Технология программирования MPI (5)

Антонов Александр Сергеевич,
к.ф.-м.н., вед.н.с. лаборатории Параллельных информационных технологий НИВЦ МГУ

Летняя суперкомпьютерная академия
Москва, 2015

MPI

Динамическое управление процессами

MPI

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

Попытка породить **maxprocs** процессов, выполняющих программу **command**, которая будет выполнена командным интерпретатором.

MPI

Создаётся интеркоммуникатор **`intercomm`**, объединяющий порождающие и порожденные процессы для возможности дальнейших обменов данными. В **`argv`** передаются параметры запуска программы **`command`** (если не требуется, можно указать предопределённую константу **`MPI_ARGV_NULL`**). Первые четыре аргумента значимы только на процессе **`root`**, на остальных процессах они игнорируются.

MPI

Вызов является коллективным для процессов коммуникатора **`comm`** и не завершается до тех пор, пока во всех порождённых процессах не будет вызвана процедура **`MPI_Init`**. И наоборот, процедура **`MPI_Init`** в порождаемых процессах не выполнится, пока все порождающие процессы не вызовут **`MPI_Comm_spawn`**.

MPI

Порождённые процессы получают свой собственный коммуникатор **`MPI_COMM_WORLD`**, отличный от того, который был у выполнявшихся ранее процессов. Порядок нумерации процессов в группах интеркоммуникатора **`intercomm`** соответствует порядку процессов в коммуникаторе **`comm`** порождающих процессов и в коммуникаторе **`MPI_COMM_WORLD`** порождённых процессов.

MPI

В порождённых процессах интеркоммуникатор может быть получен при помощи вызова процедуры **`MPI_Comm_get_parent`**. Если не удаётся породить **`maxprocs`** процессов, то возвращается ошибка **`MPI_ERR_SPAWN`**. Аргумент **`info`** задаёт информацию о том, где и как запускать порождаемые процессы. Если не требуется, можно использовать предопределённую константу **`MPI_INFO_NULL`**.

MPI

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

Процедура возвращает на динамически порождённых процессах интеркоммуникатор **parent** для общения с порождающими процессами. Если вызов стоит не в порождённом процессе или если коммуникатор порождающего процесса больше не существует или недоступен, то возвращается значение **MPI_COMM_NULL**.

MPI

master.c:

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char **argv)
{
   int size, rank1, rank2;
   MPI_Status status;
   MPI_Comm intercomm;
   char slave[10]="./slave";
   MPI_Init(&argc, &argv);
   MPI_Comm_size(MPI_COMM_WORLD, &size);
   MPI_Comm_spawn(slave, MPI_ARGV_NULL, 2, MPI_INFO_NULL,
0, MPI_COMM_SELF, &intercomm, MPI_ERRCODES_IGNORE);
   MPI_Recv(&rank1, 1, MPI_INT, 0, 0, intercomm, &status);
   MPI_Recv(&rank2, 1, MPI_INT, 1, 1, intercomm, &status);
```

MPI

```
    printf("Slaves %d and %d are working\n", rank1, rank2);
    MPI_Finalize();
    return 0;
}
```

MPI

slave.c:

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char **argv)
{
   int rank, size;
   MPI_Comm intercomm;
   MPI_Init(&argc, &argv);
   MPI_Comm_get_parent(&intercomm);
   MPI_Comm_rank(MPI_COMM_WORLD, &rank);
   MPI_Send(&rank, 1, MPI_INT, 0, rank, intercomm);
   MPI_Finalize();
   return 0;
}
```

MPI

```
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[])
```

Порождение процессов, выполняющих **count** разных программ.

MPI

Команды перечислены в **`array_of_commands`**. Аргументы задаются в массиве **`array_of_argv`** (если не требуется, можно указать константу **`MPI_ARGVS_NULL`**). Значения максимального количества процессов для соответствующих программ задаются в массиве **`array_of_maxprocs`**, информация о запуске – в массиве **`array_of_info`**.

