Sistemas Distribuídos
Aula 15

Roteiro

- Limitação de Lamport
- Relógio de vetores
- Propriedades
- Garantindo ordenação total
- *Totally Ordered Multicast*

Relógio de Lamport

- Algoritmo de relógio lógico distribuído para inferir relação entre eventos
  - se $e \rightarrow e'$, então $L(e) < L(e')$
  - se $L(e) = L(e')$, então $e \,||\, e'$

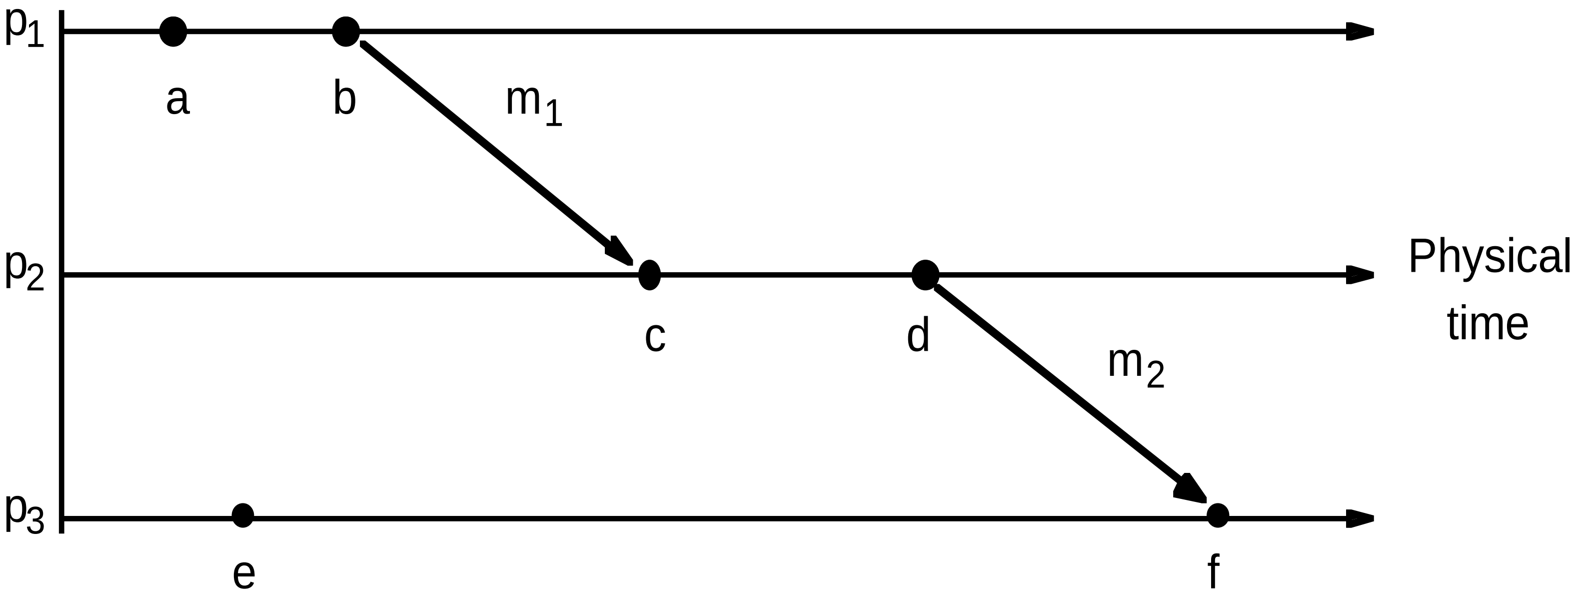

- Mensagens e eventos definidos pelo sistema distribuído

Limitação de Lamport

- Não podemos inferir ordem dos eventos a partir dos valores dos relógios
  - $L(e) < L(e')$ não implica $e \rightarrow e'$
- Como garantir ordem parcial a partir dos valores de relógio?
  - $L(e) < L(e')$ implica $e \rightarrow e'$
- **Ideia**: adicionar informação no relógio lógico utilizado para rotular eventos
  - usar um vetor, ao invés de um número

