Лекция 3

MPI

Стандарт **MPI** (**MPI** –Message Passing Interface).

На кластере реализован **OpenMPI**. Это программная реализация стандарта интерфейса передачи сообщений (**MPI**) с открытым исходным кодом.

http://www.open-mpi.org

В вычислительных системах с **распределенной памятью** процессоры работают независимо друг от друга. Для организации параллельных вычислений в таких условиях необходимо иметь возможность *распределять* вычислительную нагрузку и *организовать* информационное взаимодействие (*передачу данных*) между процессорами (ядрами).

Решение этих задач и обеспечивает интерфейс передачи данных **MPI. MPI** работает и на системах с **общей памятью**!

В общем плане, для распределения вычислений между процессорами необходимо проанализировать алгоритм решения задачи, выделить информационно независимые фрагменты вычислений, провести их программную реализацию и затем разместить полученные части программы на разных процессорах (ядрах).

MPI

В рамках MPI (как и в случае OpenMP) принят более простой подход – *разрабатывается одна программа и эта единственная программа запускается одновременно на выполнение на всех имеющихся процессорах (ядрах)*! При этом для того, чтобы избежать идентичности вычислений на разных процессорах, можно,

- во-первых, подставлять разные данные для программы на разных процессорах,
- во-вторых, в MPI (как и в OpenMP) имеются средства для идентификации процесса, и тем самым, предоставляется возможность организовать различия в вычислениях в разных процессах (процессорах).

Подобный способ организации параллельных вычислений получил наименование *модели **SPMD**, а в случае MPI эту модель часто называют: "одна программа множество процессов"* (*single program multiple processes* - ***SPMP***).

MPI

Для организации информационного взаимодействия между процессорами в самом минимальном варианте достаточно операции приема и передачи данных (при этом, конечно, должна существовать техническая возможность коммуникации между процессорами – *каналы* или *линии связи*) В MPI существует целое множество операций передачи данных. Они реализуют практически все возможные коммуникационные операции. Именно это является наиболее сильной стороной MPI.

Итак, во-первых, MPI - это **стандарт**, которому должны удовлетворять средства организации передачи сообщений.

Во-вторых, MPI – это **программные средства**, которые обеспечивают возможность передачи сообщений и при этом соответствуют всем требованиям стандарта MPI. Так, по стандарту, эти программные средства должны быть **организованы в виде библиотек** программных модулей (*библиотеки MPI*) и должны быть доступны для наиболее широко используемых алгоритмических языков C и Fortran.

MPI. Понятие параллельной программы

Под ***параллельной программой*** в рамках MPI понимается множество одновременно выполняемых ***процессов***.

Процессы могут выполняться на **разных процессорах**, но на одном процессоре могут располагаться и несколько процессов (в этом случае их исполнение осуществляется в режиме разделения времени).

В предельном случае для выполнения параллельной программы может использоваться **один процессор** – как правило, такой способ применяется для начальной проверки правильности параллельной программы.

Каждый процесс параллельной программы порождается на основе копии одного и того же программного кода (*модель SPMP*). Данный программный код, представленный в виде исполняемой программы, должен быть доступен в момент запуска параллельной программы на всех используемых процессорах.

MPI. Понятие параллельной программы

Исходный программный код для исполняемой программы разрабатывается на алгоритмических языках C или Fortran с использованием той или иной реализации библиотеки MPI.

Количество процессов и число используемых процессоров **определяется в момент запуска** параллельной программы средствами среды исполнения MPI-программ и в ходе вычислений **меняться не может**. В этом одно из главных отличий от **OpenMP**, в которой реализована «пульсирующая» модель типа разветвление – слияние.

Все процессы программы последовательно перенумерованы от 0 до *p-1*, где *p* есть общее количество процессов.

Номер процесса именуется ***рангом (rank)*** процесса.

