

# Sistemas Distribuídos

## Aula 20

### **Roteiro**

- Tipos de falhas
- Falhas Bizantinas
- Grupos redundantes
- Acordos bizantinos
- Propriedades
- Algoritmos de Consenso

# Tipos de Falhas

- Sistemas falham por diferentes razões que levam a condições diferentes
- Classificação dos tipos de falha
  - permite oferecer robustez em diferentes casos

Type of failure	Description
Crash failure	A server halts, but is working correctly until it halts
Omission failure <i>Receive omission</i> <i>Send omission</i>	A server fails to respond to incoming requests A server fails to receive incoming messages A server fails to send messages
Timing failure	A server's response lies outside the specified time interval
Response failure <i>Value failure</i> <i>State transition failure</i>	A server's response is incorrect The value of the response is wrong The server deviates from the correct flow of control
Arbitrary failure	A server may produce arbitrary responses at arbitrary times

Mais fácil  
de lidar!

Mais difícil  
de lidar!

# Falhas Bizantinas

- Outro nome para “*Arbitrary Failures*”
  - nome vem de histórias de traição e corrupção no Império Bizantino (termo cunhado por Lamport)
- Modelo mais geral de falha, que também inclui comportamento malicioso
  - “tudo pode acontecer”
- Respostas podem ser incorretas, inclusive de forma proposital para induzir falhas
  - adversário controla algumas partes do sistema
  - deseja induzir o sistema a “falhar”
  - falhar = não operar da forma esperada

# Grupos Redundantes



- Como lidar com falhas em processos (ou subsistemas)?

## Redundância!


- Ideia: grupo de processos redundantes que executam uma função e se comunicam
  - processos (ou subsistemas) distintos, que podem responder um pelo outro
  - ex. grupo de discos, grupo de SGBDs, *TMR*, etc
- Outros processos interagem com o grupo (sem saber que é um grupo)
  - grupo é transparente para outros processos

# Exemplo: RAID

- Redundant Array of Inexpensive Disks (RAID)
  - grupo de discos que se apresentam (para SO) como um único disco
  - controladora RAID de disco esconde o grupo
- Melhorar desempenho
  - via *stripping* dos blocos e acesso simultâneo
- Aumentar confiabilidade
  - via paridade/redundância dos blocos
- Diferentes configurações
  - com vantagens e desvantagens entre desempenho e confiabilidade


# Configurações RAID

RAID 0




- RAID 0: dois discos para melhorar desempenho (leitura e escrita), não possui redundância. Capacidade de 2 discos.

RAID 1



- RAID 1: dois discos (um é cópia do outro), melhora desempenho de leitura, oferece redundância. Capacidade de 1 disco

RAID 4




- RAID 4: 4 discos (bloco de paridade), melhora desempenho de leitura e escrita, oferece redundância. Capacidade de 3 discos.

# Organização de Grupos



- Como organizar grupos de processos redundantes?



- **Com hierarquia:** coordenador lidera e gerencia o grupo, faz interface com o exterior
- **Sem hierarquia:** papéis são simétricos, gerência mais complicada, não possui ponto único de falha
- RAID: hierárquico (controladora é o coordenador)

# Falha em Grupos Redundantes

- Quantos processos podem falhar e grupo continuar operacional?

**Depende do tipo de falha!**

- e do tipo de grupo
- Assumir grupos simétricos com  $k$  processos redundantes, sem hierarquia
- *Crash failure*: basta ter 1 processo operacional
  - sistema tolera até  $k - 1$  falhas no grupo
- *Value failure*: processos em falha geram valores errados. Usar valor da maioria como resposta
  - sistema tolera até  $k/2 - 1$  falhas no grupo

# Consenso / Acordo

- Processos em sistemas distribuídos precisam de consenso (acordo)
  - ex. definição do coordenador do grupo, definição de uma transação (commit/abort), etc
- Problema relativamente fácil, ignorando falhas
  - ou considerando alguns tipos de falha
  - ex. 2PC tolera alguns tipos de *Crash Failures*, *Omission Failures* e *Timing Failures*
- Considere falhas bizantinas (processos induzindo falhas de forma arbitrária)
- Processos que não estão em falha conseguem chegar a um consenso?

