Programação de Arquiteturas com Memória Distribuída Utilizando MPI

MCZA020-13 - Programação Paralela

Emilio Francesquini
e.francesquini@ufabc.edu.br

2019.Q1

Centro de Matemática, Computação e Cognição
Universidade Federal do ABC

Disclaimer

UFABC

- Estes slides foram preparados para o curso de **Programação Paralela na UFABC**.
- Estes slides são baseados naqueles produzidos por Peter Pacheco como parte do livro *An Introduction to Parallel Programming* disponíveis em: `https://www.cs.usfca.edu/~peter/ipp/`
- Este material pode ser usado livremente desde que sejam mantidos, além deste aviso, os créditos aos autores e instituições.
- Algumas figuras foram obtidas em: `http://pngimg.com`

Roteiro

UFABC

- Escrevendo o seu primeiro programa MPI
- Utilizando as funções MPI mais comuns
- Aproximação trapezoidal em MPI
- Comunicação coletiva
- Tipos de dados derivados em MPI
- Avaliação de desempenho em programas MPI
- Ordenação em paralelo
- Segurança (*safety*) em programas MPI

Primeiros Passos

Sistema com memória distribuída

UFABC

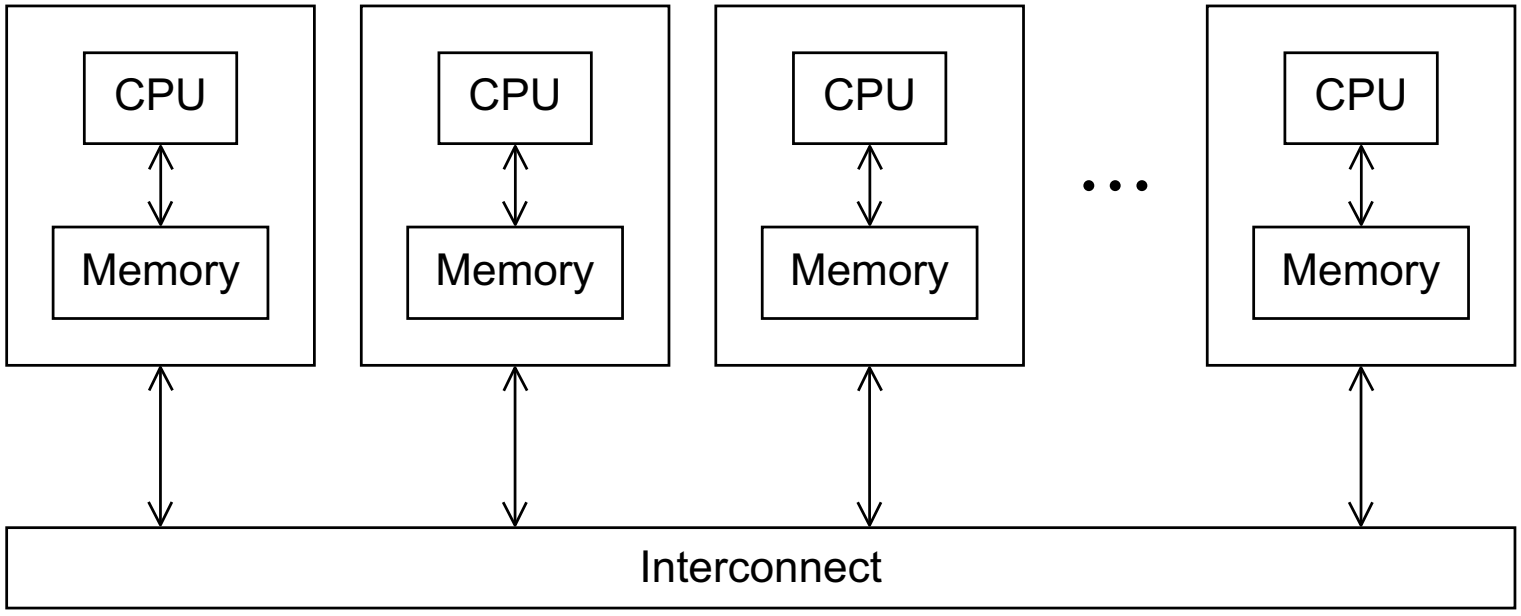

Sistema com memória compartilhada

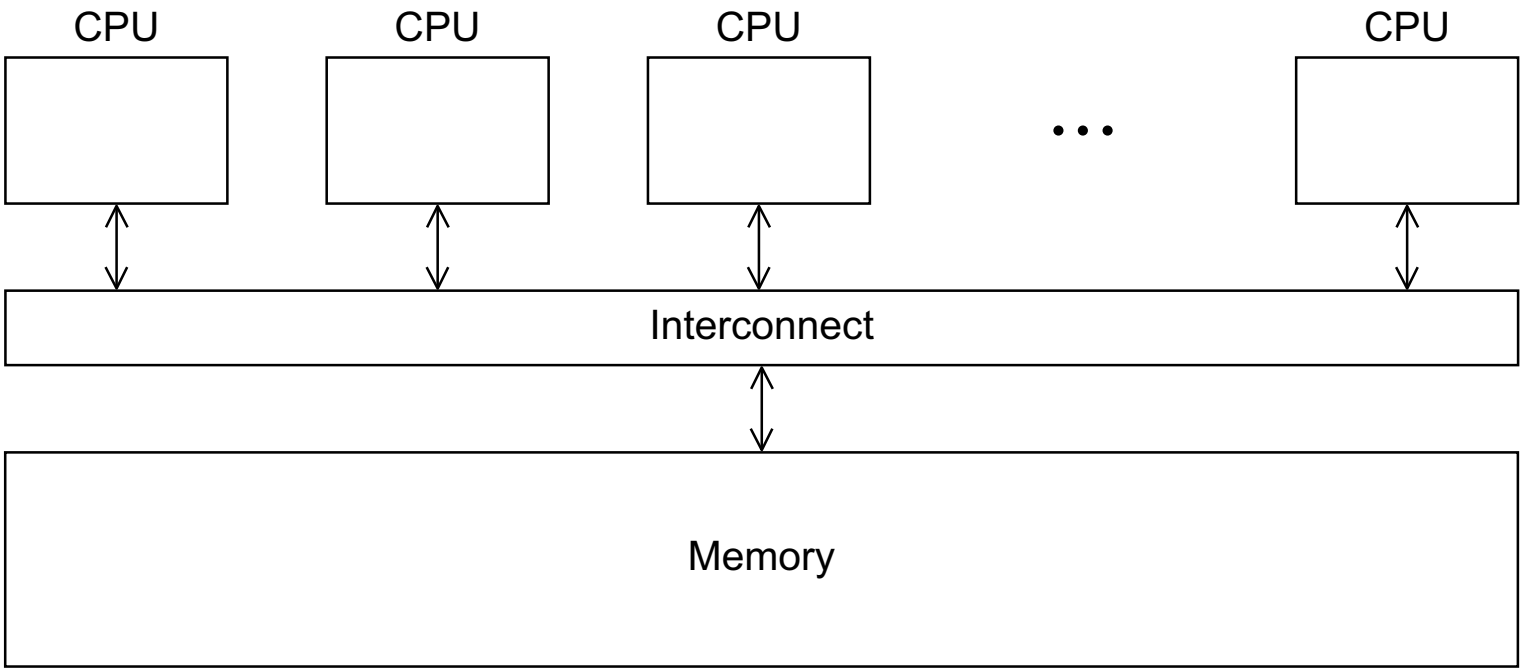

Hello World!

UFABC

```c
#include <stdio.h>

int main(void) {
    printf("hello, world\n");
    return 0;
}
```

Um clássico!

Identificação de processos MPI

UFABC

- Cada linha de execução no MPI é chamada de processo
- Processos são identificados por um número inteiro não negativo
- A identificação de um processo é chamada de rank do processo
- Um programa MPI com p processos tem processos com ranks de $0, 1, \ldots, p-1$

Hello World! - Versão MPI - Inicialização

UFABC

```c
#include <stdio.h>
#include <string.h>
#include <mpi.h>

const int MAX_STRING = 100;

int main(void) {
    char        msg[MAX_STRING];
    int         comm_sz;
    int         my_rank;

    MPI_Init(NULL, NULL);
    MPI_Comm_size(MPI_COMM_WORLD, &comm_sz);
    MPI_Comm_rank(MPI_COMM_WORLD, &my_rank);

    ...
```

Hello World! - Versão MPI - O miolo

UFABC

```
1  ...
2  if (my_rank != 0) {
3      sprintf(msg, "Greetings from process %d of %d!",
4              my_rank, comm_sz);
5      MPI_Send(msg, strlen(msg) + 1, MPI_CHAR, 0, 0,
6               MPI_COMM_WORLD);
7   } else {
8      printf("Greetings from process %d of %d!\n",
       ↪  my_rank, comm_sz);
9      for (int q = 1; q < comm_sz; q++) {
10         MPI_Recv(msg, MAX_STRING, MPI_CHAR, q,
11                  0, MPI_COMM_WORLD, MPI_STATUS_IGNORE);
12         printf("%s\n", msg);
13     }
14  }
15  ...
```

Hello World! - Versão MPI - Finalização

UFABC

```
1       ...
2       MPI_Finalize();
3       return 0;
4   }
```

Compilando

UFABC

```
1 $ mpicc -g -Wall -o mpi_hello mpi_hello.c
```

- `mpicc` - É um *wrapper* para o compilador do sistema (tipicamente o `gcc`)
  - `mpicc --showme` - Mostra o real comando que será executado
- `-g`, `-Wall`, `-o` - Flags com significado padrão entre os compiladores C

Executando

UFABC

```
mpirun mpiexec -n <número de processos> <executável>
```

```
$ mpirun -n 1 ./mpi_hello

$ mpirun -n 8 ./mpi_hello
```

- `mpirun` ou `mpiexec` - Assim como o `mpicc` é um wrapper para executar o programa
- Muitos parâmetros opcionais disponíveis
  - Há opções para escolher quais e quantos processadores/cores, quantidade de threads, processos, ...

Executando

UFABC

```
$ mpiexec -n 1 ./mpi_hello
Greetings from process 0 of 1!
$ mpiexec -n 2 ./mpi_hello
Greetings from process 0 of 2!
Greetings from process 1 of 2!
$ mpiexec -n 4 ./mpi_hello
--------------------------------------------------------------------------
There are not enough slots available in the system to
satisfy the 4 slots that were requested by the
application:
  ./mpi_hello

Either request fewer slots for your application, or
make more slots available for use.
--------------------------------------------------------------------------
$
```

Executando

UFABC

- O ambiente de execução determinou que não há slots disponíveis
  - Neste caso o ambiente detectou 2 processadores e portanto 4 está além do que há disponível
- Slots são configurados pelo administrador do sistema
- É possível colocar mais processos do que slots (oversubscription) utilizando o parâmetro `--oversubscribe`

```
1 $ mpiexec --oversubscribe -n 5 ./mpi_hello
2 Greetings from process 0 of 5!
3 Greetings from process 1 of 5!
4 Greetings from process 2 of 5!
5 Greetings from process 3 of 5!
6 Greetings from process 4 of 5!
7 $
```

Executando

UFABC

- E o que acontece se executarmos sem o `mpirun`

```
1 $ ./mpi_hello
```

Executando

UFABC

- E o que acontece se executarmos sem o `mpirun`

```
$ ./mpi_hello
```

- Ele simplesmente roda como uma aplicação sequencial

```
$ ./mpi_hello
Greetings from process 0 of 1!
$
```

Um pouco mais sobre programas MPI

UFABC

- São escritos em C
  - Como qualquer programa em C têm função `main`
  - Podem usar bibliotecas (mais comuns `stdio.h`, `stdlib.h`, ...)
  - Precisam incluir `mpi.h`
- Todos os identificadores da biblioteca MPI começam com `MPI_`
  - Por padrão a primeira letra após o *underscore* é maiúscula
  - Esta padronização ajuda a evitar confusões

Componentes de um programa MPI

UFABC

MPI_INIT

- Inicializa o MPI (pode receber parâmetros adicionais)

```
1 int MPI Init(
2     int* argc_p /* in/out */,
3     char*** argv_p /* in/out */);
```

- `argc_p` e `argv_p` são ponteiros para os parâmetros recebidos pela `main`

MPI_Finalize

- Indica ao ambiente de execução do MPI que o programa acabou e inicia a liberação dos recursos alocados

```
1 int MPI Finalize(void);
```

Esqueleto de um programa MPI

UFABC

```
1  ...
2  #include <mpi.h>
3  ...
4  int main(int argc, char *argv[]) {
5      /* Nenhuma chamada MPI pode ser feita antes da
       ↪  inicialização */
6      MPI_Init(&argc, &argv);
7      ...
8      MPI_Finalize();
9      /* Nenhuma chamada MPI pode ser feita após a
       ↪  finalização */
10     return 0;
11 }
```

Comunicadores

UFABC

- Um comunicador (*communicator*) é um conjunto de processos que podem mandar mensagens uns para os outros
- A função `MPI_Init` cria um comunicador padrão que consiste de todos os processos criados quando o programa é executado
- Este comunicador é chamado **`MPI_COMM_WORLD`**

UFABC

MPI_Comm_size

- Para obter o número de processos participantes do comunicador

```
1 int MPI_Comm_size(
2     MPI_Comm comm      /* in  */,
3     int*     comm_sz_p /* out */);
```

MPI_Comm_rank

- Devolve o rank do processo que chamou a função

```
1 int MPI_Comm_rank(
2     MPI_Comm comm    /* in */,
3     int*     my_rank /* out */);
```

MPI - Valor de retorno das funções

UFABC

- Todas as funções MPI (com exceção de `MPI_Wtime` and `MPI_Wtick`) devolvem como retorno um código de erro
  - É prudente sempre verificar o retorno
- Valores notáveis
  - `MPI_SUCCESS` - Indica sucesso na execução
  - `MPI_ERR_COMM` - Comunicador inválido. É um erro comum enviar o valor `NULL` como comunicador. Isto não é permitido nem mesmo para chamadas como `MPI_Comm_rank`.

SPMD - Single-Program Multiple-Data

UFABC

- Compilamos **um único** programa
- O processo com rank 0 é diferente (usamos um `if` para fazer isso)
  - O rank 0 recebe mensagens e as imprime enquanto os outros processos trabalham
- Não há nada especial com o rank 0 para o MPI. Mas é muito conveniente usar o rank 0 e não o rank 1, 2, 3... **Por quê?**
- O uso de condicionais como `if-else` torna o nosso programa SPMD.

