



ПАРАЛЛЕЛЬНОЕ ПРОГРАММИРОВАНИЕ В СТАНДАРТЕ MPI

Если у вас есть яблоко и у меня есть яблоко, и мы обмениваемся этими яблоками, то у вас и у меня остается по одному яблоку. А если у вас есть идея и у меня есть идея, и мы обмениваемся идеями, то у каждого из нас будет по две идеи.

Дж.Б. Шоу

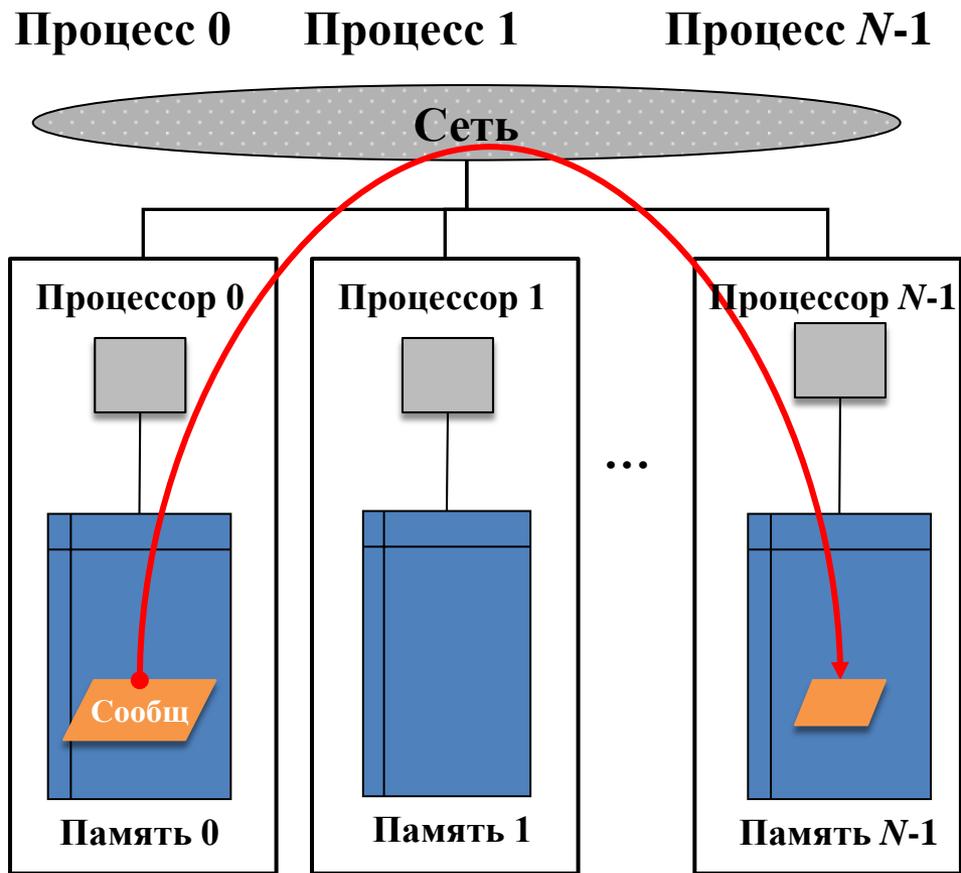
Содержание

2

- Модель передачи сообщений для параллельного программирования в системах с распределенной памятью
- Режимы запуска параллельных программ SPMD и MPMD
- Стандарт Message Passing Interface (MPI)
- Основные понятия и функции MPI

Модель передачи сообщений

3

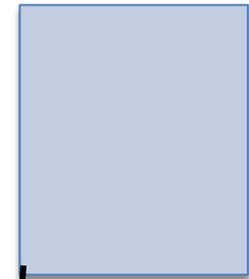


- *Параллельное приложение* состоит из нескольких *процессов*, выполняющихся одновременно.
- Каждый процесс имеет приватную память.
- Обмены данными между процессами осуществляются посредством явной отправки/получения *сообщений*.
- Процессы, как правило, выполняются на различных процессорах.

Режим MPMD

4

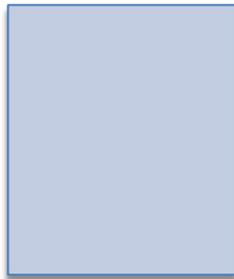
Процесс 0



master.c

```
int main()
{
// Мастер
...
}
```

Процесс 1



mytask1.c

```
int main()
{
// Рабочий 1
...
}
```

Процесс N-1



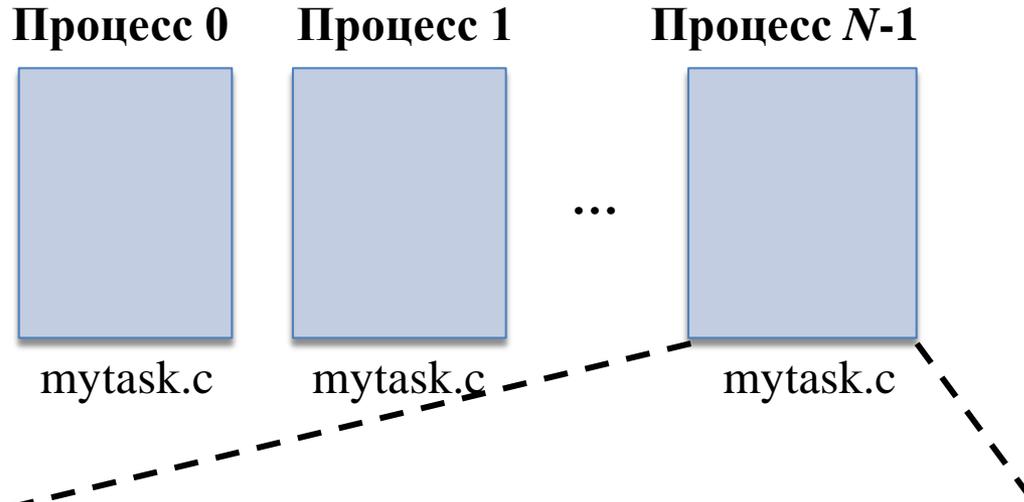
mytaskn.c

```
int main()
{
// Рабочий N
...
}
```

- Режим *MPMD* (*Multiple Program Multiple Data*) предполагает, процессы параллельного приложения имеют различные исходные коды.

Режим SPMD

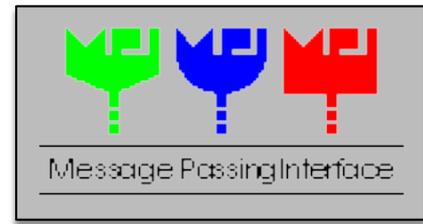
5



```
void main()
{
    ...
    myrank=GetMyrank();
    switch (myrank) {
    case 0: MasterTask(); break; // Мастер
    case 1: Task1(); break;      // Рабочий 1
    case 2: Task2(); break;      // Рабочий 2
    ...
    }
    ...
}
```

- Режим *SPMD* (*Single Program Multiple Data*) предполагает, каждый процесс параллельного приложения имеет один и тот же ИСХОДНЫЙ КОД.

Стандарт MPI

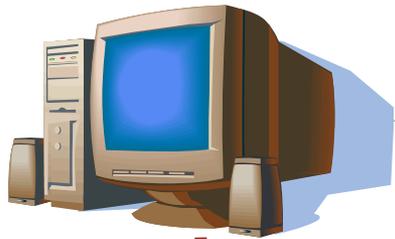


6

- *MPI (Message Passing Interface)* – стандарт, реализующий модель обмена сообщениями между параллельными процессами. Поддерживает модели выполнения SPMD и (начиная с версии 2.0) MPMD.
- Стандарт представляет собой набор спецификаций подпрограмм (более 120) на языках C, C++ и FORTRAN.
- Стандарт реализуется разработчиками в виде библиотек подпрограмм для различных аппаратно-программных платформ (кластеры, персональные компьютеры, ..., Windows, Unix/Linux, ...).
- Коммерческие (IntelMPI, MSMPI и др.) и свободно распространяемые реализации стандарта (MPICH и др.).
- Текущая версия стандарта: <http://www.mpi-forum.org>.

Цикл разработки MPI-программ

7



- Персональный компьютер
 - Первоначальная разработка и отладка
 - Отладка по результатам тестирования на суперкомпьютере



- Суперкомпьютер
 - Тестирование
 - Эксперименты

MPI-программа

8

- *MPI-программа* – множество параллельных взаимодействующих процессов.
- Процессы порождаются один раз, в момент запуска программы средствами среды исполнения MPI программ*.
- Все процессы программы последовательно перенумерованы, начиная с 0. Номер процесса именуется *рангом* процесса.
- Каждый процесс работает в своем адресном пространстве, каких-либо общих данных нет. Единственный способ взаимодействия процессов – явный обмен сообщениями.

