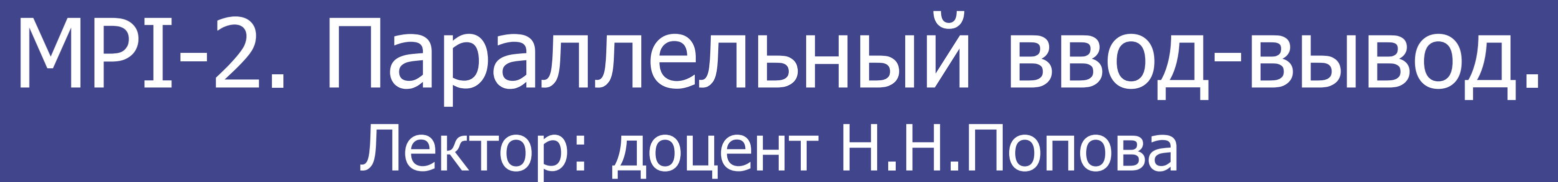

Летняя школа «Суперкомпьютерное моделирование и визуализация в научных исследованиях», Москва, МГУ, 4 – 14 июля 2010 г.

Параллельный ввод/вывод

- Несколько процессов имеют доступ к одному файлу

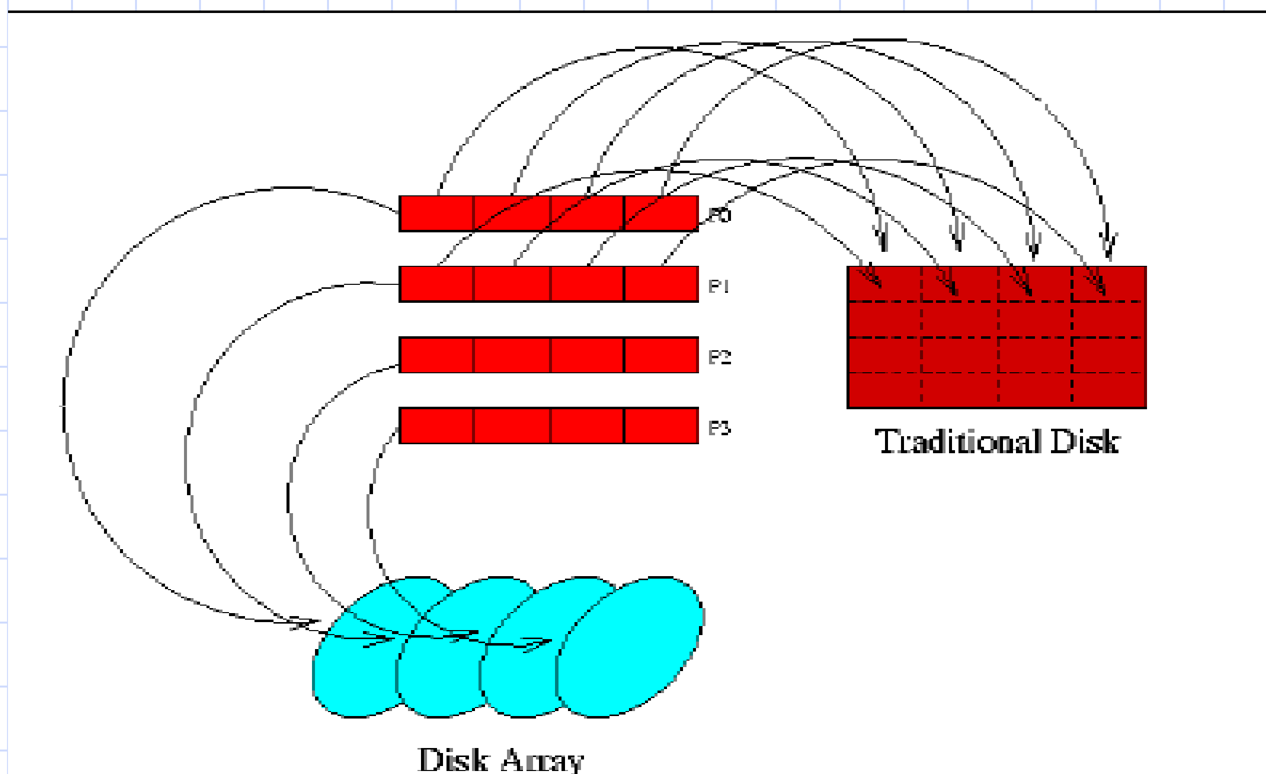

Основные возможности

- Произвольный доступ к файлам
- Коллективные операции ввода/вывода
- Индивидуальные и разделяемые файловые указатели
- Неблокирующий I/O
- Переносимое представление данных
- Использование подсказок (hints)