Comunicação - MPI_SEND

UFABC

```
1  int MPI_Send(
2      void*         msg_buf_p    /* in */,
3      int           msg_size     /* in */,
4      MPI_Datatype  msg_type     /* in */,
5      int           dest         /* in */,
6      int           tag          /* in */,
7      MPI_Comm      communicator /* in */);
```

UFABC

Table 3.1 Some Predefined MPI Datatypes

MPI datatype	C datatype
MPI_CHAR	**signed char**
MPI_SHORT	**signed short int**
MPI_INT	**signed int**
MPI_LONG	**signed long int**
MPI_LONG_LONG	**signed long long int**
MPI_UNSIGNED_CHAR	**unsigned char**
MPI_UNSIGNED_SHORT	**unsigned short int**
MPI_UNSIGNED	**unsigned int**
MPI_UNSIGNED_LONG	**unsigned long int**
MPI_FLOAT	**float**
MPI_DOUBLE	**double**
MPI_LONG_DOUBLE	**long double**
MPI_BYTE	
MPI_PACKED	

Comunicação - MPI_Recv

UFABC

```
1  int MPI_Recv(
2      void*         msg_buf_p    /* out */,
3      int           buf_size     /* in  */,
4      MPI_Datatype  buf_type     /* in  */,
5      int           source       /* in  */,
6      int           tag          /* in  */,
7      MPI_Comm      communicator /* in  */,
8      MPI_Status    status       /* out */);
```

UFABC

- Para uma mensagem ser entregue, diversos dos seus atributos precisam *casar* (*message matching*)

```
1  /* o processo com rank p roda a linha abaixo */
2  MPI_Send(send_buf_p, send_buf_sz, send_type, dest,
   ↪  send_tag, send_comm);
3
4  /* o processo com rank q roda a linha abaixo */
5  MPI_Recv(recv_buf_p, recv_buf_sz, recv_type, src,
   ↪  recv_tag, recv_comm, &status);
```

- Tomando o código acima como exemplo, uma mensagem enviada por `q` só será recebida por `r` se:
  - `recv_comm == send_comm` e;
  - `recv_tag == send_tag` e;
  - `dest == r` e;
  - `src == q`

Comunicação - Casamento de mensagens

UFABC

```
MPI_Send(send_buf_p, send_buf_sz, send_type, dest, send_tag,
         send_comm);
```

r

MPI_Send

src = q

MPI_Recv

dest = r

```
MPI_Recv(recv_buf_p, recv_buf_sz, recv_type, src, recv_tag,
         recv_comm, &status);
```

q

Recebendo mensagens

UFABC

- O `MPI_Recv` tem como parâmetros de saída apenas o buffer e o status
- A variável de status do tipo `MPI_Status` contém
  - O tamanho da mensagem
  - A origem (!) da mensagem
  - A tag (!) da mensagem

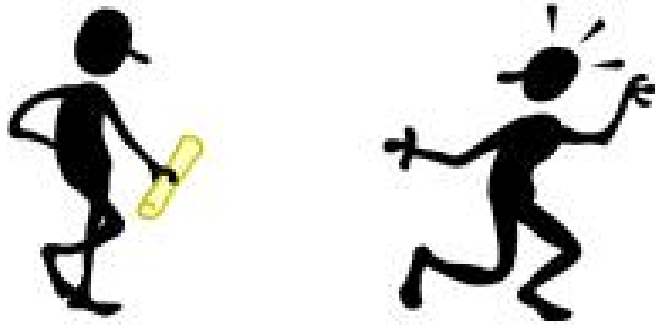

Recebendo mensagens

UFABC

- O `MPI_Recv` tem como parâmetros de saída apenas o buffer e o status
- A variável de status do tipo `MPI_Status` contém
  - O tamanho da mensagem
  - A origem (!) da mensagem
  - A tag (!) da mensagem

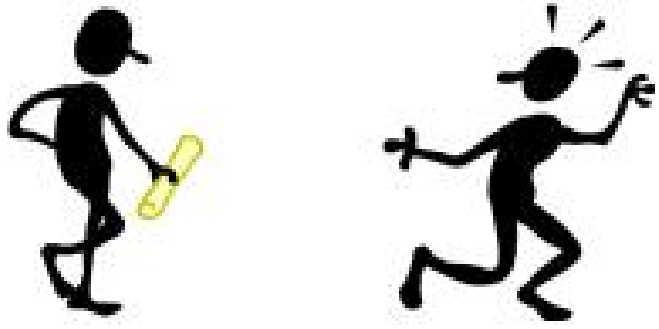

  - Existem parâmetros especiais `MPI_ANY_SOURCE` e `MPI_ANY_TAG` que aceitam mensagens vindas de **qualquer fonte e qualquer tag**

Recebendo mensagens

UFABC

- `MPI_Status` é uma struct com pelo menos os seguintes campos
  - `MPI_SOURCE`
  - `MPI_TAG`
  - `MPI_ERROR`
- Quantos dados foram recebidos?

```
1  int MPI_Get_count(
2      MPI_Status*  status_p /* in */,
3      MPI_Datatype type     /* in */,
4      int*         count_p  /* out */);
```

MPI_Status - Exemplo

UFABC

```
1  MPI_Status status;
2  MPI_Recv(recv_buf_p, recv_buf_sz, recv_type,
   ↪  MPI_ANY_SOURCE, MPI_ANY_TAG, recv_comm, &status);
3
4  int src = status.MPI_SOURCE;
5  int tag = status.MPI_TAG;
6  int count;
7  MPI_Get_count(&status, recv_type, &count);
8  ...
```

Problemas com o *send* e o *receive*

UFABC

- O comportamento exato do programa é determinado pela implementação de MPI escolhida
- `MPI_Send` pode se comportar de maneira diferente com relação ao tamanho do *buffer*, *cutoffs* ou *blocking*
- `MPI_Recv` sempre bloqueia até que uma mensagem que case seja recebida
- Estude a implementação que você escolher! Não assuma nada!

Aproximação trapezoidal em MPI

Aproximação trapezoidal em MPI

UFABC

- A ideia é aproximar o valor da integral de uma função $f(x)$ através da soma das áreas de um número crescente de trapézios
- Quanto maior o número de trapézios
  - Melhor a aproximação
  - Maior custo computacional

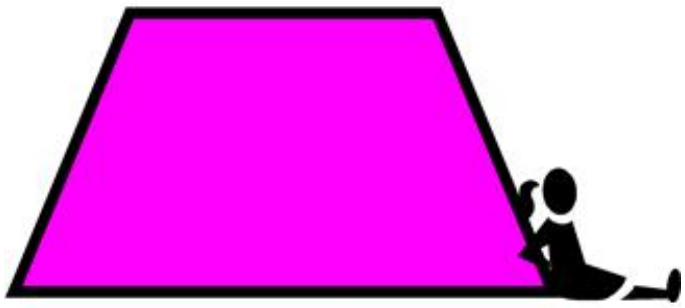

Aproximação trapezoidal

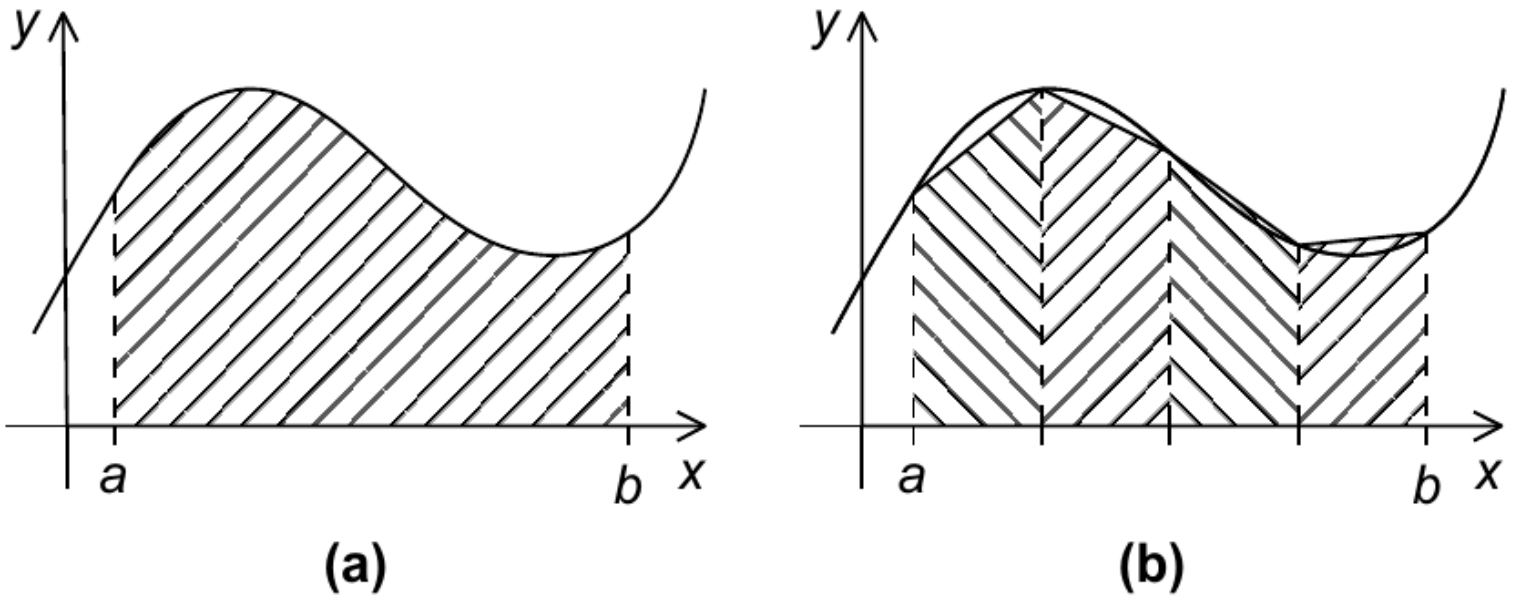

A regra trapezoidal

UFABC

- Área de um trapézio $= \frac{h}{2}[f(x_i) + f(x_{i+1})]$
- $h = \frac{b-a}{n}$
- $x_0 = a, x_1 = a + h, x_2 = a + 2h, \ldots, x_{n-1} = a + (n-1)h,$ $x_n = b$
- Soma de todas as áreas dos trapézios $= h[f(x_0)/2 + f(x_1) + f(x_2) + \ldots + f(x_{n-1}) + f(x_n)/2]$

Aproximação trapezoidal - Um trapézio

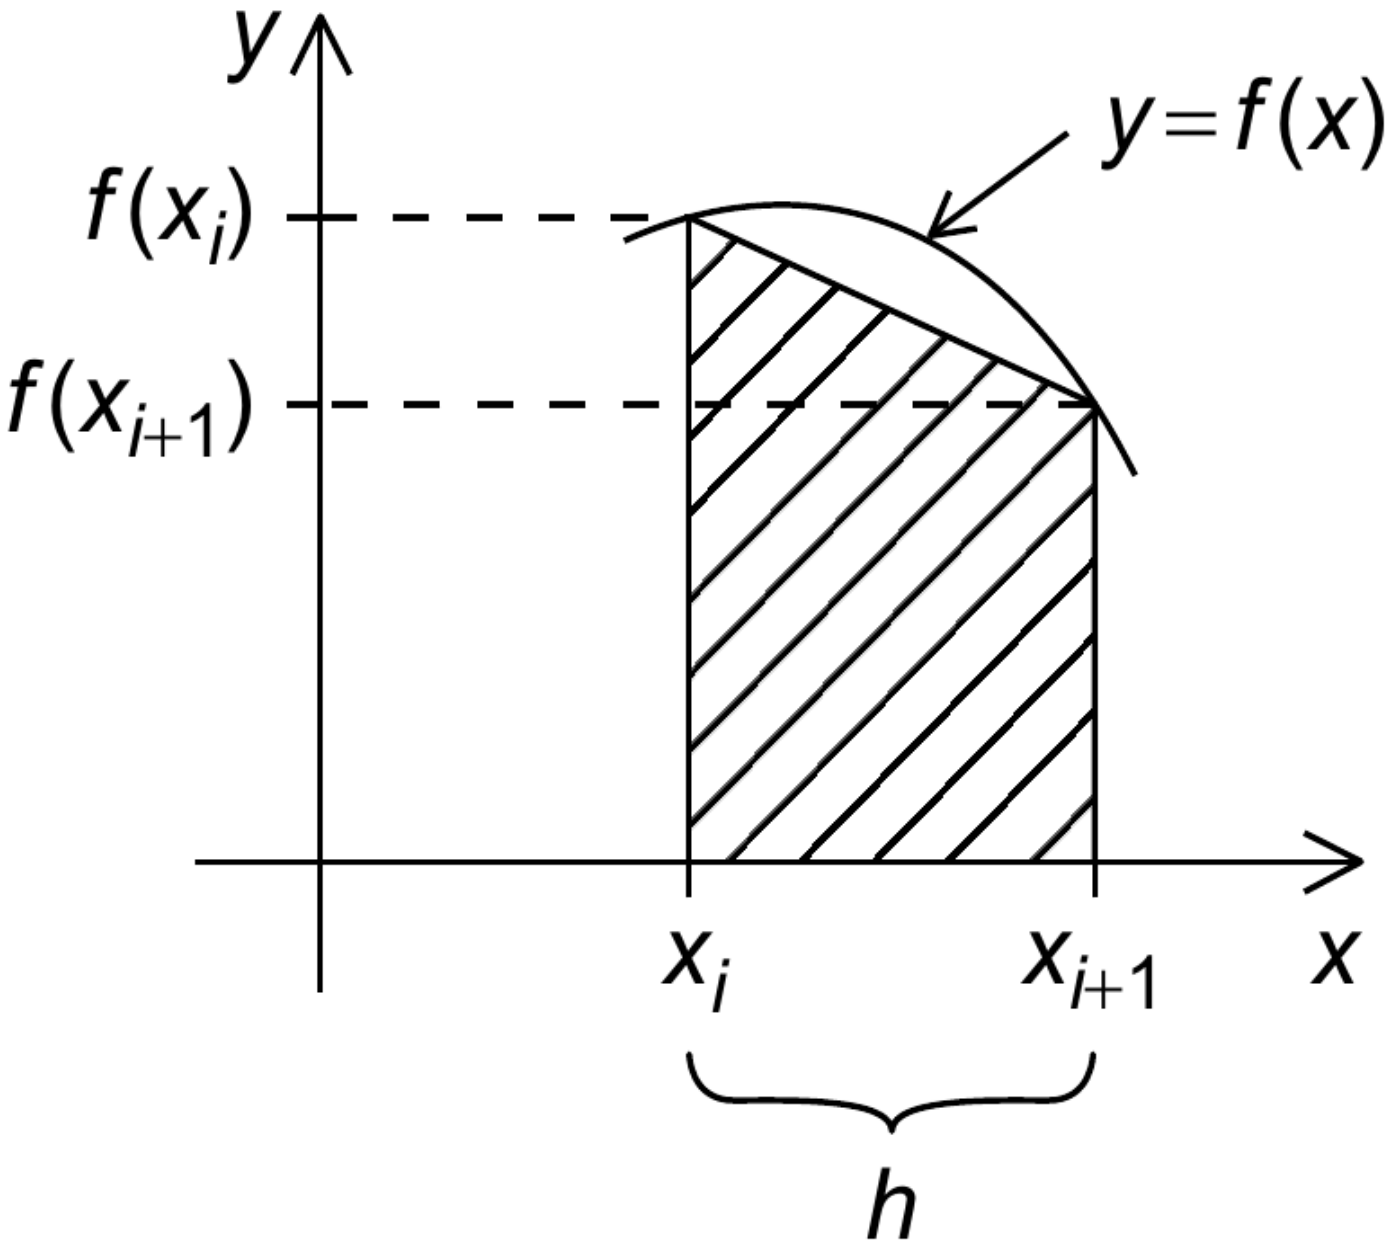

Programa sequencial - Pseudocódigo

UFABC

```
/* Input: a, b, n */
h = (b - a)/n;
approx = (f(a) + f(b))/2.0;
for (i = 1; i <= n - 1; i++) {
    x_i = a + i * h;
    approx += f(x_i);
}
approx = h * approx;
```

Paralelizando o programa sequencial - Foster nele!