* Порождение дополнительных процессов и уничтожение существующих возможно только начиная с версии MPI-2.0.

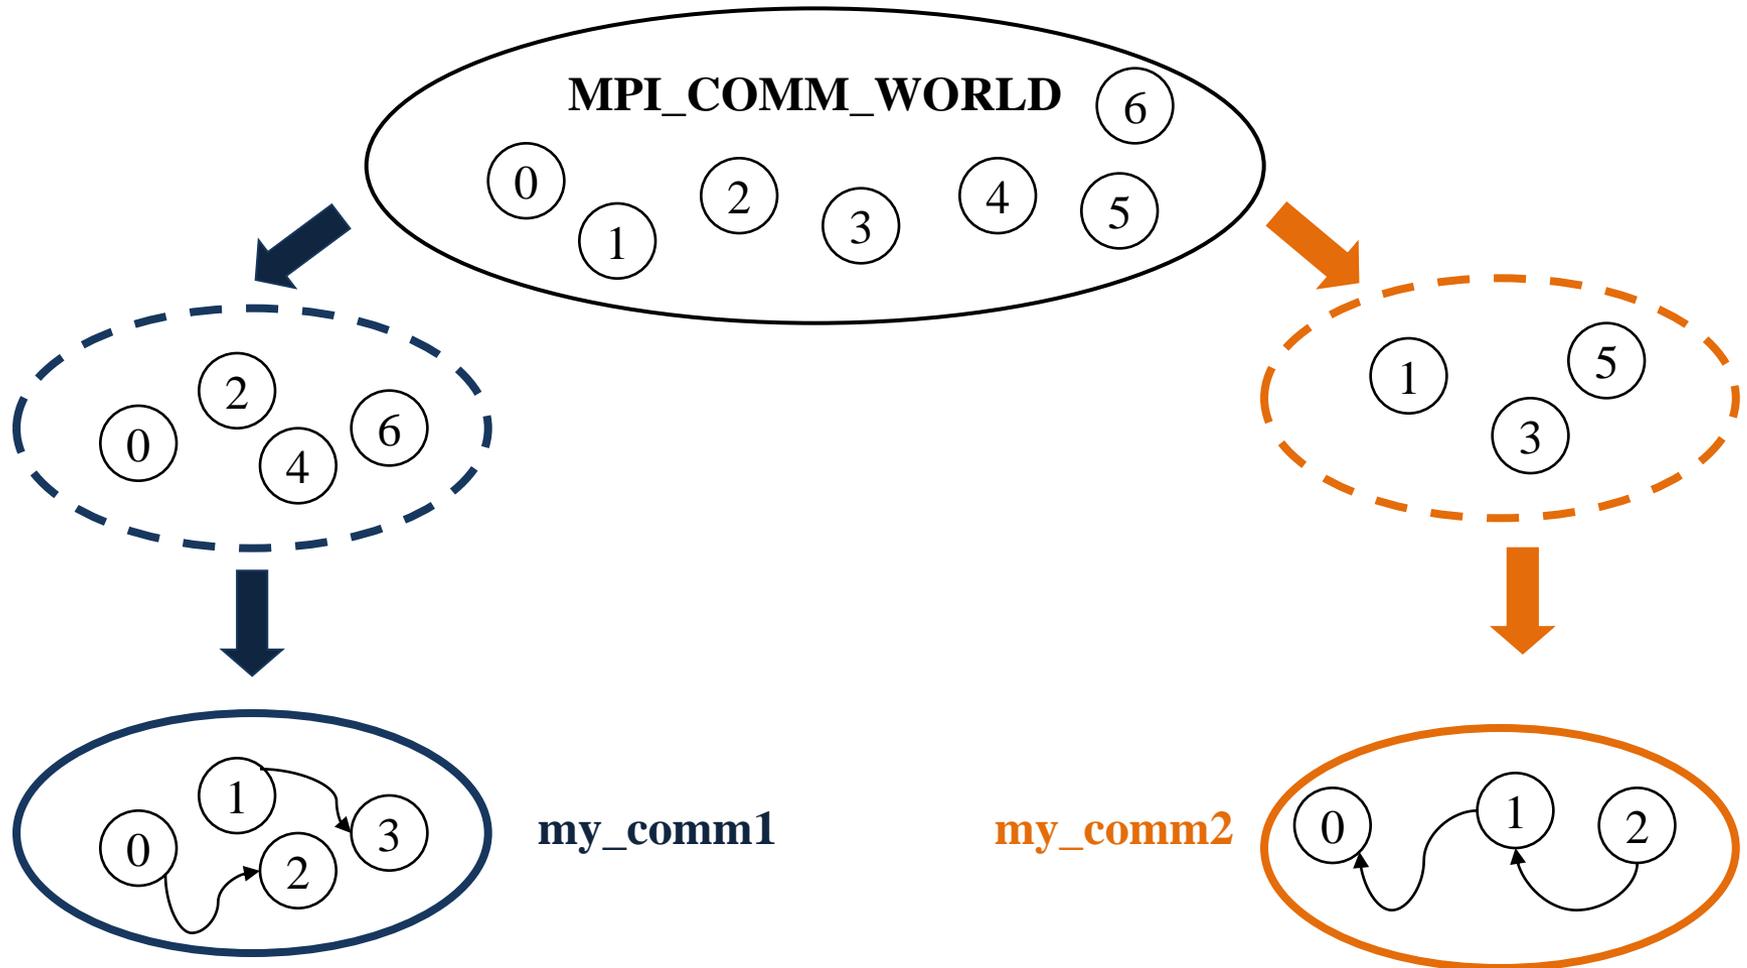
Коммуникаторы

9

- Для локализации области взаимодействия процессов можно динамически создавать специальные программные объекты – *коммуникаторы*. Один и тот же процесс может входить в разные коммуникаторы.
- Взаимодействия процессов проходят в рамках некоторого коммуникатора. Сообщения, переданные в разных коммуникаторах, не пересекаются и не мешают друг другу.
- Атрибуты процесса MPI-программы:
 - ▣ коммуникатор;
 - ▣ ранг в коммуникаторе (от 0 до $n-1$, n – число процессов в коммуникаторе).
- Стандартные коммуникаторы:
 - ▣ MPI_COMM_WORLD – все процессы приложения
 - ▣ MPI_COMM_SELF – текущий процесс приложения
 - ▣ MPI_COMM_NULL – пустой коммуникатор

Коммуникаторы

10



Сообщение

11

- *Сообщение* процесса – набор данных стандартного (определенного в MPI) или пользовательского типа.
- Основные атрибуты сообщения:
 - ранг процесса-отправителя (получателя)
 - коммуникатор
 - тег сообщения (уникальный идентификатор, целое число)
 - тип элементов данных в сообщении
 - количество элементов данных
 - указатель на буфер с сообщением

Структура MPI-программы

12

```
#include "mpi.h" // Подключение библиотеки

int main (int argc, char *argv[])
{
// Здесь код без использования MPI функций

    MPI_Init(&argc, &argv); // Инициализация выполнения

// Здесь код, реализующий обмены

    MPI_Finalize(); // Завершение

// Здесь код без использования MPI функций

    return 0;
}
```

MPI-функции

13

- Имеют имена вида `MPI_...`
- Возвращают целое число – `MPI_SUCCESS` или код ошибки.
- Простые функции общего назначения:
 - ▣ // Количество процессов в коммутаторе
`int MPI_Comm_size(MPI_Comm comm, int * size);`
 - ▣ // Ранг процесса в коммутаторе
`int MPI_Comm_rank(MPI_Comm comm, int * rank);`
 - ▣ // Замер времени (сек.)
`double MPI_Wtime(void);`
 - ▣ // Имя текущего процессорного узла
`int MPI_Get_processor_name(char * name, int * len);`