MPI. Понятие параллельной программы

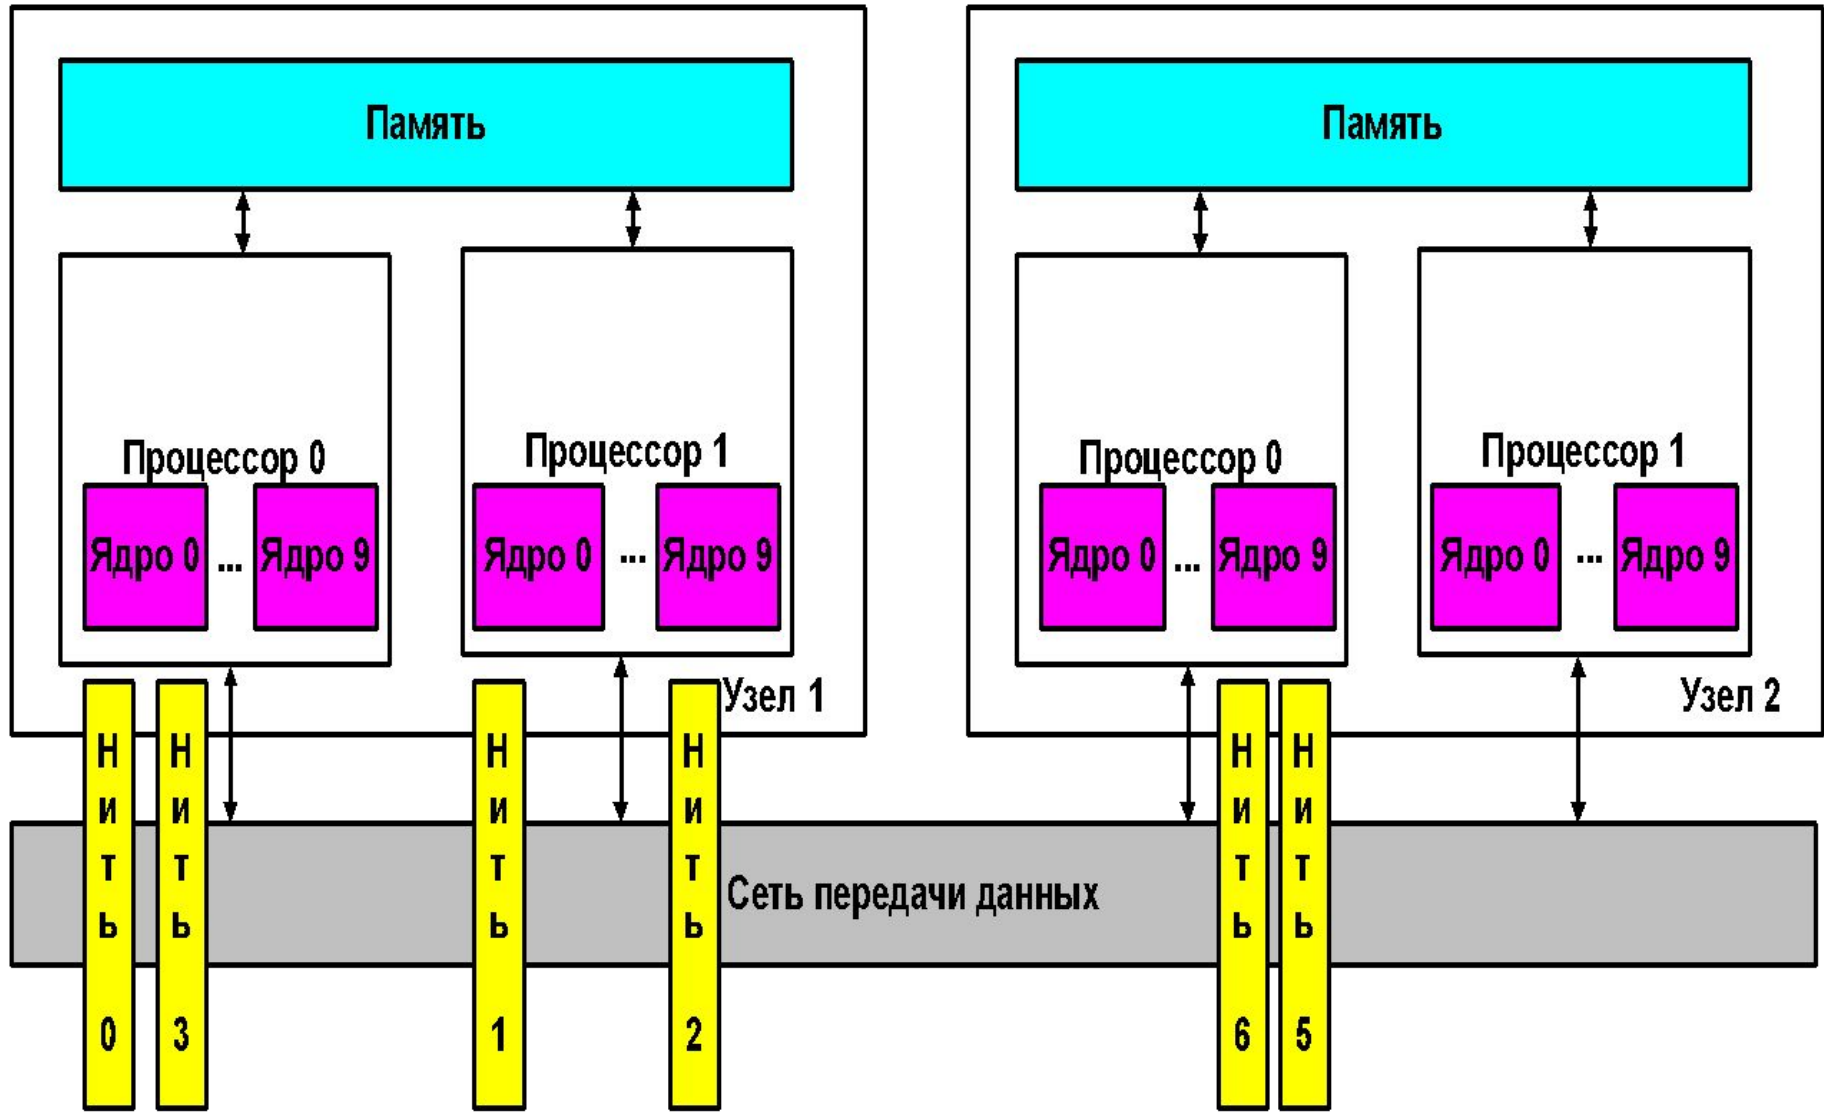

OpenMP. Параллельная программа

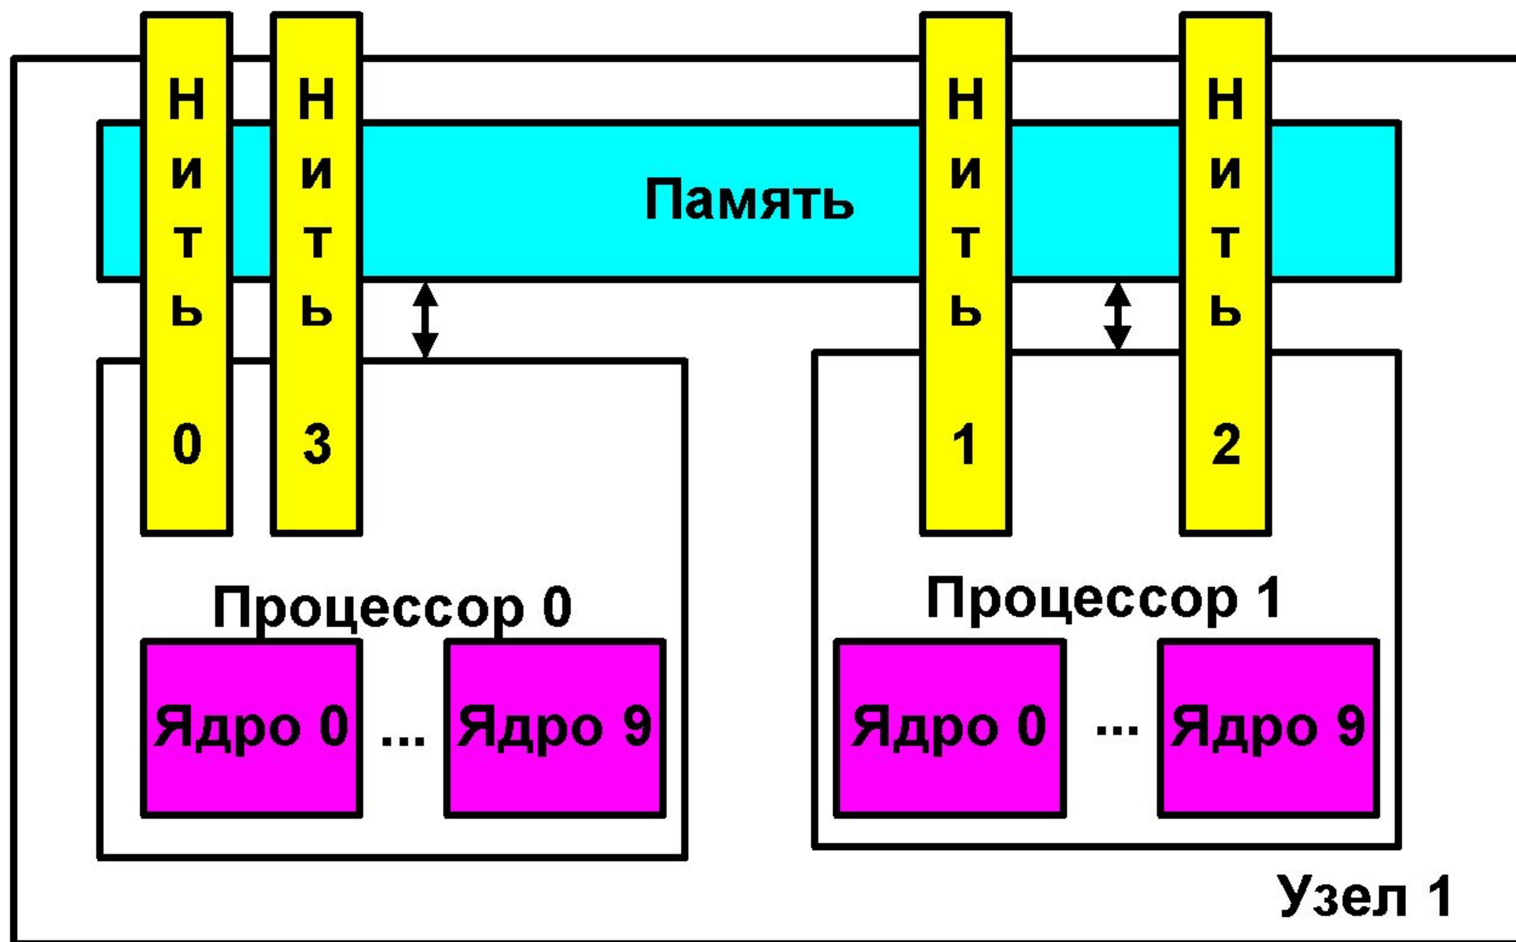

MPI. Операции передачи данных

Основу MPI составляют операции передачи сообщений. Среди предусмотренных в составе MPI функций различаются ***парные*** (*point-to-point*) операции между двумя процессами и ***коллективные*** (*collective*) коммуникационные действия для одновременного взаимодействия нескольких процессов.

Для выполнения парных операций могут использоваться разные *режимы передачи*, среди которых синхронный, блокирующий и др.

Стандарт MPI предусматривает необходимость реализации большинства основных коллективных операций передачи данных.

MPI. Понятие коммуникаторов

Процессы параллельной программы объединяются в ***группы***. Под ***коммуникатором*** в MPI понимается специально создаваемый служебный объект, объединяющий в своем составе группу процессов и ряд дополнительных параметров (*контекст*), используемых при выполнении операций передачи данных.

Как правило, парные операции передачи данных выполняются для процессов, принадлежащих **одному и тому же коммуникатору**. Коллективные операции применяются одновременно для всех процессов коммуникатора.

В ходе вычислений могут создаваться новые и удаляться существующие группы процессов и коммуникаторы. Один и тот же процесс может принадлежать разным группам и коммуникаторам. Все имеющиеся в параллельной программе процессы входят в состав создаваемого по умолчанию коммуникатора с идентификатором **MPI_COMM_WORLD**.

При необходимости передачи данных между процессами из разных групп необходимо создавать глобальный коммуникатор (*intercommunicator*).

MPI. Типы данных

При выполнении операций передачи сообщений для указания передаваемых или получаемых данных в функциях MPI необходимо указывать ***тип*** пересылаемых данных.

MPI содержит большой набор *базовых типов* данных, во многом совпадающих с типами данных в алгоритмических языках C и Fortran.

Кроме того, в MPI имеются возможности для создания новых *производных типов* данных для более точного и краткого описания содержимого пересылаемых сообщений.

MPI. Инициализация и завершение MPI программ

Первой вызываемой функцией MPI должна быть функция:

int MPI_Init (int *agrc, char ***argv);

для инициализации среды выполнения MPI-программы. Параметрами функции являются количество аргументов в командной строке и текст самой командной строки, передаваемые в основную программу **main**.

Последней вызываемой функцией MPI обязательно должна являться функция:

int MPI_Finalize (void);

MPI. Инициализация и завершение MPI программ

Структура параллельной программы, разработанная с использованием MPI, должна иметь следующий вид:

```
#include "mpi.h"
int main ( int argc, char *argv[] ) {
<программный код без использования MPI функций>
MPI_Init ( &agrc, &argv );
<программный код с использованием MPI функций>
MPI_Finalize();
<программный код без использования MPI функций>
return 0; }
```

1. Файл **mpi.h** содержит определения именованных констант, прототипов функций и типов данных библиотеки MPI,