Relógio de Vetor

- Cada processo mantém um vetor
- Cada componente do vetor associado a um processo
  - dimensão do vetor é o número de processos, *n*
- Cada evento local rotulado com vetor local
- Evento *e* no processo *j*, V(*e*) = $[c_1, c_2, c_3, \ldots, c_n]$
  - $[c_1, c_2, c_3, \ldots, c_n]$: vetor do processo *j*
  - c_i = valor do relógio no processo *i* que o processo *j* conhece (não necessariamente é o valor atual do relógio em *i*)
- Inicialmente, todos processos com vetor em 0

Algoritmo do Relógio de Vetor

- Para cada evento local em *i*, incrementa próprio c_i
  - receber mensagem é evento
- Para cada mensagem, transmite vetor atual
- Ao receber mensagem com vetor $[d_1, d_2, ..., d_n]$, processo *i* faz
  - ajusta vetor para $c_k = \max(c_k, d_k)$ para todo *k*
  - incrementa c_i

Exemplo de Relógio de Vetor

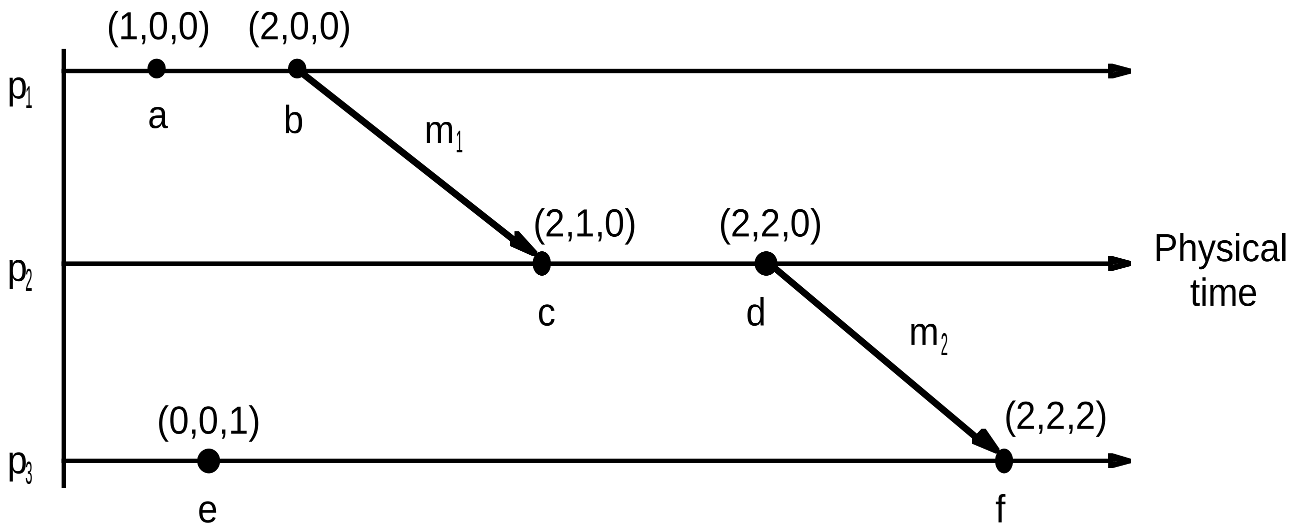

- V(a) = (1,0,0), V(e) = (0,0,1), V(b) = (2,0,0)
- m_1 contém (2,0,0)
- V(c) = max{ (0,0,0) , (2,0,0)} + (0,1,0) = (2,1,0)
- m_2 contém (2,2,0)
- V(f) = max{ (0,0,1) , (2,2,0)} + (0,0,1) = (2,2,2)

Comparando Vetores

- Cada evento está associado a um vetor
  - valor de relógio do evento
- Comparação componente a componente
  - Dizemos que V(*e*) < V(*e*') se

    (i) V(*e*)[k] <= V(*e*')[k] para todo k

    (ii) existe z tal que V(*e*)[z] < V(*e*')[z] (ao menos uma componente estritamente menor)
- Agora temos a propriedade
  - se V(e) < V(e') então e → e'
  - podemos usar o valor do tempo lógico do evento para resgatar a relação de “ocorreu antes”

Comparando Valores

- Definição de igualdade entre relógios
  - Dizemos que V(*e*) = V(*e*') se

    (i) não for o caso de V(*e*) < V(*e*')

    (ii) nao for o caso de V(*e*') < V(*e*)
- Concorrência
  - se V(*e*) = V(*e*') então *e* || *e*'
  - podemos usar o valor de tempo lógico do evento para resgatar a relação de concorrência

