Sistemas Distribuídos

Comunicação em Grupo

abril de 2015

Grupos em Aplicações Distribuídas

Primitiva de comunicação em grupo

- um processo envia uma mensagem para um grupo de processos e todos os destinatários recebem
- garantias variadas: confiabilidade e ordenação

Grupos em Aplicações Distribuídas

grupos fortemente acoplados:

- replicação de serviços
  - confiabilidade
  - tempo de resposta
- clientes com estado compartilhado
- computação científica
- ...

Primitiva de comunicação em grupo

- um processo envia uma mensagem para um grupo de processos e *todos* os destinatários recebem
- garantias variadas

Grupos em Aplicações Distribuídas

grupos fracamente acoplados:

- observadores "melhor esforço"
  - monitoramento de ambientes de execução
  - consumo de dados: valores de mercados, etc

Primitiva de comunicação em grupo

- um processo envia uma mensagem para um grupo de processos e *todos* os destinatários recebem
- garantias variadas: publish/subcribe e serviços de eventos

Broadcast ou *Multicast*

- em redes: conceito de entrega *para todos* e *para alguns*
- conceitos se confundem em sistemas distribuídos

Comunicação em Grupo: Problemas Novos

- alguns recebem e outros não
- processos rececebem mensagens em ordens diferentes

Garantias de Entrega

- confiabilidade
- ordenação

Implementação

- chegada X entrega

Exemplo: envio de msg para um grupo de processos

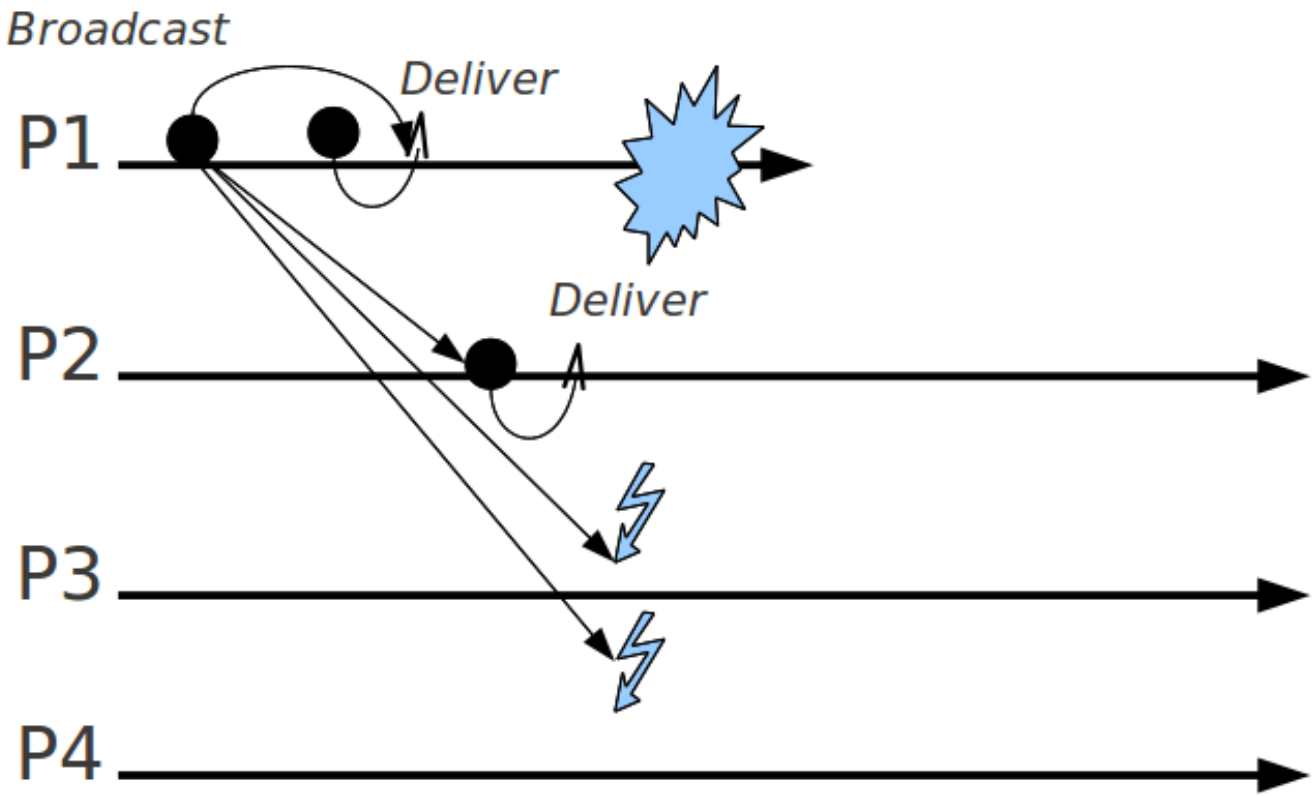

Níveis de garantia de entrega

1. *Melhor-esforço* (*best-effort*): garantia de entrega entre processos corretos
2. *Confiável* (*reliable*): garantia *all-or-nothing* mesmo se o emissor falhar
3. *Ordem* xyz: garantia de entrega na ordem *xyz*


Garantia de entrega: Implementação

- uso de *holdback queue*
- em geral, mensagens com *identificadores únicos*
  - o que já existe no SO agora em bibliotecas ou middlewares
  - custos de espaço e processamento!

