САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ
ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ

Параллельные вычисления

Проектирование многопроцессных программ

Михаил Моисеев

Санкт-Петербург
2012

Проектирование многопроцессных программ

- Модель взаимодействующих процессов
  - с общей памятью
  - без общей памяти
- Стандарты и библиотеки
  - POSIX
  - MPI
  - PVM
  - …

Создание многопроцессных программ на основе MPI

- MPI (Message Passing Interface) – спецификация интерфейсов (API) для передачи сообщений между процессами
- Разрабатывается MPI Forum http://www.mpi-forum.org
  - Последняя версия MPI 3.0 (2012)
- Поддерживаются языки C, C++, Fortran
- Имеются реализации для ОС Linux, Mac OS, Windows

Модель параллельных вычислений MPI

- В MPI рассматриваются автономные процессы, исполняющие произвольный код и обрабатывающие произвольные данные (MIMD)
- Каждый процесс выполняется в своем адресном пространстве, взаимодействие процессов организуется с помощью сообщений
  - сообщение от одного процесса другому
  - сообщение от одного процесса группе процессов
  - ожидание сообщения одним процессом от группы процессов
- MPI обеспечивает запуск и управление процессами
  - начальный запуск процессов
  - динамический запуск процессов
- Поддержка разделяемой памяти процессов

Модель параллельных вычислений MPI

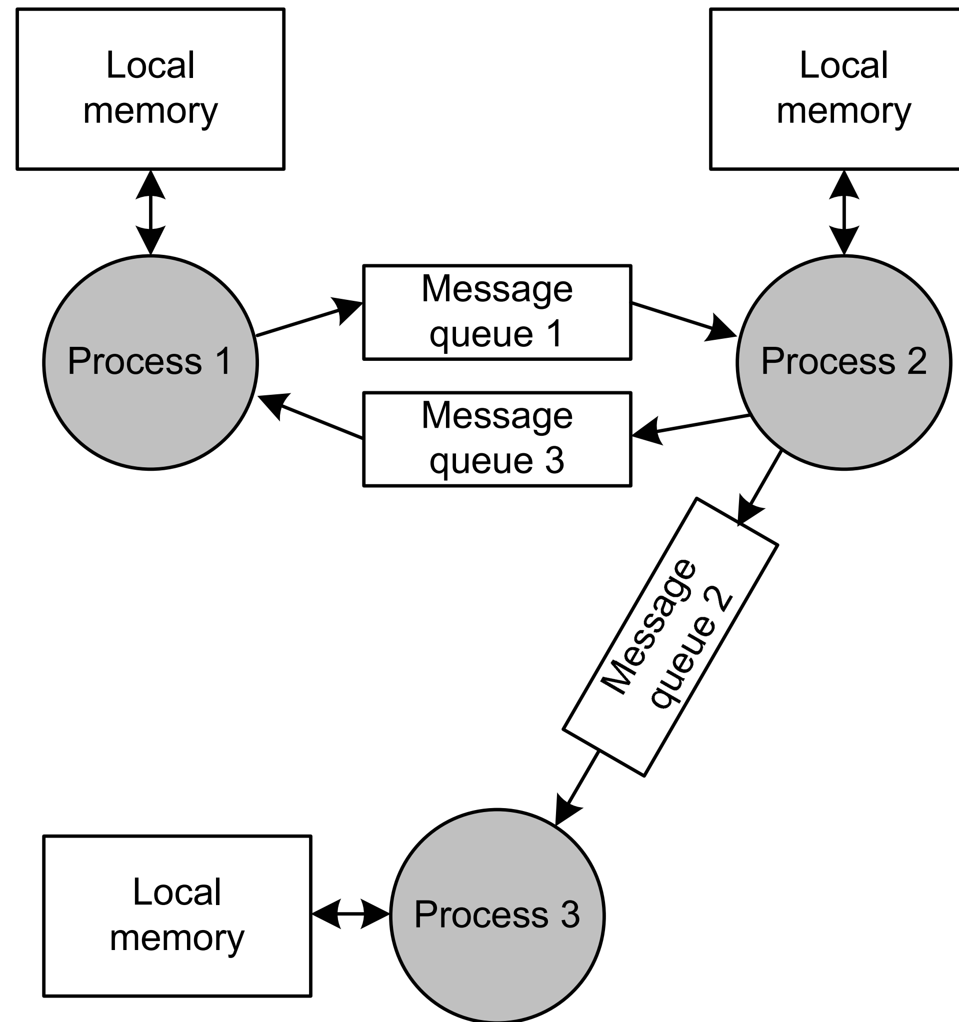

Использование MPI

- Инициализация/завершение

```
int MPI_Init(int *argc, char ***argv)

int MPI_Finalize(void)
```