Exemplo de Relógio de Vetor

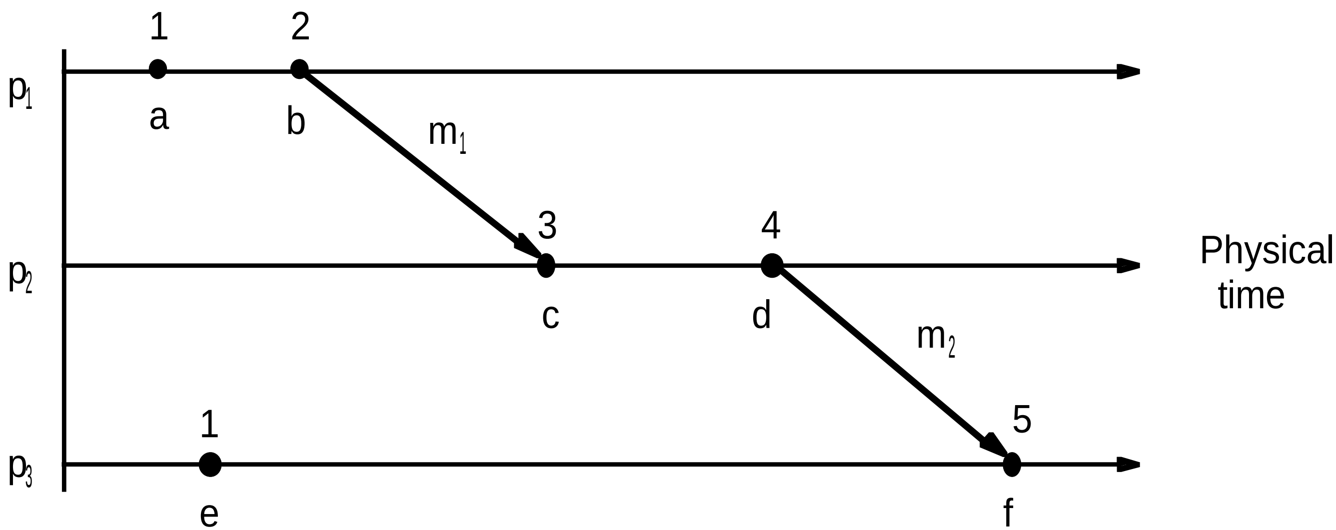

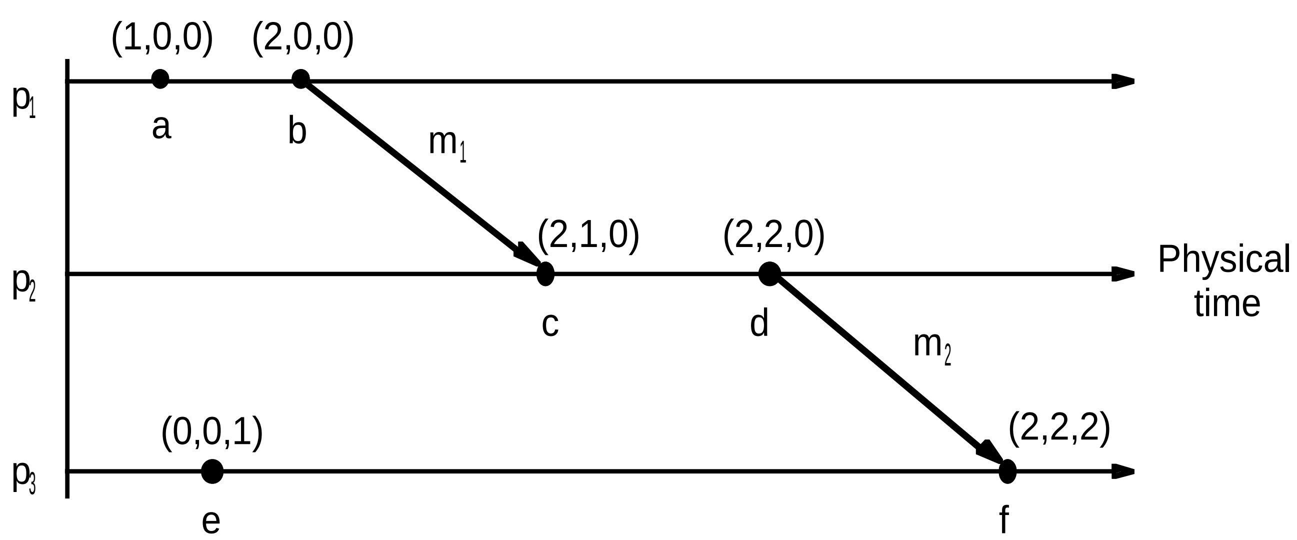

- Relógio de Lamport: L(*e*) < L(*c*) mas não temos *e* → *c*
- Relógio de Vetor V(*e*) = V(*c*) então *e* || *c*