2. Функции **MPI_Init** и **MPI_Finalize** являются обязательными и должны быть выполнены (**и только один раз!**) каждым процессом параллельной программы,

MPI. Определение количества и ранга процессов

Определение ***количества процессов*** в выполняемой параллельной программе осуществляется при помощи функции:

int MPI_Comm_size (MPI_Comm comm, int *size).

Для определения ***номера (ранга) процесса*** используется функция:

int MPI_Comm_rank (MPI_Comm comm, int *rank).

Как правило, вызов функций **MPI_Comm_size** и **MPI_Comm_rank** выполняется сразу после **MPI_Init**.

Число процессов (**size**) задается **средой выполнения** MPI **при запуске программы** и **не может быть изменено** при выполнении программы! (В отличие от OpenMP).

MPI_Comm определяет специальный тип объекта-коммуникатора MPI, **comm –** имя коммуникатора, в который группируются все процессы программы.

MPI. Определение количества и ранга процессов

```
#include "mpi.h"
int main ( int argc, char *argv[] ) {
int size, rank;
<программный код без использования MPI функций>
MPI_Init ( &agrc, &argv );
MPI_Comm_size ( MPI_COMM_WORLD, &size);
MPI_Comm_rank ( MPI_COMM_WORLD, &rank);
<программный код с использованием MPI функций>
MPI_Finalize();
<программный код без использования MPI функций>
return 0; }
```

1. Коммуникатор **MPI_COMM_WORLD** создается по умолчанию и представляет все процессы выполняемой параллельной программы,
2. Ранг, получаемый при помощи функции **MPI_Comm_rank**, является рангом процесса, выполнившего вызов этой функции, т.е. переменная **rank** будет принимать различные значения в разных процессах.

MPI. Передача сообщений

Для передачи сообщения процесс-отправитель должен выполнить функцию:

int MPI_Send(void *buf, int count, MPI_Datatype type, int dest, int tag, MPI_Comm comm),

где

- **buf** – адрес буфера памяти, в котором располагаются данные отправляемого сообщения,
- **count** – количество элементов данных в сообщении,
- **type** - тип элементов данных пересылаемого сообщения,
- **dest** - ранг процесса, которому отправляется сообщение,
- **tag** - значение-тег, используемое для идентификации сообщений,
- **comm** - коммуникатор, в рамках которого выполняется передача данных,
- **MPI_Datatype –** тип данных MPI

MPI. Базовые типы данных

MPI_Datatype	C Datatype
MPI_BYTE	
MPI_CHAR	signed char
MPI_DOUBLE	double
MPI_FLOAT	float
MPI_INT	int
MPI_LONG	long
MPI_LONG_DOUBLE	long double
MPI_PACKED	
MPI_SHORT	short
MPI_UNSIGNED_CHAR	unsigned char
MPI_UNSIGNED	unsigned int
MPI_UNSIGNED_LONG	unsigned long
MPI_UNSIGNED_SHORT	unsigned short

MPI. Передача сообщений

1. Отправляемое сообщение определяется через указание блока памяти (буфера), в котором это сообщение располагается. Используемая для указания буфера тройка (**buf, count, type**) входит в состав параметров практически всех функций передачи данных.
2. Процессы, между которыми выполняется передача данных, в обязательном порядке должны принадлежать коммуникатору, указываемому в функции **MPI_Send**,
3. Параметр **tag** используется только при необходимости различения передаваемых сообщений, в противном случае в качестве значения параметра может быть использовано произвольное целое неотрицательное число, лежащее в диапазоне от 0 до 32767.

