICHEIROS DISTRIBUÍDOS

A semântica tradicional centralizada consiste em uma leitura ver sempre o resultado da última escrita (serialização dos acessos).

Num sistema distribuído, o problema complica-se devido à existência de caches em múltiplas máquinas.

A semântica dum esquema de gestão das caches depende do que se faz nas operações de leitura e escrita:

- Associado às escritas está a propagação das modificações para o servidor (e sua visualização por outros clientes).
- Associada às leituras está a verificação da coerência da cache em relação ao servidor.

SUMÁRIO

Introdução à replicação

- Primário-secundário
- Multi-master

Caching

- Sistemas de ficheiros distribuídos
- Caching NFS
- Caching CIFS
- Caching Callback Promise

CACHING EM SISTEMAS UNIX

Caching de ficheiros locais em servidores UNIX

Leituras servidas a partir da cache

Read-ahead - carrega para cache blocos antes que serão necessários caso se continue a ler sequencialmente

Delayed-write (30 seg. máx) – escritas são feitas na cache e apenas propagadas para disco após X segundos. Porquê?

Aproximação semelhante noutros sistemas.

NFS: GESTÃO DE CACHE SEM ESTADO NO SERVIDOR

Cliente NFS coloca na cache blocos obtidos remotamente

Problema: como garantir que se acede a versão atual? Porque difere da gestão de cache num servidor?

Necessário verificar se versão do servidor foi modificada

NFS: GESTÃO DE CACHE SEM ESTADO NO SERVIDOR (2)

Para cada bloco da cache, mantém-se a seguinte informação:

- Tc - última hora a que a entrada na cache foi validada (hora local)
- Tw-client - estampilha horária da última vez que o ficheiro foi escrito (hora do servidor), guardado no cliente

No momento T, considera-se válida uma entrada na cache sse: T-Tc< t (com t um parâmetro)

- Se t é grande, aumenta-se o risco de aceder a informação desatualizada
- Se t é pequeno, pode levar a interações com o servidor desnecessárias

Caso contrário, é necessário verificar se o ficheiro não foi alterado no servidor, i.e., se Tw-server = Tw-client

- Tw-server: data da última modificação no servidor
- Se Tw-server ≠ Tw-client todos os blocos do ficheiro são retirados da cache pois o ficheiro foi modificado.
- Caso contrário, atualiza-se o valor de Tc

Os blocos modificados por uma escrita no cliente são marcados como *dirty* e enviados assincronamente para o servidor ou logo que um *sync* ocorre no cliente.

NFS: GESTÃO DE CACHE SEM ESTADO NO SERVIDOR (3)

Para cada ficheiro, apenas existe um Tw-server

Qual as consequências para a gestão da cache?

Como se comporta esta aproximaçã
com um sistema de bases de dados

Otimização: os atributos do ficheiro são piggybacked sempre que possível com todas as respostas do servidor, o que permite atualizar Tc

GESTÃO DE CACHE SEM ESTADO NO SERVIDOR

Leituras. Para garantir a frescura da informação *cached*, os clientes de servidores *stateless* têm de testar a validade da mesma:

- teste antes de cada acesso - aumenta a coerência mas diminui a performance
- teste periódico - semântica sem garantias totais

Escrita. A propagação de escritas pode ser efectuada em vários momentos.

- Escrita "Write-through". A cada escrita no cliente corresponde uma (ou mais) escritas no servidor. Propriedades?
- Favorece a fiabilidade e a semelhança com a semântica tradicional tipo "sistema equivalente a uma só cópia" à custa do sacrifício do desempenho.
- Escrita "Delayed-Write". As escritas são inicialmente efectuadas na cache local e, posteriormente, enviadas para o servidor. Propriedades?
- Estes esquemas diminuem o tráfego de rede mas diminuem a fiabilidade e consistência. Quando o servidor é *stateless* e ignora os clientes, não é possível implementar a semântica "equivalência a uma só cópia".

SUMÁRIO

Introdução à replicação

- Primário-secundário
- Multi-master

Caching

- Sistemas de ficheiros distribuídos
- Caching NFS
- Caching CIFS
- Caching Callback Promise

GESTÃO DE CACHE NO SISTEMA CIFS: OPPORTUNISTIC LOCKS

Neste esquema, introduzido no sistema CIFS (sucessor do SMB), existem vários tipos de *locks*:

Opportunistic locks (oplocks) exclusivos que permitem ao cliente ter acesso exclusivo ao ficheiro e fazer *caching* arbitrário do mesmo. Um *oplock* pode ser retirado ao cliente pelo servidor.