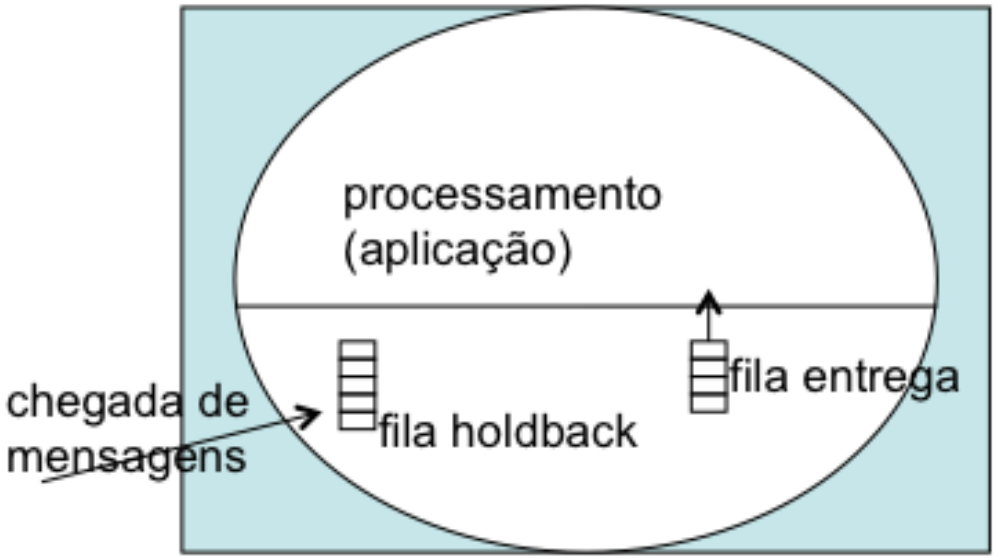

Garantia de entrega: Implementação

Broadcast do melhor-esforço

- Um processo envia uma msg em um passo de comunicação para todos os processos do sistema, incluindo ele mesmo
- O custo para garantir confiabilidade é apenas do lado do emissor (se ele falhar, nenhuma garantia de entrega é oferecida)


Interface e propriedades do "Bcast melhor-esforço"

```
Module:
 Name: BestEffortBroadcast (beb).
Events:
 Request: <bebBroadcast | m>: bcast m
 Indication: <bebDeliver | src, m>: entrega m

Properties:
 BEB1: Validade melhor-esforço: se Pi e Pj
    são corretos, toda msg de Pi é entregue por Pj
 BEB2: Não duplicação: nenhuma msg é entregue
    mais de uma vez
 BEB3: Não-criação: se a msg é entregue por Pj
    então ela foi difundida por Pi
```

Algoritmo Bcast básico

```
Implements: BestEffortBroadcast (beb)

Uses: PerfectPointToPointLinks (pp2p)

event <bebBroadcast | m> do
   forall pi do
      trigger <pp2pSend | pi, m>;

event <pp2pDeliver> | pi, m> do
   trigger <bebDeliver | pi, m>;
```

Exemplo de execução de Bcast básico

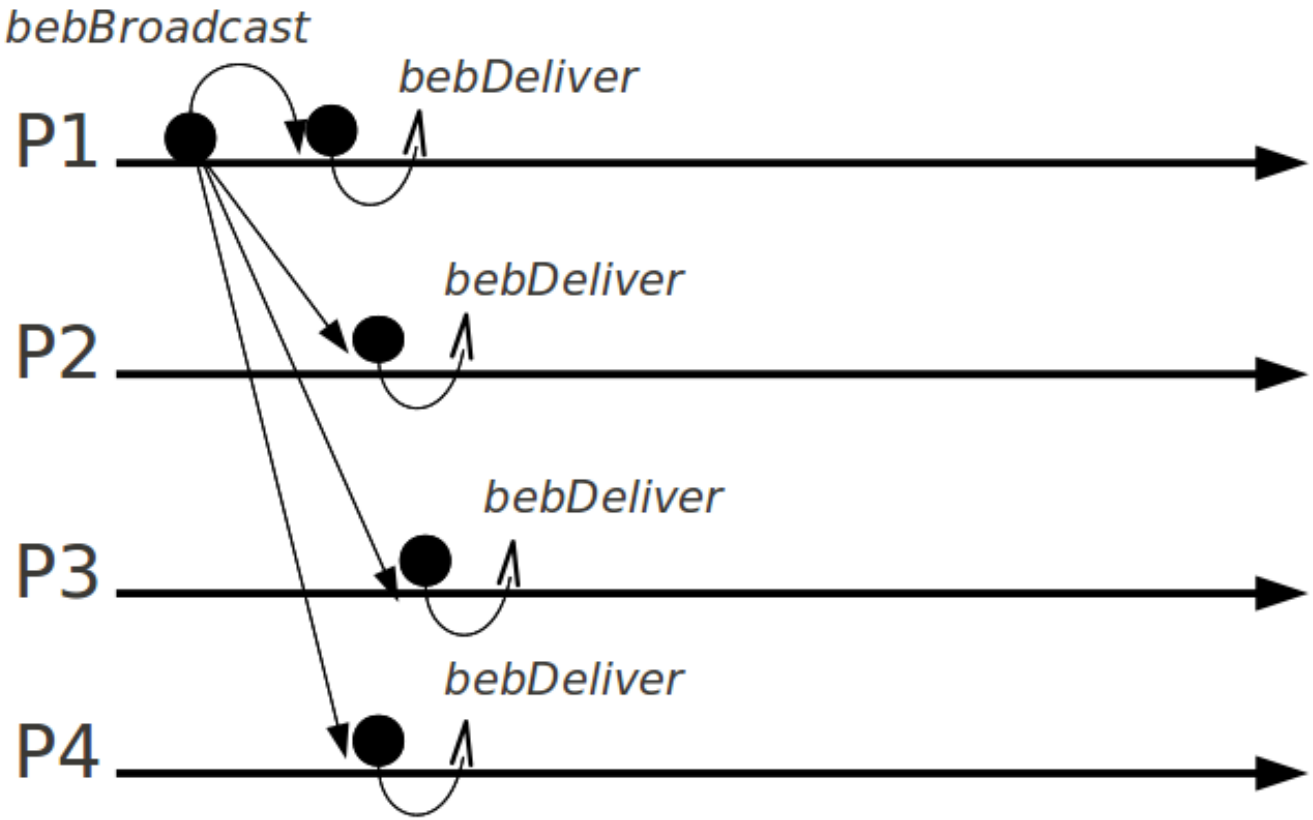

Desempenho: o algoritmo requer um único passo de comunicação e troca N mensagens

Interface de comunicação p2p utilizada...