Outras Propriedades

- Seja RT(x) o valor de tempo real da ocorrência do evento x (ex. UTC)
  - se V(a) < V(b) então RT(a) < RT(b)
- Seja L(x) o valor do relógio de Lamport de x
  - se V(a) < V(b) então L(a) < L(b)
  - pois vetor recupera relação de ordem
- Mas oferece apenas ordenação parcial
  - não oferece ordenação total dos eventos (ainda temos eventos concorrentes)
  - mas faz o melhor possível, resgata a relação de ocorreu antes e concorrência

Sincronização de Relógios

- Relógios em sistemas diferentes serão sempre diferentes
  - até mesmo em relógios atômicos
- Relógios não sincronizados em sistemas distribuídos podem levar a comportamento errático
- Duas abordagens de solução
  - sincronização do relógio
  - consistência na ordem dos eventos (ordenação total dos eventos)
- Na prática, ambos são usados

BD Distribuído e Replicado

- Conta com saldo inicial de $1000
- Dois usuários fazem transações

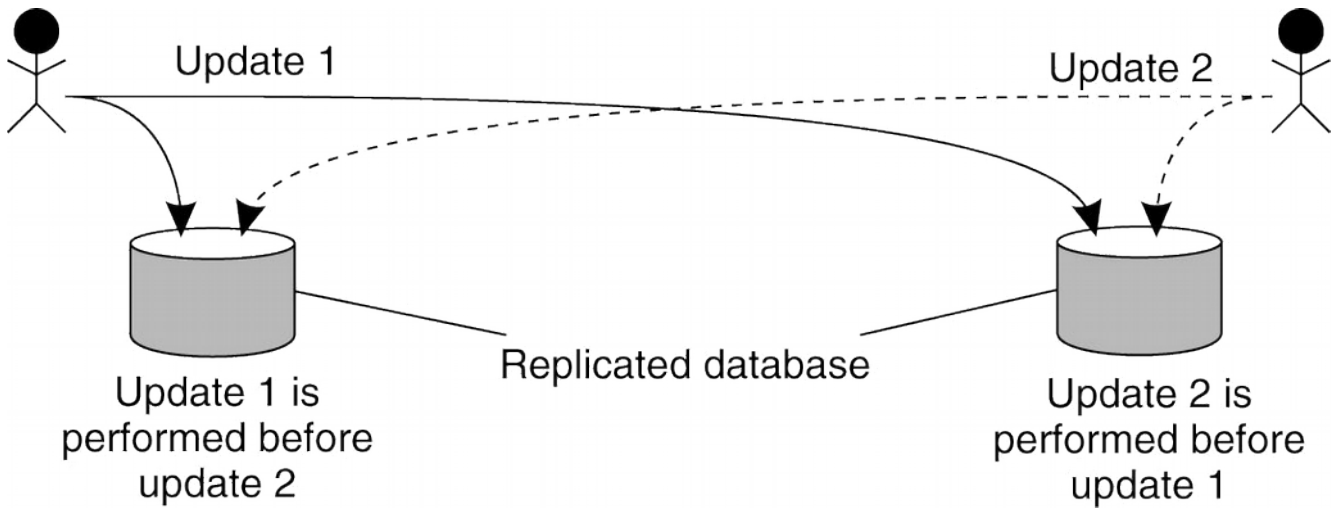

- Usuário 1: aumenta saldo em $100
- Usuário 2: aumenta saldo em 1%
- Saldo final da conta?
  - se u1 → u2 : $1111
  - se u2 → u1 : $1110
- Como obter consistência nos dois bancos?
  - valor final não importa muito, consistência sim