Oplocks partilhados que permitem aos clientes ter acesso ao ficheiro em leitura e fazer *caching* arbitrário do mesmo. Um *oplock* pode ser retirado ao cliente pelo servidor.

Mandatory locks que permitem acessos exclusivos e *caching* e que não podem ser retirados pelo servidor

Os clientes fazem ou não *caching* dos ficheiros conforme o tipo de *lock* que têm. Se não têm nenhum podem sempre aceder ao ficheiro mas sem fazer *caching* do mesmo.

ILUSTRAÇÃO

Neste exemplo ilustra-se a utilização de *oplocks* para acesso ao ficheiro F1 por dois clientes A e B.

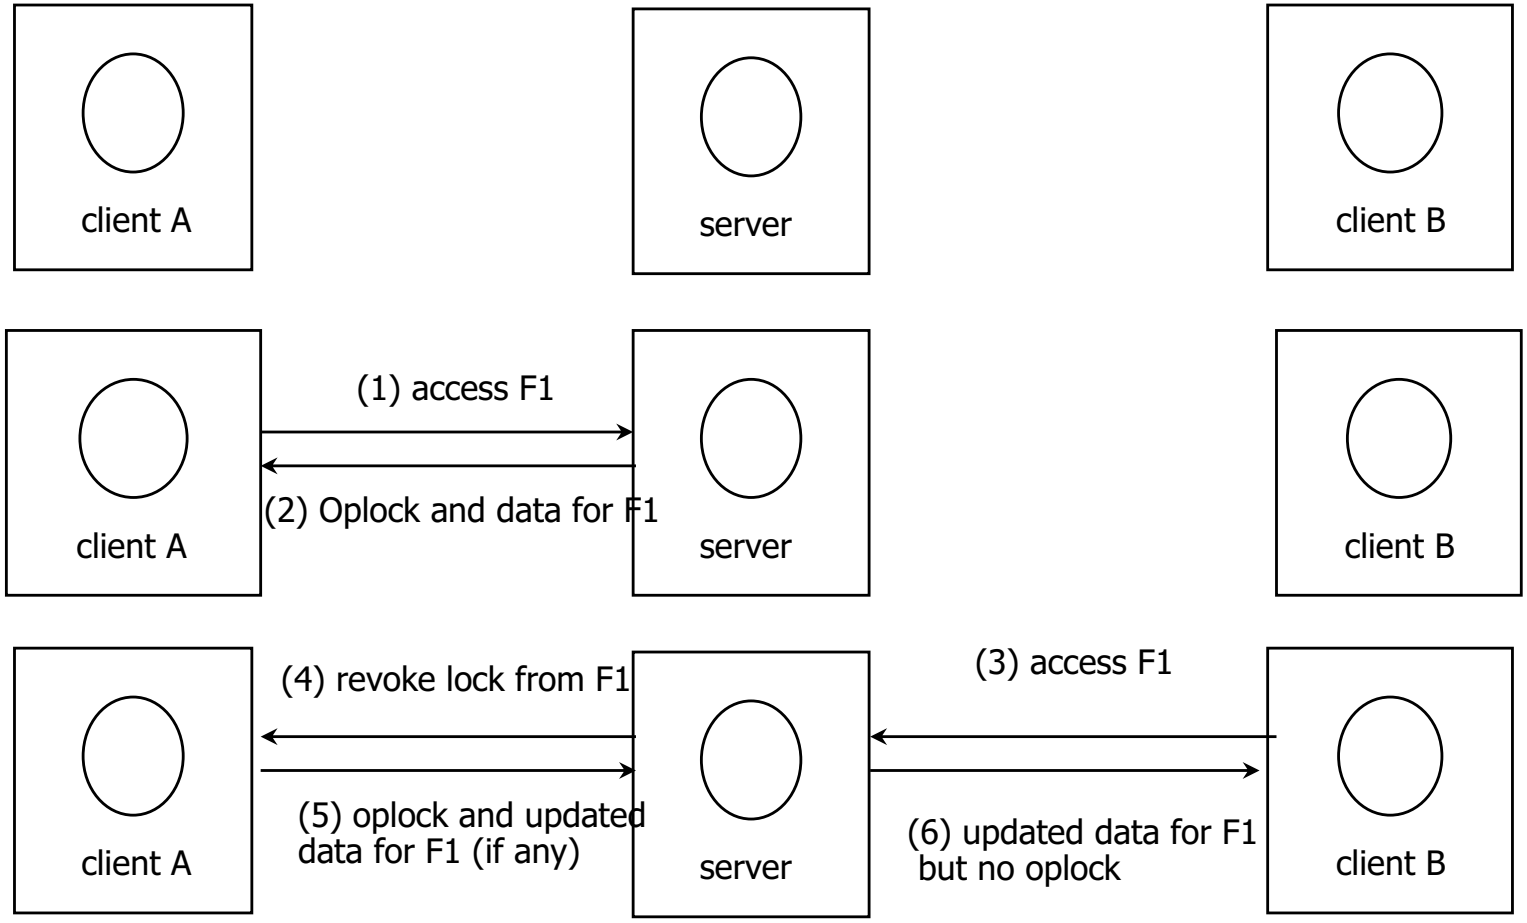

GESTÃO DOS OPLOCKS

1. O primeiro cliente obtém:
   1. Oplock exclusivo caso pretenda escrever o ficheiro
   2. Oplock partilhado caso pretenda apenas ler o ficheiro
2. Quando surgem novos clientes de leitura:
   1. Existe um cliente com oplock exclusivo
      Cliente perde lock e deve enviar as modifcações efctuadas
      Ambos os clientes ficam sem oplocks (e portanto sem poder fazer cache)
   2. Existe um cliente com oplock partilhado
      Ambos os clientes ficam com oplock partilhado
3. Quando surge um novo cliente de escrita
   1. Existe um cliente com oplock exclusivo
      Cliente perde lock e deve enviar as modifcações efctuadas
      Ambos os clientes ficam sem oplocks (e portanto sem poder fazer cache)
   2. Existe um (ou mais) clientes com oplock partilhado
      Clientes perdem o oplock
      Todos os clientes ficam sem oplocks (e portanto sem poder fazer cache)

GESTÃO DOS OPLOCKS (CONT.)

Quando um ficheiro é aberto para leitura/escrita tenta-se prolongar concorrência, assumindo que o cliente é de leitura até à primeira escrita – nesse momento, efectua-se o procedimento de adição de um novo cliente.

Se um *oplock* é quebrado, deixa de haver *caching* do ficheiro.

SUMÁRIO