Простая MPI-программа

14

```
#include "mpi.h"
#include <stdio.h>

int main (int argc, char *argv[])
{
    int num, rank;

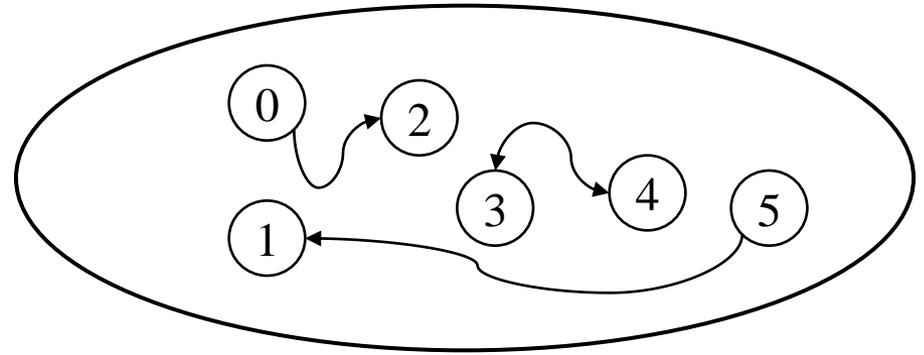
    MPI_Init (&argc, &argv);
    MPI_Comm_size (MPI_COMM_WORLD, &num);
    MPI_Comm_rank (MPI_COMM_WORLD, &rank);
    printf("Привет! Я %d-й процесс из %d.\n", rank, num);
    MPI_Finalize();
    return 0;
}
```

```
Привет! Я 1-й процесс из 4.
Привет! Я 0-й процесс из 4.
Привет! Я 3-й процесс из 4.
Привет! Я 2-й процесс из 4.
```

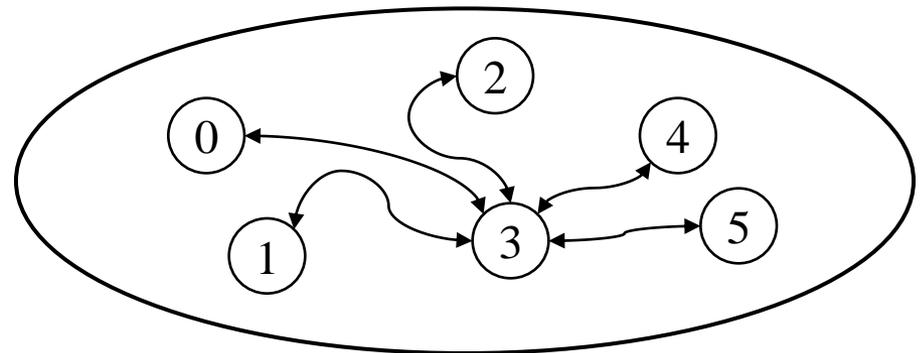
Виды взаимодействия процессов

15

- *Взаимодействие "точка-точка"* – обмен между **двумя** процессами одного коммутатора.



- *Коллективное взаимодействие* – обмен между **всеми** процессами одного коммутатора.



Взаимодействие "точка-точка"

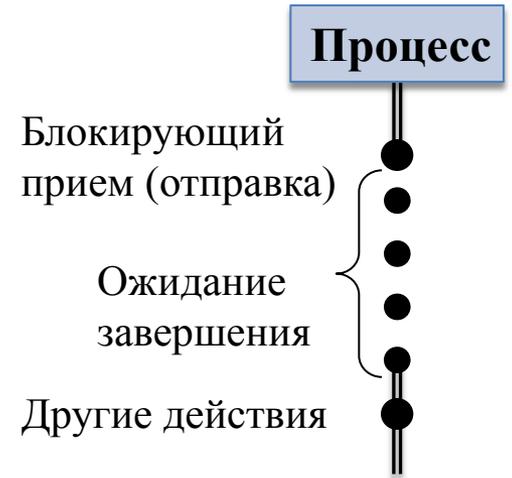
16

- Участвуют два процесса: отправитель сообщения и получатель сообщения.
 - Отправитель должен вызвать одну из функций отправки сообщения и явно указать атрибуты получателя (коммуникатор и номер в коммуникаторе) и тег сообщения.
 - Получатель должен вызвать одну из функций получения сообщения и указать (тот же) коммуникатор отправителя; получатель может не знать ранг отправителя и/или тег сообщения.
- Свойства:
 - Сохранение порядка (если P_0 передает P_1 сообщения A и затем B , то P_1 получит A , а затем B).
 - Гарантированное выполнение обмена (если P_0 вызвал функцию отправки, а P_1 вызвал функцию получения, то P_1 получит сообщение от P_0).

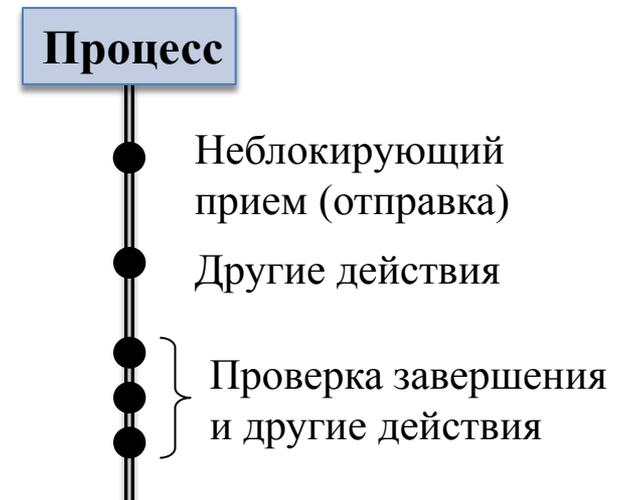
Виды коммуникационных функций "точка-точка"

17

- **Блокирующая** функция запускает операцию и возвращает управление процессу только после ее завершения.
 - После завершения допустима модификация отправленного (принятого) сообщения.



- **Неблокирующая** функция запускает операцию и возвращает управление процессу немедленно.
 - Факт завершения операции проверяется позднее (с помощью другой функции).
 - До завершения операции недопустима модификация отправляемого (получаемого) сообщения.



Блокирующие vs неблокирующие операции

18

- Блокирующие операции
 - ▣ Имеют более простую семантику.
 - ▣ Относительно легко используются в программе, не требуют дополнительных действий для завершения обмена.
 - ▣ Могут снизить быстродействие программы.
 - ▣ Могут привести к тупикам.
- Неблокирующие операции
 - ▣ Имеют более сложную семантику.
 - ▣ Относительно трудно используются в программе, требуют дополнительных действий для завершения обмена
 - ▣ Могут повысить быстродействие программы.
 - ▣ Не вызывают тупиков.

Блокирующая отправка сообщения

19

□ `int MPI_Send`

- ▣ IN `void * buf` – указатель на буфер с сообщением
- ▣ IN `int count` – количество элементов в буфере
- ▣ IN `MPI_Datatype datatype` – MPI-тип данных элементов в буфере
- ▣ IN `int dest` – ранг процесса-получателя
- ▣ IN `int tag` – тег сообщения
- ▣ IN `MPI_Comm comm` – коммуникатор

Блокирующее получение сообщения

20

□ `int MPI_Recv`

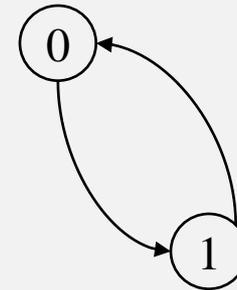
- ▣ OUT `void * buf` – указатель на буфер с сообщением
- ▣ IN `int count` – количество элементов в буфере
- ▣ IN `MPI_Datatype datatype` – MPI-тип данных элементов в буфере
- ▣ IN `int src` – ранг процесса-отправителя
- ▣ IN `int tag` – тег сообщения
- ▣ IN `MPI_Comm comm` – коммуникатор
- ▣ OUT `MPI_Status* status` – информация о фактически полученных данных (указатель на структуру с двумя полями: `source` – номер процесса-источника, `tag` – тег сообщения)

Пример программы

21

```
#include "mpi.h"
#include <stdio.h>
int main(int argc, char *argv[])
{
    int numtasks, rank, dest, src, rc, tag=777;
    char inmsg, outmsg='x';
    MPI_Status Stat;

    MPI_Init(&argc, &argv);
    MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    if (rank == 0) {
        dest = 1; src = 1;
        rc = MPI_Send(&outmsg, 1, MPI_CHAR, dest, tag, MPI_COMM_WORLD);
        rc = MPI_Recv(&inmsg, 1, MPI_CHAR, src, tag, MPI_COMM_WORLD, &Stat);
    } else
    if (rank == 1) {
        dest = 0; src = 0;
        rc = MPI_Recv(&inmsg, 1, MPI_CHAR, src, tag, MPI_COMM_WORLD, &Stat);
        rc = MPI_Send(&outmsg, 1, MPI_CHAR, dest, tag, MPI_COMM_WORLD);
    }
    MPI_Finalize();
}
```



Неблокирующая отправка сообщения

22

□ `int MPI_Isend`

- ▣ IN `void * buf` – указатель на буфер с сообщением
- ▣ IN `int count` – количество элементов в буфере
- ▣ IN `MPI_Datatype datatype` – MPI-тип данных элементов в буфере
- ▣ IN `int dest` – ранг процесса-получателя
- ▣ IN `int tag` – тег сообщения
- ▣ IN `MPI_Comm comm` – коммуникатор
- ▣ OUT `MPI_Request *request` – дескриптор операции (для последующей проверки завершения операции)

Неблокирующее получение сообщения

23

□ `int MPI_Irecv`

- ▣ OUT `void * buf` – указатель на буфер с сообщением
- ▣ IN `int count` – количество элементов в буфере
- ▣ IN `MPI_Datatype datatype` – MPI-тип данных элементов в буфере
- ▣ IN `int src` – ранг процесса-отправителя
- ▣ IN `int tag` – тег сообщения
- ▣ IN `MPI_Comm comm` – коммуникатор
- ▣ OUT `MPI_Request *request` – дескриптор операции (для последующей проверки завершения операции)

Завершение неблокирующих обменов

24

- Проверка завершения

int MPI_Test

(MPI_Request *request, int *flag, MPI_Status *status)

- ▣ int MPI_Testany (...)
- ▣ int MPI_Testall (...)
- ▣ int MPI_Testsome (...)