Eventos e Tempos

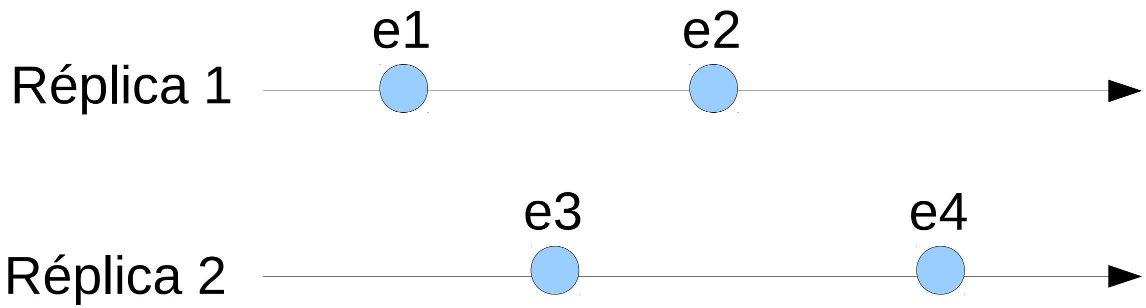

- e1: R1 recebe update u1
- e2: R1 recebe update u2
- e3: R2 recebe update u2
- e4: R2 recebe update u1

- L(e1) < L(e2), L(e3) < L(e4)
  - mas L(e1) || L(e3), L(e2) || L (e4)
- Não temos relação entre eventos nas diferentes réplicas
- Como relacionar eventos (transações) das diferentes réplicas?

Réplicas enviam mensagens!

Trocando Mensagens

- Novo sistema distribuído
  - usuário envia transação para uma réplica
  - réplica envia transação para a outra

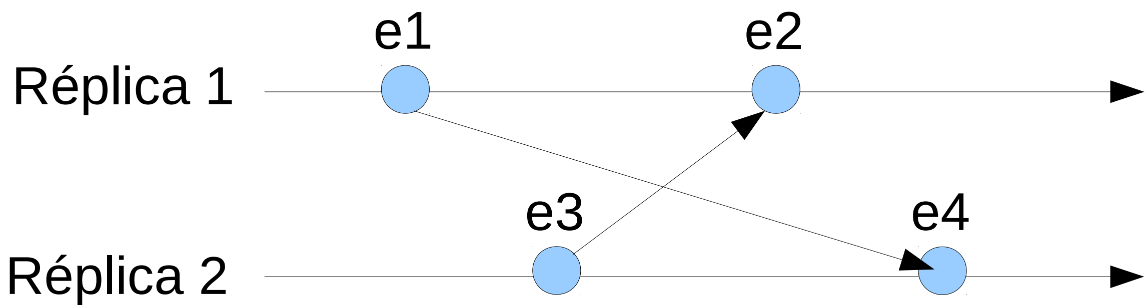

- e1: R1 recebe update u1, envia para R2
- e2: R1 recebe u2 de R2
- e3: R2 recebe update u2, envia para R1
- e4: R2 recebe u1 de R1

- Temos agora $L(e1) < L(e4)$, $L(e3) < L(e2)$
  - mas ainda $L(e2) \,||\, L(e4)$
- Relógio de vetor também não resolve

Garantindo Ordem Total

- **Ideia**: processar transações distribuídas em uma ordem
  - todos processos executam transações na mesma ordem
  - transação será confirmada antes de ser executada
- **Algoritmo:**
  - manter em cada processo um relógio lógico de Lamport
    - cada transação tem valor de relógio
  - cada processo mantém uma fila com todas as transações (incluindo as suas)
    - ordenada pelo valor do relógio lógico da transação
  - cada transação em P_i é enviada a todos processos
    - via *multicast*, incluindo ao próprio processo
  - transação recebida por P_j é colocada na fila de transações e confirmada para todo processos
    - via *multicast*, incluindo o próprio processo

Garantindo Ordem Total

- **Multicast:** mensagem de *broadcast* enviada para todos os processos do sistema de forma eficiente
- Assumir rede FIFO e que mensagens não se perdem
  - m_1 transmitida antes de m_2 por P_i implica que todo P_j recebe m_1 antes de m_2
- **Processar transação**
  - transação da cabeça da fila é executada após o recebimento da confirmação de todos os processos
    - incluindo o próprio processo que iniciou a transação
- Filas vão ser idênticas em todos os processos
  - ordenadas por tempo lógico das transações

Garantindo Ordem Total

- **Problema**: tempo lógico de dois eventos em processos diferentes pode ser o mesmo