Interface do enlace

```
Module:
    Name: PerfectP2PLink
Events:
    Request: < Send | dest, msg >
    Indication: < Deliver | src, msg >
```

- entrega confiável: se p_i manda para p_j e nenhum deles falha, p_j em algum momento recebe
- ausência de duplicação de mensagens
- ausência de criação de mensagens

Propriedades do enlace

propriedades caras em alguns ambientes!

exemplo implementação PerfectP2P

1. retransmite eternamente (didático mas sem bom desempenho...)
2. elimina duplicatas
3. entrega mesmo com falhas intermitentes...

confiabilidade do broadcast de melhor esforço

1. se transmissor não falhar, garantia de entrega a todos
2. se transmissor falhar:
   - processos podem "discordar" sobre entrega de mensagem
   - broadcast de melhor esforço pode não ter transmitido para todos ou falha pode ter ocorrido antes de terem sido feitas as retransmissões necessárias


Broadcast confiável

- todos os processos devem receber (tratar) o mesmo conjunto de mensagens
  - noção de *acordo*
- solução para modelo *fail-stop*

Interface e propriedades do *Bcast confiável*

```
Molule:
 Name: Reliable Broadcast (rb).
Events:
 Request: <rbBroadcast | m>: bcast m
 Indication: <rbDeliver | src, m>: entrega m

Properties:
 RB1: Validade: se Pi e Pj
    são corretos, toda msg de Pi é entregue por Pj
 RB2: Não duplicação: nenhuma msg é entregue
    mais de uma vez
 RB3: Não-criação: se a msg é entregue por Pj
    então ela foi difundida por Pi
 RB4: Acordo: Se msg é entregue por processo correto pi,
então m é entregue em algum momento para qualquer
processo correto pj
```

Algoritmo Bcast confiável regular

```
Implements: ReliableBroadcast (rb)
Uses: BestEffortBroadcast (beb)
event <Init> do
  delivered := 0;

event <rbBroadcast | m> do
  delivered := delivered U {m};
  trigger <rbDeliver | self, m>;
  trigger <bebBroadcast | [DATA,self,m]>;

event <bebDeliver> | pi, [DATA,self,m] > do
  if(m não pertence a delivered) do
    delivered := delivered U {m};
    trigger <rbDeliver | source_m, m>;
    trigger <bebBroadcast | [DATA,source_m,m]>;
```

Exemplo de execução de Bcast confiável regular

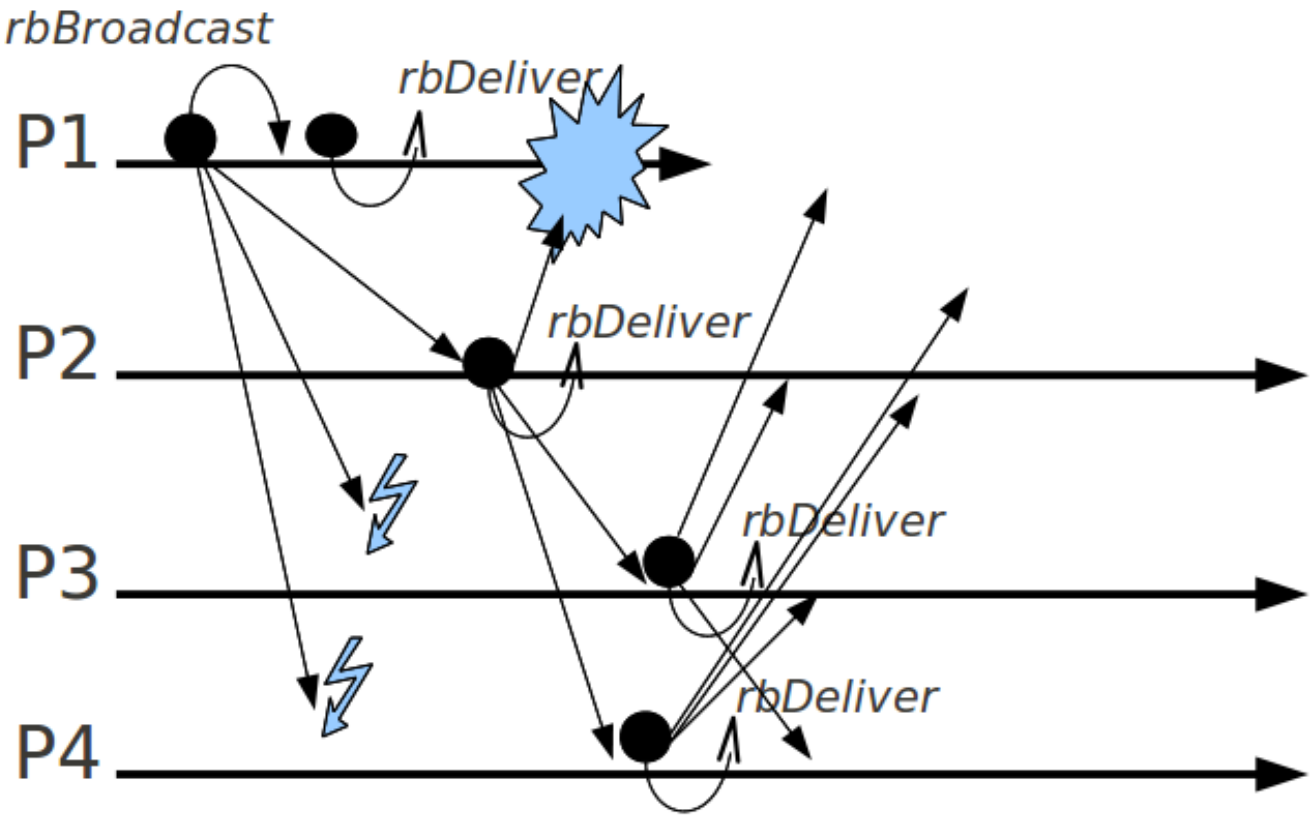

Broadcast ordenado

- As soluções anteriores não garantem ordem de entrega das mensagens enviadas por processos diferentes (mensagens de um mesmo processo devem ser entregues na ordem em que foram difundidas)
- Algumas aplicações precisam de garantias de ordem de entrega.
  - ordem total
  - ordem causal