MPI-2 I/O: непараллельный I/O

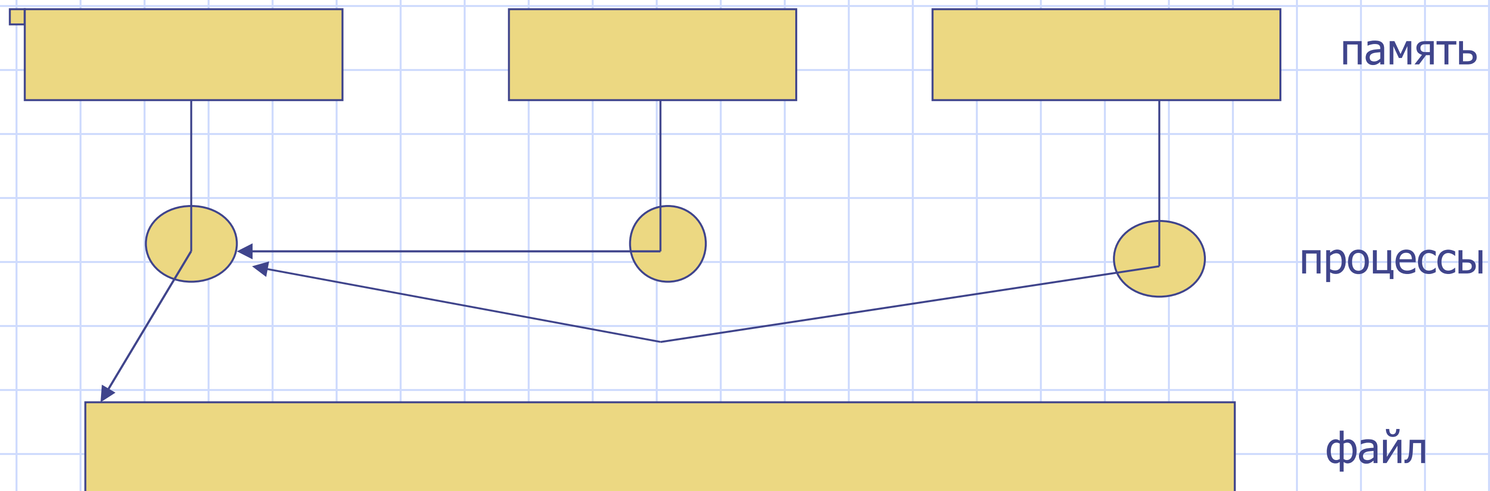

Непараллельный I/O из MPI прогр. (1)

```
/* Пример : последовательная запись в файл */
#include "mpi.h"
#include <stdio.h>
#define BUFSIZE 100
int main(int argc, char *argv[]){
    int i, myrank, numprocs, buf[BUFSIZE];
    MPI_Status status;
    FILE *myfile;
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &myrank);
    MPI_Comm_size(MPI_COMM_WORLD, &numprocs);
    for (i=0; i<BUFSIZE; i++)
     buf[i] = myrank * BUFSIZE + i;
```