- Ожидание завершения

int MPI_Wait

(MPI_Request *request, MPI_Status *status)

- ▣ int MPI_Waitany (...)
- ▣ int MPI_Waitall (...)
- ▣ int MPI_Waitsome (...)

Пример

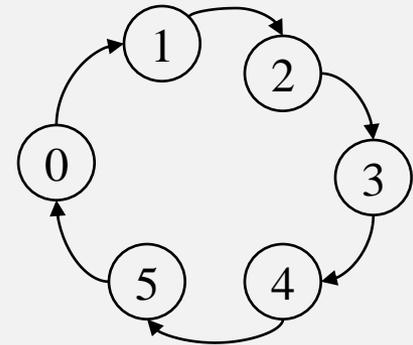
25

```
#include "mpi.h"
#include <stdio.h>
int main(int argc, char *argv[])
{
    int numtasks, rank, next, prev, buf[2], tag1=111, tag2=222;
    MPI_Request reqs[4];
    MPI_Status stats[4];

    MPI_Init(&argc, &argv);
    MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);

    prev = rank - 1;
    if (prev < 0) prev = numtasks - 1;
    next = rank + 1;
    if (next > numtasks - 1) next = 0;
    MPI_Irecv(&buf[0], 1, MPI_INT, prev, tag1, MPI_COMM_WORLD, &reqs[0]);
    MPI_Irecv(&buf[1], 1, MPI_INT, next, tag2, MPI_COMM_WORLD, &reqs[1]);
    MPI_Isend(&rank, 1, MPI_INT, prev, tag2, MPI_COMM_WORLD, &reqs[2]);
    MPI_Isend(&rank, 1, MPI_INT, next, tag1, MPI_COMM_WORLD, &reqs[3]);
    MPI_Waitall(4, reqs, stats);

    MPI_Finalize();
}
```



Режимы отправки сообщений "точка-точка"

- *По умолчанию* – операция завершается сразу после отправки сообщения.
- *Синхронный* – операция завершается после приема подтверждения от адресата.
- *Буферизованный* – операция завершается, как только сообщение копируется в системный буфер для дальнейшей отправки.
- *"По готовности"* – операция начинается, если адресат инициализировал прием и завершается сразу после отправки.

Режимы отправки сообщений "точка-точка"

27

- Режим *по готовности* формально является наиболее быстрым, но используется достаточно редко, т.к. обычно сложно гарантировать готовность операции приема.
- Режимы *по умолчанию* и *буферизованный* также выполняются достаточно быстро, но могут приводить к большим расходам ресурсов (памяти), и могут быть рекомендованы для передачи коротких сообщений.
- *Синхронный* режим является наиболее медленным, т.к. требует подтверждения приема. В то же время этот режим наиболее надежен, и может быть рекомендован для передачи длинных сообщений.

Коммуникационные функции "точка-точка"

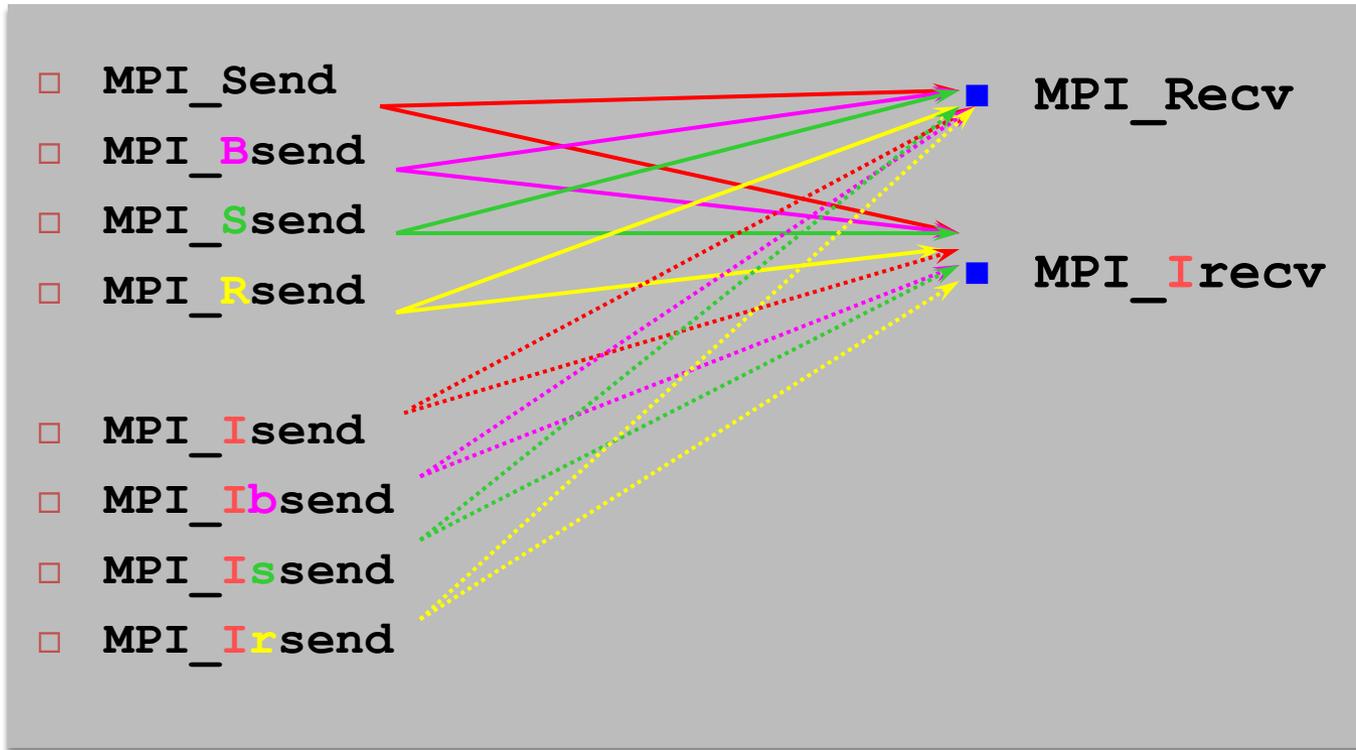
28

- Отправка: **MPI**_**[I]**[**R**, **S**, **B**]**Send**
- Прием: **MPI**_**[I]****Recv**

| Блокирующие | | Неблокирующие | | | |
|-----------------------|--------------------|---------------|-----------------------|---------------------|--------------------|
| <i>Отправка</i> | | <i>Прием</i> | <i>Отправка</i> | | <i>Прием</i> |
| <i>Стандартная</i> | MPI_Send | MPI_Recv | <i>Стандартная</i> | MPI_I S end | MPI_I R ecv |
| <i>Синхронная</i> | MPI_ S send | | <i>Синхронная</i> | MPI_I S send | |
| <i>Буферизованная</i> | MPI_ B send | | <i>Буферизованная</i> | MPI_I B send | |
| <i>По готовности</i> | MPI_ R send | | <i>По готовности</i> | MPI_I R send | |

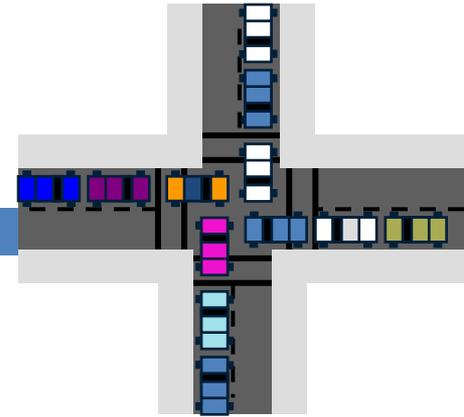
Коммуникационные функции "точка-точка"