# Acordos com Falhas Bizantinas

- **Problema:** processos conseguem chegar a um consenso em tempo finito na presença falhas bizantinas?
  - processos operacionais não sabem quais estão em falha bizantina (obviamente)
  - inicialmente estudado por Lamport et al. Em 82
- Características de sistemas distribuídos
  - 1) Tempo nos processos: síncrono (todos processos “andam” juntos), ou assíncrono
  - 2) Ordenação das mensagens: FIFO (mensagens entregues em ordem), ou não
  - 3) Tipo de transmissão de rede: multicast (um para todos), ou unicast (um para um)
  - 4) Atraso das mensagens: limitado (mensagens chegam dentro de um tempo máximo), ou não

# Acordos com Falhas Bizantinas

- Tabela indica casos onde é possível chegar a um consenso (com algum algoritmo, a saber)
  - com multicast e FIFO, é sempre possível
  - com síncrono e atraso limitado, é sempre possível
  - impossível em metade dos casos!

		Message ordering				Communication delay
		Unordered		Ordered		
Process behavior	Synchronous	X	X	X	X	Bounded
	Asynchronous			X	X	Unbounded
					X	Bounded
					X	Unbounded
		Unicast	Multicast	Unicast	Multicast	
		Message transmission				


→ Não é possível chegar a um consenso!

# Protocolo de Acordo Bizantino

- Assumir processos síncronos, comunicação unicast, com FIFO e atraso limitado
- **Problema:**  $N$  processos, um deles envia um valor  $v$  aos outros
  - todos os operacionais devem concordar no valor  $v$ , ou concordar que desconhecem o valor
  - processo que envia  $v$  pode estar em falha bizantina
- Algoritmo proposto por Lamport et al. em 82
  - 1) Cada processo envia a todo os outros o valor que recebeu
  - 2) Ao receber de todos, verifica se há uma maioria (este é o valor de consenso) ou que não consenso

# Exemplo

- $N=4$ ,  $m=1$  - Caso L3 é bizantino




- Funciona se L3 e L1 são bizantinos? Não!

- C envia  $v$  a todos,
- L1, L2 envia  $v$  para todos os outros
- L3 envia  $x$  para todos os outros
- L2 (L1) recebe  $v$  de C e L1 (L2) e  $x$  de L3, logo assume que  $v$  é o consenso (OK)

# Exemplo

- $N=4$ ,  $m=1$  - Caso C é bizantino



- Funciona se C enviar  $x$ ,  $x$ ,  $y$  ? Sim, pois consenso é  $x$  (e todos concordam)

- C envia valores diferentes
- L1, L2, L3 enviam respectivos valores
- Nenhum valor tem maioria em nenhum processo, não há consenso (OK)

# Algoritmo Geral

- Algoritmo anterior funciona para  $m=1$  (um processo em falha bizantina dentre 4 processos)
  - um processo inicial envia  $v$  e “sai do jogo”
- Para  $m>1$  podemos usar um algoritmo recursivo
- Recursivo no número de processos em falha bizantina
  - Ideia: eliminar um processo bizantino por rodada
  - usa regra majoritária em cada rodada
- Algoritmo mais elaborado (fora de escopo)
  - disponível em livro-texto mais avançado

# Propriedades de Acordo Bizantino

- Quando acordo pode ser obtido?
  - assumir unicast, FIFO, atraso limitado
- Se  $k$  estão em falha bizantina, precisamos de  $2k+1$  operacional
  - de  $3k+1$  processos no máximo  $k$  podem estar em falha bizantina
  - resultado fundamental, conhecido como regra do 2/3
  - maior do que 1/2 necessário para maioria simples (o caso de *value failure*)
- Não existe algoritmo que consiga chegar a um acordo caso contrário

# Algoritmo de Consenso

- Chegar a consenso/acordo (ex. valor de uma variável) em um sistema distribuído mediante falhas
- Propriedades
- **Término:** eventualmente todo processo operacional termina o algoritmo
- **Integridade:** se todos os processos operacionais propõem valor  $v$ , todos operacionais decidem por  $v$
- **Acordo:** todos processos operacionais chegam ao mesmo valor
- Paxos: conjunto de algoritmos para problema de consenso (para diferentes condições)
  - muitas implementações, base para outros sistemas

# Algoritmo de Consenso

- Problema antigo, difícil e importante na Computação
  - ainda estudado, na teoria e na prática
- Na moda por conta de *blockchains*
  - sistema distribuído precisa de consenso na operação das transações (ex. compra/venda no bitcoin)
  - evitam o problema do “double spending”
  - baseados em “proof-of-work” (bitcoin)

**Assunto para ser explorado!**