UFABC

1. Particione o problema em tarefas
2. Identifique as comunicações entre as tarefas
3. Agregue as tarefas em tarefas compostas
4. Mapeie a execução das tarefas aos cores

Programa paralelo - Pseudocódigo

UFABC

```
Get a, b, n;
h = (b - a)/n;
local_n = n/comm_sz;
local_a = a + my_rank * local_n * h;
local_b = local_a + local_n * h;
local_integral = Trap(local_a,local_b,local_n, h);
```

Programa paralelo - Pseudocódigo

```
if (my_rank != 0)
    Send local_integral to process 0;
else { /* my_rank == 0 */
    total_integral = local_integral;
    for (proc = 1; proc < comm_sz; proc++) {
        Receive local_integral from proc;
        total_integral += local_integral;
    }
}
if (my_rank == 0)
    print result;
```

Tarefas e comunicações para a aproximação trapezoidal

UFABC

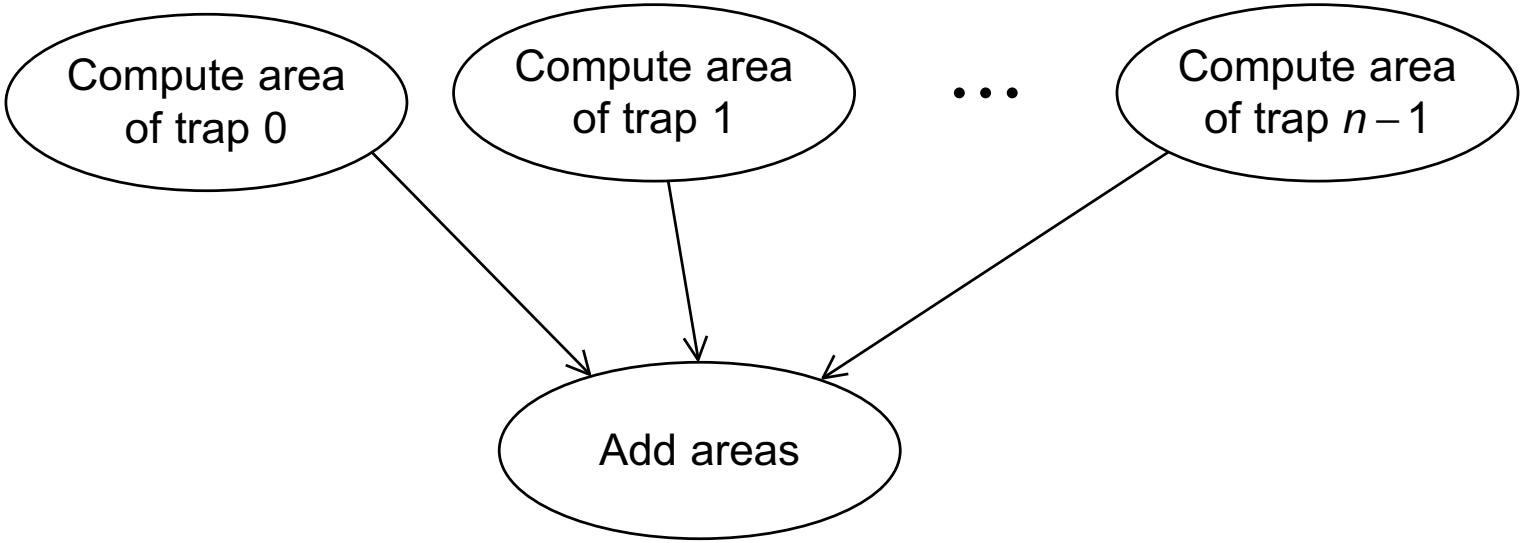

Versão 1 do código (Parte 1)

UFABC

```
1  int main(void) {
2      int my_rank, comm_sz, n = 1024, local_n;
3      double a = 0.0, b = 3.0, h, local_a, local_b;
4      double local_int, total_int;
5      int source;
6
7      MPI_Init(NULL, NULL);
8      MPI_Comm_rank(MPI_COMM_WORLD, &my_rank);
9      MPI_Comm_size(MPI_COMM_WORLD, &comm_sz);
10
11     ...
```

Versão 1 do código (Parte 2)

UFABC

```
1  ...
2
3  h = (b-a)/n;
4  local_n = n/comm_sz;
5  local_a = a + my_rank*local_n*h;
6  local_b = local_a + local_n*h;
7  local_int = Trap(local_a, local_b, local_n, h);
8
9  ...
```

Versão 1 do código (Parte 3)

UFABC

```
1  ...
2
3  /* Soma as integrais parciais calculadas por cada um dos
4     processos */
5  if (my_rank != 0) {
6      MPI_Send(&local_int, 1, MPI_DOUBLE, 0, 0,
7               MPI_COMM_WORLD);
8   } else {
9      total_int = local_int;
10     for (source = 1; source < comm_sz; source++) {
11         MPI_Recv(&local_int, 1, MPI_DOUBLE, source, 0,
12                  MPI_COMM_WORLD, MPI_STATUS_IGNORE);
13         total_int += local_int;
14     }
15  }
16
17  ...
```

Versão 1 do código (Parte 4)

UFABC

```
1       ...
2
3       /* Imprime o resultado */
4       if (my_rank == 0) {
5           printf("With n = %d trapezoids, our estimate\n",
            ↪  n);
6           printf("of the integral from %f to %f =
            ↪  %.15e\n",
7                   a, b, total_int);
8        }
9
10      MPI_Finalize();
11      return 0;
12  } /*  main  */
```

Versão 1 do código (Parte 5)

UFABC

```
1  double Trap(double left, double right, int n_traps,
   ↪  double base_len) {
2
3      double estimate, x;
4      int i;
5
6      estimate = (f(left) + f(right))/2.0;
7      for (i = 1; i <= n_traps-1; i++) {
8         x = left + i*base_len;
9         estimate += f(x);
10     }
11     estimate = estimate*base_len;
12
13     return estimate;
14 }
```

UFABC

Considere o seguinte programa. **O que ele imprime?**

```c
#include <stdio.h>
#include <mpi.h>
int main(void) {
    int my_rank, comm_sz;
    MPI Init(NULL, NULL);
    MPI Comm size(MPI COMM WORLD, &comm_sz);
    MPI Comm rank(MPI COMM WORLD, &my_rank);
    printf("Proc %d of %d > Does anyone have a
    ↪  toothpick?\n", my_rank, comm_sz);
    MPI Finalize();
    return 0;
}
```

Resultado da execução com 6 processos

UFABC

```
Proc 0 of 6 > Does anyone have a toothpick?
Proc 1 of 6 > Does anyone have a toothpick?
Proc 2 of 6 > Does anyone have a toothpick?
Proc 4 of 6 > Does anyone have a toothpick?
Proc 3 of 6 > Does anyone have a toothpick?
Proc 5 of 6 > Does anyone have a toothpick?
```

Saída imprevisível!

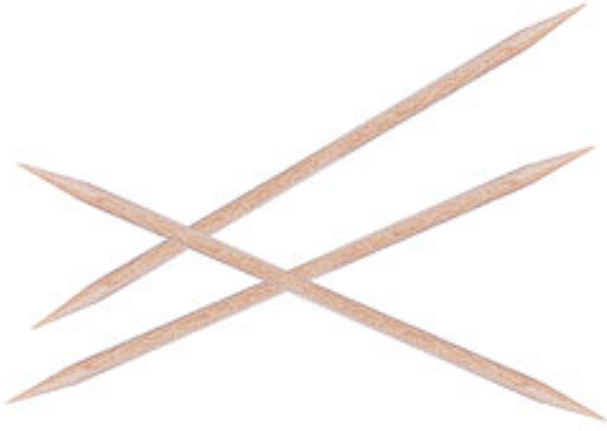

UFABC

- A maior parte das implementações de MPI só permite acesso à `stdin` pelo processo com rank 0 relativo ao comunicador `MPI_COMM_WORLD`
- O processo 0 deve ler a entrada (com `scanf` por exemplo) e enviar o que for necessário aos demais processos

```
1  ...
2  MPI_Comm_rank(MPI_COMM_WORLD, &my_rank);
3  MPI_Comm_size(MPI_COMM_WORLD, &comm_sz);
4  Get_data(my_rank, comm_sz, &a, &b, &n);
5  h = (b - a)/n;
6  ...
```

Uma função para ler a entrada do usuário

UFABC

```
1  void Get_input(int my_rank, int comm_sz, double* a_p,
   ↪  double* b_p, int* n_p) {
2      int dest;
3      /* caso seja o processo mestre */
4      if (my_rank == 0) {
5          printf("Enter a, b, and n\n");
6          scanf("%lf %lf %d", a_p, b_p, n_p);
7          for (dest = 1; dest < comm_sz; dest++) {
8              MPI_Send(a_p, 1, MPI_DOUBLE, dest, 0,
                ↪  MPI_COMM_WORLD);
9              MPI_Send(b_p, 1, MPI_DOUBLE, dest, 0,
                ↪  MPI_COMM_WORLD);
10             MPI_Send(n_p, 1, MPI_INT, dest, 0,
                ↪  MPI_COMM_WORLD);
11         }
12     } else { /* my_rank != 0 */
13     ...
```

Uma função para ler a entrada do usuário

UFABC

```
1  ...
2          } else { /* my_rank != 0 */
3              MPI_Recv(a_p, 1, MPI_DOUBLE, 0, 0,
                ↪  MPI_COMM_WORLD, MPI_STATUS_IGNORE);
4              MPI_Recv(b_p, 1, MPI_DOUBLE, 0, 0,
                ↪  MPI_COMM_WORLD, MPI_STATUS_IGNORE);
5              MPI_Recv(n_p, 1, MPI_INT, 0, 0,
                ↪  MPI_COMM_WORLD, MPI_STATUS_IGNORE);
6          }
7      }
```

Comunicação coletiva

Comunicação estruturada como uma árvore

UFABC

1. Primeira fase
    1. Processo 1 envia ao 0, 3 ao 2, 5 ao 4, e 7 ao 6
    2. Processos 0, 2, 4 e 6 acumulam os valores recebidos
    3. Processos 2 e 6 enviam os valores calculados aos processos 0 e 4 respectivamente
    4. Processos 0 e 4 acumulam os valores recebidos
2. Segunda fase
    1. Processo 4 envia o valor calculado ao processo 0
    2. Processo 0 acumula o valor recebido ao seu valor calculado mais recente

