Comunicação Avançada em MPI

Tópicos:

- Exemplo: Difusão de Dados em Anel
- Armazenamento de Mensagens em Trânsito
- Comunicação Sem Bloqueio em MPI
- Outros Modos de Comunicação em MPI

Referência: Pacheco,P.S. *Parallel Programming with MPI* Morgan Kaufmann, San Francisco, 1997.

Difusão de Dados em Anel

Problema de Difusão:

- Dado um array **X**, com um segmento armazenado em cada processador, obter em todos os processadores, o array total **Y** contendo todos os segmentos de **X**

Uma Possível Solução:

- Dispor os processadores num “anel”
- Enviar dados para o processador seguinte no anel; cada processador copia os dados recebidos
- Repetir o passo anterior P-2 vezes, sempre enviando adiante os novos dados recebidos (P-1 passos no total)

Difusão de Dados em Anel

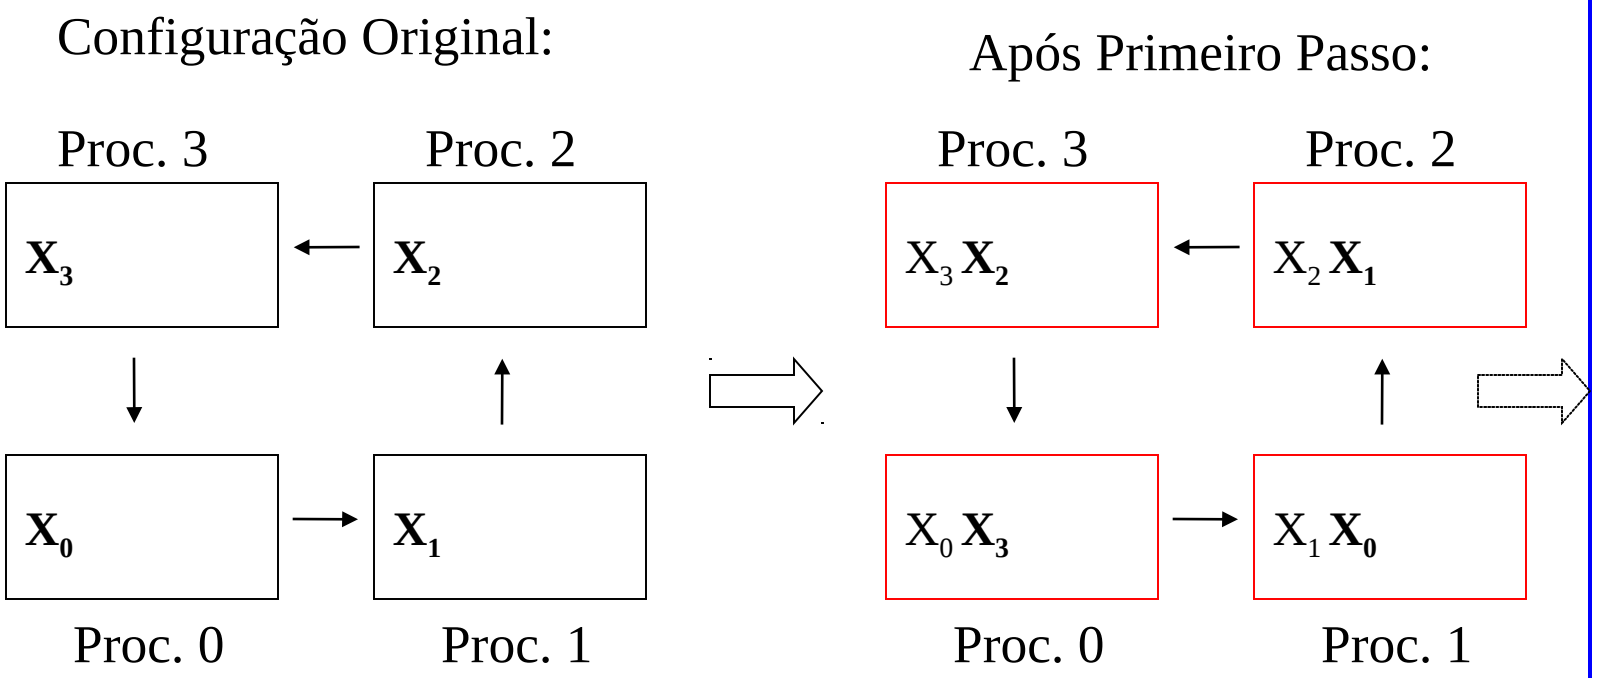

Difusão de Dados em Anel

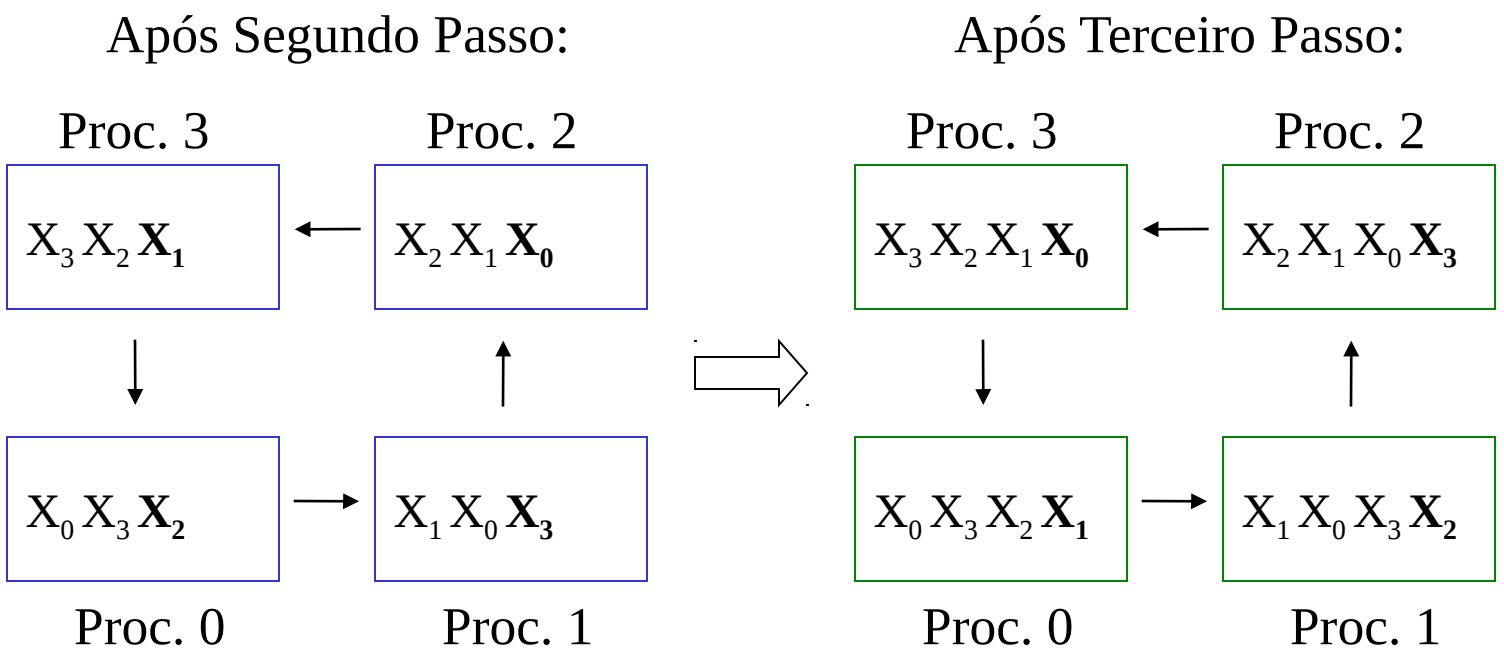

Difusão de Dados em Anel

Algoritmo:

- Inicialização:
  - Copiar bloco local para a posição definitiva
  - Achar proc. vizinhos no anel (sucessor e predecessor)
- Procedimento no Passo i:
  - Enviar bloco (my_rank - i + P) % P para o sucessor
  - Receber bloco (my_rank - i + P - 1) % P do predec.
  - Copiar bloco recebido: tamanho = *blocksize* = n / P
- Número Total de Passos: P - 1 ($0 \leq i < P-1$)

Difusão de Dados em Anel

Implementação:

```
void Difusao_anel (
        float     x[]                   /* in  */,
        int       blocksize             /* in  */,
        float     y[]                   /* out */,
        MPI_Comm  ring_comm  /* in  */) {
    int        i, p, my_rank, sucessor, predecessor, send_offset, recv_offset;
    MPI_Status  status;

    MPI_Comm_size(ring_comm, &p);
    MPI_Comm_rank(ring_comm,&my_rank);
    /* Copia x para o local correto em y */
    for (i = 0; i < blocksize; i++)   y[i + my_rank*blocksize] = x[i];
```

Difusão de Dados em Anel

```
  sucessor = (my_rank + 1) % p;
  predecessor = (my_rank - 1 + p) % p;

  for (i = 0; i < p - 1; i++) {
      send_offset = ((my_rank - i + p) % p)*blocksize;
      recv_offset = ((my_rank - i - 1 + p) % p)*blocksize;
      MPI_Send(y + send_offset, blocksize, MPI_FLOAT,
          sucessor, 0, ring_comm);
      MPI_Recv(y + recv_offset, blocksize, MPI_FLOAT,
          predecessor, 0, ring_comm, &status);
   }
}
```

Armazenamento de Mensagens em Trânsito

No Exemplo Anterior (supondo P=2):

Proc.0	Proc.1
MPI_Send p/ 1	MPI_Send p/ 0
MPI_Recv de 1	MPI_Recv de 0

- Hipótese: Sist. Oper. armazena msgs em trânsito

→ O que irá ocorrer se não há buffers no sistema?
(padrão MPI não especifica que existam buffers)

- Se os dois processadores iniciam o prog. juntos:
  - Proc.0 não retorna de MPI_Send antes de 1 fazer Recv
  - Proc.1 não retorna de MPI_Send antes de 0 fazer Recv
  - *Deadlock* !

Armazenamento de Mensagens em Trânsito

- Embora o programa do Exemplo esteja correto, pode haver deadlock se não houver buffers
  - Programas assim são ditos *inseguros*
  - Programas *seguros* não causam deadlock, mesmo que não haja buffers de sistema para mensagens em trânsito
- Como tornar um programa *seguro*?
  - Solução 1: Reorganizar as chamadas a *Send* / *Recv*

Proc.0 (par)	Proc.1 (ímpar)
MPI_Send p/ 1	MPI_Recv de 0
MPI_Recv de 1	MPI_Send p/ 0

Armazenamento de Mensagens em Trânsito

- Solução 2:Utilizar MPI_Sendrecv( ) → não há deadlock
  - Equivalente a MPI_Send( ) seguido de MPI_Recv( )

```
int MPI_Sendrecv(
      void*          send_buf        /*  in  */,
      int            send_count      /*  in  */,
      MPI_Datatype   send_type       /*  in  */,
      int            destination     /*  in  */,
      int            send_tag        /*  in  */,
      void*          recv_buf        /*  out  */,
      int            recv_count      /*  in  */,
      MPI_Datatype   recv_type       /*  in  */,
      int            source          /*  in  */,
      int            recv_tag        /*  in  */,
      MPI_Comm       recv_tag        /*  in  */,
      MPI_Status*    status          /*  out  */  )
```

Comunicação Sem Bloqueio em MPI

Já vistas: Funções com bloqueio

- MPI_Send (buffer , ...):
  Só retorna quando buffer já pode ser reutilizado
- MPI_Recv (buffer , ...):
  Só retorna quando buffer já contém dados recebidos

Otimização:

- Funções sem bloqueio (retorno imediato)
- Idéia: Apenas comandar o início de *send / recv*
- Objetivo: Sobrepor comunicação e computação (pode ser útil se há um proc. de comunicação dedicado)