MPI. Передача сообщений

Сразу же после завершения функции **MPI_Send** процесс-отправитель может начать повторно использовать буфер памяти, в котором располагалось отправляемое сообщение.

Вместе с этим, следует понимать, что в момент завершения функции **MPI_Send** состояние самого пересылаемого сообщения может быть совершенно различным - сообщение может располагаться в процессе-отправителе, может находиться в процессе передачи, может храниться в процессе-получателе или же может быть принято процессом-получателем при помощи функции **MPI_Recv**.

Тем самым, завершение функции **MPI_Send** означает лишь, что операция передачи начала выполняться и пересылка сообщения будет рано или поздно будет выполнена.

MPI. Прием сообщений

Для приема сообщения процесс-получатель должен выполнить функцию:

int MPI_Recv(void *buf, int count, MPI_Datatype type, int source, int tag, MPI_Comm comm, MPI_Status *status),

где

- **buf, count, type** – буфер памяти для приема сообщения, назначение каждого отдельного параметра соответствует описанию в **MPI_Send**,
- **source** - ранг процесса, от которого должен быть выполнен прием сообщения,
- **tag** - тег сообщения, которое должно быть принято для процесса,
- **comm** - коммуникатор, в рамках которого выполняется передача данных,
- **status** – указатель на структуру данных с информацией о результате выполнения операции приема данных.

MPI. Прием сообщений

1. Буфер памяти должен быть достаточным для приема сообщения, а тип элементов передаваемого и принимаемого сообщения должны совпадать; при нехватке памяти часть сообщения будет потеряна и в коде завершения функции будет зафиксирована ошибка переполнения.
2. При необходимости приема сообщения от любого процесса-отправителя для параметра **source** может быть указано значение **MPI_ANY_SOURCE**.
3. При необходимости приема сообщения с любым тегом для параметра **tag** может быть указано значение **MPI_ANY_TAG**.
4. **MPI_Status –** специальная структура MPI, которая содержит три поля:

- **status.MPI_SOURCE** – ранг процесса-отправителя принятого сообщения,
- **status.MPI_TAG** - тег принятого сообщения.
- **status.MPI_Error** - код ошибки.

MPI. Прием сообщений

Вызов функции **MPI_Recv** **не должен согласовываться** со временем вызова соответствующей функции передачи сообщения **MPI_Send** – прием сообщения может быть инициирован до момента, в момент или после момента начала отправки сообщения.

По завершении функции **MPI_Recv** в заданном буфере памяти будет располагаться принятое сообщение. Принципиальный момент здесь состоит в том, что функция **MPI_Recv** является **блокирующей** для процесса-получателя, т.е. его выполнение приостанавливается до завершения работы функции.

Таким образом, если по каким-то причинам ожидаемое для приема сообщение будет отсутствовать, выполнение параллельной программы будет **блокировано**.

Рассмотренный выше набор из 6 функций MPI оказывается достаточным для разработки параллельных программ!

MPI_Init, MPI_Finalize, MPI_Comm_size, MPI_Comm_rank, MPI_Send, MPI_Recv.

MPI. Определение времени выполнения

Получение времени текущего момента выполнения программы обеспечивается при помощи функции:

double MPI_Wtime(void),

результат вызова которой есть количество секунд, прошедшее от некоторого определенного момента времени в прошлом. Этот момент времени в прошлом, от которого происходит отсчет секунд, может зависеть от среды реализации библиотеки MPI и, тем самым, для ухода от такой зависимости функцию **MPI_Wtime** следует использовать только для определения длительности выполнения тех или иных фрагментов кода параллельных программ. Возможная схема применения функции **MPI_Wtime** может состоять в следующем:

```
double t1, t2, dt;
t1 = MPI_Wtime();
…
t2 = MPI_Wtime();
dt = t2 – t1;
```

Точность измерения времени также может зависеть от среды выполнения параллельной программы. Для определения текущего значения точности может быть использована функция:

double MPI_Wtick(void),

позволяющая определить время в секундах между двумя последовательными показателями времени аппаратного таймера используемой компьютерной системы.

MPI. Коллективные операции пересылки данных

Для выполнения коммуникационных ***коллективных операций***, в которых принимают участие все процессы коммуникатора, в MPI предусмотрен специальный набор функций.

MPI. Передача данных от одного процесса всем процессам программы

int MPI_Bcast (void *buf, int count, MPI_Datatype type, int root, MPI_Comm comm),
где
- **buf**, **count**, **type** – буфер памяти с отправляемым сообщением (для процесса с рангом **root**), и для приема сообщений для всех остальных процессов,
- **root** - ранг процесса, выполняющего рассылку данных,
- **comm** - коммуникатор, в рамках которого выполняется передача данных.

Функция **MPI_Bcast** осуществляет рассылку данных из буфера **buf**, содержащего **count** элементов типа **type** с процесса, имеющего номер **root**, всем процессам, входящим в коммуникатор **comm**.