- Пример программы

```
#include "mpi.h"

int main( int argc, char **argv )

{

   MPI_Init( &argc, &argv );

   ...

   MPI_Finalize();

}
```

Обмен сообщениями между процессами

- Передача сообщения `MPI_Send`
- Прием сообщения `MPI_Recv`
- Сообщение может быть достаточно большого размера
- Проблема синхронизации действий отправителя и получателя

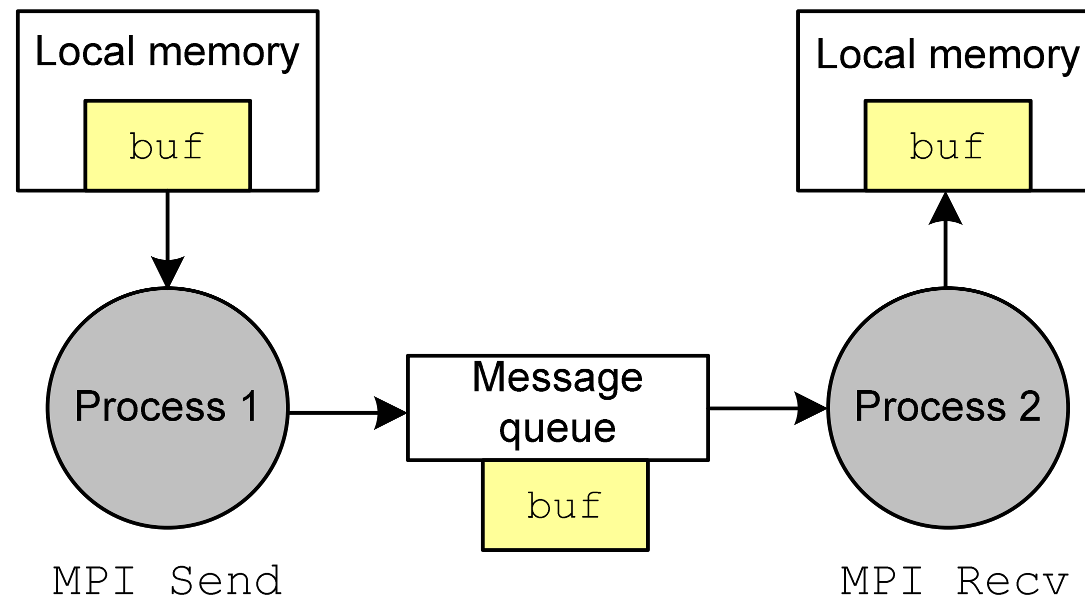

Обмен сообщениями между процессами

- Отправка сообщения с блокировкой процесса

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

  - `Buf` – передаваемый буфер данных
  - `Count` – размер передаваемых данных (в числе объектов указанного типа)
  - `Datatype` – тип передаваемых данных (Integer, Real, Double, …)
  - `Dest` – идентификатор процесса, которому отправляется сообщение
  - `Tag` – тип сообщения (позволяет различать сообщения)
  - `Comm` – коммуникатор, определяющий множество процессов
- Процесс блокируется до момента когда сообщение получено или скопировано в промежуточный буфер
  - `После этого Buf` может быть перезаписан или освобожден

Режимы передачи сообщений

- `Standart` – при передаче сообщение может копироваться или не копироваться в промежуточный буфер (определяется реализацией MPI)
- `Buffered` – передаваемое сообщение буферизируется, операция `Send` завершается независимо от приемной стороны

  `int` **`MPI_Bsend`**`(…)`
- `Synchronous` – операция `Send` завершается только после начала выполнения `Receive` на приемной стороне

  `int` **`MPI_Ssend`**`(…)`
- `Ready` – операция `Send` может быть запущена только при наличии уже начатой операции `Receive`, иначе вызов `Send` завершается с ошибкой