Непараллельный I/O из MPI прогр. (2)

```
if (myrank != 0)
    MPI_Send(buf, BUFSIZE, MPI_INT, 0, 99, MPI_COMM_WORLD);
  else {
    myfile = fopen("testfile", "w");
    fwrite(buf, sizeof(int), BUFSIZE, myfile);
    for (i=1; i<numprocs; i++) {
       MPI_Recv(buf, BUFSIZE, MPI_INT, i, 99, MPI_COMM_WORLD,
              &status);
       fwrite(buf, sizeof(int), BUFSIZE, myfile);
    }
    fclose(myfile);
  }
  MPI_Finalize();
  return 0;
}
```

Непараллельный I/O из MPI прогр. (3)

Когда имеет смысл:

- I/O поддерживается только на определенном узле многопроцессорной системы
- В программе используется высокоуровневая библиотека, не поддерживающая параллельный ввод-вывод
- Результирующий файл должен обрабатываться последовательным ПО
- Возможное повышение эффективности за счет буферизации данных

Почему надо использовать параллельный ввод-вывод:

- Масштабируемость, эффективность при увеличении числа процессоров

MPI-2 I/O: не MPI параллельный I/O

```
/* не MPI параллельная запись в разные файлы */
#include "mpi.h"
#include <stdio.h>
#define BUFSIZE 100
int main(int argc, char *argv[])
{
    int i, myrank, buf[BUFSIZE];
    char filename[128];
    FILE *myfile;
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &myrank);
    for (i=0; i<BUFSIZE; i++)
      buf[i] = myrank * BUFSIZE + i;
    sprintf(filename, "testfile.%d", myrank);
    myfile = fopen(filename, "w");
    fwrite(buf, sizeof(int), BUFSIZE, myfile);
    fclose(myfile);
    MPI_Finalize();
    return 0;
}
```

Преимущества:
- параллельный доступ

Недостатки:
- много файлов
- использование файлов при повторном запуске (то же число процессов)

MPI-2 I/O: MPI I/O в разные файлы

```
/* Параллельная MPI-запись в разные файлы */
#include "mpi.h"
#include <stdio.h>
#define BUFSIZE 100
int main(int argc, char *argv[]){
 int i, myrank, buf[BUFSIZE];
 char filename[128];
 MPI_File myfile;
 MPI_Init(&argc, &argv);
 MPI_Comm_rank(MPI_COMM_WORLD, &myrank);
   for (i=0; i<BUFSIZE; i++)
        buf[i] = myrank * BUFSIZE + i;
    sprintf(filename, "testfile.%d", myrank);
    MPI_File_open(MPI_COMM_SELF, filename,
        MPI_MODE_WRONLY | MPI_MODE_CREATE,
        MPI_INFO_NULL, &myfile);
   MPI_File_write(myfile, buf, BUFSIZE, MPI_INT,
         MPI_STATUS_IGNORE);
   MPI_File_close(&myfile);
    MPI_Finalize();
    return 0;
}
```