29



Тупики (deadlocks)

30



□ Гарантированный тупик

P0

```
MPI_Recv (от процесса P1);  
MPI_Send (процессу P1);
```

P1

```
MPI_Recv (от процесса P0);  
MPI_Send (процессу P0);
```

□ Возможный тупик

P0

```
MPI_Send (процессу P1);  
MPI_Recv (от процесса P1);
```

P1

```
MPI_Send (процессу P0);  
MPI_Recv (от процесса P0);
```

Разрешение тупиков

31

P0

```
MPI_Send (процессу P1);  
MPI_Recv (от процесса P1);
```

P1

```
MPI_Recv (от процесса P0);  
MPI_Send (процессу P0);
```

P0

```
MPI_Send (процессу P1);  
MPI_Recv (от процесса P1);
```

P1

```
MPI_Irecv (от процесса P0);  
MPI_Send (процессу P0);  
MPI_Wait
```

P0

```
// Совмещенные прием и передача  
MPI_Sendrecv
```

P1

```
// Совмещенные прием и передача  
MPI_Sendrecv
```

Совмещение приема и передачи сообщения

32

□ **int MPI_Sendrecv**

- ▣ OUT `void * sbuf` - адрес начала буфера с посылаемым сообщением;
- ▣ IN `int scount` - число передаваемых элементов в сообщении;
- ▣ IN `MPI_Datatype stype` - тип передаваемых элементов;
- ▣ IN `int dest` - ранг процесса-получателя;
- ▣ IN `int stag` - идентификатор посылаемого сообщения;
- ▣ OUT `void *rbuf` - адрес начала буфера приема сообщения;
- ▣ IN `int rcount` - число принимаемых элементов сообщения;
- ▣ IN `MPI_Datatype rtype` - тип принимаемых элементов;
- ▣ IN `int source` - ранг процесса-отправителя;
- ▣ IN `int rtag` - идентификатор принимаемого сообщения;
- ▣ IN `MPI_Comm comm` - идентификатор коммуникатора;
- ▣ OUT `MPI_Status status` - параметры принятого сообщения.

Пример

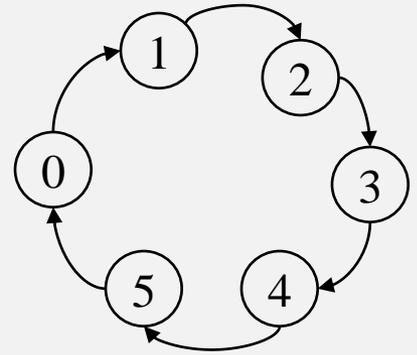
33

```
#include "mpi.h"
#include <stdio.h>
int rank, numtasks, prev, next, buf[2];
MPI_Status status1, status2;

int main(int argc, char *argv[])
{
    MPI_Init(&argc, &argv);
    MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);

    prev=rank-1; if (prev < 0) prev=numtasks-1;
    next=rank+1; if (next > size-1) next=0;
    MPI_Sendrecv(rank, 1, MPI_INTEGER, prev, 777, buf[1], 1, MPI_INTEGER, next,
777, MPI_COMM_WORLD, status2);
    MPI_Sendrecv(rank, 1, MPI_INTEGER, next, 888, buf[0], 1, MPI_INTEGER, prev,
888, MPI_COMM_WORLD, status1);
    printf("Process %d, prev=%d, next=%d\n", rank, buf[0], buf[1]);

    MPI_Finalize();
    return 0;
}
```



Получение сообщений

34

□ "Джокеры"

- ▣ ранг процесса `MPI_ANY_SOURCE`
- ▣ тег сообщения `MPI_ANY_TAG`

□ Информация об ожидаемом сообщении

▣ С блокировкой

```
int MPI_Probe(int src, int tag,  
MPI_Comm comm, MPI_Status * status);
```

▣ Без блокировки

```
int MPI_Iprobe(int src, int tag,  
MPI_Comm comm, int * flag, MPI_Status *  
status);
```

▣ Количество элементов в принятом сообщении

```
int MPI_Get_count(MPI_Status * status,  
MPI_Datatype type, int * cnt);
```



Пример

35

- Процесс-получатель не знает заранее длины ожидаемого сообщения.

```
MPI_Probe(MPI_ANY_SOURCE, msgtag_INT, MPI_COMM_WORLD, &status);  
MPI_Get_count(&status, MPI_INT, &cnt);  
buffer = malloc(sizeof(int) * cnt);  
MPI_Recv(buffer, cnt, MPI_INT, MPI_ANY_SOURCE, msgtag_INT, MPI_COMM_WORLD,  
&status);
```

- Процесс-получатель собирает сообщения от разных отправителей с содержимым различных типов.

```
for (i=0; i<3; i++) {  
    MPI_Probe(MPI_ANY_SOURCE, MPI_ANY_TAG, MPI_COMM_WORLD, &status);  
    switch (status.MPI_TAG) {  
        case msgtag_FLOAT: MPI_Recv(floatBuf, floatBufSize, MPI_FLOAT,  
MPI_ANY_SOURCE, MPI_ANY_TAG, MPI_COMM_WORLD, &status); break;  
        case msgtag_INT: MPI_Recv(intBuf, intBufSize, MPI_INT, MPI_ANY_SOURCE,  
MPI_ANY_TAG, MPI_COMM_WORLD, &status); break;  
        case msgtag_CHAR: MPI_Recv(charBuf, charBufSize, MPI_CHAR, MPI_ANY_TAG,  
MPI_COMM_WORLD, &status); break;  
    }  
}
```

Коллективные операции

36

- Прием и/или передачу выполняют одновременно *все* процессы коммутатора.
- Коллективная функция имеет большое количество параметров, часть которых нужна для приема, а часть для передачи. При вызове в разных процессах та или иная часть игнорируется.
- Значения *всех* параметров коллективных функций (за исключением адресов буферов) должны быть идентичными во всех процессах.
- MPI назначает теги для сообщений автоматически.

Барьерная синхронизация

37

- `int MPI_Barrier (MPI_Comm comm)`
 - ▣ Обеспечивает *синхронизацию* процессов – одновременное достижение процессами указанной точки вычислений.
 - ▣ Должна вызываться всеми процессами коммутатора.
 - ▣ Продолжение вычислений любого процесса произойдет по окончании выполнения функции `MPI_Barrier` всеми процессами коммутатора.