  `int` **`MPI_Rsend`**`(…)`

Обмен сообщениями между процессами

- Получение сообщения с блокировкой процесса

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

  - `Buf` – буфер для приема данных
  - `Count` – размер приемного буфера (в числе объектов указанного типа)
  - `Datatype` – тип передаваемых данных (Integer, Real, Double, …)
  - `Source` – идентификатор процесса (rank) или MPI_ANY_SOURCE
  - `Tag` – тип принимаемого сообщения или MPI_ANY_TAG
  - Status – хранит статус сообщения, а также данные об отправителе
- Возможность получать сообщения от произвольного отправителя
- Определение числа принятых данных

```
int MPI_Get_count(MPI_Status *, MPI_Datatype, int *count)
```

Семантика передачи сообщений

- Сохранение порядка сообщений (**Order**) – последовательная отправка сообщений A и B гарантирует получение этих сообщений в том же порядке
  - При использовании конкретного получателя на приемной стороне
  - При однопоточной реализации
- Отсутствие гарантии справедливой обработки сообщений
  - При наличии постоянного потока сообщений одно конкретное сообщение на приемной стороне может быть никогда не получено
- Ограничение ресурсов
  - Необходимо наличие достаточных ресурсов для буферизации и обработки сообщений

Адресация процессов

- Процесс, которому отправляется сообщение, адресуется с помощью аргументов `Dest` и `Comm`
- `Comm` – коммуникатор, определяющий текущую группу процессов
- Коммуникатор `MPI_COMM_WORLD` позволяет обращаться ко всем процессам, в которых выполнена инициализация MPI
- `Dest` – идентификатор (номер) процесса в данной группе процессов
- Группа процессов упорядочена – каждый процесс имеет уникальный номер в группе

Группы процессов

- Группа процессов – упорядоченная коллекция процессов
  - Каждый процесс имеет идентификатор (**rank**) – целое число от 0 до n-1
- Процесс может входить в несколько групп
- Группы процессов обеспечивают разделение пространства процессов для ограничения взаимодействия процессов
  - Выбора одного из процессов по его идентификатору
  - Организации коллективных операций
- Предопределенная пустая группа – `MPI_GROUP_EMPTY`

Управление группами процессов

- Конструкторы групп процессов

  `int MPI_Group_incl(MPI_Group group, int n, int *ranks, MPI_Group *newgroup)` – создание новой группы процессов `newgroup` из существующей группы `group`, в которую будет входить `n` процессов с номерами заданными в `ranks`

  `int MPI_Group_excl(MPI_Group group, int n, int *ranks, MPI_Group *newgroup)` – создание новой группы процессов `newgroup` из существующей группы `group`, из которой удалены `n` процессов с номерами заданными в `ranks`

- Деструкторы групп процессов

  `int MPI_Group_free(MPI_Group *group)`

Управление группами процессов

- Определение размера группы

```
int MPI_Group_size(MPI_Group group, int *size)
```

- Определение идентификатора процесса в группе

```
int MPI_Group_rank(MPI_Group group, int *rank)

int MPI_Group_translate_ranks(MPI_Group group1, int n, int
*ranks1, MPI_Group group2, int *ranks2)
```

- Операции над группами процессов

```
int MPI_Group_union(MPI_Group group1, MPI_Group group2,
MPI_Group *newgroup)

int MPI_Group_intersection(MPI_Group group1, MPI_Group group2,
MPI_Group *newgroup)
```

Коммуникаторы

- Операции с группами процессов выполняются с помощью коммуникаторов
- Коммуникаторы для операций обмена
  - Внутри группы процессов
  - Между двумя группами процессов
- Предопределенные коммуникаторы
  - `MPI_COMM_WORLD` – все процессы
  - `MPI_COMM_SELF` – сам процесс

Управление коммуникаторами

- Создание коммуникатора связанного с указанной подгруппой процессов

```
int MPI_Comm_create(MPI_Comm comm, MPI_Group group, MPI_Comm *newcomm)
```

- Выделение подгруппы в группы процессов, связанной с коммуникатором

```
int MPI_Comm_split(MPI_Comm comm, int color, int key, MPI_Comm *newcomm)
```