Параллельный I/O в один файл

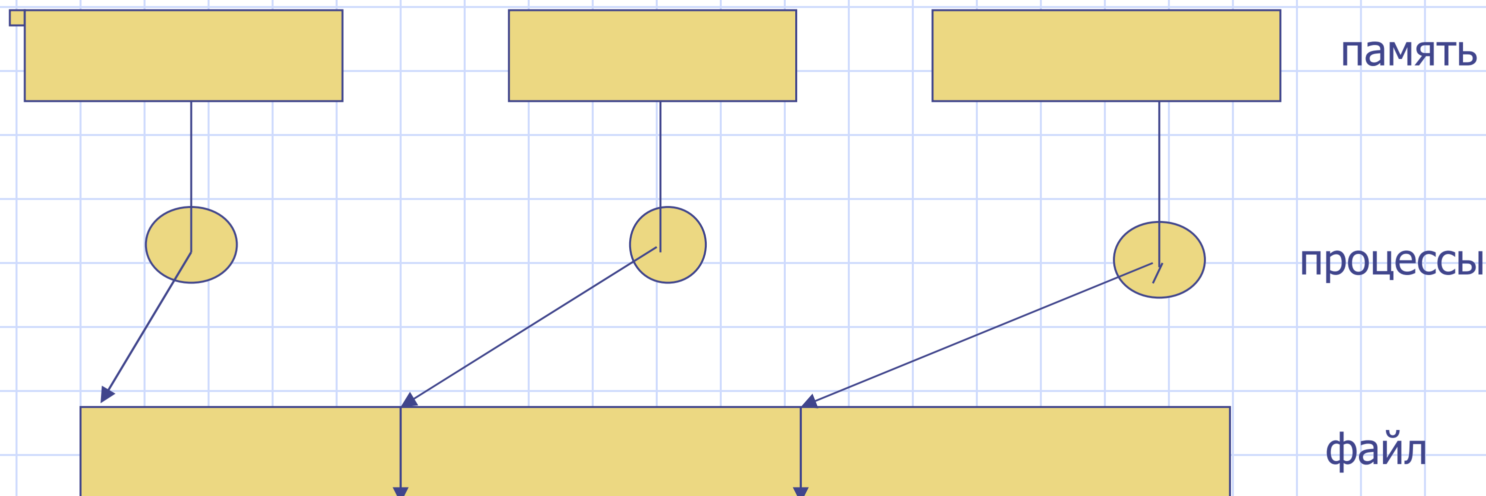

Параллельный MPI I/O: запись в один файл

```
/* параллельный MPI вывод в файл */
#include "mpi.h"
#include <stdio.h>
#define BUFSIZE 100
int main(int argc, char *argv[]){
        int i, myrank, buf[BUFSIZE];
        MPI_File thefile;
        MPI_Init(&argc, &argv);
        MPI_Comm_rank(MPI_COMM_WORLD, &myrank);
       for (i=0; i<BUFSIZE; i++)
        buf[i] = myrank * BUFSIZE + i;
        MPI_File_open(MPI_COMM_WORLD, "testfile",
      MPI_MODE_CREATE | MPI_MODE_WRONLY,
      MPI_INFO_NULL, &thefile);
              MPI_File_set_view(thefile, myrank * BUFSIZE * sizeof(int),
         MPI_INT, MPI_INT, "native", MPI_INFO_NULL);
                MPI_File_write(thefile, buf, BUFSIZE, MPI_INT,
         MPI_STATUS_IGNORE);
        MPI_File_close(&thefile);
        MPI_Finalize();
        return 0;
}
```

Параллельный I/O : один файл-чтение (1)

```
/* параллельное чтение из файла произвольным числом процессов*/
#include "mpi.h"
#include <stdio.h>
int main(int argc, char *argv[]){
    int myrank, numprocs, bufsize, *buf, count;
    MPI_File thefile;
    MPI_Status status;
    MPI_Offset filesize;
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &myrank);
    MPI_Comm_size(MPI_COMM_WORLD, &numprocs);
    MPI_File_open(MPI_COMM_WORLD, "testfile", MPI_MODE_RDONLY,
                 MPI_INFO_NULL, &thefile);
```

Параллельный I/O: один файл-чтение (2)

```
MPI_File_get_size(thefile, &filesize); /* in bytes */
    filesize = filesize / sizeof(int);      /* in number of ints */
    bufsize = filesize / numprocs + 1;      /* local number to read */
    buf = (int *) malloc (bufsize * sizeof(int));
    MPI_File_set_view(thefile, myrank * bufsize * sizeof(int),
                    MPI_INT, MPI_INT, "native", MPI_INFO_NULL);
    MPI_File_read(thefile, buf, bufsize, MPI_INT, &status);
    MPI_Get_count(&status, MPI_INT, &count);
    printf("process %d read %d ints\n", myrank, count);
    MPI_File_close(&thefile);
    MPI_Finalize();
    return 0;
}
```

Чтение из общего файла с использованием индивидуального файлового указателя

```
/* чтение из общего файла с использованием индивид. Файлового указателя*/
#include "mpi.h"
#define FILESIZE (1024 * 1024)
int main(int argc, char *argv[]){
    int rank, nprocs, bufsize, *buf, nints;
    MPI_File fh;
    MPI_Status status;
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &nprocs);
    bufsize = FILESIZE/nprocs;
    buf = (int *) malloc(bufsize);
    nints = bufsize/ sizeof(int);

    MPI_File_open(MPI_COMM_WORLD, "testfile", MPI_MODE_RDONLY,
        MPI_INFO_NULL, &fh);
    MPI_File_seek(fh, rank*bufsize, MPI_SEEK_SET);
    MPI_File_read (fh,buf, nints, MPI_INT, &status);
    MPI_File_close(&fh);
    free (buf);
    MPI_Finalize();
    return 0;
}
```