MPI

Все порождаемые процессы объединяются одним коммуникатором **`MPI_COMM_WORLD`**.

Порядок нумерации процессов соответствует порядку перечисления запускаемых программ.

MPI

Ряд процедур MPI позволяет организовать общение двух независимо существующих групп процессов, не объединённых каким-либо коммуникатором. Для этого одна из таких групп (*сервер*) должна принимать соединение от другой группы (*клиент*).

MPI

```
int MPI_Open_port(MPI_Info info,
char *port_name)
```

Устанавливает на сервере адрес, задаваемый строкой **port_name**, для связи с клиентами. Тип адреса зависит от реализации, возможно, с использованием информации из аргумента **info**. Если не требуется, можно указать константу **MPI_INFO_NULL**. В **port_name** возвращается строка длиной не более **MPI_MAX_PORT_NAME** символов. Обычно **port_name** является сетевым адресом.

MPI

```
int MPI_Close_port(char
*port_name)
```

Освобождает сетевой адрес, заданный строкой **`port_name`**.

MPI

```
int MPI_Comm_accept(char
*port_name, MPI_Info info, int
root, MPI_Comm comm, MPI_Comm
*newcomm)
```

Возвращает интеркоммуникатор **newcomm**, для установления связи с клиентом по адресу **port_name**. Процедура является коллективной для **comm**. Значение **port_name** должно быть получено при помощи вызова процедуры **MPI_Open_port**.

MPI

```
int MPI_Comm_connect(char
*port_name, MPI_Info info, int
root, MPI_Comm comm, MPI_Comm
*newcomm)
```

Возвращает интеркоммуникатор **newcomm**, для установления связи с сервером по адресу **port_name**. Если адрес не существует (или порт закрыт), то возвращается ошибка **MPI_ERR_PORT**. Адрес **port_name** должен быть тем же, который возвращает процедура **MPI_Open_port**.

MPI

```
int MPI_Publish_name(char
*service_name, MPI_Info info,
char *port_name)
```

Сопоставление известному имени **`service_name`** системно-зависимого адреса **`port_name`**. В дальнейшем для установления связи можно использовать имя **`service_name`**.

MPI

```
int MPI_Unpublish_name(char
*service_name, MPI_Info info,
char *port_name)
```

Удаление сопоставления имени **`service_name`** с адресом **`port_name`**. Если сопоставления не было, вернется ошибка **`MPI_ERR_SERVICE`**. Перед закрытием соответствующего порта все сопоставления имен должны быть удалены.

MPI

```
int MPI_Lookup_name(char
*service_name, MPI_Info info,
char *port_name)
```

По имени сервиса **service_name** определяется связанный с ним адрес **port_name**. Если данный адрес с сервисом не был связан, процедура вернет ошибку **MPI_ERR_NAME**.

MPI

server.c:

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char **argv)
{
   int r;
   char port_name[MPI_MAX_PORT_NAME];
   MPI_Status status;
   MPI_Comm intercomm;
   MPI_Open_port(MPI_INFO_NULL, port_name);
   MPI_Publish_name("example", MPI_INFO_NULL, port_name);
   MPI_Comm_accept(port_name, MPI_INFO_NULL, 0,
MPI_COMM_SELF, &intercomm);
   MPI_Recv(&r, 1, MPI_INT, 0, 0, intercomm, &status);
```

MPI

```
    MPI_Unpublish_name("example", MPI_INFO_NULL,
port_name);
    MPI_Close_port(port_name);
    printf("Client is sent %d\n", r);
    MPI_Finalize();
    return 0;
}
```

MPI

client.c:

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char **argv)
{
   int rank;
   char port_name[MPI_MAX_PORT_NAME];
   MPI_Comm intercomm;
   MPI_Lookup_name("example", MPI_INFO_NULL, port_name);
   MPI_Comm_connect(port_name, MPI_INFO_NULL, 0,
MPI_COMM_SELF, &intercomm);
   MPI_Comm_rank(MPI_COMM_WORLD, &rank);
   MPI_Send(&rank, 1, MPI_INT, 0, 0, intercomm);
   MPI_Finalize();
   return 0;
}
```

MPI

```
int MPI_Comm_disconnect(MPI_Comm *comm)
```

Процессы, вызвавшие процедуру, дожидаются завершения всех связанных с коммуникатором **comm** пересылок данных (в отличие от использования процедуры **MPI_Comm_free**), удаляют данный коммуникатор и устанавливают **comm** в **MPI_COMM_NULL**.