- Другие операции

`int MPI_Comm_rank(MPI_Comm comm, int *rank)` – определение номера процесса в коммуникаторе

Пример программы 1

```
int main(int argc, char **argv)
{
  int me, count; int* buf;
  ...
  MPI_Comm_rank(MPI_COMM_WORLD, &me);
  if(me == 0) {
     MPI_Send(buf, count, MPI_INTEGER, 1, SOME_TAG,
              MPI_COMM_WORLD);
  } else
     MPI_Recv(buf, count, MPI_INTEGER, 0, SOME_TAG,
              MPI_COMM_WORLD, &status);
}
```

Пример программы 2 (Писатель)

```
int main(int argc, char **argv)
{
  int me, count; int* buf;
  ...
  MPI_Comm_rank(MPI_COMM_WORLD, &me);
  int reader = 0;
  if(me == 0) {
     reader = 1;
  }
  MPI_Send(buf, count, MPI_INTEGER, reader, SOME_TAG,
  MPI_COMM_WORLD);
}
```

Пример программы 2 (Читатель)

```
int main(int argc, char **argv)
{
  int me, count; int* buf; MPI_Status status;
  ...
  MPI_Comm_rank(MPI_COMM_WORLD, &me);
  int writer = 0;
  if (me == 0) {
     writer = 1;
  }
  MPI_Recv(buf, count, MPI_INTEGER, writer, SOME_TAG,
  MPI_COMM_WORLD, &status);
}
```

Пример программы 3

```
int main(int argc, char **argv)
{
  int me, count; int* buf;
  MPI_Group GroupWorld, subgroup;
  MPI_Comm the_comm;
  int ranks[] = {2, 4, 6, 8};
  ...
  MPI_Comm_group(MPI_COMM_WORLD, &GroupWorld);
  MPI_Group_incl(MPI_GROUP_WORLD, 4, ranks, &subgroup);
  MPI_Comm_create(MPI_COMM_WORLD, subgroup, &the_comm);
  ...
}
```

Пример программы 4

```
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
int color = rank % 3;
MPI_Comm_split(MPI_COMM_WORLD, color, rank, &myComm);
if (color == 0){
  ...
}
else if (color == 1){
 ...
}
else if (color == 2){
 ...
}
```

Неблокирующие обмены сообщениями

- Отправка сообщения без блокировки

```
int MPI_Isend(void* buf, int count, MPI_Datatype datatype, int dest,int tag, MPI_Comm comm, MPI_Request *request)
```

  - `Request` – объект обеспечивающий контроль за операцией отправки
  - `ISsend, IBsend, IRsend`

- Получение сообщения без блокировки

```
int MPI_Irecv(void* buf, int count, MPI_Datatype datatype, int source,int tag, MPI_Comm comm, MPI_Request *request)
```

  - `Request` – объект обеспечивающий контроль за операцией приема

Неблокирующие обмены сообщениями

- При выполнении неблокирующих операций необходимо контролировать состояние операции
  - После выполнения ISend процесс начинает передачу сообщения
  - После выполнения IRecv процесс готов к приему сообщения
- Контроль завершения обмена
  - Завершение отправки сообщения – процесс может освобождать буфер
  - Завершение приема сообщения – процесс может читать полученное сообщение

Неблокирующие обмены сообщениями

- Ожидание завершения неблокирующей операции

```
int MPI_Wait(MPI_Request *request, MPI_Status *status)
```

  - `Request` – идентификатор операции обмена
  - `Status` – результат операции

- Проверка текущего состояния операции

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

  - `Request` – идентификатор операции обмена
  - `Flag` – индикатор завершения операции (`true`)
  - `Status` – результат операции

Неблокирующие обмены сообщениями

- Ожидание завершения одной из операций

```
int MPI_Waitany(int count, MPI_Request *array_of_requests, int
*index, MPI_Status *status)
```

- Ожидание завершения всех операций

```
int MPI_Waitall(int count, MPI_Request *array_of_requests,
MPI_Status *array_of_statuses)
```

- Проверка группы операций

```
int MPI_Testany(int count, MPI_Request *array_of_requests, int
*index, int *flag, MPI_Status *status)
```

- Проверка всех операций

```
int MPI_Testall(int count, MPI_Request *array_of_requests, int
*flag, MPI_Status *array_of_statuses)
```