Ordem Total

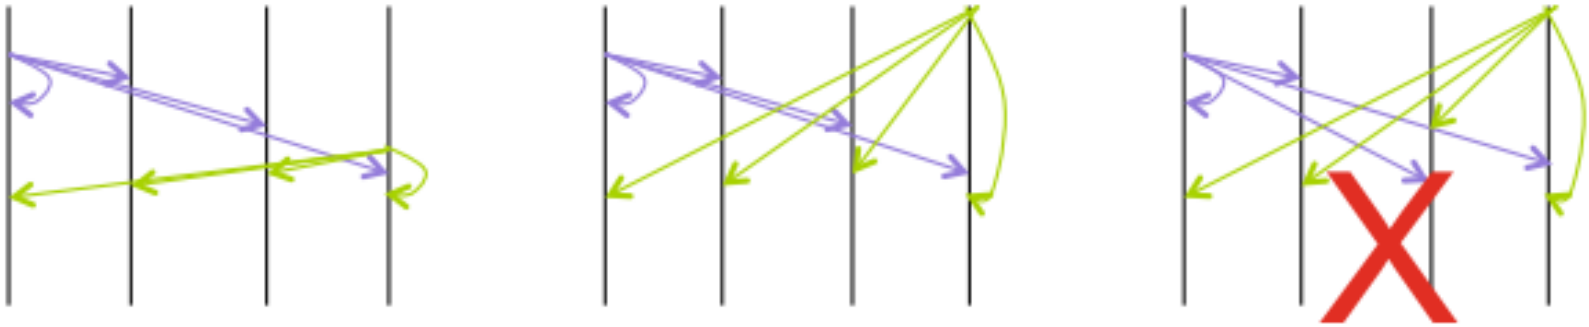

- Não importa a ordem de entrega, mas deve ser a mesma em todos os processos do grupo.

Ordem total com sequenciador

Ordem total com votação de ordem

Ordem Causal

possível relação de causalidade

- uma mensagem pode ter sido consequencia de outra ainda não vista

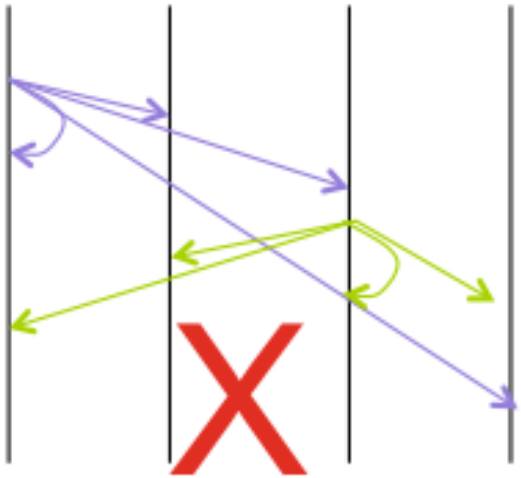

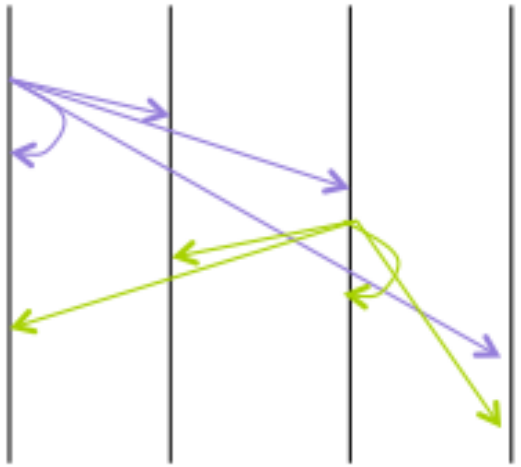

Causalidade em eventos distribuídos...

- $a -> b$: o evento a ocorre antes do evento b se
  - a ocorre antes de b em um mesmo processo P
  - `a=send(m)` no processo P e `b=receive(m)` no processo Q
  - existe c tal que a precede c e c precede b
- $a||b$: os eventos a e b são concorrentes