MPI. Передача данных от одного процесса всем процессам программы

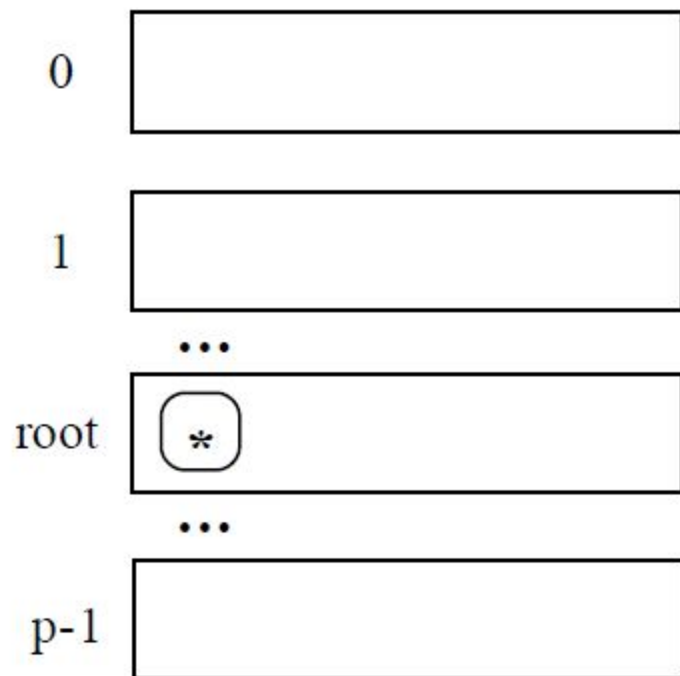

а) до начала операции

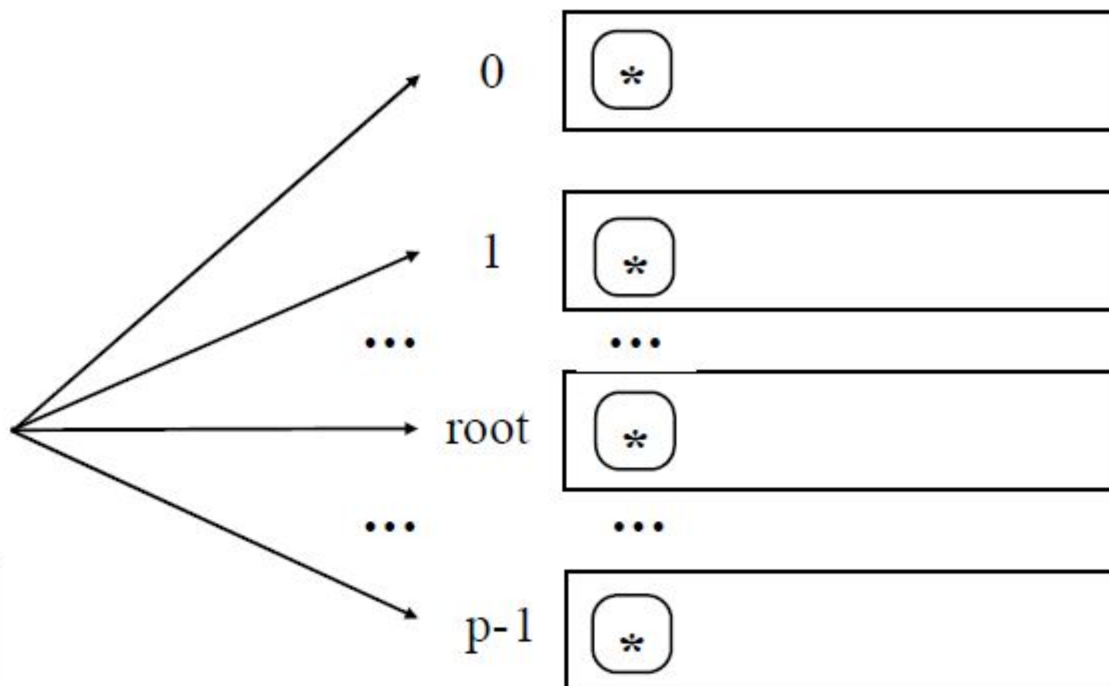

б) после завершения операции

MPI. Передача данных от одного процесса всем процессам программы

Функция **MPI_Bcast** определяет коллективную операцию и, тем самым, при выполнении необходимых рассылок данных вызов функции **MPI_Bcast** должен быть осуществлен всеми процессами указываемого коммуникатора.

Указываемый в функции **MPI_Bcast** буфер памяти имеет различное назначение в разных процессах. Для процесса с рангом **root**, с которого осуществляется рассылка данных, в этом буфере должно находиться рассылаемое сообщение. Для всех остальных процессов указываемый буфер предназначен для приема передаваемых данных.

MPI. Передача данных от всех процессов одному процессу. Операции редукции

В этой операции над собираемыми значениями осуществляется та или иная обработка данных (именуется *операцией редукции данных*). Для наилучшего выполнения действий, связанных с редукцией данных, в MPI предусмотрена функция:

int MPI_Reduce (void *sendbuf, void *recvbuf, int count, MPI_Datatype type, MPI_Op op, int root, MPI_Comm comm),

где

- **sendbuf** - буфер памяти с отправляемым сообщением,
- **recvbuf** – буфер памяти для результирующего сообщения (только для процесса с рангом **root**),
- **count** - количество элементов в сообщениях,
- **type** – тип элементов сообщений,
- **op** - операция, которая должна быть выполнена над данными,
- **root** - ранг процесса, на котором должен быть получен результат,
- **comm** - коммуникатор, в рамках которого выполняется операция.

MPI. Передача данных от всех процессов одному процессу. Операции редукции

Операция	Описание
MPI_MAX	Определение максимального значения
MPI_MIN	Определение минимального значения
MPI_SUM	Определение суммы значений
MPI_PROD	Определение произведения значений
MPI_LAND	Выполнение логической операции "И" над значениями сообщений
MPI_BAND	Выполнение битовой операции "И" над значениями сообщений
MPI_LOR	Выполнение логической операции "ИЛИ" над значениями сообщений
MPI_BOR	Выполнение битовой операции "ИЛИ" над значениями сообщений
MPI_LXOR	Выполнение логической операции исключающего "ИЛИ" над значениями сообщений
MPI_BXOR	Выполнение битовой операции исключающего "ИЛИ" над значениями сообщений
MPI_MAXLOC	Определение максимальных значений и их индексов
MPI_MINLOC	Определение минимальных значений и их индексов

MPI. Передача данных от всех процессов одному процессу. Операции редукции

Элементы получаемого сообщения на процессе **root** представляют собой результаты обработки соответствующих элементов передаваемых процессами сообщений:

$$y_j = \bigotimes_{i=0}^{n-1} x_{ij}, 0 \le j < n,$$

где $\otimes$ есть операция, задаваемая при вызове функции **MPI_Reduce**.