Неблокирующие обмены сообщениями

- Удаление обмена без ожидания завершения операции

```
int MPI_Request_free(MPI_Request *request)
```

- Вызовы `Test` и `Wait` завершают текущую операцию
- Проверка состояния без завершения операции

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

- Проверка наличия сообщения

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

- Отмена передачи сообщения, после вызова Cancel необходимо завершить обмен с помощью вызова `Free`, `Wait` или `Test`

```
int MPI_Cancel(MPI_Request *request)
```

Коллективные обмены

- Коллективные обмены включают все группы одной группы или несколько групп процессов
- Барьерная синхронизация, вызвавший процесс блокируется до тех пока все процессы группы не вызовут эту функцию

```
int MPI_Barrier(MPI_Comm comm)
```

  - Comm – коммуникатор, определяющий группу процессов

Коллективные обмены

- Широковещательная рассылка сообщения процессам группы

```
int MPI_Bcast(void* buffer, int count, MPI_Datatype datatype,
int root, MPI_Comm comm)
```

  - Root – идентификатор (rank) рассылающего процесса

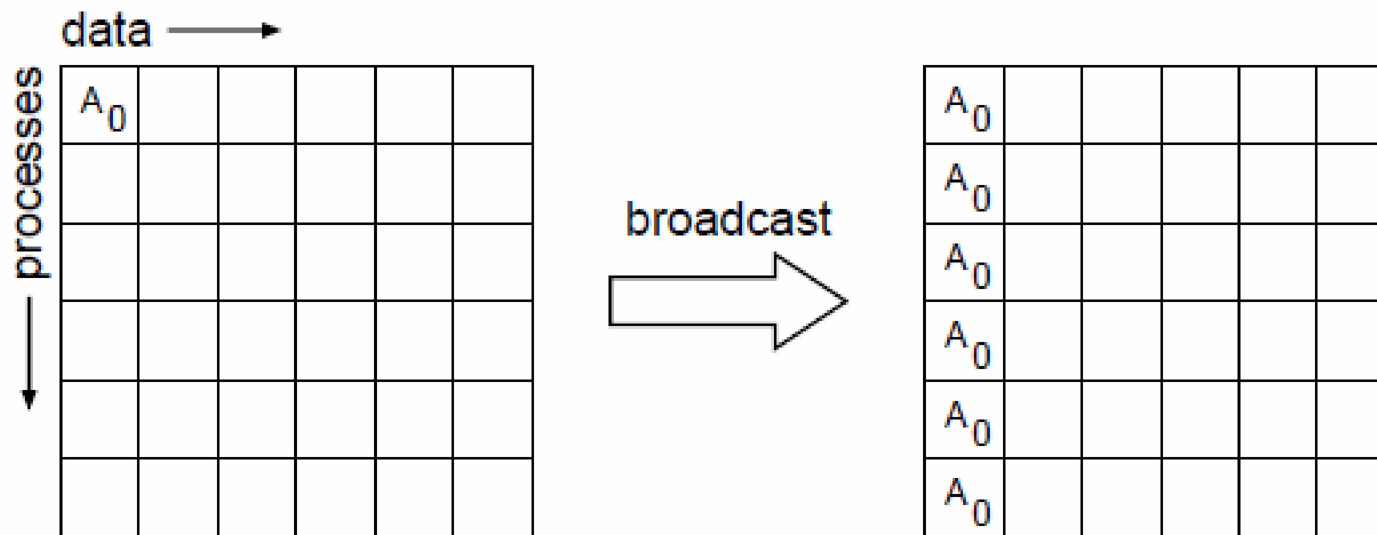

Коллективные обмены

- Получение сообщения от каждого процесса группы

```
int MPI_Gather(void* sendbuf, int sendcount, MPI_Datatype
sendtype, void* recvbuf, int recvcount, MPI_Datatype
recvtype, int root, MPI_Comm comm)
```