MPI

Параллельный ввод/вывод

MPI

В MPI под *файлом* (*file*) понимается упорядоченная последовательность типизированных блоков данных. Поддерживается произвольный или последовательный доступ к любому неделимому набору этих блоков. Файл может быть открыт группой процессов и обрабатываться с помощью коллективных операций. Под *смещением* (*displacement*) понимается расстояние в байтах относительно начала файла.

MPI

Элементарный тип данных (*etype*) – единица доступа к данным и позиционирования в файле. Это может быть любой предопределённый или производный тип. Производные элементарные типы создаются при помощи любой из процедур создания типов данных MPI, обеспечивающих, чтобы получающиеся смещения внутри типа были неотрицательными и монотонно не убывали. Доступ к данным производится в единицах элементарных типов.

MPI

Файловый тип (*filetype*) - основа разделения файла между процессами, определяет шаблон доступа к файлу. Файловый тип – это либо элементарный тип, либо производный тип данных MPI, состоящий из нескольких вхождений одного и того же элементарного типа. Размер любого «пропуска» в файловом типе должен быть кратным размеру этого элементарного типа. Смещения внутри файлового типа неотрицательные и монотонно неубывающие.

MPI

Образ (*view*) определяет текущий набор данных, доступный в открытом файле в виде упорядоченного набора элементарных типов. Каждый процесс имеет свой образ файла, определяемый тремя параметрами: смещением, элементарным типом и файловым типом. Шаблон, описанный файловым типом, получается таким, как если бы он задавался процедурой **`MPI_Type_contiguous`** из файлового типа и сколь угодно большого числа повторений.

MPI

Пусть элементарный тип данных изображается так: ■

Пусть пропуск в файле изображается так: □

Тогда файловый тип может быть задан, например, следующим образом: □■■□□□

Разбиение файла на элементы файлового типа может иметь следующий вид:

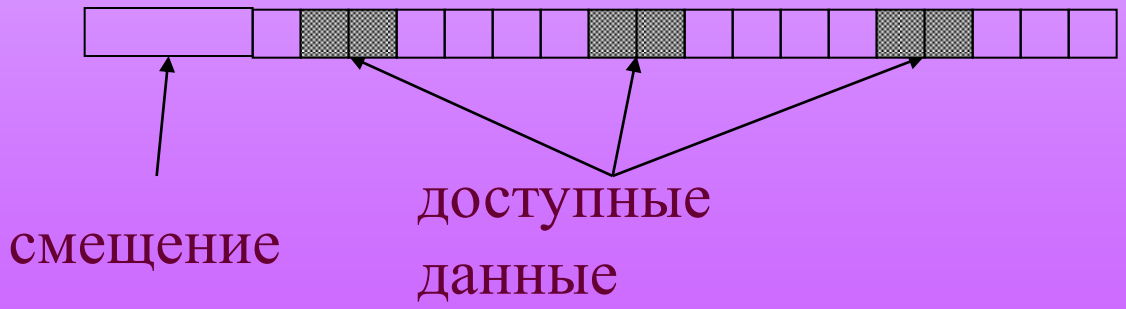

MPI

Образы разных процессов могут дополнять друг друга для распределения данных.