Uma soma estruturada como árvore

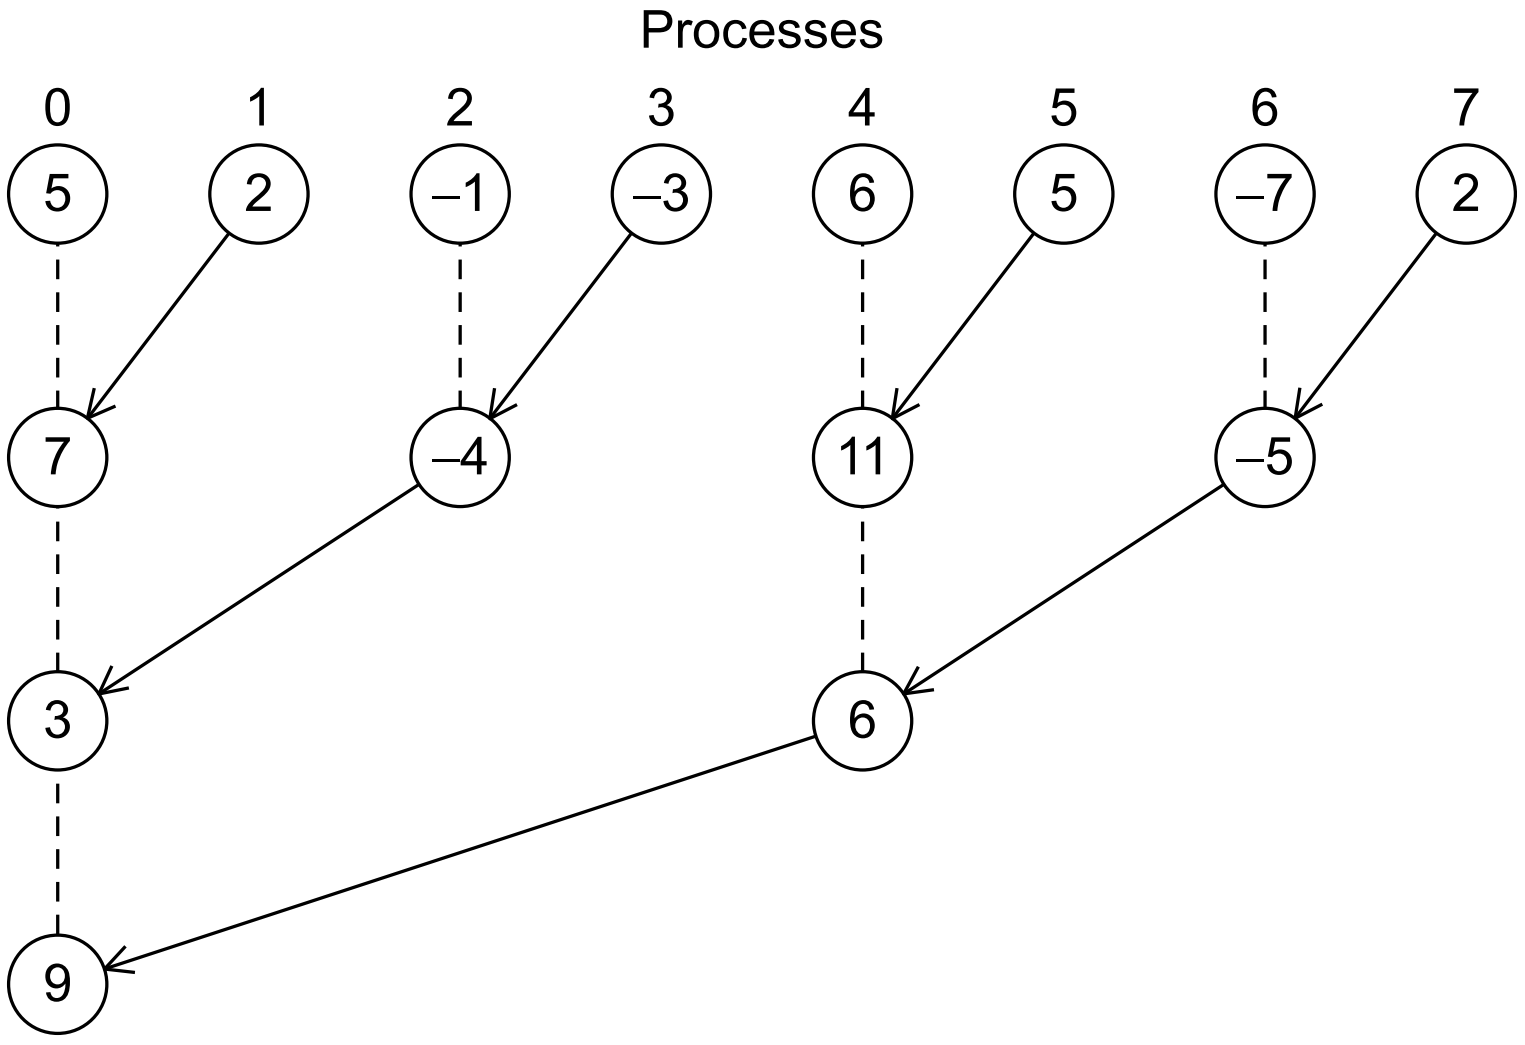

Uma soma estruturada como árvore - Alternativa

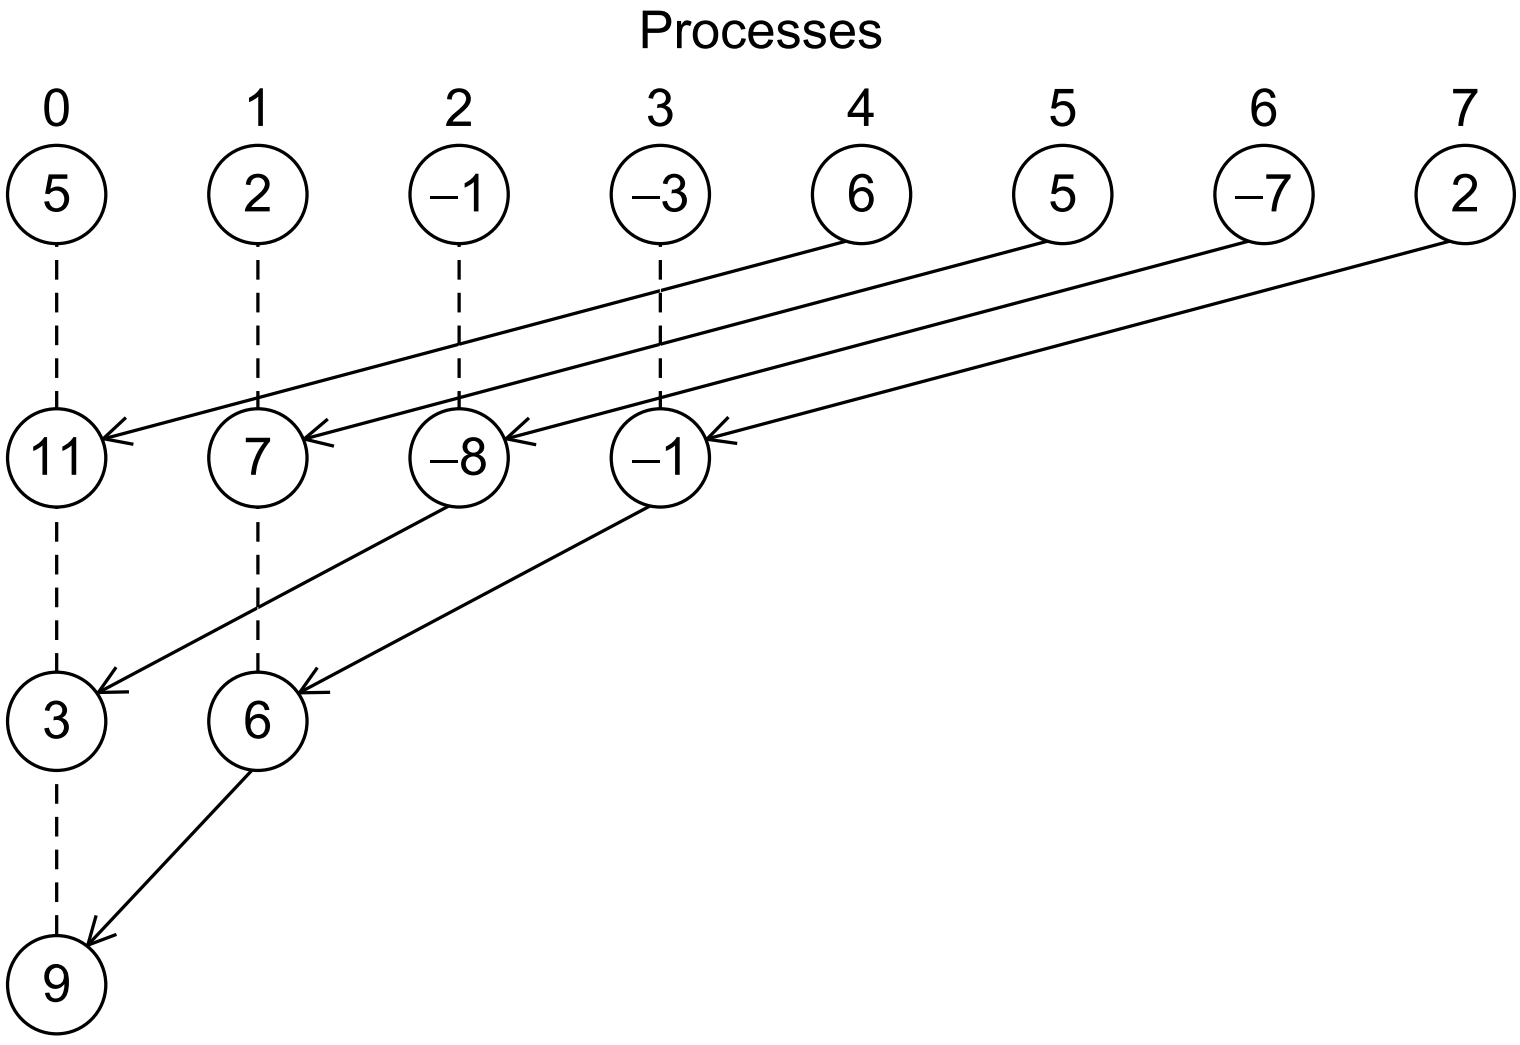

MPI_Reduce

UFABC

```
int MPI Reduce(
    void*         input_data_p  /* in */,
    void*         output_data_p /* out */,
    int           count         /* in */,
    MPI_Datatype  datatype      /* in */,
    MPI_Op        operator      /* in */,
    int           dest_process  /* in */,
    MPI_Comm      comm          /* in */);
```

```
MPI_Reduce(&local_int, &total_int, 1, MPI_DOUBLE,
    MPI_SUM, 0, MPI_COMM_WORLD);
```

```
double local x[N], sum[N];
...
MPI_Reduce(local_x, sum, N, MPI_DOUBLE, MPI_SUM, 0,
    MPI_COMM_WORLD);
```

Operações de redução pré-definidas

UFABC

Table 3.2 Predefined Reduction Operators in MPI

Operation Value	Meaning
MPI_MAX	Maximum
MPI_MIN	Minimum
MPI_SUM	Sum
MPI_PROD	Product
MPI_LAND	Logical and
MPI_BAND	Bitwise and
MPI_LOR	Logical or
MPI_BOR	Bitwise or
MPI_LXOR	Logical exclusive or
MPI_BXOR	Bitwise exclusive or
MPI_MAXLOC	Maximum and location of maximum
MPI_MINLOC	Minimum and location of minimum

Funções coletivas *vs.* ponto-a-ponto

UFABC

- **Todos** os processos do comunicador devem chamar a **mesma** função coletiva
- Por exemplo, um programa que chama `MPI_Reduce` em um processo enquanto outro processo faz uma chamada ao `MPI_Recv` está incorreto e muito provavelmente vai travar (entrar em um impasse) ou até mesmo capotar[1]

[1] Termo não tão técnico contudo também é uma excelente tradução de *crash*

Funções coletivas *vs.* ponto-a-ponto

UFABC

- Assim como na comunicação ponto a ponto, os argumentos das chamadas às funções coletivas tem que *casar*
- Por exemplo, se um processo passa 0 como `dest_process` e outro passa 1, então a saída da chamada ao `MPI_Reduce` não vai casar causando capotes[2] ou até mesmo impasses.

[2] Outro termo muito técnico

UFABC

- O argumento `output_data_p` é utilizado apenas no `dest_process`
- Contudo, todos os processos precisam completar o parâmetro com algo (dada a sintaxe da linguagem C). Como o parâmetro será ignorado nos processos não destino, pode-se enviar `NULL` sem problemas.

Funções coletivas *vs.* ponto-a-ponto

UFABC

- Comunicações ponto-a-ponto são casadas baseando-se em tags e comunicadores
- Comunicações coletivas não usam tags $\rightarrow$ Comunicações coletivas são casadas baseando-se, apenas, na ordem em que são chamadas

UFABC

Table 3.3 Multiple Calls to `MPI_Reduce`

Time	Process 0	Process 1	Process 2
0	`a = 1; c = 2`	`a = 1; c = 2`	`a = 1; c = 2`
1	`MPI_Reduce(&a, &b, ...)`	`MPI_Reduce(&c, &d, ...)`	`MPI_Reduce(&a, &b, ...)`
2	`MPI_Reduce(&c, &d, ...)`	`MPI_Reduce(&a, &b, ...)`	`MPI_Reduce(&c, &d, ...)`

Múltiplas chamadas à `MPI_Reduce`

Exemplo

UFABC

- Suponha que cada processo chame `MPI_Reduce` com o operador `MPI_SUM` e com o processo de destino 0
- À primeira vista pode parecer que após as duas chamadas à `MPI_Reduce`, o valor `b` será 3 e o valor `d` será 6

Exemplo

- Note, contudo, que as localizações da memória e o nome das variáveis são irrelevantes para o casamento das chamadas do `MPI_Reduce`
- A ordem das chamadas vai determinar o casamento, logo o valor em **b** será $1 + 2 + 1 = 4$ e o valor armazenado em **d** será $2 + 1 + 2 = 5$

MPI_Allreduce

UFABC

- Útil em uma situação onde todos os processos precisam do resultado de uma redução para continuar a computação

```
1  int MPI_Allreduce(
2      void*         input_data_p  /* in  */,
3      void*         output_data_p /* out */,
4      int           count         /* in  */,
5      MPI_Datatype  datatype      /* in  */,
6      MPI_Op        operator      /* in  */,
7      MPI_Comm      comm          /* in  */);
```