- Обратная операция

```
int MPI_Scatter(...)
```

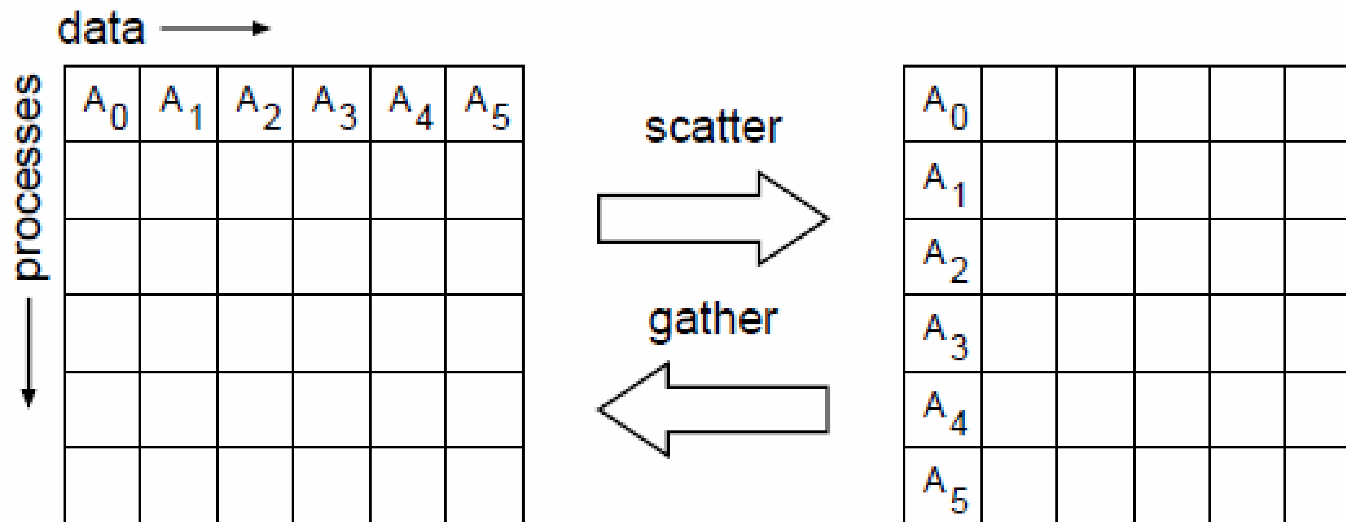

Пример программы

```
int main(int argc, char **argv)
{
  int me, count; int *data;
  MPI_Comm_rank(MPI_COMM_WORLD, &me);
  if(me == 0){
     data = ...;
     MPI_Bcast(data, count, MPI_INTEGER, 0, MPI_COMM_WORLD);
  }
  MPI_Recv(...);
  ...
}
```

Удаленный доступ к памяти

- Удаленный доступ к памяти (RMA) – возможность чтения/записи области памяти другого процесса
  - Операции выполняются одним процессом
  - Другой процесс «не знает» о внешнем доступе к его памяти
- Инициализация разделяемой памяти (вызывается для всех процессов группы)

```
int MPI_Win_create(void *base, MPI_Aint size, int
disp_unit, MPI_Info info,MPI_Comm comm, MPI_Win *win)
```

- Операции доступа к разделяемой памяти

```
int MPI_Put(void *addr, int count, ... MPI_Win win)
int MPI_Get(void *addr, int count, ... MPI_Win win)
```

Удаленный доступ к памяти

- Обеспечение синхронизации лежит на пользователе
- Операции блокировки области памяти

```
int MPI_Win_lock(int lock_type, int rank, int assert,
MPI_Win win)

int MPI_Win_unlock(int rank, MPI_Win win)
```

- Пример

```
...
MPI_Win_lock(MPI_LOCK_EXCLUSIVE, rank, assert, win)
MPI_Put(..., rank, ..., win)
MPI_Win_unlock(rank, win)
...
```

Управление процессами в MPI

- MPI позволяет динамически запускать и завершать процессы
- Запуск нового процесса

```
int MPI_Comm_spawn(char *command, char *argv[], int
maxprocs, MPI_Infoinfo, int root, MPI_Comm comm,
MPI_Comm *intercomm, int array_of_errcodes[])
```

  - `Command` – имя запускаемой программы
  - `Maxprocs` – число запускаемых процессов
  - `Intercomm` – коммуникатор для передачи сообщений созданным процессам

Управление процессами в MPI

- Запуск нескольких программ или программы с разными входными аргументами

```
int MPI_Comm_spawn_multiple(int count, char
*array_of_commands[],char **array_of_argv[], int
array_of_maxprocs[],MPI_Info array_of_info[], int root,
MPI_Comm comm,MPI_Comm *intercomm, int
array_of_errcodes[])
```