Файловый тип процесса 0: 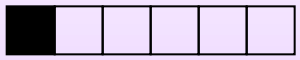

Файловый тип процесса 1: 

Файловый тип процесса 2: 

Разбиение файла на элементы файловых типов трёх процессов:

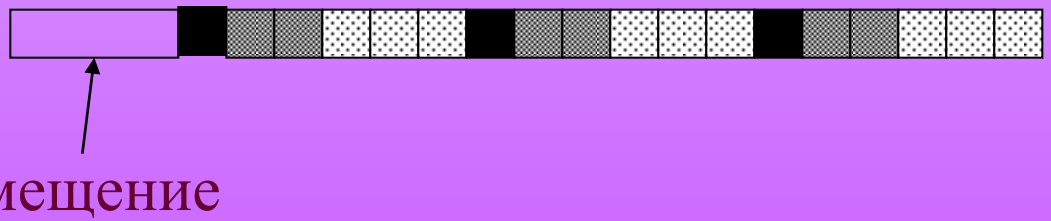

MPI

Сдвиг (*offset*) – позиция в файле относительно текущего образа, выраженная через количество элементарных типов. При вычислении сдвига «пропуски» в файловом типе образа не учитываются. Нулевой сдвиг – это позиция первого видимого в образе элементарного типа (после пропуска смещения и начальных «пропусков» в образе). Например, сдвиг **2** для процесса **1** в предыдущем примере будет иметь позиция **8**-го элементарного типа после смещения.

MPI

Размер файла (*file size*) измеряется в байтах от начала файла. Только что созданный файл имеет размер 0 байт. Использование размера файла в качестве абсолютного смещения определяет позицию байта, следующего сразу за последним байтом файла. Для любого образа *конец файла* (*end of file*) – это сдвиг первого элементарного типа, доступного в данном образе после последнего байта файла.

MPI

Указатель на файл (*file pointer*) – неявный сдвиг, устанавливаемый средствами MPI. *Индивидуальные указатели* на файл – это файловые указатели, локальные для каждого процесса, открывающего файл. *Общие файловые указатели* – это указатели, используемые группой процессов.

Дескриптор файла (*file handle*) – скрытый объект, создаваемый процедурой **`MPI_File_open`** и удаляемый процедурой **`MPI_File_close`**.

MPI

```
int MPI_File_open(MPI_Comm comm,
char *filename, int amode,
MPI_Info info, MPI_File *fh)
```

Открытие файла **filename** на всех процессах интракоммуникатора **comm**. Если нужно открыть файл на одном процессе, можно использовать предопределённый коммуникатор **MPI_COMM_SELF**. Возвращаемый дескриптор файла **fh** в дальнейшем используется для доступа к файлу вплоть до его закрытия. Формат имени файла **filename** зависит от реализации.

MPI

amode задаёт способ доступа к файлу комбинациеё (при помощи побитовой операции «или) следующих констант:

MPI_MODE_RDONLY – только чтение;

MPI_MODE_RDWR – чтение и запись;

MPI_MODE_WRONLY – только запись;

MPI_MODE_CREATE – создавать файл, если он не существует;

MPI_MODE_EXCL – выдавать ошибку, если файл уже существует;

MPI

MPI_MODE_DELETE_ON_CLOSE – удалять файл при закрытии;

MPI_MODE_UNIQUE_OPEN – к файлу не будет осуществляться доступ другими процессами;

MPI_MODE_SEQUENTIAL – файл будет доступен только в последовательном режиме;

MPI_MODE_APPEND – установить начальную позицию всех файловых указателей на конец файла.

MPI

`int MPI_File_close(MPI_File *fh)`

Синхронизация состояния (**`MPI_File_sync`**) и закрытие файла, связанного с дескриптором **`fh`**. Если файл был открыт со способом доступа **`MPI_MODE_DELETE_ON_CLOSE`**, то он удаляется. Процедура является коллективной. Перед вызовом должны быть завешены все операции, использующие файловый дескриптор **`fh`**. После выполнения процедуры **`fh`** принимает значение **`MPI_FILE_NULL`**.