Comunicação Sem Bloqueio em MPI

Implementação de comunicação sem bloqueio:

- MPI_Send (...) → MPI_Isend (...): Inicia *send*
- MPI_Recv (...) → MPI_Irecv (...): Inicia *recv*
- Espera pelo término da transmissão:
  - MPI_Wait( ): Bloqueia a execução esperando msg
- Verificação do término da transmissão:
  - MPI_Test( ): Não bloqueia a execução; retorna flag indicando se a transmissão já terminou
- Uso típico: MPI_Isend+MPI_Wait , MPI_Irecv+MPI_Wait

Obs: É possível misturar funções com/sem bloqueio, à vontade, num mesmo programa

Comunicação Sem Bloqueio em MPI

Para o Exemplo Anterior:

```
MPI_Request send_request, recv_request;
. . .
send_offset = my_rank*blocksize;
recv_offset = ((my_rank - 1 + p) % p)*blocksize;
for (i = 0; i < p - 1; i++)                                    {
    MPI_Isend(y + send_offset, blocksize, MPI_FLOAT,
        successor, 0, ring_comm, &send_request);
    MPI_Irecv(y + recv_offset, blocksize, MPI_FLOAT,
        predecessor, 0, ring_comm, &recv_request );
    send_offset = ((my_rank - i - 1 + p) % p)*blocksize;
    recv_offset = ((my_rank - i - 2 + p) % p)*blocksize;
    MPI_Wait(&send_request, &status);
    MPI_Wait(&recv_request, &status);        }
```

Início da Comunic.

Comput.

Final da Comunic.

Comunicação Sem Bloqueio em MPI (cont.)

Comparação de Desempenho: (tempos em ms)

	Intel-Paragon		IBM-SP2	
P	Com Bloq.	Sem Bloq.	Com Bloq.	Sem Bloq.
2	0.14	0.10	0.11	0.08
8	1.00	0.94	0.85	0.54
32	4.90	4.20	3.90	2.50

Obs: Ganho de desempenho seria maior se houvesse mais computação a ser feita

Outros Modos de Comunicação em MPI

Modos de Comunicação em MPI:

- Standard: MPI_Send( ), MPI_Isend( ), ...
- Synchronous: *Send* só termina depois que *Recv* inicia
  - MPI_Ssend( ) , MPI_Issend( ) , ...
- Ready: *Send* assume que *Recv* já ocorreu (sem buffer)
  - MPI_Rsend( ) , MPI_Irsend( ) , ...
- Buffered: Buffer auxiliar declarado pelo usuário
  - MPI_Bsend( ) , MPI_Ibsend( ) , ...
  - Tamanho do buffer auxiliar deve ser suficiente

Outros Modos de Comunicação em MPI

Exemplo Anterior, com Modo *Buffered*:

```
char       buffer[MAX_BUF];      int    buffer_size = MAX_BUF;
. . .
MPI_Buffer_attach(buffer, buffer_size);
for (i = 0; i < p - 1; i++) {
      send_offset = ((my_rank - i + p) % p)*blocksize;
      recv_offset = ((my_rank - i - 1 + p) % p)*blocksize;
      MPI_Bsend(y + send_offset, blocksize, MPI_FLOAT,
         successor, 0, ring_comm);
      MPI_Recv(y + recv_offset, blocksize, MPI_FLOAT,
         predecessor, 0, ring_comm, &status);
}
MPI_Buffer_detach(&buffer, &buffer_size);
```

Modos de envio/recepção em MPI na comunicação ponto-a-ponto

Pode-se combinar funções de envio diferentes com/sem bloqueio com a recepção com ou sem bloqueio:

MODOS	COM BLOQUEIO	SEM BLOQUEIO
Envio padrão	MPI_SEND ( )	MPI_ISEND ( )
Envio síncrono	MPI_SSEND ( )	MPI_ISSEND ( )
Envio buferizado	MPI_BSEND ( )	MPI_IBSEND ( )
Recepção	MPI_RECV ( )	MPI_IRECV ( )