Redução seguida de redistribuição

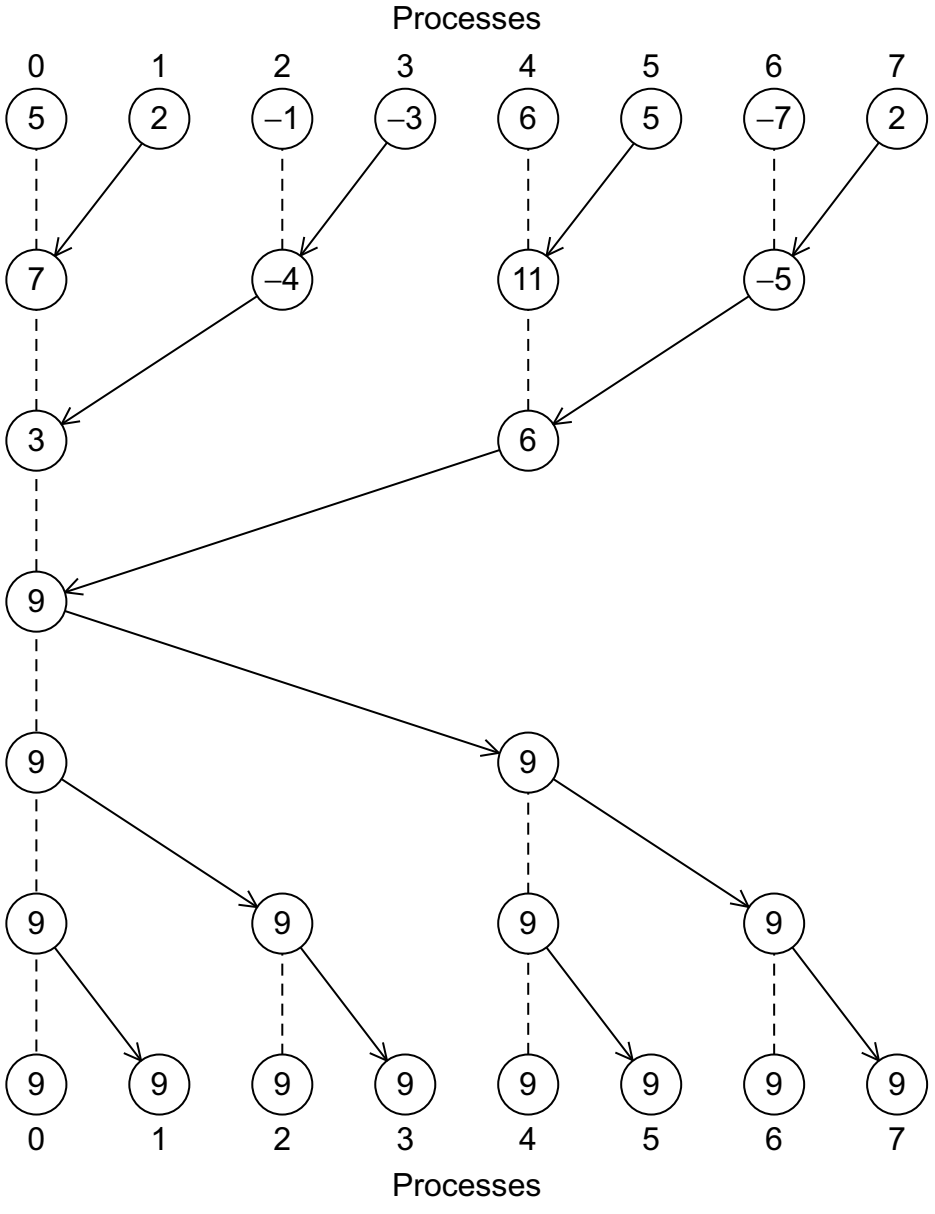

Redução seguida de redistribuição - Borboleta

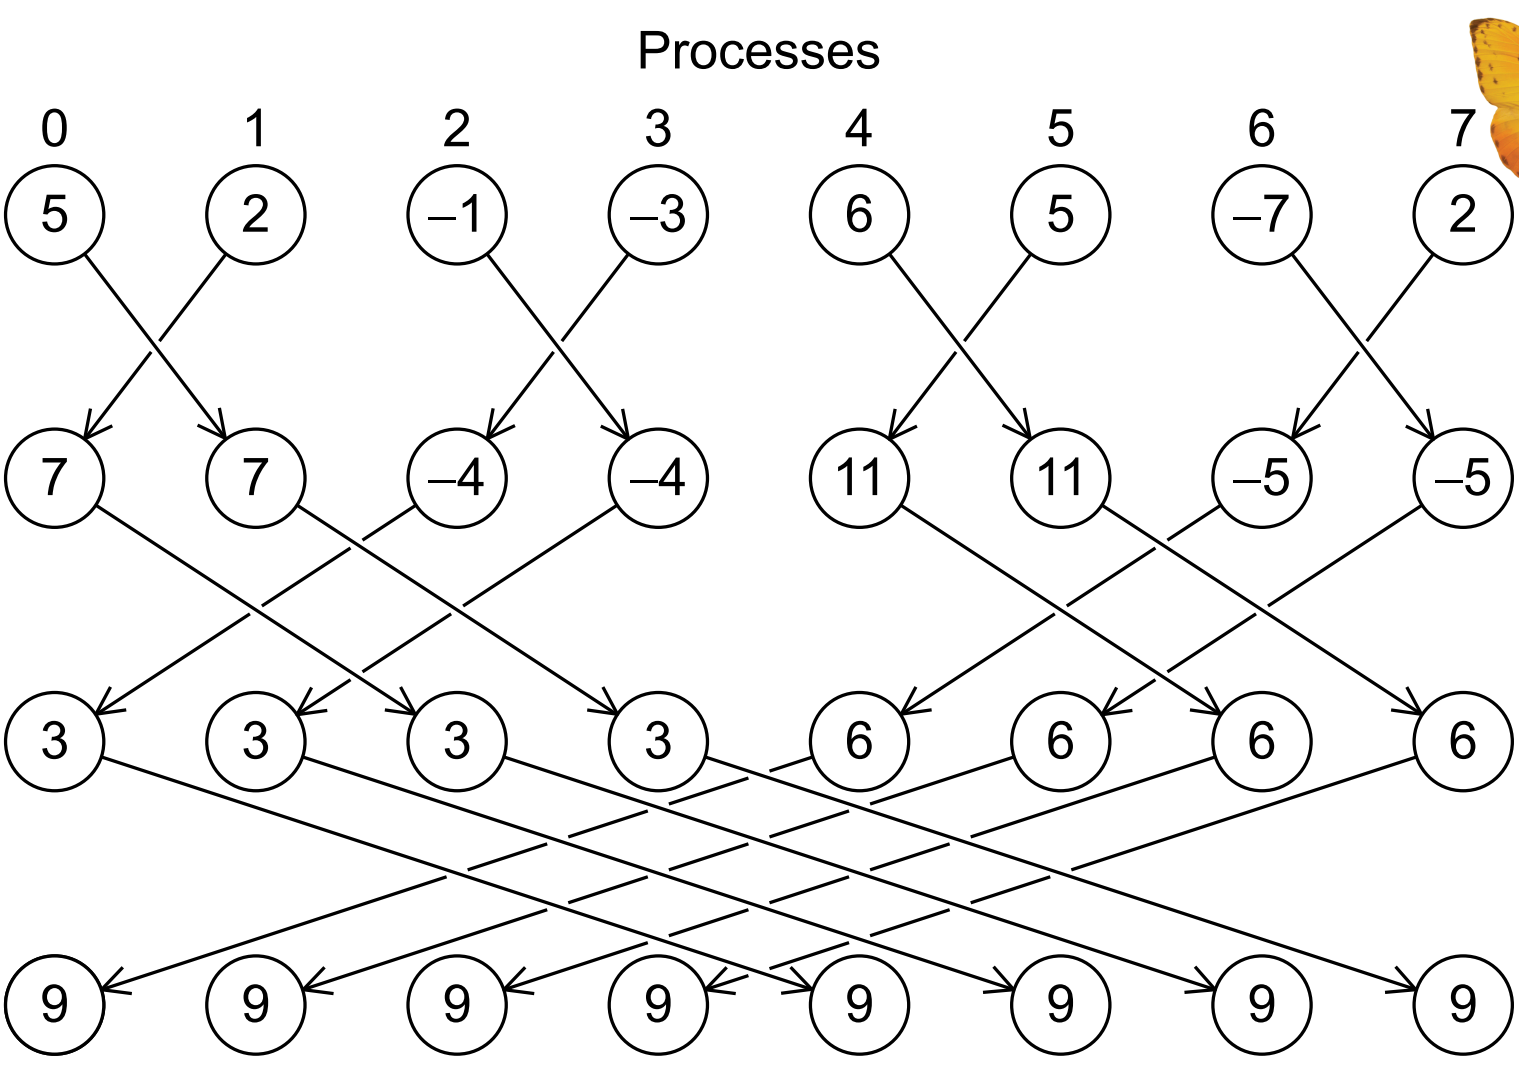

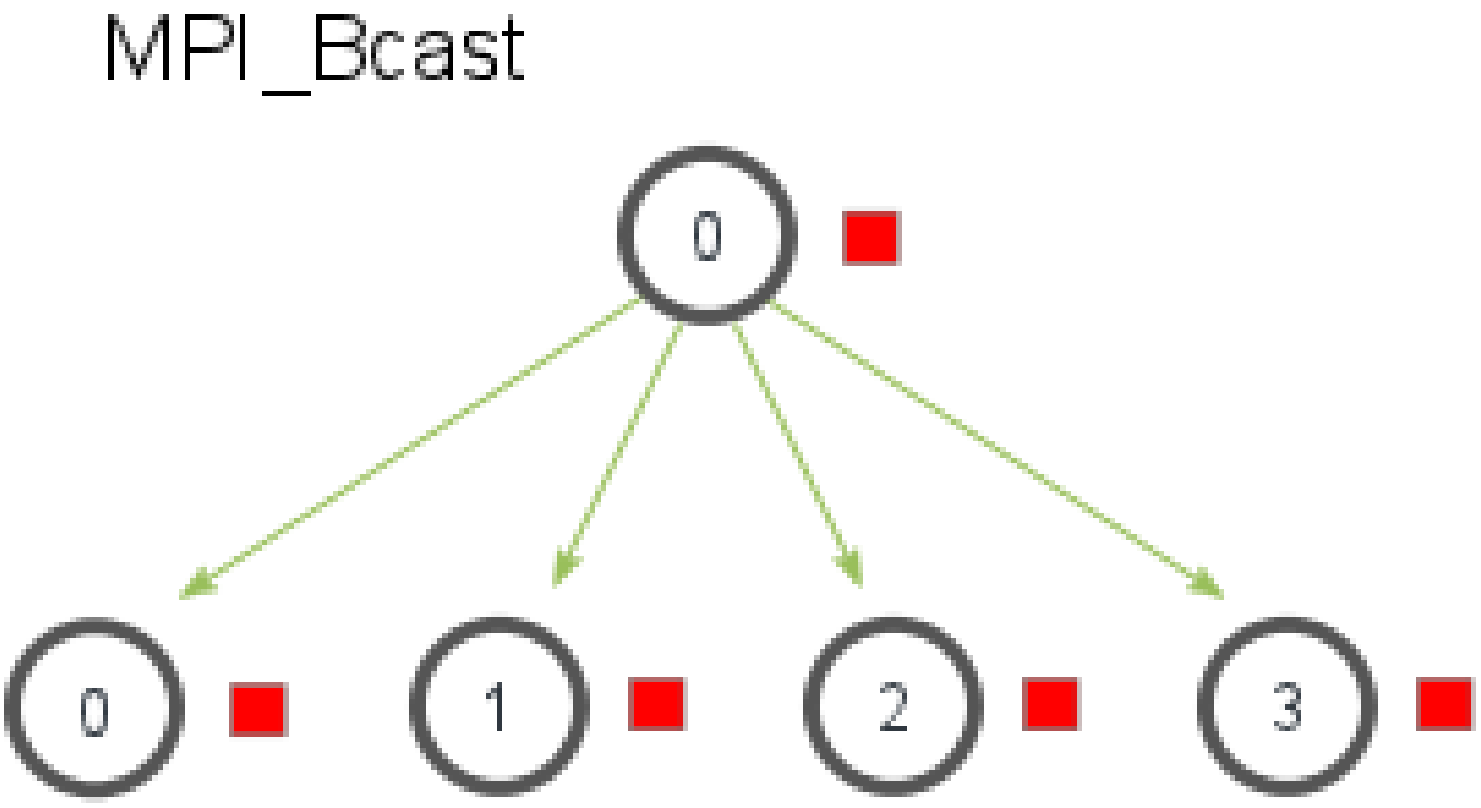

Fonte: http://mpitutorial.com/tutorials/mpi-scatter-gather-and-allgather/

UFABC

- Dados que estão em um processo são enviados a todos os processos do mesmo comunicador

```
1  int MPI_Bcast(
2      void*         data_p      /* in/out */,
3      int           count       /* in     */,
4      MPI_Datatype  datatype    /* in     */,
5      int           source_proc /* in     */,
6      MPI_Comm      comm        /* in     */);
```

Organização das comunicações

UFABC

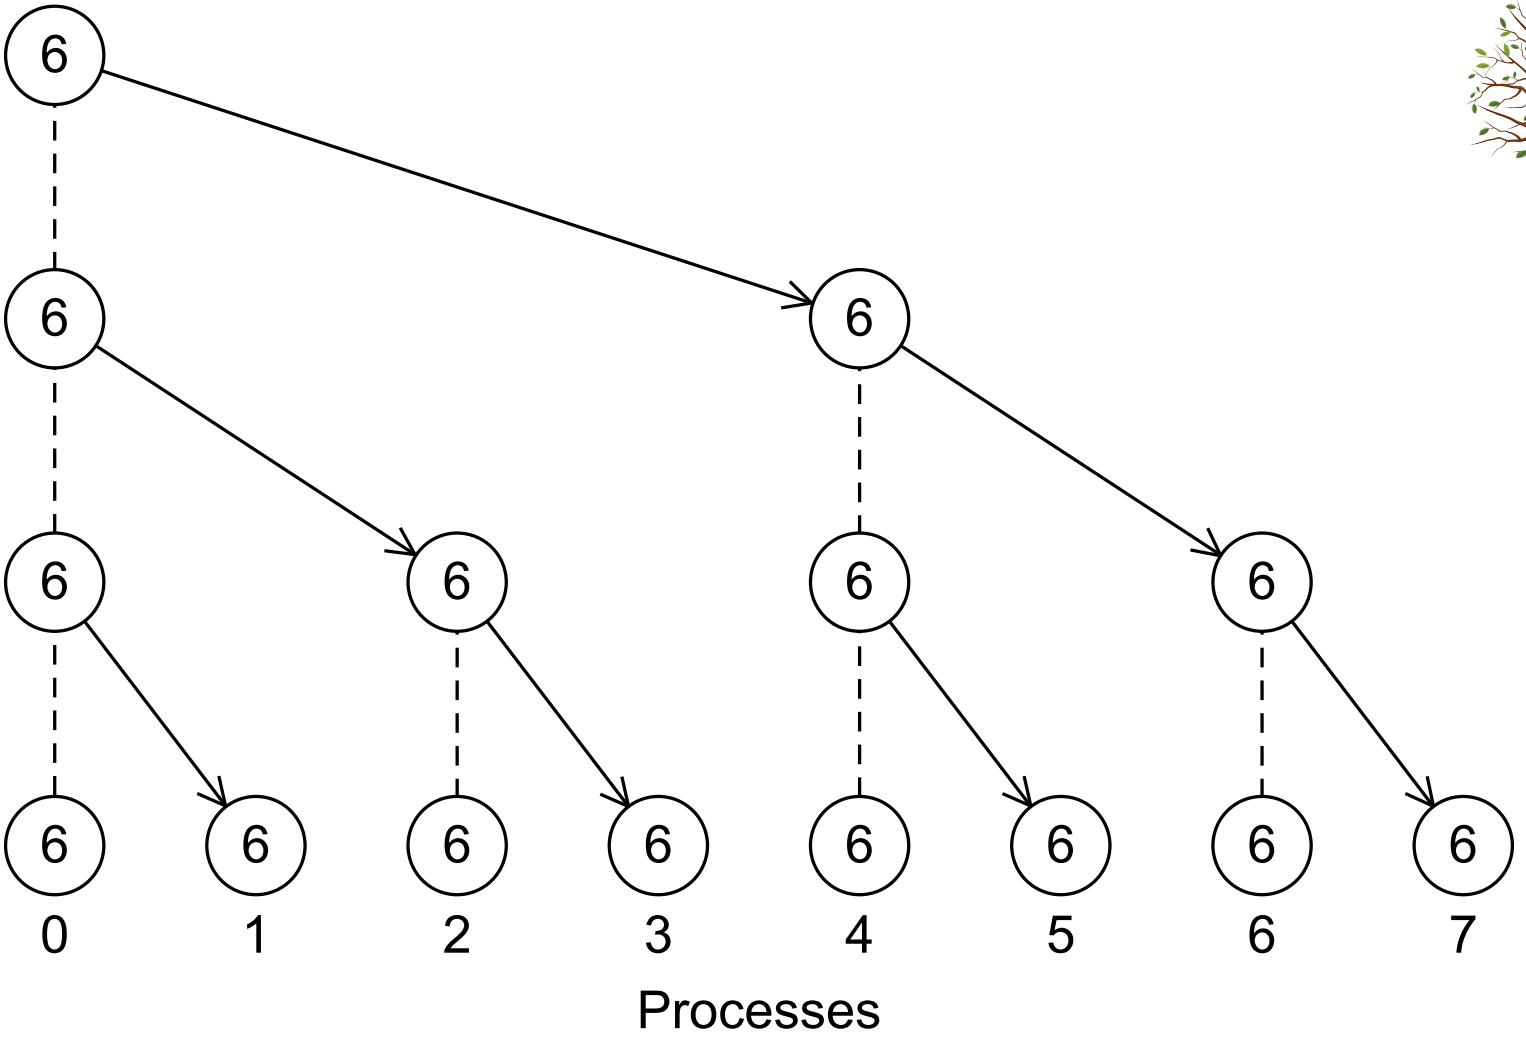

Uma versão do `Get_input` que utiliza `MPI_Broadcast`

UFABC

```
1  void Get_input(int my_rank, int comm_sz, double* a_p,
   ↪  double* b_p, int* n_p) {
2      if (my_rank == 0) {
3          printf("Enter a, b, and n\n");
4          scanf("%lf %lf %d", a_p, b_p, n_p);
5      }
6      MPI_Bcast(a_p, 1, MPI_DOUBLE, 0, MPI_COMM_WORLD);
7      MPI_Bcast(b_p, 1, MPI_DOUBLE, 0, MPI_COMM_WORLD);
8      MPI_Bcast(n_p, 1, MPI_INT, 0, MPI_COMM_WORLD);
9  }
```

UFABC

Queremos computar a soma de vetores

$$x + y = (x_0, x_1, \ldots, x_{n-1}) + (y_0, y_1, \ldots, y_{n-1})$$
$$= (x_0 + y_0, x_1 + y_1, \ldots, xn - 1 + y_{n-1})$$
$$= z$$

Implementação da versão sequencial

UFABC

```
1  void Vector sum(double x[], double y[], double z[], int
   ↪  n) {
2      int i;
3
4      for (i = 0; i < n; i++)
5          z[i] = x[i] + y[i];
6  }
```

Algumas maneiras comuns de particionar vetores

UFABC

Há algumas maneiras bem comuns de particionar os vetores. Abaixo algumas delas.