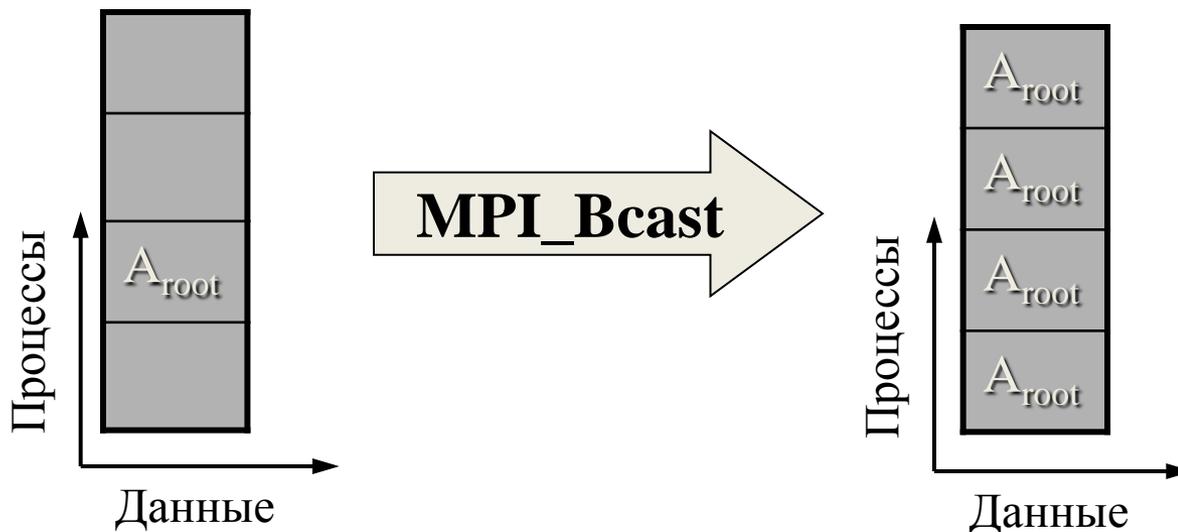


Широковещательная рассылка

38

□ int **MPI_Bcast**

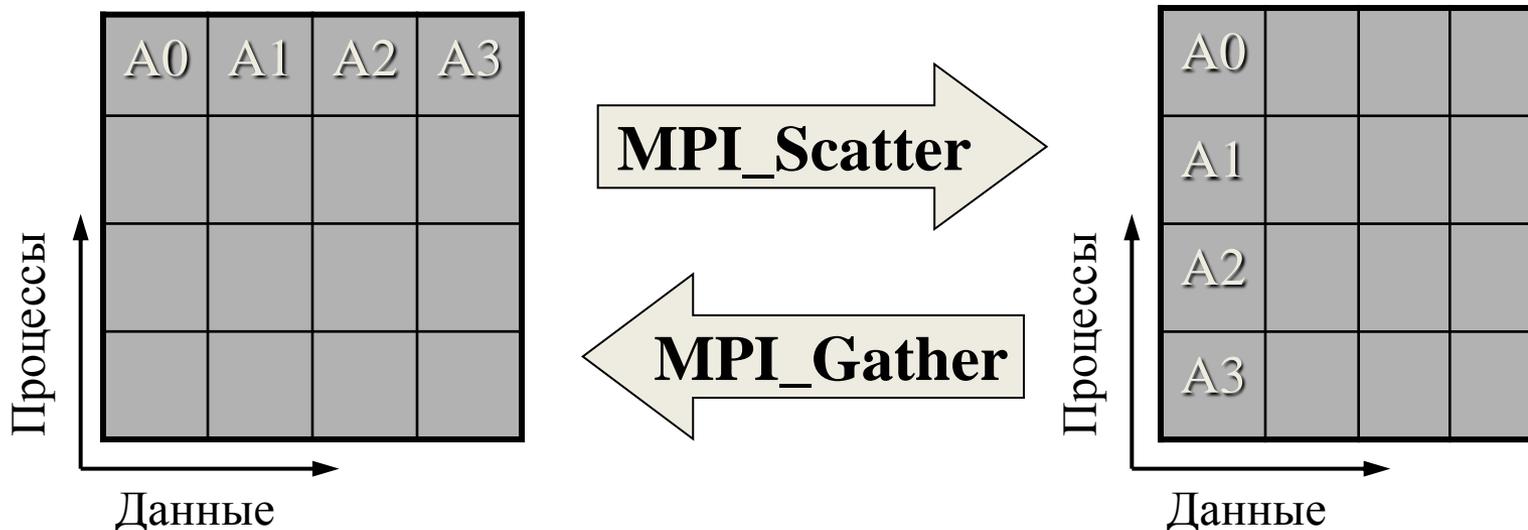
- IN/OUT void *buf – указатель на буфер с сообщением (отправляемым – для процесса с рангом root, принимаемым – для остальных процессов)
- IN int count – количество элементов в буфере
- IN MPI_Datatype datatype – MPI-тип данных элементов в буфере
- IN int root – ранг процесса, выполняющего рассылку данных
- IN MPI_Comm comm – коммуникатор



Коллективный прием сообщения

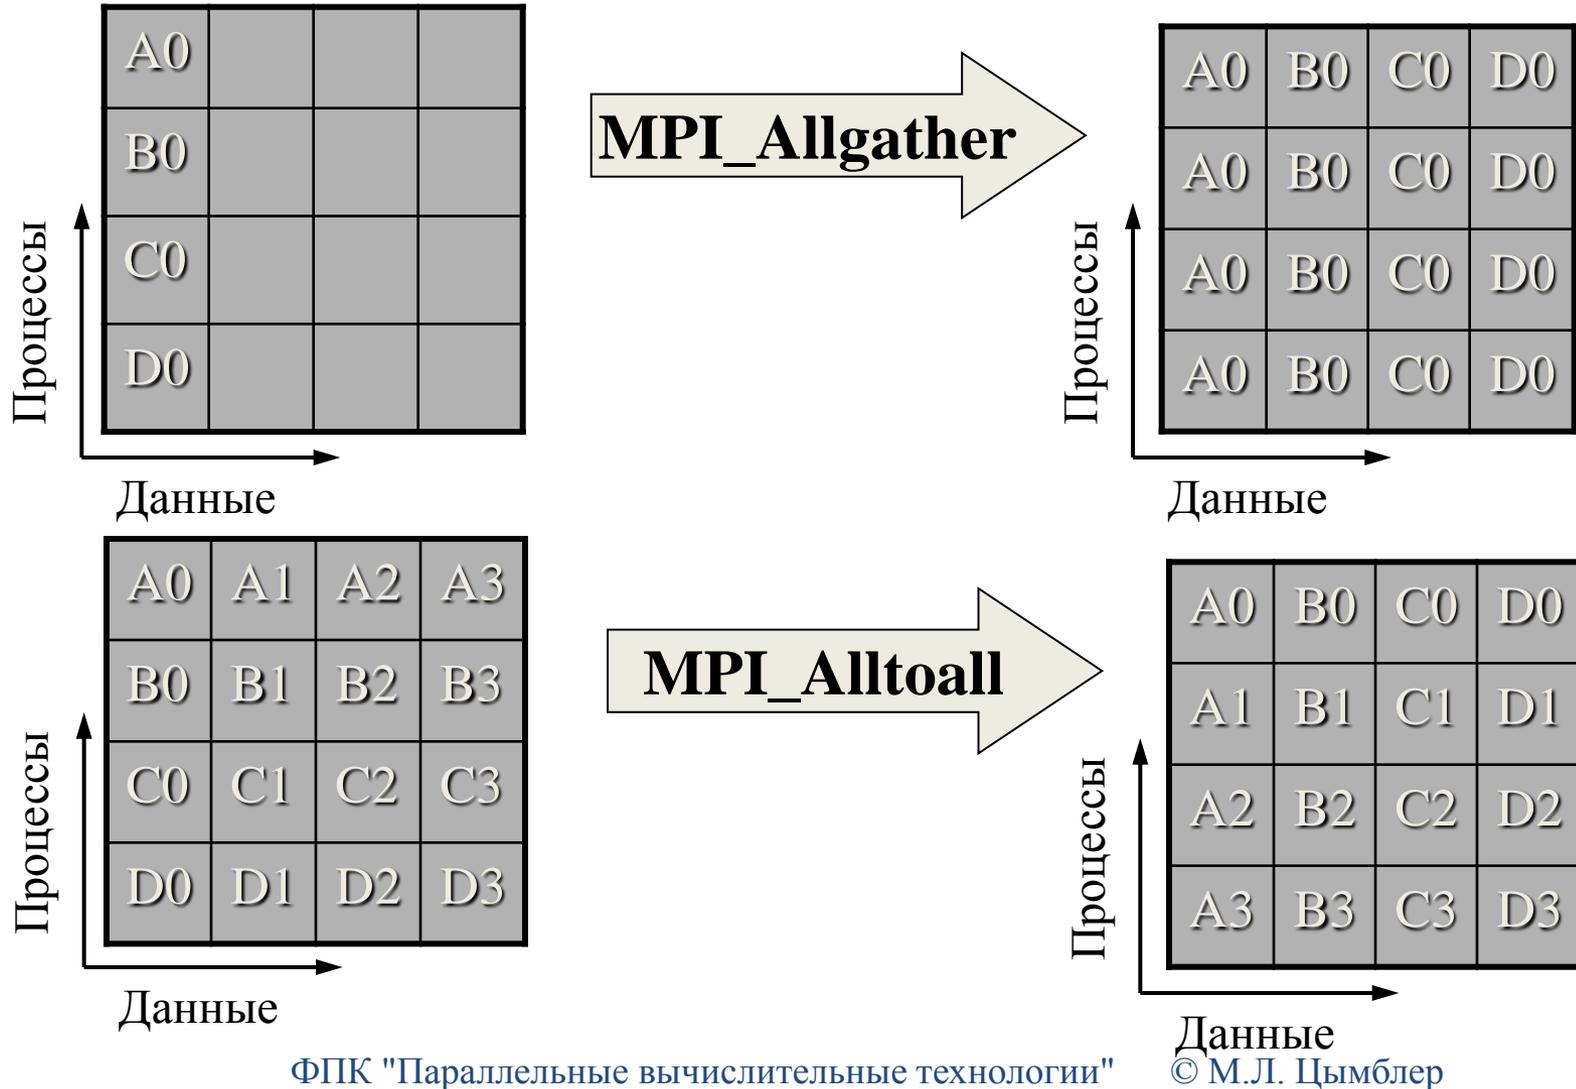
39

- Сборка элементов данных из буферов всех процессов в буфере процесса с рангом `root`
int MPI_Gather(void * sbuf, int scount, MPI_Datatype stype, void * rbuf, int rcount, MPI_Datatype rtype, int root, MPI_Comm comm);
- Рассылка элементов данных из буфера процесса с рангом `root` в буферы всех процессов (обратная к `MPI_Gather`)
int MPI_Scatter