MPI

```
int MPI_File_delete(char
*filename, MPI_Info info)
```

Удаление файла с именем **filename**. Если не существует, возникает ошибка **MPI_ERR_NO_SUCH_FILE**. Если удаляемый файл открыт данным процессом, то поведение при любой попытке доступа к файлу зависит от реализации. При этом также зависит от реализации, будет ли удален данный файл. Если нет, возникает ошибка **MPI_ERR_FILE_IN_USE** или **MPI_ERR_ACCESS**.

MPI

```
int MPI_File_set_size(MPI_File
fh, MPI_Offset size)
```

Изменяет в **`size`** байт размер файла, заданного дескриптором **`fh`**. Процедура является коллективной, все процессы группы должны устанавливать одно и то же значение **`size`**. Если новый размер меньше прежнего, то файл урезается. Если больше, то размер файла увеличивается до **`size`**. Прежние данные не изменяются, а значения данных в новых участках файла являются неопределёнными.

MPI

Процедура **`MPI_File_set_size`** не изменяет файловые указатели. Если при открытии файла был определён способ доступа **`MPI_MODE_SEQUENTIAL`**, то использование данной процедуры является ошибочным.

Перед вызовом процедуры **`MPI_File_set_size`** должны быть завешены все операции, использующие файловый дескриптор **`fh`**.

MPI

```
int
MPI_File_preallocate(MPI_File
fh, MPI_Offset size)
```

Обеспечивает пространство для хранения первых **size** байт файла, заданного дескриптором **fh**. Данная операция является коллективной. При этом записанные ранее данные не изменяются. В новых областях файла данные не определены. Если **size** больше текущего размера файла, то размер увеличивается до **size**. Если меньше либо равно, то размер не изменяется.

MPI

Процедура **MPI_File_preallocate** не изменяет файловые указатели. Если при открытии файла был определён способ доступа **MPI_MODE_SEQUENTIAL**, то использование данной процедуры ошибочно.

Перед вызовом процедуры **MPI_File_preallocate** должны быть завешены все операции, использующие файловый дескриптор **fh**.

MPI

```
int MPI_File_get_size(MPI_File
fh, MPI_Offset *size)
```

Процедура возвращает в аргументе **`size`** размер в байтах файла, заданного дескриптором **`fh`**.

MPI

```
int MPI_File_get_group(MPI_File fh, MPI_Group *group)
```

Процедура возвращает в аргументе **group** копию группы коммуникатора, использованного при открытии файла с дескриптором **fh**.

```
int MPI_File_get_amode(MPI_File fh, int *amode)
```

Процедура возвращает в аргументе **amode** способ доступа, заданный при открытии файла с дескриптором **fh**.

MPI

```
int MPI_File_set_view(MPI_File
fh, MPI_Offset disp,
MPI_Datatype etype, MPI_Datatype
filetype, char *datarep,
MPI_Info info)
```

Процедура изменяет образ файла для вызвавшего процесса. В аргументе **disp** задаётся начальное смещение создаваемого образа, в аргументе **etype** – элементарный тип данных, в аргументе **filetype** – файловый тип.

MPI

Процедура **`MPI_File_set_view`** обнуляет все индивидуальные и общие файловые указатели. Процедура является коллективной, значения **`datarep`** и размеры элементарных типов должны совпадать во всех процессах группы; значения **`disp`**, **`filetype`** и **`info`** могут различаться. Типы данных, передаваемые в **`etype`** и **`filetype`**, должны быть согласованы.

MPI

Если файл был открыт как **`MPI_MODE_SEQUENTIAL`**, то в качестве **`disp`** должно быть задано специальное смещение **`MPI_DISPLACEMENT_CURRENT`**.

Если файл открыт для записи, то ни элементарный тип, ни файловый тип не должны иметь перекрывающихся областей. При этом файловые типы из разных процессов могут перекрывать друг друга.

MPI

Если в файловом типе есть «пропуски», то тогда данные в них недоступны для вызывающего процесса. Однако аргументы **`disp`**, **`etype`** и **`filetype`** могут быть изменены посредством последующих вызовов процедуры **`MPI_File_set_view`**, что позволяет получить доступ к различным частям файла.