Table 3.4 Different Partitions of a 12-Component Vector among Three Processes

Process	Components											
	Block				Cyclic				Block-Cyclic Blocksize = 2			
0	0	1	2	3	0	3	6	9	0	1	6	7
1	4	5	6	7	1	4	7	10	+6’	3	8	9
2	8	9	10	11	2	5	8	11	4	5	10	11

Opções de particionamento

UFABC

- Particionamento em blocos
  - Atribui-se blocos contendo componentes consecutivos a cada processo
- Particionamento cíclico
  - Atribui-se os componentes utilizando *round-robin*
- Particionamento bloco-cíclico
  - Utiliza-se uma atribuição cíclica de blocos

Soma de vetores - Implementação paralela

UFABC

```
1  void Parallel_vector_sum(
2      double  local_x[]  /* in  */,
3      double  local_y[]  /* in  */,
4      double  local_z[]  /* out */,
5      int     local_n    /* in  */) {
6
7          int local_i;
8
9      for (local_i = 0; local_i < local_n; local_i++)
10         local_z[local_i] = local_x[local_i] +
           ↪  local_y[local_i];
11 }
```

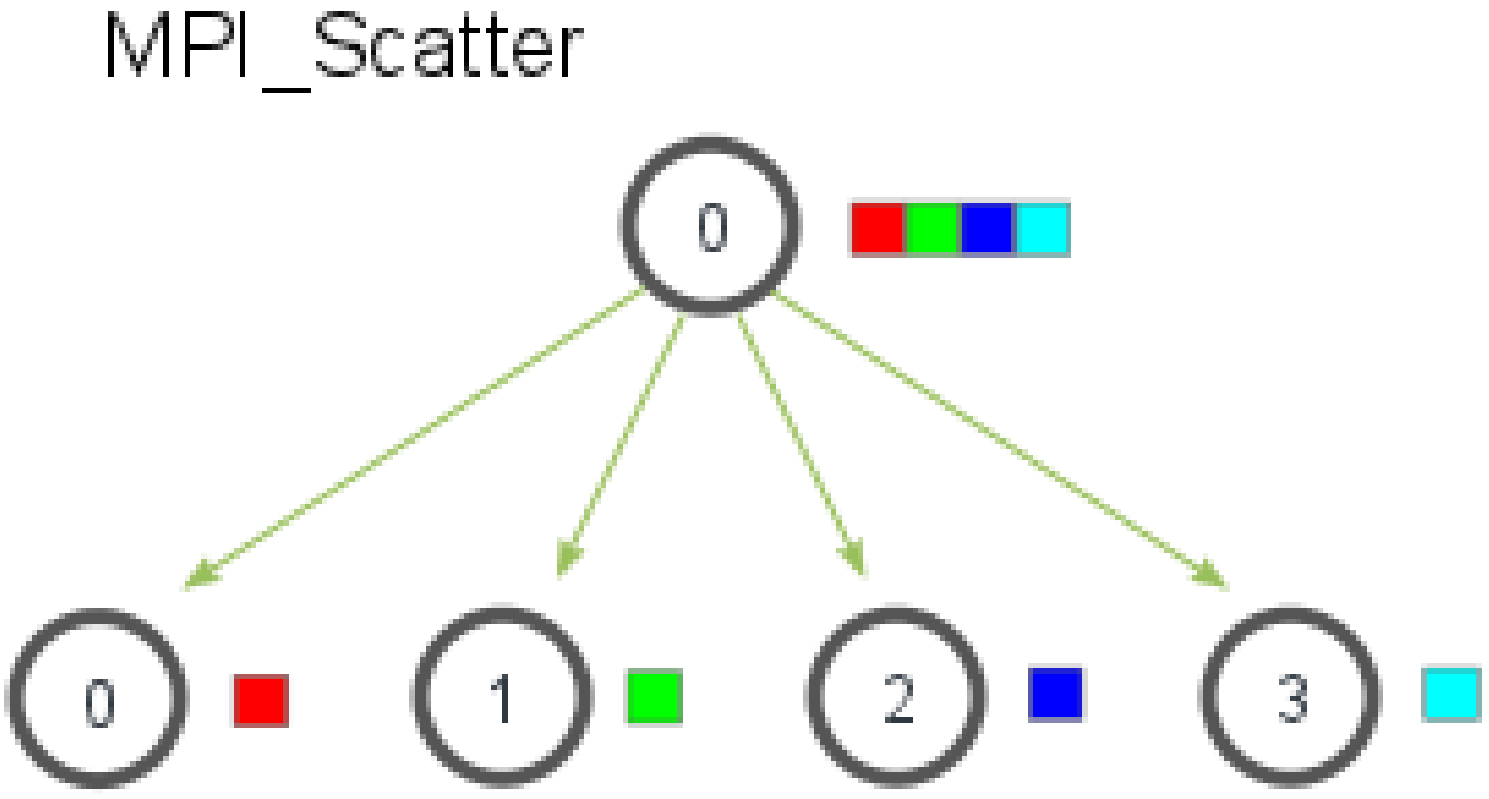

Fonte: http://mpitutorial.com/tutorials/mpi-scatter-gather-and-allgather/

MPI_Scatter

UFABC

- A função `MPI_Scatter` pode ser usada, por exemplo, para ler a entrada toda em um processo e distribuir apenas as partes necessárias entre os demais.

```
1  int MPI_Scatter(
2      void*        send_buf_p /* in  */,
3      int          send_count /* in  */,
4      MPI_Datatype send type  /* in  */,
5      void*        recv_buf_p /* out */,
6      int          recv_count /* in  */,
7      MPI_Datatype recv type  /* in  */,
8      int          src_proc   /* in  */,
9      MPI_Comm     comm       /* in  */);
```

Lendo e distribuindo o vetor

UFABC

```
1  void Read_vector(
2                   double    local_a[]   /* out */,
3                   int       local_n     /* in  */,
4                   int       n           /* in  */,
5                   char      vec_name[]  /* in  */,
6                   int       my_rank     /* in  */,
7                   MPI_Comm  comm        /* in  */) {
8
9      double* a = NULL;
10     int i;
11     int local_ok = 1;
12     char* fname = "Read_vector";
13
14     ...
```

Lendo e distribuindo o vetor

UFABC

```
1       ...
2
3       if (my_rank == 0) {
4           a = malloc(n * sizeof(double));
5           printf("Enter the vector %s\n", vec_name);
6           for (i = 0; i < n; i++)
7               scanf("%lf", &a[i]);
8           MPI_Scatter(a, local_n, MPI_DOUBLE, local_a,
            ↪  local_n, MPI_DOUBLE, 0,
9                       comm);
10          free(a);
11      } else {
12          MPI_Scatter(a, local_n, MPI_DOUBLE, local_a,
            ↪  local_n, MPI_DOUBLE, 0,
13                      comm);
14      }
15  }
```

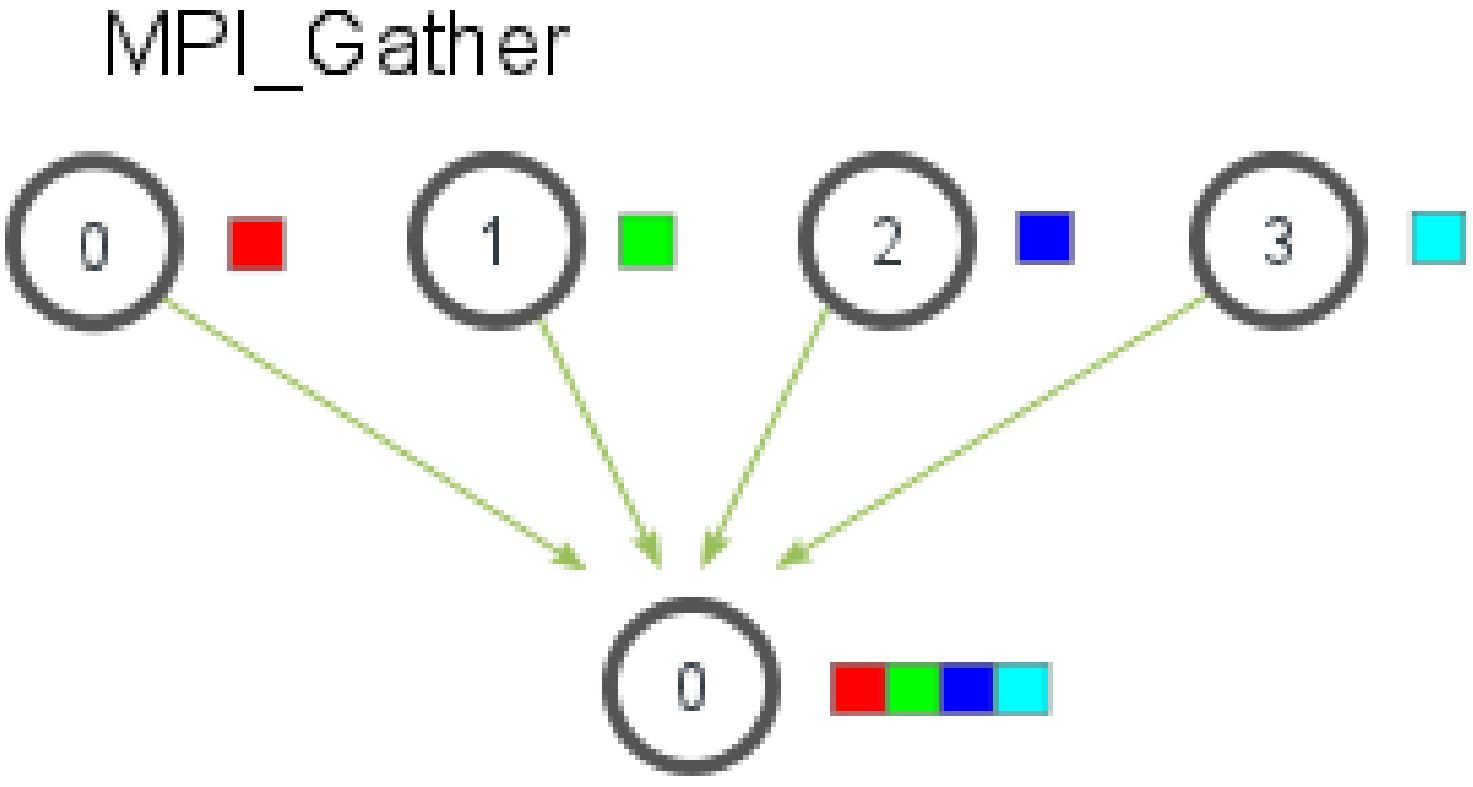

Fonte: http://mpitutorial.com/tutorials/mpi-scatter-gather-and-allgather/

MPI_Gather

UFABC

- A função `MPI_Gather` permite coletr todos os componentes de um vetor em processo para que este possa utilizá-los

```
1  int MPI_Gather(
2      void*        send_buf_p /* in */,
3      int          send_count /* in */,
4      MPI_Datatype send type  /* in */,
5      void*        recv_buf_p /* out */,
6      int          recv_count /* in */,
7      MPI_Datatype recv type  /* in */,
8      int          dest_proc  /* in */,
9      MPI_Comm     comm       /* in */);
```

Imprimindo um vetor distribuído

UFABC

```
1  void Print_vector(
2                    double    local_b[]  /* in */,
3                    int       local_n    /* in */,
4                    int       n          /* in */,
5                    char      title[]    /* in */,
6                    int       my_rank    /* in */,
7                    MPI_Comm  comm       /* in */) {
8
9      double* b = NULL;
10     int i;
11
12     ...
```

Imprimindo um vetor distribuído

UFABC

```
1       ...
2
3       if (my_rank == 0) {
4           b = malloc(n * sizeof(double));
5           MPI_Gather(local_b, local_n, MPI_DOUBLE, b,
            ↪  local_n, MPI_DOUBLE, 0, comm);
6           printf("%s\n", title);
7           for (i = 0; i < n; i++)
8               printf("%f ", b[i]);
9           printf("\n");
10          free(b);
11      } else
12          MPI_Gather(local_b, local_n, MPI_DOUBLE, b,
            ↪  local_n, MPI_DOUBLE, 0, comm);
13  }
```

UFABC

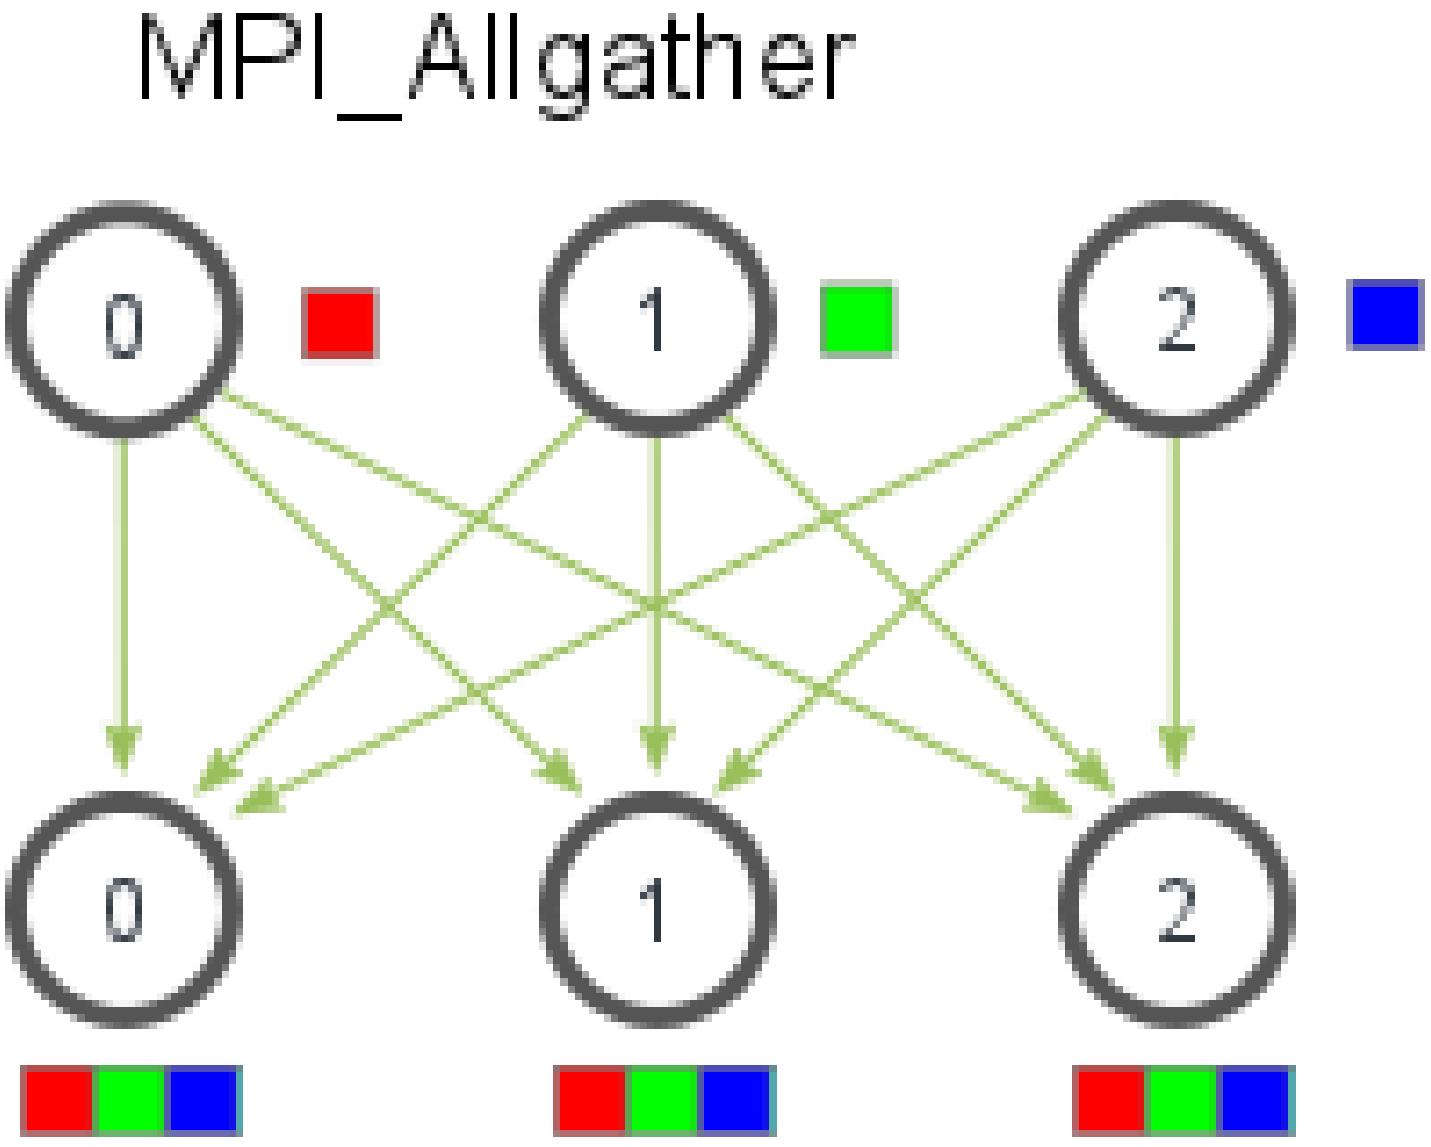

MPI_Allgather

UFABC

- `MPI_Allgather` concatena o conteúdo de cada um dos processos apontado por `send_buf_p` e armazena em cada um dos processos na posição apontada por `recv_buf_p`
- Como de costume, `recv_count` é a quantidade de dados recebida por cada um dos processos

```
1  int MPI_Allgather(
2      void*        send_buf_p /* in */,
3      int          send_count /* in */,
4      MPI_Datatype send_type  /* in */,
5      void*        recv_buf_p /* out*/,
6      int          recv_count /* in */,
7      MPI_Datatype recv_type  /* in */,
8      MPI_Comm     comm       /* in */);
```