- **Solução**: adicionar número do processo como parte do relógio lógico: “L(e).identificador”
  - apenas para quebrar empate na fila
  - não afeta funcionamento do relógio lógico
  - assumir que identificador de processo é único

Exemplo de Ordem Total

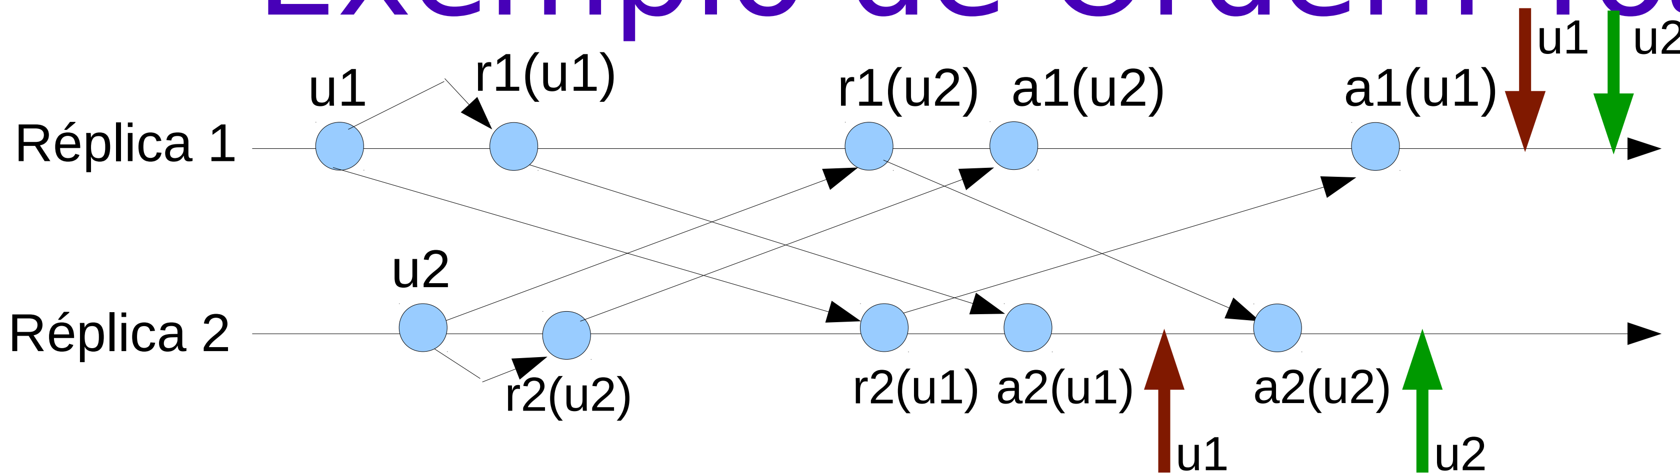

Obs: confirmação enviada pelo processo para ele mesmo surpimida!

- u1, u2: transações a serem executadas
- r*i*(u*j*) : recebimento da transação *j* pelo processo *i* (vai para fila de transações, gera confirmação)
- a*i*(u*j*) : recebimento da confirmação da transação *j* pelo processo *i*
- No início, fila de transações em R1: [u1 (1.1)], fila em R2: [u2 (1.2)]
- Depois de r1(u2), fila em R1: [u1 (1.1), u2 (1.2)]
- Depois de r2(u1), fila em R2: [u1 (1.1), u2 (1.2)]
- Depois de a2(u1) R2 pode executar u1: cabeça da fila, e confirmada por todos
- Depois de a1(u2) R1 **não** pode executar u1, pois precisa aguardar confirmação de u1 vindo de r2, a1(u1)
- Depois de a2(u2) R2 pode executar u2: cabeça da fila e confirmada por todos
- Depois de a1(u1) R1 pode executar u1, e em seguida u2

Totally Ordered Multicast

- Algoritmo garante ordenação total das transações de forma distribuída
  - sem o uso de um servidor central
- Transações locais são transmitidas para todos processos do sistema
  - requer a confirmação do recebimento de cada transação para todos os processos do sistema
- Alta complexidade de mensagens
  - 1 + n mensagens de multicast por transação
- Atrasa execução dos eventos
  - execução apenas após chegada das confirmações
- Ainda é utilizado em alguns contextos
  - principalmente como primitiva para outros mecanismos