MPI. Передача данных от всех процессов одному процессу. Операции редукции

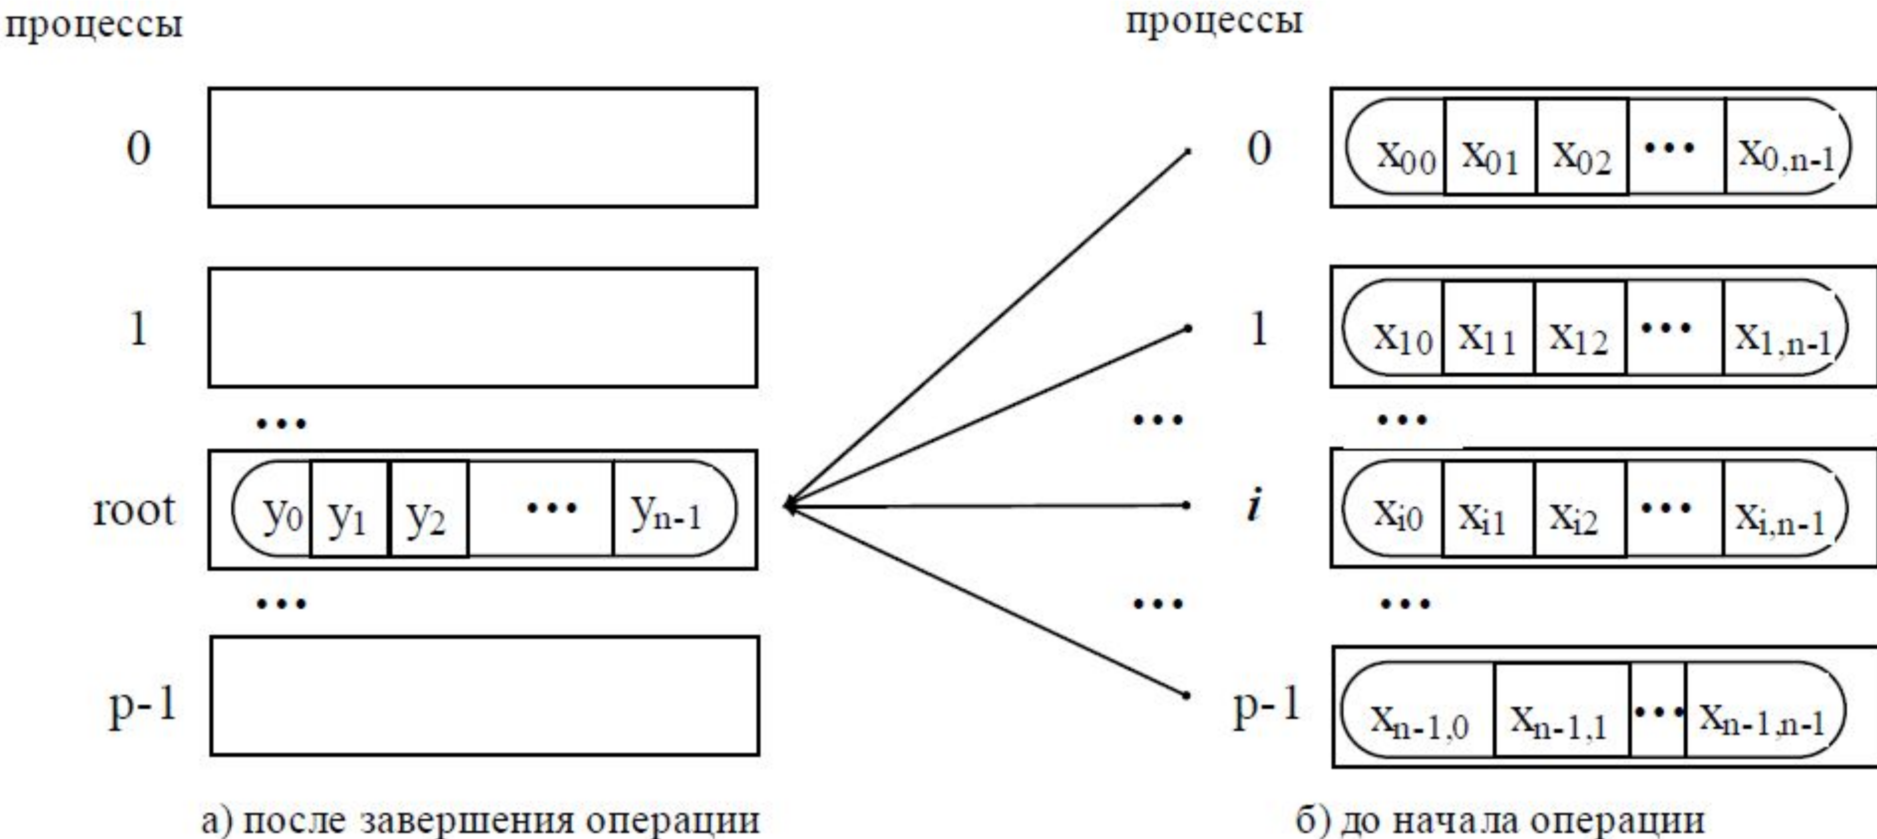

а) после завершения операции

б) до начала операции

$$y_j = \bigotimes_{i=0}^{n-1} x_{ij}, \; 0 \le j < n ,$$

MPI. Передача данных от всех процессов одному процессу. Операции редукции

Функция **MPI_Reduce** определяет коллективную операцию и, тем самым, вызов функции должен быть выполнен всеми процессами указываемого коммуникатора, все вызовы функции должны содержать одинаковые значения параметров **count**, **type**, **op**, **root**, **comm**.

Передача сообщений должна быть выполнена всеми процессами, результат операции будет получен только процессом с рангом **root**.

Выполнение операции редукции осуществляется над отдельными элементами передаваемых сообщений. Так, например, если сообщения содержат по два элемента данных и выполняется операция суммирования **MPI_SUM**, то результат также будет состоять из двух значений, первое из которых будет содержать сумму первых элементов всех отправленных сообщений, а второе значение будет равно сумме вторых элементов сообщений соответственно.