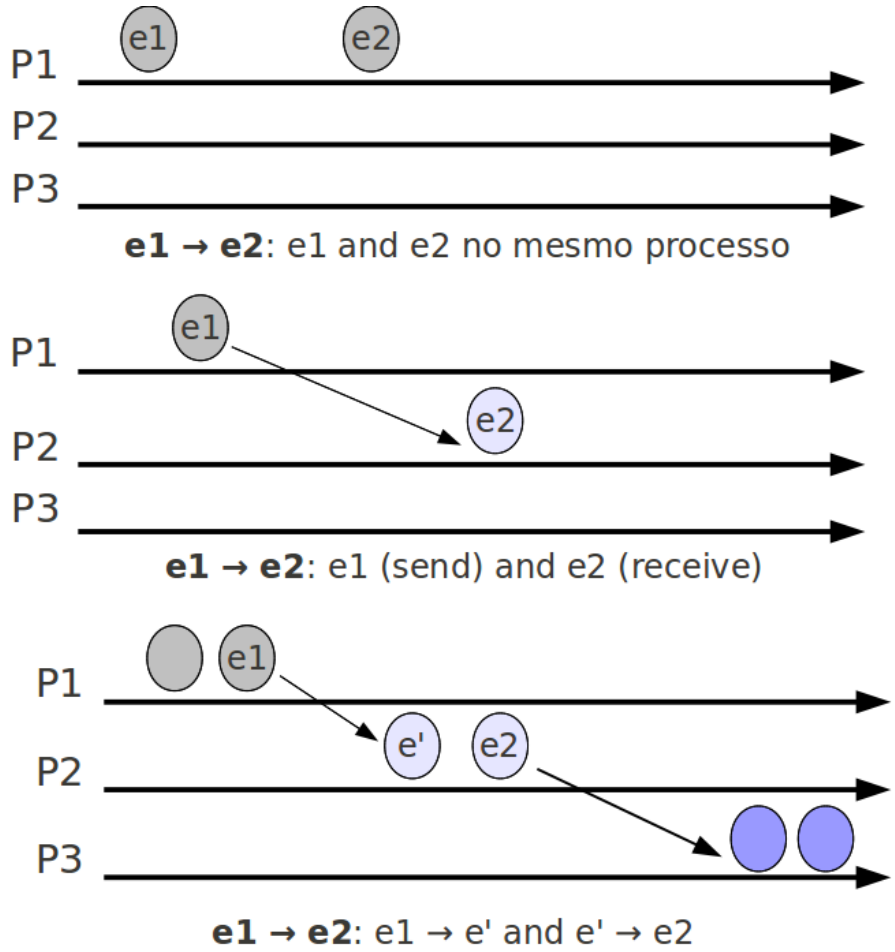

Interface e propriedades do "Bcast ordem causal"

```
Molule:
 Name: ReliableCausalOrder (rco)
Events:
 Request: <rcoBroadcast | m>: bcast m
 Indication: <rcoDeliver | src, m>: entrega m

Properties:
 CB: Entrega causal: m2 só é entregue por Pi
     se toda msg mi tal que mi->m2 foram entregues
 RB1: Validade
 RB2: Não-duplicação
 RB3: não-criação
 RB4: Acordo
```

Algoritmo Bcast ordem causal

```
Uses: ReliableBroadcast (rb)
event <Init> do
 delivered := 0; past := 0;
event <rcoBroadcast | m> do
  trigger <rbBroadcast | [DATA,past,m]>;
  past := past U {(self,m)};
event <rbDeliver> | pi, [DATA,past_m,m] > do
  if(m não-pertence a delivered) then
    forall (s_n, n) in past_m do
      if(n não-pertence delivered) then
        trigger <rcoDeliver | s_n, n>;
        delivered := delivered U {n};
        past := past U {(s_n,n)};
    trigger <rcoDeliver | pi, m>;
    delivered := delivered U {m};
    past := past U {(pi,m)};
```

custos proibitivos... cada mensagem carrega todas as que a precedem causalmente

Relógio Lógico (Lamport)

- conceito de relógio lógico modela ordenação (parcial) de eventos
- cada evento associado a um valor $r(e_i)$ de forma que $e_i \prec e_j \Rightarrow r(e_i) < r(e_j)$

Relógio Lógico — Implementação

- cada processo P mantém um contador, inicialmente $RL_P = 0$
- a cada evento e, P associa um valor $RL_P(e)$ e incrementa seu contador
- se evento e é envio de mensagem, P acrescenta campo *timestamp* com valor $RL_P(e)$
- ao receber mensagem M com timestamp TS, processo Q faz $RL_Q = max(RL_Q, TS) + 1$

Broadcast causal com espera

- uso de relógio lógico e timestamps: funciona se tempo de entrega de mensagens tem limite máximo

Broadcast causal

- uso de mensagens "posteriores" para validar mensagens com timestamp TS

- algoritmo de semáforos distribuídos

Andrews: semáforos distribuídos — user

```
type kind = enum(V, P, ACK)
chan sem[1:n](sender: int, kind, timestamp: int)
chan go[1:n](timestamp : int)
User[i: 1..n]:: var lc : int := 0      # logical clock
                var ts : int           # timestamp in go messages
                # execute a V operation
                broadcast sem(i, V, lc); lc := lc+1
                ...
                # execute a P operation
                broadcast sem(i, P, lc); lc := lc+1
                receive go[i](ts); lc := max(lc, ts+1); lc := lc+1
```

Andrews: semáforos distribuídos — helper

```
Helper[i: 1..n]:: var mq : queue of (int, kind, int)     # ordered by timestamps
                  var lc : int := 0                      # logical clock
                  var nV : int := 0, nP : int := 0       # semaphore counters
                  var sender : int, k : kind, ts : int   # values in messages
                  do true → { loop invariant DSEM }
                       receive sem[i](sender, k, ts); lc := max(lc, ts+1); lc := lc+1
                       if k = P or k = V →
                            insert (sender, k, ts) at appropriate place in mq
                            broadcast sem(i, ACK, lc); lc := lc+1
                       [] k = ACK →
                            record that another ACK has been seen
                            fa fully acknowledged V messages →
                                 remove the message from mq; nV := nV+1
                            af
                            fa fully acknowledged P messages st nV > nP →
                                 remove the message from mq; nP := nP+1
                                 if sender = i → send go[i](lc); lc := lc+1 fi
                            af
                       fi
                  od
```

Vetor de timestamps

Vetor de timestamps: idéia básica

- Dados N processos, usa-se um vetor de N elementos (ao invés de um valor escalar)
- A cada evento "e", associa-se um **vetor de timestamps** cujo i-ésimo elemento indica quantos mensagens do processo i já foram vistas