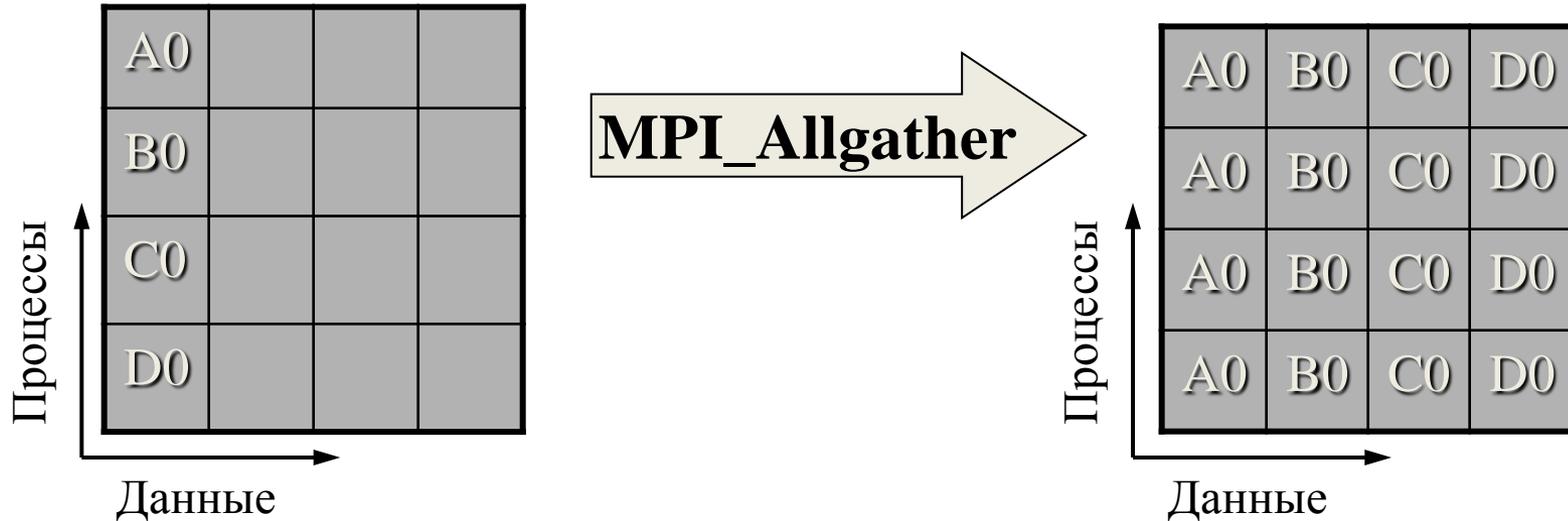
Широковещательные прием и передача

40



Широковещательный прием

41



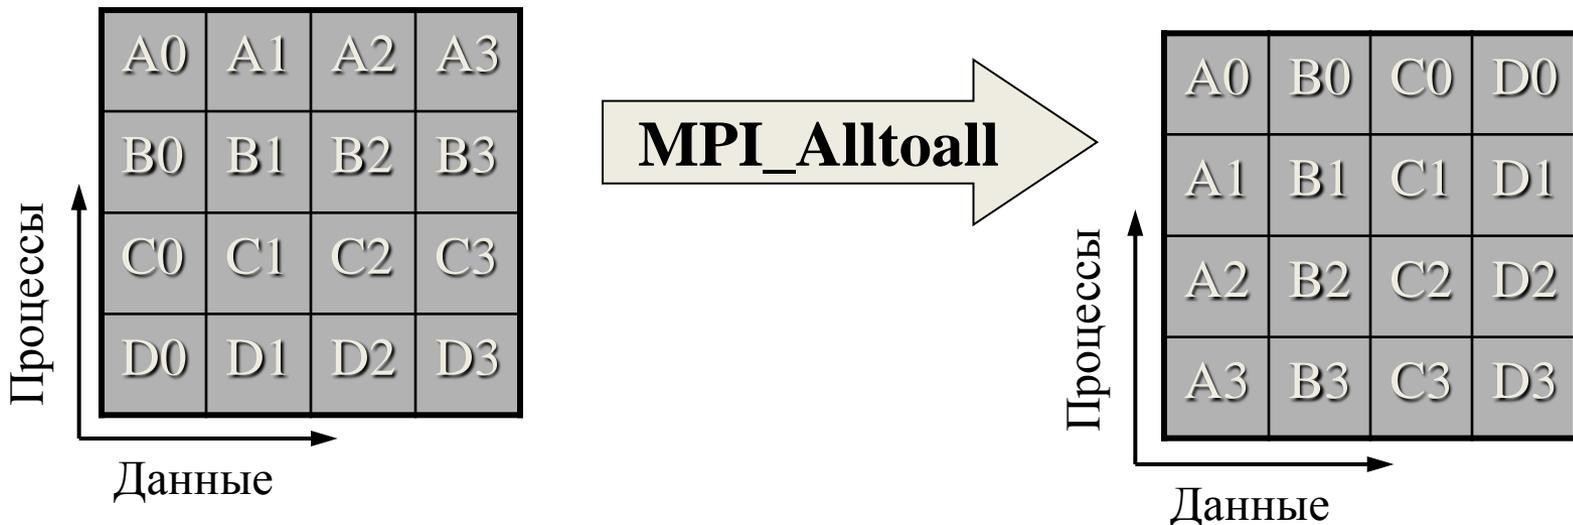
```
int MPI_Allgather(void *sbuf, int scount, MPI_Datatype stype,  
void *rbuf, int rcount, MPI_Datatype rtype, MPI_Comm comm)
```

Широковещательная передача

42

```
int MPI_Alltoall(void *sbuf, int scount, MPI_Datatype stype,  
void *rbuf, int rcount, MPI_Datatype rtype, MPI_Comm comm)
```

- **sbuf**, **scount**, **stype** - параметры передаваемых сообщений,
- **rbuf**, **rcount**, **rtype** - параметры принимаемых сообщений
- **comm** - коммуникатор, в рамках которого выполняется передача данных



Глобальные операции над данными

43

- Выполнение `count` независимых глобальных операций `op` над соответствующими элементами массивов `sbuf`. Результат выполнения над i -ми элементами `sbuf` записывается в i -й элемент массива `rbuf` процесса с рангом `root`.

```
int MPI_Reduce(void * sbuf, void * rbuf, int  
count, MPI_Datatype type, MPI_Op op, int root,  
MPI_Comm comm);
```

- Глобальные операции:
 - ▣ `MPI_MAX`, `MPI_MIN`
 - ▣ `MPI_SUM`, `MPI_PROD`
 - ▣ ...
 - ▣ `MPI_Op_Create()`

Пример: вычисление π

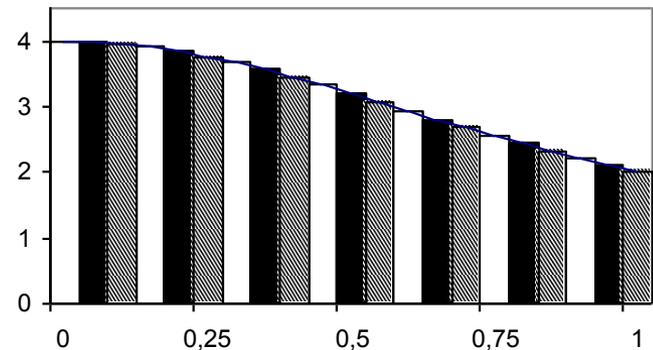
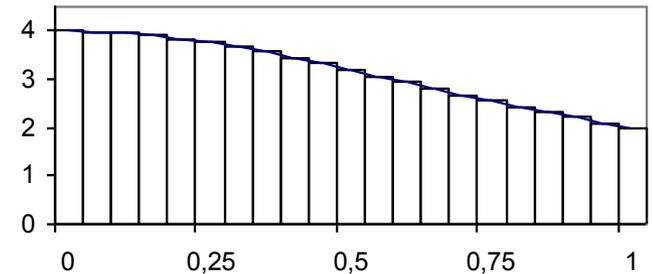
44

□
$$\pi = \int_0^1 \frac{4}{1+x^2} dx$$

□ Метод прямоугольников для численного интегрирования.