MPI. Передача данных от всех процессов одному процессу. Операции редукции

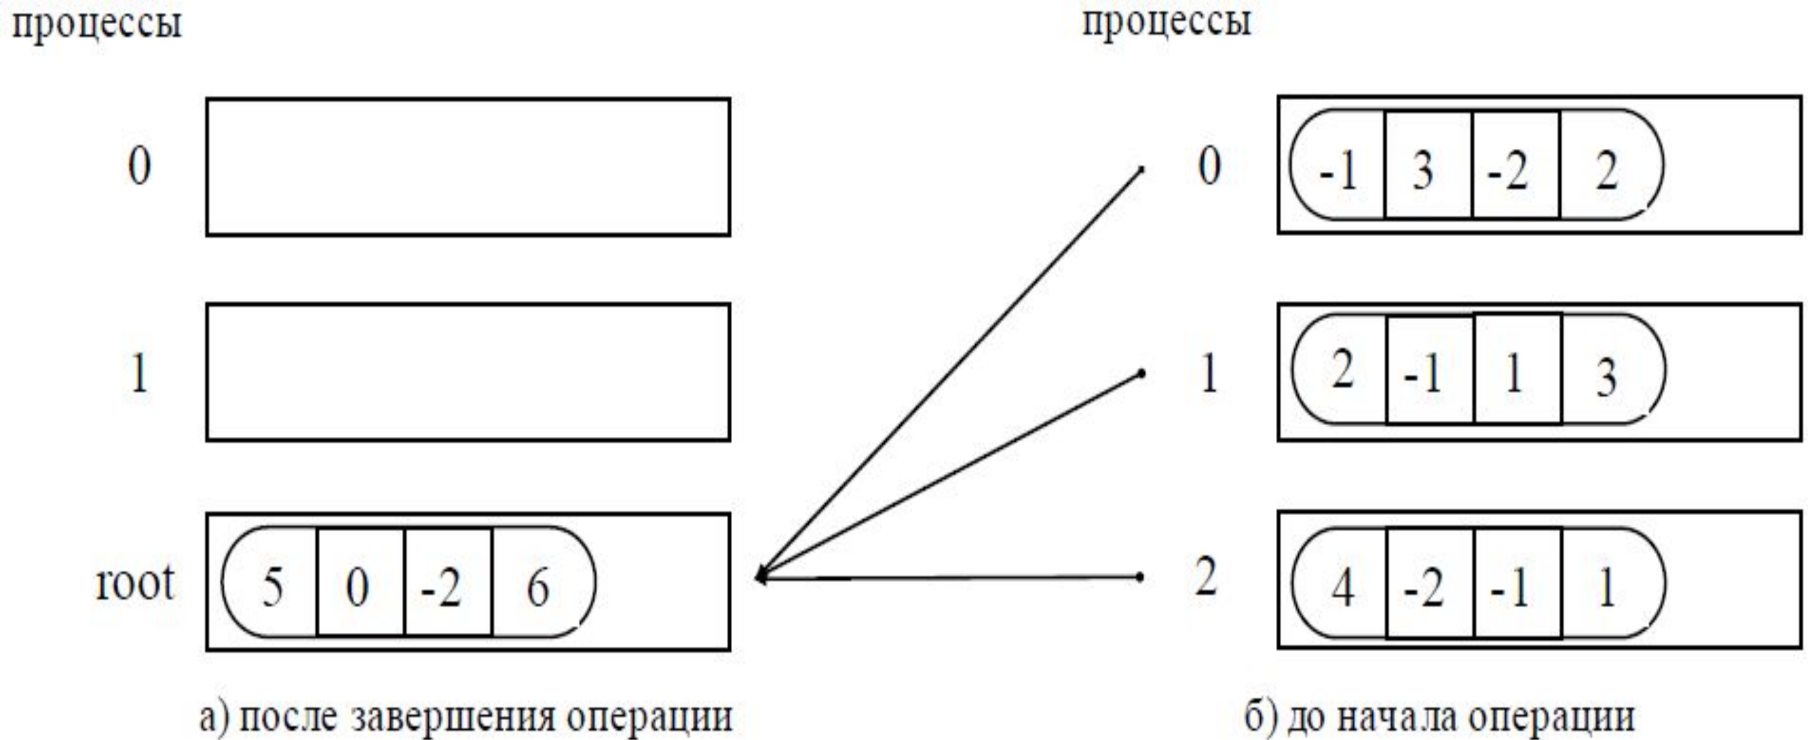

MPI. Понятие параллельной программы

MPI_Init MPI_Send … MPI_Recv MPI_Finalize

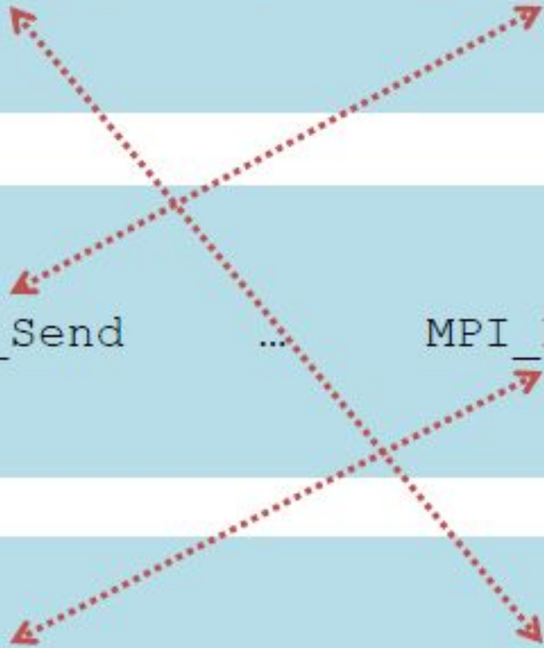

MPI_Init MPI_Send … MPI_Recv MPI_Finalize

MPI_Init MPI_Send … MPI_Recv MPI_Finalize

MPI. Что осталось «за кадром»?

1. Модификации обмена сообщениями точка-точка.
2. Модификации коллективных обменов сообщениями.
3. Работа с коммуникаторами, с данными
4. Виртуальные топологии.

MPI. Компиляция и запуск

Компиляция для языка Си:

mpicc <имя исходного файла.c> -o <имя исполняемого файла>

Запуск без системы SLURM на одном узле:

mpirun –n <число процессов> <имя исполняемого файла>

Запуск в системе SLURM на одном узле:

salloc –N1 –n<число процессов> mpirun <имя исполняемого файла>

параметр –N задает число узлов.

Запуск в системе SLURM на двух узлах:

salloc –N2 –n<число процессов> mpirun -mca oob_tcp_if_include bond0 <имя исполняемого файла>

Строка **-mca oob_tcp_if_include bond0** «подключает» интерфейс между узлами.

MPI. Примеры программ

Программа 1. Определение версии MPI

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char* argv[])
{
 int version, sub_version;

    MPI_Init(&argc, &argv);

    MPI_Get_version(&version, &sub_version);

    printf("MPI Version %d.%d\n", version, sub_version);

    MPI_Finalize();
    return 0;
}
```

MPI. Примеры программ

Программа 2. Определение числа процессов и номера процесса

```
//Число процессов задается параметрами среды выполнения MPI при запуске
#include <stdio.h>
#include "mpi.h"
int main(int argc, char **argv)
{
   int rank, size;
   MPI_Init(&argc, &argv);
   MPI_Comm_size (MPI_COMM_WORLD, &size);
   MPI_Comm_rank (MPI_COMM_WORLD, &rank);
   printf ("process %d, size %d\n", rank, size);
   MPI_Finalize();
return (0);
}
```

MPI. Примеры программ

Программа 3. Определение имени узла (узлов)

```
#include "mpi.h"
#include <stdio.h>
int main(int argc, char *argv[])
{
   int rank, size, len;
   char name[MPI_MAX_PROCESSOR_NAME];
   MPI_Init(&argc,&argv);
   MPI_Comm_size(MPI_COMM_WORLD,&size);
   MPI_Comm_rank(MPI_COMM_WORLD,&rank);
    MPI_Get_processor_name (name, &len); /*Процедура возвращает в
строке name имя узла, на котором запущен вызвавший процесс. В
переменной len возвращается количество символов в имени, не
превышающее
значения константы MPI_MAX_PROCESSOR_NAME*/
   printf ("Hello.  I am %d of %d on %s\n", rank, size, name);
   MPI_Finalize();
   return 0; }
```

MPI. Примеры программ

Программа 4. Системный таймер. Замер времени. Точность таймера

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char **argv)
{
double start_time, end_time, tick;
   MPI_Init(&argc, &argv);
start_time = MPI_Wtime();
sleep (1);
end_time = MPI_Wtime();
tick = MPI_Wtick();
printf ("Time to measure %E\n", end_time-start_time);
printf ("Accuracy of timer %E\n", tick);
MPI_Finalize();
return 0;
}
```

MPI. Примеры программ

Программа 5. Обмен сообщениями двух процессов

```
#include "mpi.h"
#include <stdio.h>
#include <stdlib.h>
int main(int argc, char **argv)
{
   int rank;
   float a, b;
   MPI_Status status;
   MPI_Init(&argc, &argv);
   MPI_Comm_rank (MPI_COMM_WORLD, &rank);
```

MPI. Примеры программ

Программа 5. Продолжение

```
a = 0.0;   b = 0.0;
  if(rank == 0)
  {      b = 1.0;
     MPI_Send(&b, 1, MPI_FLOAT, 1, 5, MPI_COMM_WORLD);
     MPI_Recv(&a, 1, MPI_FLOAT, 1, 5, MPI_COMM_WORLD,
&status);   }
  if(rank == 1)
  {      a = 2.0;
     MPI_Recv(&b, 1, MPI_FLOAT, 0, 5, MPI_COMM_WORLD,
&status);
     MPI_Send(&a, 1, MPI_FLOAT, 0, 5, MPI_COMM_WORLD);
}
  printf("process %d a = %f, b = %f\n", rank, a, b);
  MPI_Finalize();
return (0);
}
```

MPI. Примеры программ

Программа 6. Обмен сообщениями четных и нечетных процессов

```
#include "mpi.h"
#include <stdio.h>
#include <stdlib.h>
int main(int argc, char **argv)
{
   int size, rank, b, c, d;
   MPI_Status status;
   MPI_Init (&argc, &argv);
   MPI_Comm_size (MPI_COMM_WORLD, &size);
   MPI_Comm_rank (MPI_COMM_WORLD, &rank);
```

MPI. Примеры программ

Программа 6. Продолжение

```
b = -1;   c = 0;   d = 1;
   if((rank%2) == 0){
      if(rank<size-1) {
 MPI_Send(&b, 1, MPI_INT, rank+1, 5, MPI_COMM_WORLD);
  MPI_Recv(&c, 1, MPI_INT, rank+1, 5, MPI_COMM_WORLD,
&status);}
      else c=1;  }
   else      {
MPI_Recv(&c, 1, MPI_INT, rank-1, 5, MPI_COMM_WORLD,
&status);
 MPI_Send(&d, 1, MPI_INT, rank-1, 5, MPI_COMM_WORLD);}
   printf ("process %d, b = %d, c = %d, d = %d\n  ", rank, b, c, d);
   MPI_Finalize();
return (0);
}
```

MPI. Примеры программ

Программа 7.