Vetor de timestamp

Definição da relação $<$

- Sejam a e b dois eventos quaisquer
- $VT(a) < VT(b)$:
  1. $\forall i, VT(a)[i] \leq VT(b)[i]$
  2. $\exists j, VT(a)[j] < VT(b)[j]$
- Note que $<$ é uma *ordem parcial*, existem eventos que não podem ser comparados por serem concorrentes
  - Ex., $x = [0, 0, 1, 0]$ e $y = [1, 0, 0, 0]$, pois $VT(x) \neq VT(y)$ e não vale $VT(x) < VT(y)$ nem $VT(y) < VT(x)$

Vetor de timestamp

Funcionamento

- Cada processo mantém seu VT que começa com 0 em todas as posições
- Para cada evento "e" local e de envio de msg, incrementa o componente do processo local no VT e associa VT_p ao evento "e": $VT_p[p] = VT_p[p] + 1$ e $VT(e) = VT_p$
- Quando Q recebe uma mensagem, atualiza cada campo do seu VT:
  - $VT_q[i] = VT_q[i] + 1, i = q$
  - $VT_q[i] = max(VT_q[i], VT_m[i]), i \neq q$

Esta última parte garante que tudo que acontecer depois em P_q passa a ser causalmente relacionado com tudo o que aconteceu antes em P_i

Exemplo de uso de VT para ordenação de eventos

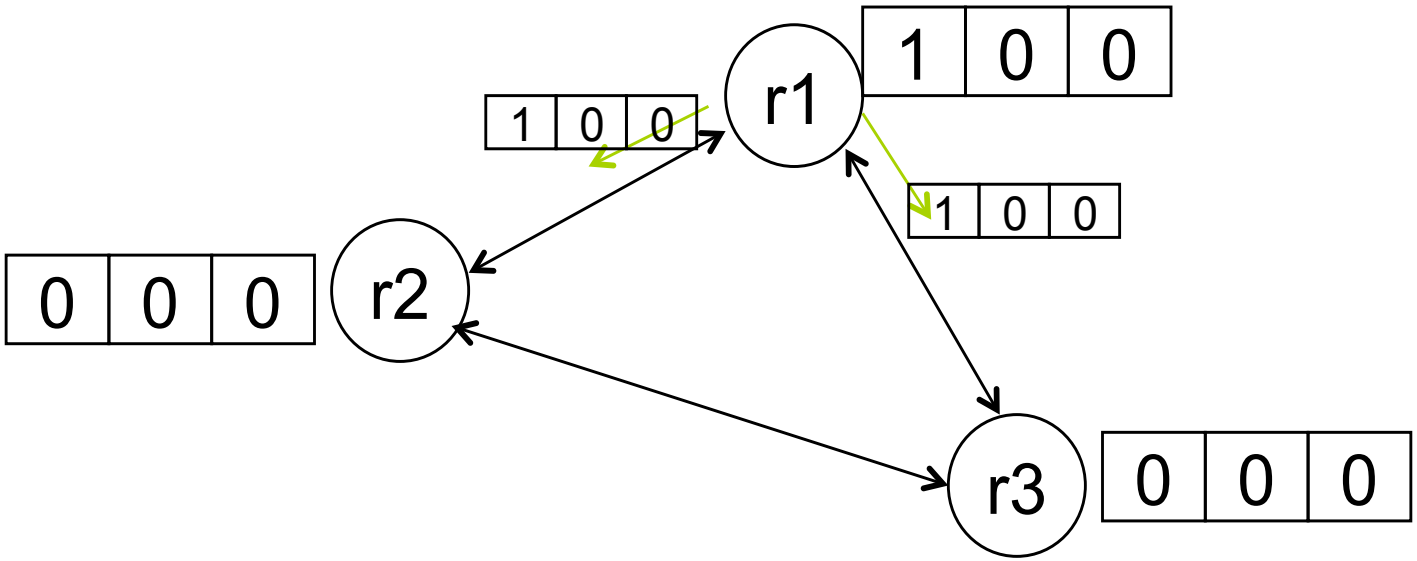

VT para ordenação causal

- é necessário não apenas estabelecer ordem mas garantir que foram vistas todas as mensagens que precedem causalmente determinada mensagem!