□ Циклическая схема распределения вычислений

▣ Получаемые на отдельных процессорах частные суммы должны быть просуммированы.



□ - Процесс 0
■ - Процесс 1
▨ - Процесс 2

Пример: вычисление π

45

```
#include "mpi.h"
#include <math.h>

int N; // Количество интервалов
double PI25DT=3.141592653589793238462643;

double f(double a)
{
    return (4.0 / (1.0 + a*a));
}

int main(int argc, char *argv[])
{
    int rank, num, i;
    double mypi, pi, h, sum, x, t1, t2;

    MPI_Init(&argc, &argv);
    MPI_Comm_size(MPI_COMM_WORLD, &num);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    if (rank == 0) {
        printf("Input number of intervals: "\n);
        scanf("%d\n", &N)
        t1 = MPI_Wtime();
    }
    MPI_Bcast(&N, 1, MPI_INT, 0, MPI_COMM_WORLD);
```

```
// Вычисление локальной суммы
h = 1.0 / (double) N;
sum = 0.0;
for (i = rank + 1; i <= N; i += num) {
    x = h * ((double)i - 0.5);
    sum += f(x);
}
mypi = h * sum;

// Сложение локальных сумм (редукция)
MPI_Reduce(&mypi, &pi, 1, MPI_DOUBLE, MPI_SUM,
0, MPI_COMM_WORLD);

// вывод результатов
if (rank == 0) {
    t2 = MPI_Wtime();
    printf("Pi is %.16f,
        Error is %.16f\n",
        pi, fabs(pi - PI25DT));
    printf("Time is %f\n", t2-t1);
}
MPI_Finalize();
return 0;
}
```

Типы данных в MPI

46

- Поддерживаются стандартные типы данных и возможность создания пользовательских типов данных.
- Приложение MPI может работать на гетерогенном вычислительном комплексе.
 - Одни и те же типы данных на разных машинах могут иметь разное представление:
 - Стандарты IEEE, IBM, Cray представления float-чисел.
 - Кодировки Windows и KOI-8.
 - Ориентация байтов в числах (на компьютерах с процессорами Intel младший байт занимает младший адрес, у компьютеров с др. процессорами – наоборот).
 - "Выравнивание" данных (добавление "пустот" в данные структурного типа для кратности их размера 2, 4 или 8 для ускорения доступа).
 - Процессы обмениваются данными в формате XDR (eXternal Data Representation), принятом в Internet. Поэтому среда исполнения должна знать не просто количество передаваемых байтов, но и тип содержимого.

Стандартные типы данных MPI

47

| Тип MPI | Соответствующий тип C |
|---------------------------------|---------------------------------|
| <code>MPI_CHAR</code> | <code>signed char</code> |
| <code>MPI_SHORT</code> | <code>signed short int</code> |
| <code>MPI_INT</code> | <code>signed int</code> |
| <code>MPI_LONG</code> | <code>signed long int</code> |
| <code>MPI_UNSIGNED_CHAR</code> | <code>unsigned char</code> |
| <code>MPI_UNSIGNED_SHORT</code> | <code>unsigned short int</code> |
| <code>MPI_UNSIGNED</code> | <code>unsigned int</code> |
| <code>MPI_UNSIGNED_LONG</code> | <code>unsigned long int</code> |
| <code>MPI_FLOAT</code> | <code>float</code> |
| <code>MPI_DOUBLE</code> | <code>double</code> |
| <code>MPI_LONG_DOUBLE</code> | <code>long double</code> |
| <code>MPI_BYTE</code> | - |
| <code>MPI_PACKED</code> | - |

Пример

48

```
#define msgTag 777
struct {
    int i;
    float f[4];
    char c[8];
} myStruct;
...
MPI_Send(&myStruct, sizeof(myStruct), MPI_BYTE, dest, msgTag,
MPI_COMM_WORLD );
```

```
char tempBuf[sizeof(s)];
```

```
MPI_Recv(tempBuf, sizeof(tempBuf), MPI_BYTE, src, msgTag,
MPI_COMM_WORLD, &status);
```

- **Ненадежно:** отправитель и получатель могут иметь разные двоичные представления (и, следовательно, размер) сообщения.

Пример

49

```
#define msgTag 777
struct {
    int i;
    float f[4];
    char c[8];
} myStruct;
...
MPI_Send(&myStruct.i, 1, MPI_INT, dest, msgTag, MPI_COMM_WORLD );
MPI_Send( myStruct.f, 4, MPI_FLOAT, dest, msgTag+1, MPI_COMM_WORLD );
MPI_Send( myStruct.c, 8, MPI_CHAR, dest, msgTag+2, MPI_COMM_WORLD );
...
```

```
MPI_Recv (...);
MPI_Recv (...);
MPI_Recv (...);
```

- Неэффективно: каждый элемент структуры передается отдельно.

Пример

50

```
int bufSize = 0;
void *tempBuf;

MPI_Pack_size(1, MPI_INT, MPI_COMM_WORLD, &bufSize);
MPI_Pack_size(4, MPI_FLOAT, MPI_COMM_WORLD, &bufSize);
MPI_Pack_size(8, MPI_CHAR, MPI_COMM_WORLD, &bufSize );
tempBuf = malloc(bufSize);
MPI_Pack(&myStruct.i, 1, MPI_INT, tempBuf, sizeof(tempBuf), &bufPos, MPI_COMM_WORLD);
MPI_Pack(myStruct.f, 4, MPI_FLOAT, tempBuf, sizeof(tempBuf), &bufPos, MPI_COMM_WORLD);
MPI_Pack(myStruct.c, 8, MPI_CHAR, tempBuf, sizeof(tempBuf), &bufPos, MPI_COMM_WORLD);
MPI_Send(tempBuf, bufPos, MPI_BYTE, dest, msgTag, MPI_COMM_WORLD);
```

```
int bufPos = 0;
char tempBuf[sizeof(myStruct)];
...
MPI_Recv(tempBuf, sizeof(tempBuf), MPI_BYTE, src, msgTag, MPI_COMM_WORLD, &status);
MPI_Unpack(tempBuf, sizeof(tempBuf), &bufPos, &s.i, 1, MPI_INT, MPI_COMM_WORLD);
MPI_Unpack(tempBuf, sizeof(tempBuf), &bufPos, s.f, 4, MPI_FLOAT, MPI_COMM_WORLD);
MPI_Unpack(tempBuf, sizeof(tempBuf), &bufPos, s.c, 8, MPI_CHAR, MPI_COMM_WORLD);
```

- Более эффективно: данные упаковываются перед пересылкой. Неудобно при программировании.

Пользовательские типы данных

51

□ Создание типа "массив"

```
int MPI_Type_contiguous(int count,  
MPI_Datatype oldtype, MPI_Datatype *newtype);
```

```
#define N 100  
int A[N];  
MPI_Datatype MPI_INTARRAY100;  
...  
MPI_Type_contiguous(N, MPI_INT, & MPI_INTARRAY100);  
MPI_Type_commit(&MPI_INTARRAY100);  
...  
MPI_Send(A, 1, MPI_INTARRAY100, ... );  
// то же, что и MPI_Send(A, N, MPI_INT, ... );  
...  
MPI_Type_free(&intArray100);
```

MPI-2: нововведения

61

- Динамическое порождение процессов
 - Разрешается создание и уничтожение процессов по ходу выполнения программы.
 - Предусмотрен специальный механизм, позволяющий устанавливать связь между только что порожденными процессами и уже работающей частью MPI-программы.
 - Имеется возможность установить связь между двумя приложениями даже в том случае, когда ни одно из них не было инициатором запуска другого.
- Одностороннее взаимодействие процессов
 - Обмен сообщениями по схеме Put/Get вместо традиционной схемы Send/Receive. Активной стороной может быть один процесс (при обмене не требуется активность отправителя либо получателя).
- Параллельный ввод-вывод
 - Специальный интерфейс для работы процессов с файловой системой.
- Расширенные коллективные операции
 - Во многие коллективные операции добавлена возможность взаимодействия между процессами, входящими в разные коммутаторы.
 - Многие коллективные операции внутри коммутатора могут выполняться в режиме, при котором входные и выходные буфера совпадают.
- Интерфейс для C++

Заключение

62

- Модель передачи сообщений для параллельного программирования в системах с распределенной памятью
- Режимы SPMD и MPMD запуска параллельных программ
- Стандарт Message Passing Interface (MPI)
- Основные понятия и функции MPI