При конструировании элементарных и файловых типов нельзя использовать абсолютные адреса.

MPI

Аргумент **`datarep`** задаёт *представление данных* в файле. В стандарте MPI описывается три вида представления:

"**`native`**"

"**`internal`**"

"**`external32`**"

MPI

```
int MPI_File_get_view(MPI_File
fh, MPI_Offset *disp,
MPI_Datatype *etype,
MPI_Datatype *filetype, char
*datarep)
```

В аргументе **disp** возвращается текущее значение смещения, в аргументах **etype** и **filetype** – новые типы, эквивалентные элементарному типу и файловому типу соответственно, в аргументе **datarep** – представление данных. Длина **datarep** не больше **MPI_MAX_DATAREP_STRING**.

MPI

Данные перемещаются между файлами и процессами при помощи вызовов операций чтения и записи. Доступ к данным имеет три основных аспекта:

позиционирование (указание явного смещения или использование указателя на файл),

синхронизация (блокирующие или неблокирующие операции) и

координация (локальные или коллективные операции).

MPI

Процедуры доступа к данным с указанием явного смещения:

Синхронизация	**Координация**	
	локальные	коллективные
блокирующие	**MPI_File_read_at** **MPI_File_write_at**	**MPI_File_read_at_all** **MPI_File_write_at_all**
неблокирующие или разделенные коллективные	**MPI_File_iread_at** **MPI_File_iwrite_at**	**MPI_File_read_at_all_begin** **MPI_File_read_at_all_end** **MPI_File_write_at_all_begin** **MPI_File_write_at_all_end**

MPI

Процедуры доступа к данным с заданием индивидуальных файловых указателей:

Синхронизация	**Координация**	
	локальные	коллективные
блокирующие	**MPI_File_read** **MPI_File_write**	**MPI_File_read_all** **MPI_File_write_all**
неблокирующие или разделенные коллективные	**MPI_File_iread** **MPI_File_iwrite**	**MPI_File_read_all_begin** **MPI_File_read_all_end** **MPI_File_write_all_begin** **MPI_File_write_all_end**

MPI

Процедуры доступа к данным с заданием общих файловых указателей:

Синхронизация	Координация	
	локальные	коллективные
блокирующие	`MPI_File_read_shared` `MPI_File_write_shared`	`MPI_File_read_ordered` `MPI_File_write_ordered`

неблокирующие или разделенные коллективные	`MPI_File_iread_shared`
	`MPI_File_iwrite_shared`
		`MPI_File_read_ordered_begin`
		`MPI_File_read_ordered_end`
		`MPI_File_write_ordered_begin`
		`MPI_File_write_ordered_end`

MPI

```
#include <stdio.h>
#include "mpi.h"
int main(int argc, char **argv)
{
    int rank;
    MPI_File fh;
    char buf[10];
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_File_open(MPI_COMM_WORLD, "file1.txt",
MPI_MODE_RDONLY, MPI_INFO_NULL, &fh);
    MPI_File_set_view(fh, rank*10, MPI_CHAR, MPI_CHAR,
"native", MPI_INFO_NULL);
    MPI_File_read_all(fh, buf, 10, MPI_CHAR,
MPI_STATUS_IGNORE);
    printf("process %d, buf=%s\n", rank, buf);
    MPI_File_close(&fh);
    MPI_Finalize();
}
```

MPI

```
int MPI_File_sync(MPI_File fh)
```

Процедура гарантирует, что все предыдущие записи вызывающего процесса в файл с дескриптором **`fh`** будут завершены.
Процедура является коллективной.
Пользователь должен гарантировать, что все неблокирующие коллективные операции должны быть завершены перед вызовом **`MPI_File_sync`**.

MPI

Задание 8: Замерьте скорость обмена данными между процессами, установившими клиент-серверную связь.

MPI

Задание 9: Напишите программу, в которой один процесс считывает из файла нечётные элементы массива данных некоторого типа, а другой процесс – чётные элементы.