Introdução à replicação

- Primário-secundário
- Multi-master

Caching

- Sistemas de ficheiros distribuídos
- Caching NFS
- Caching CIFS
- Caching Callback Promise

SOLUÇÃO "CALLBACK PROMISE"

Introduzido no AFS e usado também no Coda.

Neste sistema os clientes fazem *caching* de ficheiros inteiros, sendo o ficheiro a unidade de transferência entre o cliente e o servidor. Quando um cliente obtém um cópia do ficheiro, o servidor *promete* informar o cliente de qualquer modificação efectuada ao ficheiro – a esta promessa chama-se uma "*callback promise*".

Desde que o cliente tenha uma "*callback promise*" válida, assume que a sua cópia do ficheiro está actualizada. Neste caso, um ficheiro é aberto no cliente sem nenhuma comunicação com o servidor.

Quando um programa no cliente fecha um ficheiro que acabou de modificar, o cliente AFS/Coda envia as modificações para o servidor. Nessa altura, o servidor notifica todos os clientes com "callback promises" válidas.

Um cliente, ao receber a notificação, anula a sua "callback promise" e, se o ficheiro estiver aberto, obtém uma nova cópia do ficheiro.

Solução "Callback promise"

Com este esquema todos as escritas feitas no cliente são temporárias até ao fecho do ficheiro. Desta forma, a única semântica que pode ser implementada é uma semântica dita "semântica de sessão". Com esta semântica, uma leitura lê o resultado das escritas feitas depois do último *close* do ficheiro.

Quando um cliente é inicializado, ele tem de revalidar as "*calback promises*" que tem. Porquê?

Pode ter ter perdido os "calbacks" feitas pelo servidor enquanto o cliente esteve desligado.

PARA SABER MAIS

G. Coulouris, J. Dollimore and T. Kindberg, Blair Gordon, Distributed Systems - Concepts and Design, Addison-Wesley, 5th Edition, 2011

- Capítulo 12.1-12.4 e 18.3-18.4
- CIFS/SMF: slides