- Получение коммуникатора родительского процесса

```
int MPI_Comm_get_parent(MPI_Comm *parent)
```

Создание многопроцессных программ на основе POSIX

- POSIX включает объекты для создания многопроцессных программ (http://pubs.opengroup.org/onlinepubs/009695399/mindex.html)
- Способы организации межпроцессного взаимодействия
  - Файлы
  - Сокеты
  - Сигналы
  - Каналы/именованные каналы (pipe/fifo)
  - **Очереди сообщений (message queue)**
  - **Семафоры**
  - **Разделяемая память**

Синхронизация процессов с помощью семафоров POSIX

- Семафор должен быть доступен из нескольких процессов, операции над семафором должны выполняться атомарно
- Идентификация семафоров с помощью ключей `key_t`
- Создание/получение созданного ключа

```
key_t ftok(const char *path, int id);
```

  - `Path` – путь к некоторому файлу, который существует в системе во время работы программы
  - Id – ненулевое число
- Значение ключа является уникальным для разных `Path` и `Id`

Операции над семафорами

- Создание/получение семафора (группы семафоров)

  `int semget(key_t key, int nsems, int semflg)`

  - `Nsems` – число семафоров
  - `Semflg` – права доступа к семафору `(IPC_CREAT, IPC_EXCL)`
- Начальное значение семафора – нулевое

```
#include <sys/ipc.h>
#include <sys/sem.h>
key_t semkey = ftok("/tmp", 1);
if (semkey == (key_t) -1) ...; // Some error

int semid = semget(semkey, 1, IPC_CREAT);
if (semid == -1) ...; // Some error
```

Операции над семафорами

- Выполнение операций над семафором

  `int semop(int semid, struct sembuf *sops, size_t nsops)`

  - Sops – массив операций, которые нужно выполнить
  - Nsops – число операций в Sops
- Структура описывающая операции `sembuf`
  - `short sem_num` – номер семафора в группе
  - `short sem_op` – выполняемая операция
  - `short sem_flg` – флаги операции
- Возможные операции
  - `sem_op` > 0 – процесс увеличивает значение семафора на sem_op
  - `sem_op = 0` – процесс ожидает пока семафор не обнулится
  - `sem_op` < 0 – процесс ожидает пока значение семафора не станет достаточным, затем вычитает модуль sem_op из значения семафора

Пример программы

```
int semid;
struct sembuf sb[2];
int nsops = 2;
...
sb[0].sem_num = 0;
sb[0].sem_op = -1;
sb[0].sem_flg = IPC_NOWAIT;
sb[1].sem_num = 1;
sb[1].sem_op =  1;
sb[1].sem_flg = 0;

int result = semop(semid, sb, nsops);
```

Работа с разделяемой памятью

- Разделяемая память используется для повышения производительности
- Операции с разделяемой памятью должны защищаться с помощью семафоров
- Идентификация областей разделяемой памяти осуществляется с помощью ключей
- Создание/получение доступа к области разделяемой памяти

```
int shmget(key_t key, size_t size, int shmflg)
```

  - `Key` – идентификатор области памяти
  - `Size` – размер области в байтах
  - `Shmflg` – флаги доступа

Работа с разделяемой памятью

- Присоединение области разделяемой памяти

```
void *shmat(int shmid, const void *shmaddr, int shmflg)
```

  - `Shmid` – дескриптор полученный в `shmget`
  - `Shmaddr` – позволяет определить в каком месте памяти процесса будет расположена область разделяемой памяти (0 – на выбор ОС)
- Вызов `shmat` возвращает адрес присоединенной области памяти в виртуальном адресном пространстве процесса
- Удаление присоединенной области разделяемой памяти

```
int shmdt(const void *shmaddr)
```

Пример программы (писатель)

```
#include <sys/ipc.h>
#include <sys/sem.h>
#include <sys/shm.h>
int main() {
  key_t mkey = ftok("/tmp", 1);
  key_t skey = ftok("/tmp", 2);
  int shmid = shmget(mkey, sizeof(int), IPC_CREAT);
  void* shmptr = shmat(shmid, 0, 0);
  int semid = semget(skey, 1, IPC_CREAT);
  *shmptr = 1; // Запись в разделяемую память
  struct sembuf sb[1];
  sb[0].sem_num = 0; sb[0].sem_op = 1; sb[0].sem_flg = 0;
  semop(semid, sb, 1);
}
```