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char **argv)
{int i;
MPI_Init(&argc, &argv);
if (i == MPI_SUCCESS)
printf("Successful initialization with code %d\n", i);
else
printf("Initialization failed with error code %d\n", i);
   MPI_Finalize();
if (i == MPI_SUCCESS)
printf("Successful MPI_Finalize() with code %d\n", i);
else
printf("MPI_Finalize() failed with error code %d\n", i);
return (0);
}
```

MPI. Примеры программ

Программа 8. Моделирование тупика

```
#include "mpi.h"
#include <stdio.h>
#include <stdlib.h>
int main(int argc, char **argv)
{
   int rank, b, c;
   MPI_Status status;
   MPI_Init(&argc, &argv);
   MPI_Comm_rank(MPI_COMM_WORLD, &rank);
```

MPI. Примеры программ

Программа 8. Продолжение

```
b = -10;   c = 10;
    if(rank == 0){

   MPI_Send(&b, 1, MPI_INT, 1, 5, MPI_COMM_WORLD);
    MPI_Recv(&c, 1, MPI_INT, 1, 5, MPI_COMM_WORLD,
&status);  }
  if(rank == 1)
   {
        MPI_Recv(&c, 1, MPI_INT, 0, 5, MPI_COMM_WORLD,
&status);
        MPI_Send(&b, 1, MPI_INT, 0, 5, MPI_COMM_WORLD);
      }
   printf("process %d, b = %d, c = %d\n ", rank, b, c);
   MPI_Finalize();
return (0);
}
```

MPI

Программа 9. Программа с приветом

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char* argv[]){
int size, rank, RecvRank;
MPI_Status Status;
MPI_Init(&argc, &argv);
MPI_Comm_size(MPI_COMM_WORLD, &size);
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
if ( rank == 0 ){
// Действия, выполняемые только процессом с рангом 0
printf ("\n Hello from process %3d", rank);
for ( int i=1; i<size; i++ ) {
MPI_Recv(&RecvRank, 1, MPI_INT, MPI_ANY_SOURCE,
MPI_ANY_TAG, MPI_COMM_WORLD, &Status);
printf("\n Hello from process %3d", RecvRank); }}
else // Сообщение, отправляемое всеми процессами,
// кроме процесса с рангом 0
MPI_Send(&rank,1,MPI_INT,0,0,
  MPI_COMM_WORLD); MPI_Finalize();
return 0; }
```

Каждый процесс определяет свой ранг, после чего действия в программе разделяются. Все процессы, кроме процесса с рангом 0, передают значение своего ранга нулевому процессу. Процесс с рангом 0 сначала печатает значение своего ранга, а далее последовательно принимает сообщения с рангами процессов и также печатает их значения. Порядок приема сообщений заранее не определен и зависит от условий выполнения параллельной программы (более того, этот порядок может изменяться от запуска к запуску).

MPI

Возможный вариант результатов печати процесса 0 может состоять в следующем (для параллельной программы из четырех процессов):

```
Hello from process 0
Hello from process 2
Hello from process 1
Hello from process 3
```

Такой "плавающий" вид получаемых результатов существенным образом усложняет разработку, тестирование и отладку параллельных программ, т.к. в этом случае исчезает один из основных принципов программирования – повторяемость выполняемых вычислительных экспериментов.

Как правило, если это не приводит к потере эффективности, желательно обеспечивать однозначность расчетов и при использовании параллельных вычислений. Так, для рассматриваемого простого примера можно восстановить постоянство получаемых результатов при помощи задания ранга процесса-отправителя в операции приема сообщения:

```
MPI_Recv(&RecvRank, 1, MPI_INT, i, MPI_ANY_TAG, MPI_COMM_WORLD, &Status).
```

Указание ранга процесса-отправителя регламентирует порядок приема сообщений, и, как результат, строки печати будут появляться строго в порядке возрастания рангов процессов (повторим, что такая регламентация в отдельных ситуациях может приводить к замедлению выполняемых параллельных вычислений).

MPI

Для разделения фрагментов кода между процессами обычно используется подход, примененный в только что рассмотренной программе - при помощи функции **MPI_Comm_rank** определяется ранг процесса, а затем в соответствии с рангом выделяются необходимые для процесса участки программного кода.

Наличие в одной и той же программе фрагментов кода разных процессов также значительно усложняет понимание и, в целом, разработку MPI-программы. Как результат, можно рекомендовать при увеличении объема разрабатываемых программ выносить программный код разных процессов в отдельные программные модули (функции). Общая схема MPI программы в этом случае будет иметь вид:

```
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
if ( rank == 0 ) DoProcess0();
else if ( rank == 1 ) DoProcess1();
else if ( rank == 2 ) DoProcess2();
```

Во многих случаях, как и в рассмотренном примере, выполняемые действия являются отличающимися только для процесса с рангом 0. В этом случае общая схема MPI программы принимает более простой вид:

```
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
if ( rank == 0 ) DoManagerProcess();
else DoWorkerProcesses();
```

MPI и OpenMP

Плюсы MPI

- Переносимость для систем с общей и распределенной памятью
- Масштабируемость при увеличении узлов

Минусы MPI

- Сложность разработки и отладки
- Высокая латентность
- Явные коммуникации
- Сложность балансировки загрузки

Плюсы OpenMP

- Простая реализация параллелизма
- Низкая латентность
- Неявные коммуникации
- Динамическая балансировка загрузки

Минусы OpenMP

- Переносимость только для систем с общей памятью
- Масштабируемость в пределах одного узла
- Отсутствие возможности задать порядок нитей

MPI + OpenMP

Архитектура MPI+OpenMP: плюсы

1. Удобное применение для кластеров с SMP-узлами:

- MPI – между узлами: избегаем накладных расходов на MPI-коммуникации внутри узла;

- OpenMP – внутри узла: получаем передачу сообщений большего размера за меньшее время и динамическую балансировку загрузки.

2. Потенциальная возможность получить большее ускорение, чем "чистый" MPI или "чистый" OpenMP.

Архитектура MPI+OpenMP: минусы

1. Меньшая масштабируемость OpenMP.
2. Возможность тупиков в MPI.

MPI + OpenMP

Компиляция MPI+OpenMP-программ

mpicc <имя исходного файла.c> -fopenmp -o <имя исполняемого файла>