Multiplicação vetor × matriz

Multiplicação vetor × matriz

UFABC

- Seja
  - $A = (a_{ij})$, uma matriz $m \times n$
  - x um vetor com n componentes
  - $y = Ax$, um vetor com m componentes
- Então, cada um dos componentes y_i de y se dá por
  - $Y_i = a_{i0}x_0 + a_{i1}x_1 + \ldots + a_{i,n-1}x_{n-1}$
  - Cada Y_i é o produto interno (*dot product*) da i-ésima linha de A por x

Multiplicação vetor × matriz

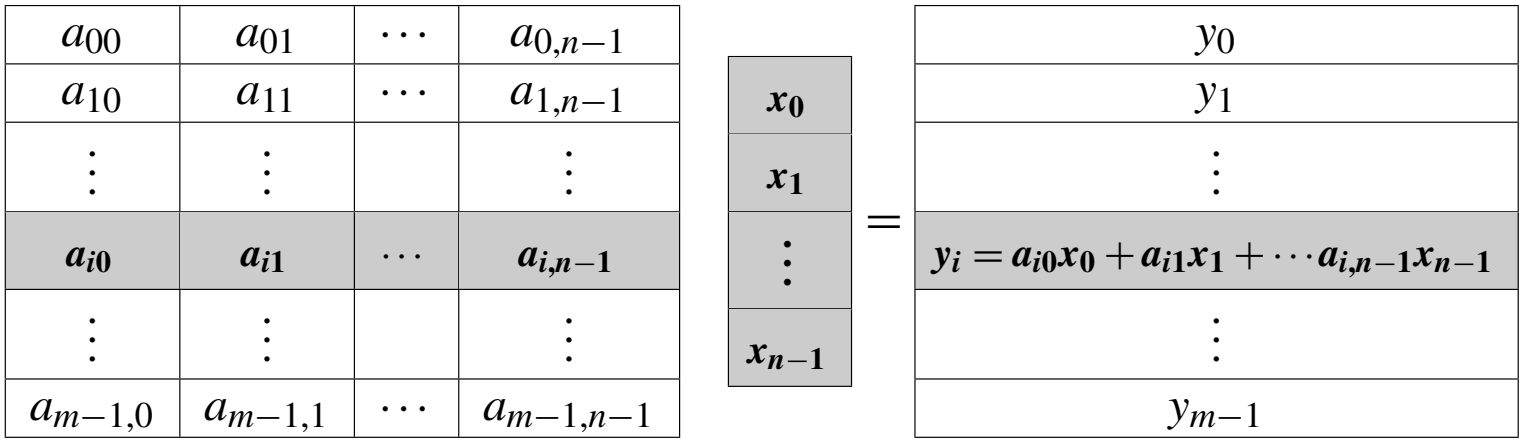

Pseudocódigo sequencial

UFABC

```
/* For each row of A */
for (i = 0; i < m; i++) {
    /* Form dot product of ith row with x */
    y[i] = 0.0;
    for (j = 0; j < n; j++)
        y[i] += A[i][j]*x[j];
}
```

UFABC

$$\begin{pmatrix} 0 & 1 & 2 & 3 \\ 4 & 5 & 6 & 7 \\ 8 & 9 & 10 & 11 \end{pmatrix}$$

será armazenado na memória como uma sequência

```
0 1 2 3 4 5 6 7 8 9 10 11
```

Código sequencial

UFABC

```
1  void Mat_vect_mult(
2       double A[] /* in */,
3       double x[] /* in */,
4       double y[] /* out */,
5       int    m   /* in */,
6       int    n   /* in */) {
7
8       int i, j;
9       for (i = 0; i < m; i++) {
10          y[i] = 0.0;
11          for (j = 0; j < n; j++)
12              y[i] += A[i * n + j] * x[j];
13      }
14 }
```

UFABC

```
1  void Mat_vect_mult(
2                      double    local_A[]  /* in  */,
3                      double    local_x[]  /* in  */,
4                      double    local_y[]  /* out */,
5                      int       local_m    /* in  */,
6                      int       n          /* in  */,
7                      int       local_n    /* in  */,
8                      MPI_Comm  comm       /* in  */) {
9      double* x;
10     int local_i, j;
11
12     ...
```

UFABC

```
1       ...
2
3       x = malloc(n * sizeof(double));
4       MPI_Allgather(local_x, local_n, MPI_DOUBLE,
5                     x, local_n, MPI_DOUBLE, comm);
6
7       for (local_i = 0; local_i < local_m; local_i++) {
8           local_y[local_i] = 0.0;
9           for (j = 0; j < n; j++)
10              local_y[local_i] +=
                ↪  local_A[local_i*n+j]*x[j];
11      }
12      free(x);
13  }
```

Tipos derivados em MPI

Tipos derivados

UFABC

- Usados para representar qualquer coleção de dados em memória
  - Guarda tanto os seus tipos quanto suas posições relativas
- A ideia é a de que se uma função que envie os dados sabe sobre essas informações, ela pode informar o MPI para evitar uma cópia adicional
- Da mesma maneira, uma função que recebe esses dados pode utilizar este mesmo mecanismo

UFABC

- Mais formalmente, um tipo derivado é composto de uma sequência da dados dos tipos básicos do MPI em conjunto com os seus deslocamentos relativos
- Exemplo com o programa da regra trapezoidal

Variável	Endereço
a	24
b	40
n	48

```
{(MPI_DOUBLE,0),(MPI_DOUBLE,16),(MPI_INT,24)}
```

MPI_Type_create_struct

UFABC

- Cria um tipo derivado que consiste de elementos com diferentes tipos básicos do MPI

```
1  int MPI_Type_create_struct(
2      int              count                           /* in  */,
3      int              array_of_blocklengths[]         /* in  */,
4      MPI_Aint         array_of_displacements[] /* in  */,
5      MPI_Datatype     array_of_types[]                /* in  */,
6      MPI_Datatype*    new_type_p                      /* out */);
```

MPI_Get_address

UFABC

- Devolve o endereço da memória relativa ao ponteiro `location_p`
- O tipo especial **`MPI_Aint`** é um inteiro que é grande suficiente para armazenar um ponteiro na máquina

```
1  int MPI_Get_address(
2      void*      location_p /* in  */,
3      MPI_Aint* address_p  /* out */);
```

MPI_Type_commit

UFABC

- Otimiza a representação interna do tipo pelo MPI para acelerar as comunicações

```
1  int MPI_Type_commit(MPI_Datatype* new_mpi_t_p /*
   ↪  in/out */);
```

MPI_Type_free

UFABC

- Quando as comunicações estiverem finalizadas, libera o espaço armazenado pelas estruturas internas do MPI

```
1  int MPI_Type_free(MPI_Datatype* old_mpi_t_p /*
   ↪  in/out */);
```

Exemplo - Função para obtenção da entrada

UFABC

```
1  void Build_mpi_type(
2     double*         a_p              /* in  */,
3     double*         b_p              /* in  */,
4     int*            n_p              /* in  */,
5     MPI_Datatype*   input_mpi_t_p    /* out */) {
6
7  int array_of_blocklengths[3] = {1, 1, 1};
8  MPI_Datatype array_of_types[3] = {MPI_DOUBLE,
   ↪  MPI_DOUBLE, MPI_INT};
9  MPI_Aint a_addr, b_addr, n_addr;
10 MPI_Aint array_of_displacements[3] = {0};
11
12 ...
```

Exemplo - Função para obtenção da entrada

```
1     ...
2
3     MPI_Get_address(a_p, &a_addr);
4     MPI_Get_address(b_p, &b_addr);
5     MPI_Get_address(n_p, &n_addr);
6     array_of_displacements[1] = b_addr-a_addr;
7     array_of_displacements[2] = n_addr-a_addr;
8     MPI_Type_create_struct(3, array_of_blocklengths,
9           array_of_displacements, array_of_types,
10          input_mpi_t_p);
11    MPI_Type_commit(input_mpi_t_p);
12  }
```

Exemplo - Função para obtenção da entrada

UFABC

```
1  void Get_input(
2                int      my_rank  /* in  */,
3                int      comm_sz  /* in  */,
4                double*  a_p      /* out */,
5                double*  b_p      /* out */,
6                int*     n_p      /* out */) {
7      MPI_Datatype input_mpi_t;
8      Build_mpi_type(a_p, b_p, n_p, &input_mpi_t);
9
10     if (my_rank == 0) {
11         printf("Enter a, b, and n\n");
12         scanf("%lf %lf %d", a_p, b_p, n_p);
13     }
14     MPI_Bcast(a_p, 1, input_mpi_t, 0, MPI_COMM_WORLD);
15     MPI_Type_free(&input_mpi_t);
16 }
```

Avaliação de desempenho

Tempo decorrido paralelo

UFABC

- A função **MPI_Wtime** devolve o número de segundos desde algum momento arbitrário no passado

```
1  double MPI_Wtime(void);
2
3  double inicio, fim;
4  inicio = MPI_Wtime();
5  /* Faz um monte de coisas interessantes */
6  fim = MPI_Wtime();
7  printf("O código interessante no processador %d levou %e
   ↪  segundos\n", my_rank, finish - start);
```

Tempo decorrido sequencial

UFABC

- Neste caso você não precisa *linkar* com a biblioteda do MPI
- Veja exemplos de como medir o tempo no código disponível na página da disciplina

MPI_Barrier

UFABC

- Garante que nenhum processo vai receber o controle de volta (a função bloqueia) até que todos os processos no comunicador tenham alcançado esta chamada

```
1  int MPI_Barrier(MPI_Comm comm /* in */);
```

MPI_Barrier

UFABC

O seguinte código pode ser utilizado para medir o tempo de um bloco de código com chamadas MPI e obter uma única medida

```
1  double local_start, local_finish, local_elapsed,
   ↪  elapsed;
2
3  MPI_Barrier(comm);
4  local_start = MPI_Wtime();
5  /* Código a ser medido */
6  local_finish = MPI_Wtime();
7  local_elapsed = local_finish - local_start;
8  MPI_Reduce(&local_elapsed, &elapsed, 1, MPI_DOUBLE,
   ↪  MPI_MAX, 0, comm);
9  if (my_rank == 0)
10     printf("Tempo decorrido = %e segundos\n", elapsed);
```

Tempo de execução de uma sequência de multiplicações matriz/vetor

UFABC

Table 3.5 Run-Times of Serial and Parallel Matrix-Vector Multiplication (times are in milliseconds)

	Order of Matrix				
comm_sz	*1024*	*2048*	*4096*	*8192*	*16,384*
1	4.1	16.0	64.0	270	1100
2	2.3	8.5	33.0	140	560
4	2.0	5.1	18.0	70	280
8	1.7	3.3	9.8	36	140
16	1.7	2.6	5.9	19	71

UFABC

$$S(n,p) = \frac{T_{\text{sequencial}}(n)}{T_{\text{paralelo}}(n,p)}$$

$$E(n,p) = \frac{S(n,p)}{p} = \frac{\frac{T_{\text{sequencial}}(n)}{T_{\text{paralelo}}(n,p)}}{p} = \frac{T_{\text{sequencial}}(n)}{p \cdot T_{\text{paralelo}}(n,p)}$$

UFABC

Table 3.6 Speedups of Parallel Matrix-Vector Multiplication

	Order of Matrix				
comm_sz	*1024*	*2048*	*4096*	*8192*	*16,384*
1	1.0	1.0	1.0	1.0	1.0
2	1.8	1.9	1.9	1.9	2.0
4	2.1	3.1	3.6	3.9	3.9
8	2.4	4.8	6.5	7.5	7.9
16	2.4	6.2	10.8	14.2	15.5

UFABC

Table 3.7 Efficiencies of Parallel Matrix-Vector Multiplication

	Order of Matrix				
comm_sz	*1024*	*2048*	*4096*	*8192*	*16,384*
1	1.00	1.00	1.00	1.00	1.00
2	0.89	0.94	0.97	0.96	0.98
4	0.51	0.78	0.89	0.96	0.98
8	0.30	0.61	0.82	0.94	0.98
16	0.15	0.39	0.68	0.89	0.97

Lembrete: Escalabilidade

UFABC

- Um programa é escalável se o tamanho do problema pode ser aumentado a uma taxa tal que a eficiência não diminua conforme o número de processos cresce.
- Dizemos que um programa é fortemente escalável se ele é capaz de manter a eficiência constante sem que haja necessidade de aumentar o tamanho do problema
- Dizemos que um programa é fracamente escalável se ele é capaz de manter a eficiência se o tamanho do problema for aumentado em uma taxa proporcional (=linear) ao aumento do número de processos

Pergunta

Qual tipo de escalabilidade é apresentada pelo programa de multiplicação matriz/vetor?

Um algoritmo de ordenação paralelo

Ordenação - Regras do jogo

UFABC

- n chaves e p (`comm_sz`) processos
- n/p chaves associadas a cada processo
- Não há restrições sobre quais chaves serão associadas a quais processos
- Quando o algoritmo terminar
  - As chaves associadas a cada processo devem estar armazenadas em ordem
  - Se $0 \leq q < r < p$, então cada chave associada ao processo q deve ser menor ou igual a todas as chaves associadas ao processo r

A estrela mal compreendida - Bubble Sort

UFABC

```
1  void Bubble_sort(
2                   int a[] /* in/out */,
3                   int n   /* in */) {
4      int list_length, i, temp;
5
6      for (list_length = n; list_length >= 2;
       ↪  list_length--)
7          for (i = 0; i < list_length - 1; i++)
8              if (a[i] > a[i+1]) {
9                  temp = a[i];
10                 a[i] = a[i+1];
11                 a[i+1] = temp;
12             }
13 }
```

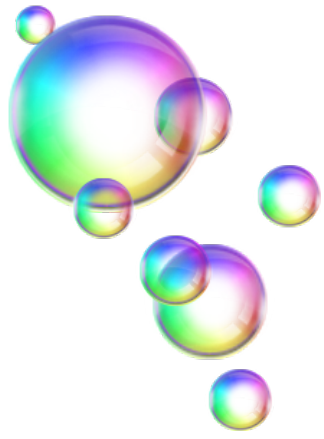

Ordenação por transposição par-ímpar

UFABC

- Funciona em uma sequência de fases
- Fases pares - comparam e trocam iniciando dos índices pares
  - `(a[0],a[1]),(a[2],a[3]),(a[4],a[5])...`
- Fases ímpares - comparam e trocam iniciando dos índices ímpares
  - `a[0],(a[1],a[2]),(a[3],a[4]),(a[5],a[6])...`

Exemplo

UFABC

- Começo: `5, 9, 4, 3`
- Fase par: compara e troca `(5, 9), (4, 3)`
  - Resultado: `5, 9, 3, 4`
- Fase ímpar: compara e troca `(9, 3)`
  - Resultado: `5, 3, 9, 4`
- Fase par: compara e troca `(5, 3), (9, 4)`
  - Resultado: `3, 5, 4, 9`
- Fase ímpar: compara e troca `(5, 4)`
  - Resultado: `3, 4, 5, 9`

Código sequencial

UFABC

```
1  void Odd_even_sort(int a[], int n) {
2      int phase, i, temp;
3      for (phase = 0; phase < n; phase++)
4          if (phase % 2 == 0) { /* Even phase */
5              for (i = 1; i < n; i += 2)
6                  if (a[i - 1] > a[i]) {
7                      temp = a[i];
8                      a[i] = a[i - 1];
9                      a[i - 1] = temp;
10                 }
11         } else { /* Odd phase */
12             for (i = 1; i < n - 1; i += 2)
13                 if (a[i] > a[i+1]) {
14                     temp = a[i];
15                     a[i] = a[i+1];
16                     a[i+1] = temp;
17                 }
18         }
19 }
```