Exemplo de entrega em ordem causal

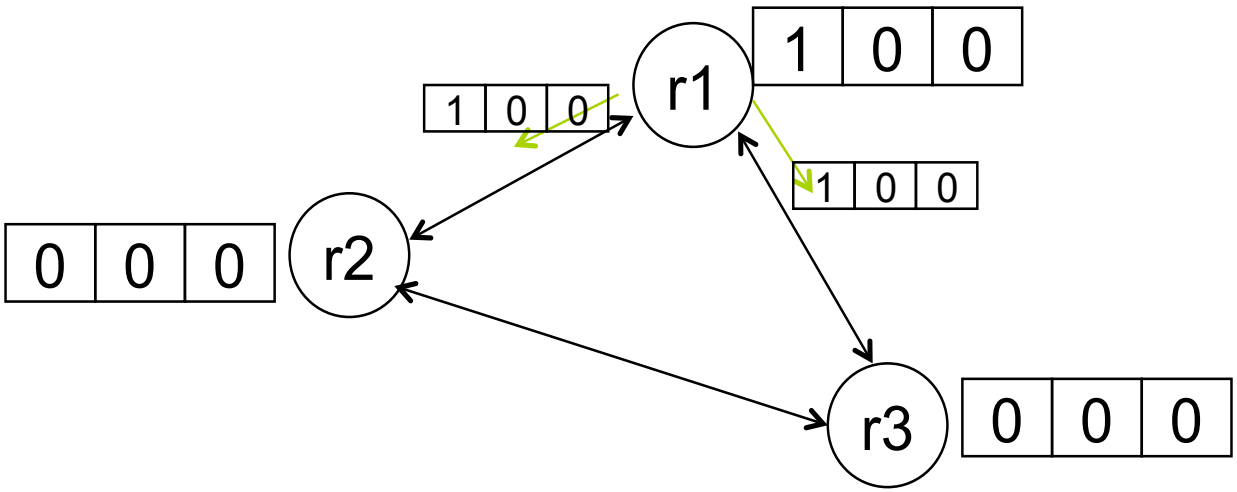

Exemplo de entrega em ordem causal

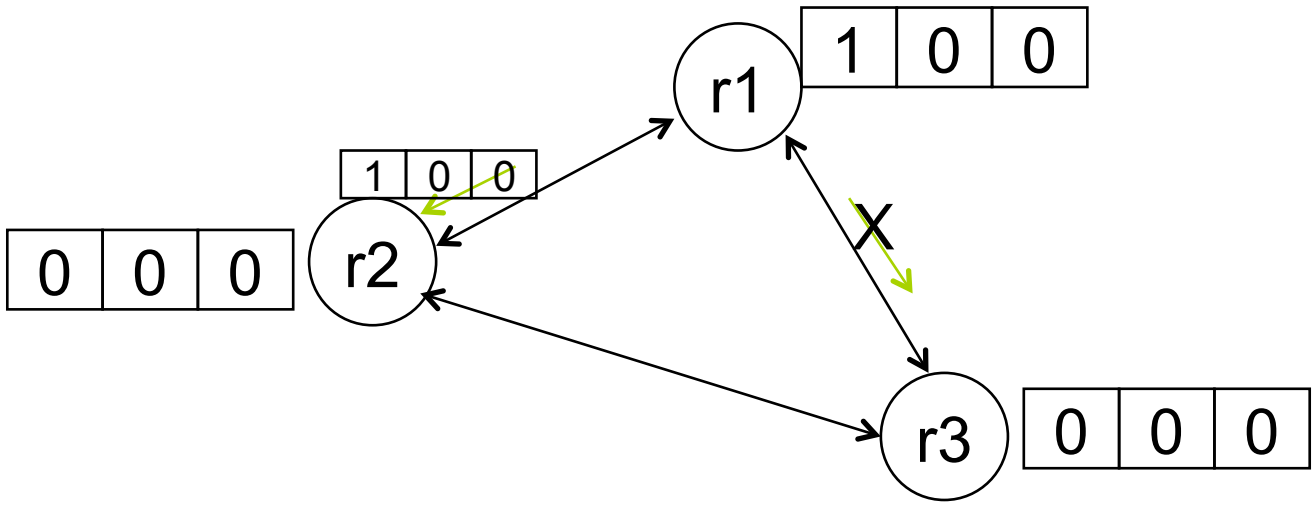

Exemplo de entrega em ordem causal

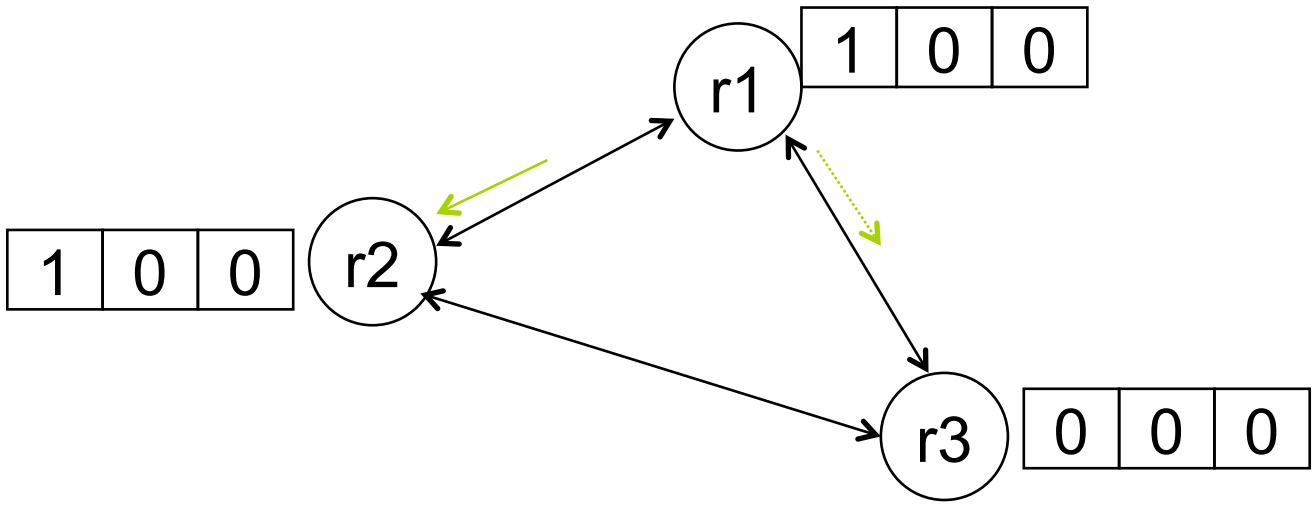

Exemplo de entrega em ordem causal

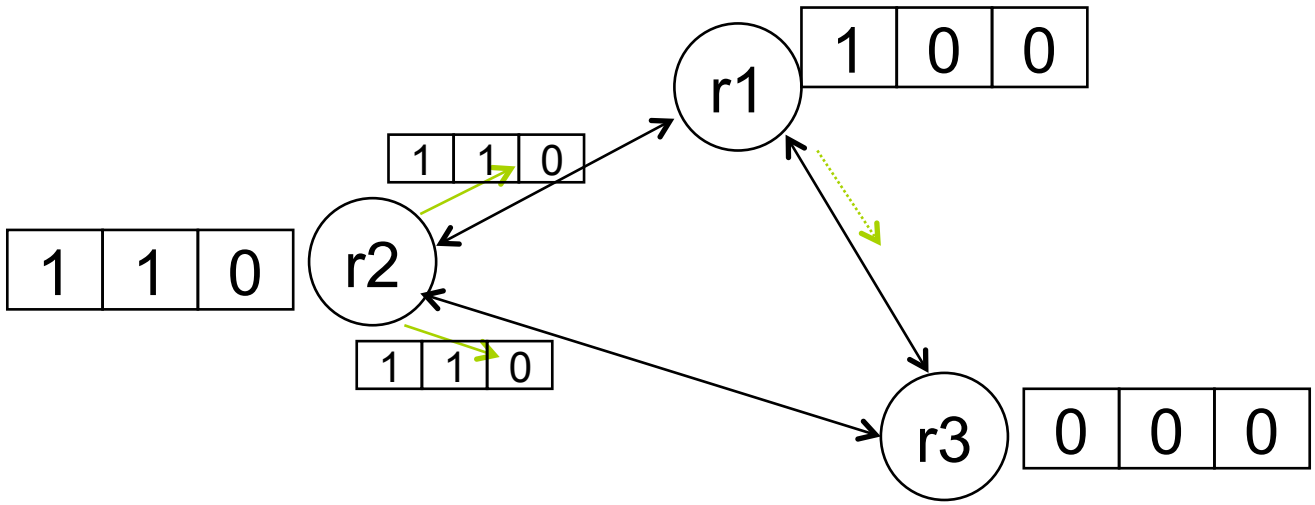

Exemplo de entrega em ordem causal

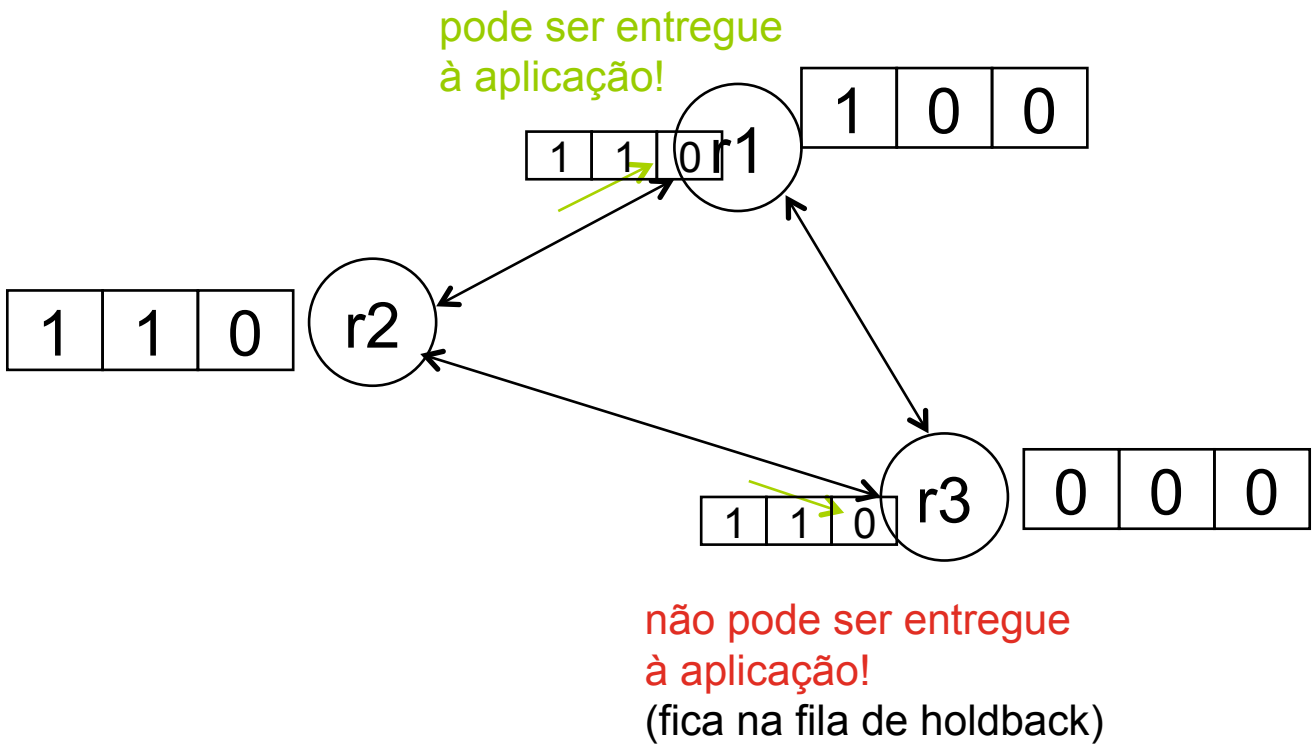

- a entrega deve ser postergada até as mensagens anteriores serem vistas
- ack's ou reenvios sob demanda

Gerência de Grupos

- algoritmos de ordenação supõem que cada participante conhece os membros do grupo
- grupos estáticos x dinâmicos (falhas, adesões, etc)

serviço de *membership*

- alerta participantes sobre saídas e entradas

exemplo de serviço “GroupMembership”

```
Module:
 Name: GroupMembership (gm).
Events:
 Indication: <gmView | V>: atualiza conjunto de membros
 entregando uma visão. Uma visão V é uma tupla (i, M) onde
 i é um identificador único e M é o conjunto de processos
 participantes
```

Implementação de GroupMembership

considerando apenas saídas:

```
Implements: GroupMembershop (gm)

Uses:
  UniformConsensus (uc)
  PerfectFailureDetector (P)

event <Init> do view := (0, H); wait := false; correct := H;
                trigger <gmView | view>;

event <crash | pi> do correct := correct \ {pi};

upon (correct < viewmemb> & (wait == false) do
                 wait := true;
                 trigger <ucPropose | view.id+1, correct>;

event <ucDecided | id, memb> do
                 view := (id, memb); wait := false;
                trigger <gmView | view>;
```

Controle de participantes e broadcasts:

- o que acontece se grupo muda durante entrega?
- mensagem de processo que falhou pode chegar em nova visão?

virtual synchrony

- ordenação da indicação de nova visão em relação aos broadcasts

Referências:

- R. Guerraoui and L. Rodrigues. *Introduction to Reliable Distributed Programming* Springer, 2006