Пример программы (читатель)

```
int main() {
  key_t mkey = ftok("/tmp", 1);
  key_t skey = ftok("/tmp", 2);
  int shmid = shmget(mkey, sizeof(int), IPC_CREAT);
  void* shmptr = shmat(shmid, 0, 0);
  int semid = semget(skey, 1, IPC_CREAT);
  struct sembuf sb[1];
  sb[0].sem_num = 0; sb[0].sem_op = -1; sb[0].sem_flg = 0;
  // Блокировка процесса до тех пор пока писатель не закончит запись
  int result = semop(semid, sb, 1);
  int i = *shmptr; // Чтение значения из разделяемой памяти
  return i;
}
```

Пример программы

```
int main() {
  int PERM = S_IRUSR | S_IWUSR;
  key_t skey = ftok("/tmp", 1);
  int semid = semget(skey, 1, PERM | IPC_CREAT | IPC_EXCL);
  if (semid < 0) {
    // Получаем уже созданный семафор
    semid = semget(skey, 1, PERM);
  } else {
    // Если семафор создан нами, то увеличиваем его значение
    struct sembuf sb[1];
    sb[0].sem_num = 0; sb[0].sem_op = 1; sb[0].sem_flg = 0;
    semop(semid, sb, 1);
  }
  ...
}
```

Передача сообщений между процессами

- Между процессами можно создавать очереди сообщений
- Сообщение включает
  - Тип сообщения
  - Размер данных
  - Данные
- В одной очереди могут передаваться сообщения от разных процессов, сообщения могут приниматься разными процессами
- Идентификация очереди сообщений осуществляется с помощью ключа

Передача сообщений между процессами

- Создание/получение доступа к очереди сообщений

```
int msgget(key_t key, int msgflg)
```

- Отправка сообщения

```
int msgsnd(int msqid, const void *msgp, size_t msgsz,
int msgflg)
```

  - `Msgp` – структура типа `mymsg`
  - `Msgsz` – число байт в поле `mtext`

```
struct mymsg {
    long    mtype;     /* Message type. */
    char    mtext[];   /* Message text. */
}
```

Передача сообщений между процессами

- Прием сообщения

  ```
  ssize_t msgrcv(int msqid, void *msgp, size_t msgsz, long msgtyp, int msgflg)
  ```

- `Msgtyp` – тип принимаемых сообщений
  - `Msgtyp = 0` – прием первого сообщения
  - `Msgtyp > 0` – прием первого сообщения типа `Msgtyp`
  - `Msgtyp < 0` – прием первого сообщения с наименьшим типом, который меньше или равен модулю `Msgtyp`

Передача сообщений между процессами

- Если `msgflg` содержит `IPC_NOWAIT`, то вызов `Send` или `Receive` будет не блокирующийся
- Информацию о выполнении операций можно получить с помощью

```
int msgctl(int msqid, int cmd, struct msqid_ds *buf)
```

  - Поле cmd = IPC_STAT, IPC_SET
  - `msqid_ds.msg_qnum` – число сообщений в очереди
  - `msqid_ds.msg_lspid` и `msqid_ds.msg_lrpid` - идентификаторы процессов последнего отправителя сообщения и последнего получателя сообщения
  - `msqid_ds`.msg_stime (rtime,…) – время последней операции msgsnd (msgrcv,…)

Пример программы

```
#include <sys/msg.h>
...
int result;
int msqid;
struct message {
    long type;
    char text[20];
} msg;
msg.type = 1;
strcpy(msg.text, "This is message 1");
...
result = msgsnd(msqid, (void *) &msg, sizeof(msg.text),
IPC_NOWAIT);
```

Пример программы

```
#include <sys/msg.h>
...
int result;
int msqid;
struct message {
    long type;
    char text[20];
} msg;
long msgtyp = 1;
...
result = msgrcv(msqid, (void *) &msg, sizeof(msg.text),
msgtyp, MSG_NOERROR | IPC_NOWAIT);
```