Tarefas e comunicações na ordenação por transposição

UFABC

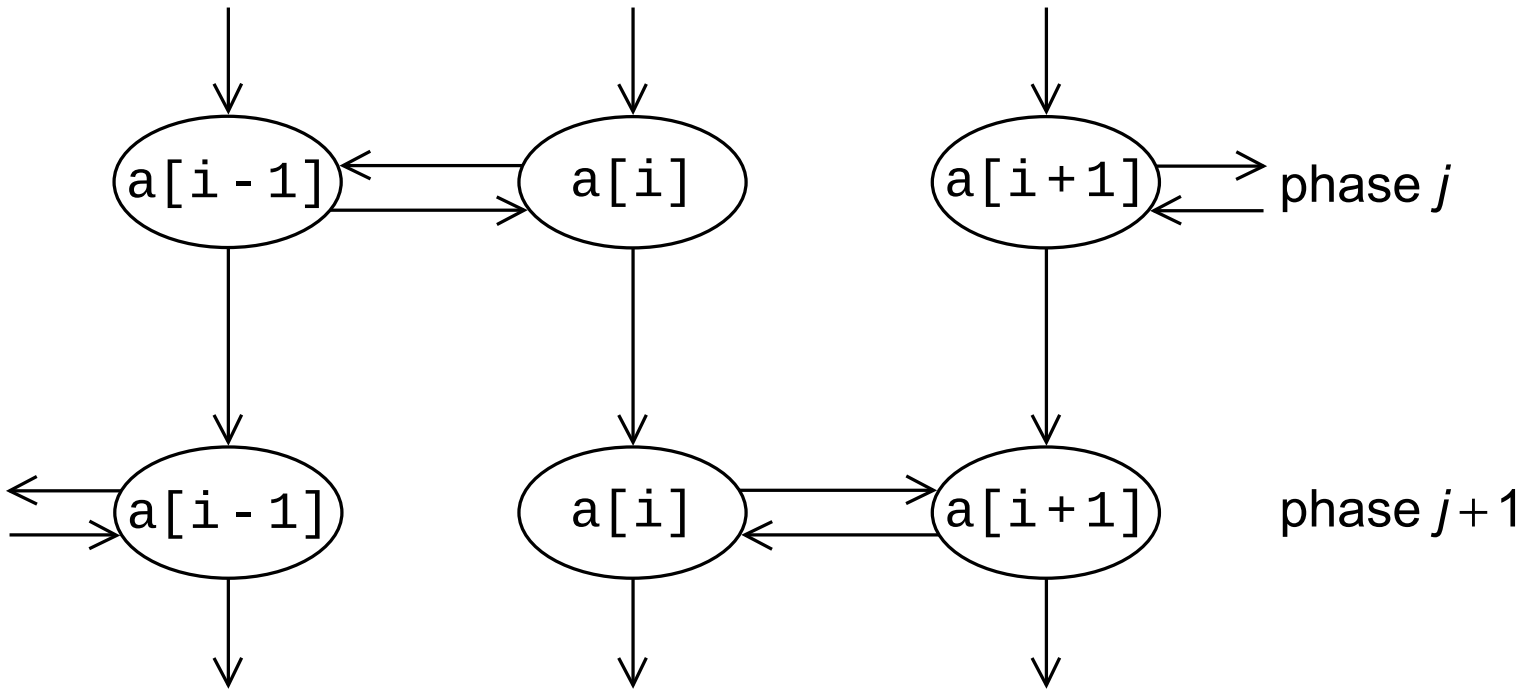

UFABC

Table 3.8 Parallel Odd-Even Transposition Sort

Time	Process 0	Process 1	Process 2	Process 3
Start	15, 11, 9, 16	3, 14, 8, 7	4, 6, 12, 10	5, 2, 13, 1
After Local Sort	9, 11, 15, 16	3, 7, 8, 14	4, 6, 10, 12	1, 2, 5, 13
After Phase 0	3, 7, 8, 9	11, 14, 15, 16	1, 2, 4, 5	6, 10, 12, 13
After Phase 1	3, 7, 8, 9	1, 2, 4, 5	11, 14, 15, 16	6, 10, 12, 13
After Phase 2	1, 2, 3, 4	5, 7, 8, 9	6, 10, 11, 12	13, 14, 15, 16
After Phase 3	1, 2, 3, 4	5, 6, 7, 8	9, 10, 11, 12	13, 14, 15, 16

Pseudocódigo

```
Ordena as chaves localmente;
for (fase = 0; fase < comm_sz; fase++) {
    colega = Computa_colega(fase, my_rank);
    if (não estou ocioso) {
       Envia chaves para o colega;
       Recebe chaves do colega;
       if (my_rank < colega)
           Mantem as chaves menores;
       else
           Mantem as chaves maiores;
    }
}
```

UFABC

```
1  if (phase % 2 == 0) /* Even phase */
2      if (my_rank % 2 != 0) /* Odd rank */
3          partner = my_rank - 1;
4      else /* Even rank */
5          partner = my_rank + 1;
6  else /* Odd phase */
7      if (my_rank % 2 != 0) /* Odd rank */
8          partner = my_rank + 1;
9      else /* Even rank */
10         partner = my_rank - 1;
11 if (partner == - 1 | | partner == comm_sz)
12     partner = MPI_PROC_NULL;
```

Segurança (*safety*) em programas MPI

UFABC

- O padrão MPI permite ao `MPI_Send` se comportar de duas maneiras distintas
  - Ele pode simplesmente copiar a mensagem para um buffer do próprio MPI e devolver o controle
  - Ele pode bloquear a chamada até que a chamada correspondente `MPI_Recv` tenha sido efetuada

- Muitas implementações de MPI tem um limiar (*threshold*) no qual elas trocam de um buffer para a versão bloqueante
- Ou seja, mensagens pequenas tendem a ser *bufferizadas*[3] pelo `MPI_Send` e mensagens grandes tendem a bloquear.

[3] Mais uma tradução de revirar Camões na sua tumba

Segurança (*safety*) em programas MPI

UFABC

- Se a chamada à `MPI_Send` executada por cada um dos processos bloqueia, nenhum processo será capaz de iniciar a execução da chamada ao `MPI_Recv`. Nestes casos o programa vai entrar em um impasse (*deadlock*).
- Um impasse ocorre quando um processo está esperando por algo que nunca acontecerá

Segurança (*safety*) em programas MPI

UFABC

- Um programa que se apoia nas características de bufferização do MPI é inseguro (*unsafe*)
- O problema é que tal programa pode rodar muitos anos sem demonstrar o problema até que um belo dia ele capota. Por que?

MPI_SSend

UFABC

- Um método alternativo ao **MPI_Send** definido pelo padrão
- O **s** extra vem de *síncrono* e a função **MPI_Ssend sempre** bloqueia até que o **MPI_Receive** correspondente seja iniciado

```
1  int MPI_Ssend(
2      void*         msg_buf_p    /* in */,
3      int           msg_size     /* in */,
4      MPI_Datatype  msg_type     /* in */,
5      int           dest         /* in */,
6      int           tag          /* in */,
7      MPI_Comm      communicator /* in */);
```

UFABC

```
1 MPI_Send(my_keys, n/comm_sz, MPI_INT, partner, 0, comm);
2 MPI_Recv(temp_keys, n/comm_sz, MPI_INT, partner, 0,
  ↪  comm, MPI_STATUS_IGNORE);
```

UFABC

```
1 MPI_Send(msg, size, MPI_INT, (my_rank + 1) % comm_sz, 0,
   ↪  comm);
2 MPI_Recv(new_msg, size, MPI_INT, (my_rank + comm_sz - 1)
   ↪  % comm_sz, 0, comm, MPI_STATUS_IGNORE);
```

```
1  if (my_rank % 2 == 0) {
2      MPI_Send(msg, size, MPI_INT, (my_rank+1) % comm_sz,
       ↪  0, comm);
3      MPI_Recv(new msg, size, MPI_INT, (my_rank+comm_sz -
       ↪  1) % comm_sz, 0, comm, MPI_STATUS_IGNORE);
4  } else {
5      MPI_Recv(new msg, size, MPI_INT, (my_rank+comm_sz -
       ↪  1) % comm_sz,0, comm, MPI_STATUS_IGNORE);
6      MPI_Send(msg, size, MPI_INT, (my_rank+1) % comm_sz,
       ↪  0, comm);
7  }
```

MPI_Sendrecv

UFABC

- Uma alternativa ao escalonamento manual de mensagens
- Faz um envio bloqueante e um recebimento na mesma chamada
- O `dest` e o `source` podem ser os mesmos ou diferentes
- É especialmente útil pois o MPI escalona as comunicações de modo que o programa não entre em um impasse ou capote

MPI_Sendrecv

UFABC

```
1  int MPI_Sendrecv(
2      void*        send_buf_p    /* in */,
3      int          send_buf_size /* in */,
4      MPI_Datatype send_buf_type /* in */,
5      int          dest          /* in */,
6      int          send_tag      /* in */,
7      void*        recv_buf_p    /* out */,
8      int          recv_buf_size /* in */,
9      MPI_Datatype recv_buf_type /* in */,
10     int          source        /* in */,
11     int          recv_tag      /* in */,
12     MPI_Comm     communicator  /* in */,
13     MPI_Status*  status_p      /* in */);
```

Comunicação segura com 5 processos

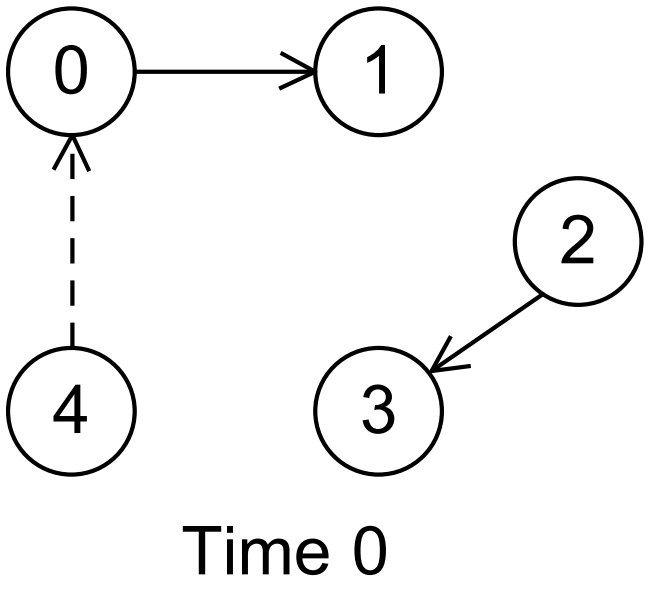

Time 0

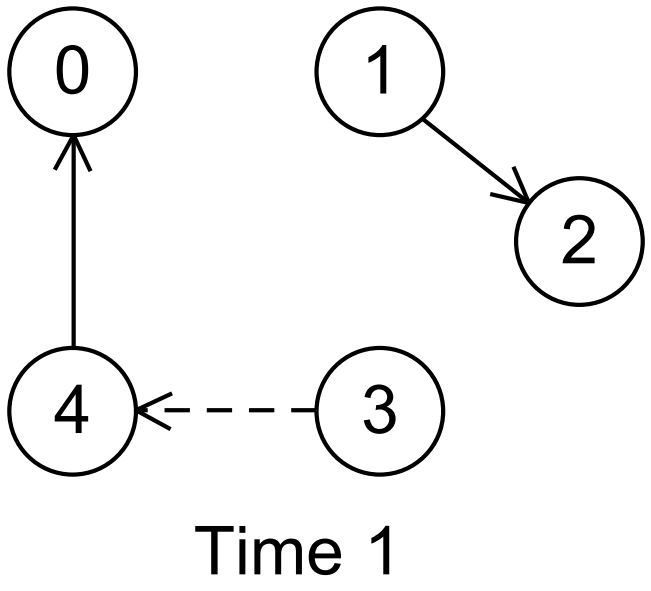

Time 1

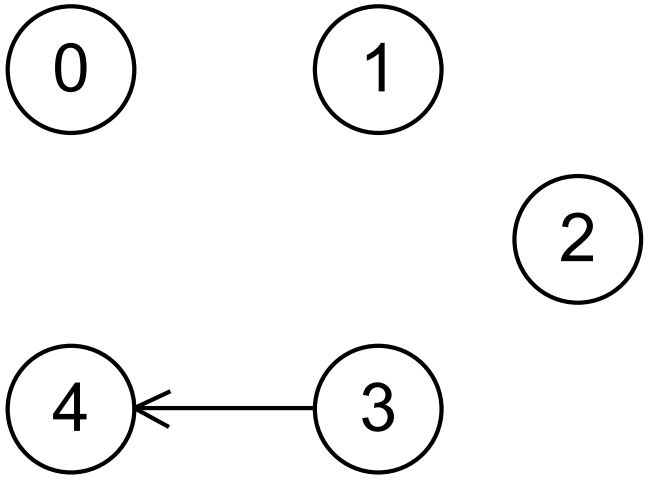

Time 2

Voltando... Versão paralela da ordenação por transposição

UFABC

```
1  void Merge_low(
2                  int  my_keys[],     /* in/out    */
3                  int  recv_keys[],   /* in        */
4                  int  temp_keys[],   /* scratch   */
5                  int  local_n        /* = n/p, in */) {
6      int m_i, r_i, t_i;
7      m_i = r_i = t_i = 0;
8      while (t_i < local_n) {
9          if (my_keys[m_i] <= recv_keys[r_i]) {
10             temp_keys[t_i] = my_keys[m_i];
11             t_i++; m_i++;
12         } else {
13             temp_keys[t_i] = recv_keys[r_i];
14             t_i++; r_i++;
15         }
16     }
17     memcpy(my_keys, temp_keys, local_n*sizeof(int));
18 }
```

UFABC

Table 3.9 Run-Times of Parallel Odd-Even Sort (times are in milliseconds)

Processes	Number of Keys (in thousands)				
	200	*400*	*800*	*1600*	*3200*
1	88	190	390	830	1800
2	43	91	190	410	860
4	22	46	96	200	430
8	12	24	51	110	220
16	7.5	14	29	60	130

Conclusão

Comentários finais

UFABC

- MPI ou, *Message Passing Interface* é uma biblioteca de funções que podem ser chamadas a partir de linguagens de programação como C, C++ e Fortran
- Um comunicador é uma coleção de processos que se comunicam por meio de mensagens
- Muitos programas paralelos utilizam a abordagem SPMD (*Single Program Multiple Data*)
- A maior parte dos programas sequenciais é determinística: se executamos o mesmo programa múltiplas vezes com a mesma entrada obtemos a mesma saída
- Programas paralelos, em geral, não têm essa característica
- Comunicações coletivas envolvem todos os processos de um comunicador

Comentários finais

UFABC

- Quando medimos o tempo de execução de um programa paralelo estamos tipicamente interessados no tempo decorrido também chamado de tempo de relógio de parede (*wall clock time*)
- Speedup é a razão entre o tempo de execução de um programa sequencial e o tempo de execução da versão paralela
- Eficiência é speedup dividido pelo número de processos paralelos
- Se é possível aumentar o tamanho do problema (n) de modo que a eficiência não diminua conforme o número de processos (p) aumenta, então dizemos que o programa paralelo é escalável
- Um programa MPI é inseguro se seu comportamento correto é dependente da bufferização do `MPI_Send`