MPI-2 I/O: Терминология

- ***Е-тип (элементарный тип данных)*** - единица доступа к данным и позиционирования. Это может быть любой определенный в *MPI* или производный тип данных.

- ***Файловый тип*** –

  базис для разбиения файла в среде процессов, определяет шаблон доступа к файлу.

  Обычный е-тип или производный тип данных *MPI*, состоящий из нескольких элементов одного и того же е-типа.

E-типы и Файловые типы

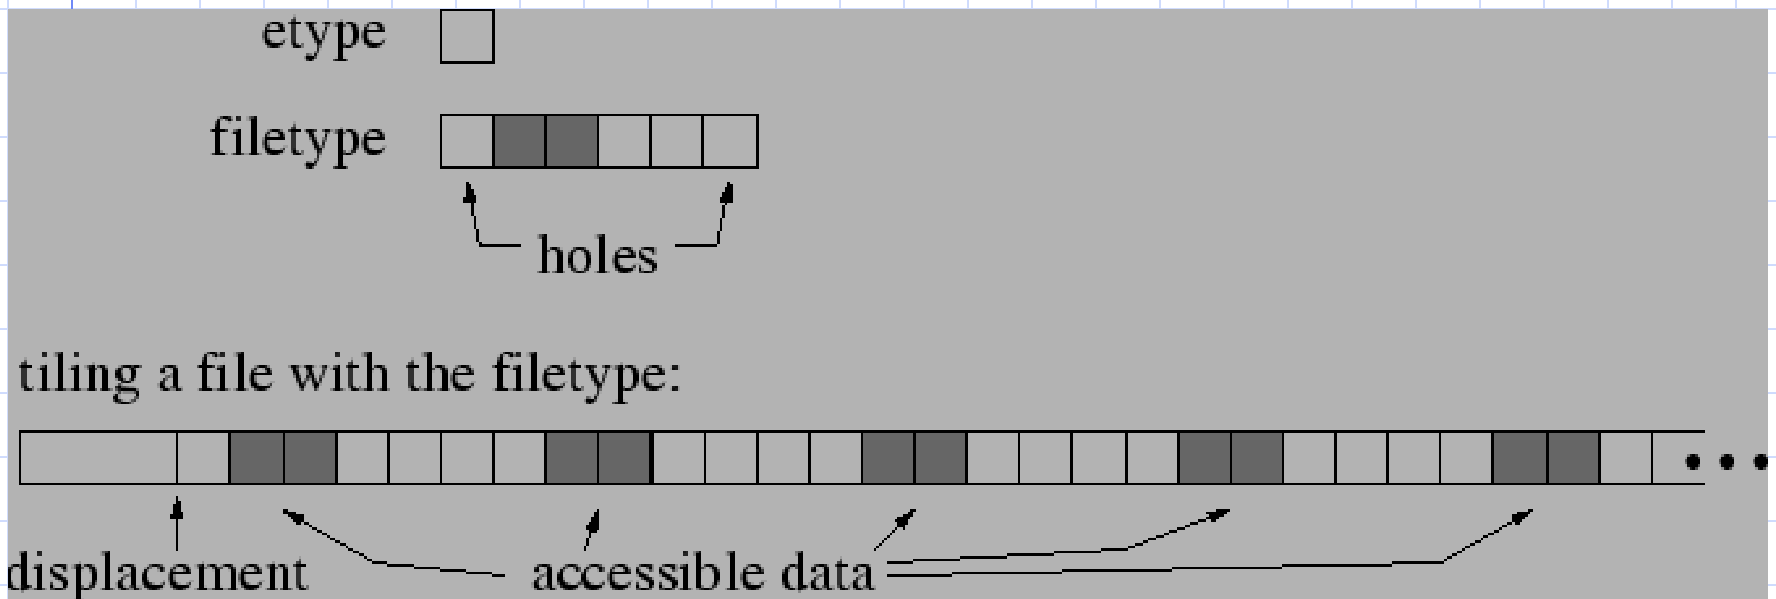

Файловые виды и структура файла

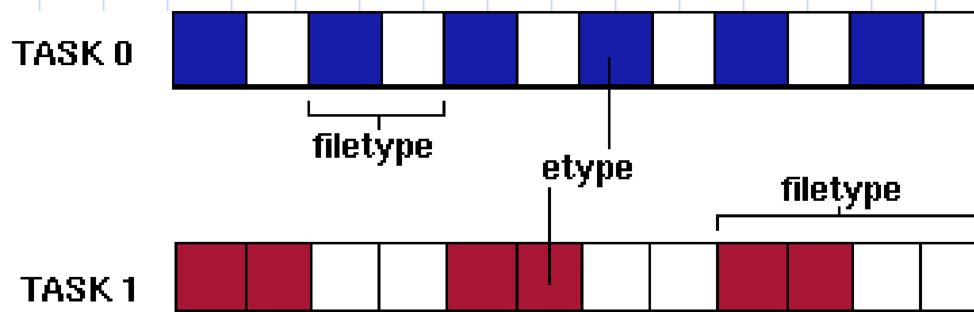

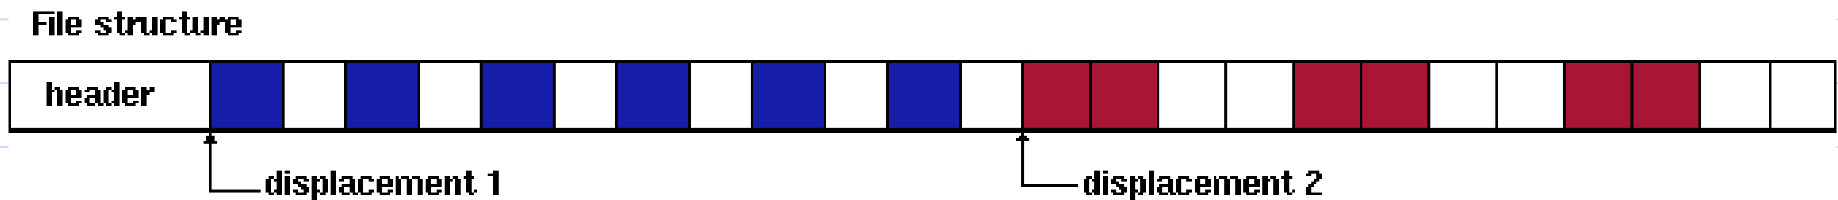

MPI-2 I/O: Терминология

- ***Вид*** (file view)- набор данных, видимый и доступный из открытого файла как упорядоченный набор е-типов. Каждый процесс имеет свой вид файла, определенный тремя параметрами: смещением, е-типом и файловым типом. Шаблон, описанный в файловом типе, повторяется, начиная со смещения.
- ***Смещение*** - это позиция в файле относительно текущего вида, представленная как число е-типов. ``Дыры'' в файловом типе вида пропускаются при подсчете номера этой позиции. Нулевое смещение - это позиция первого видимого е-типа в виде (после пропуска смещения и начальных ``дыр'' в виде).

MPI-2 I/O: Терминология

- ***Размер MPI файла*** измеряется в байтах от начала файла
- ***Конец файла*** - это смещение первого е-типа, доступного в данном виде, начинающегося после последнего байта в файле
- **«Индивидуальные файловые указатели»** - файловые указатели, локальные для каждого процесса, открытого файл.
- **«Общие файловые указатели»** - файловые указатели, которые используются одновременно группой процессов, открывающих файл.
- ***Дескриптор файла*** - закрытый объект, создаваемый MPI_FILE_OPEN и уничтожаемый MPI_FILE_CLOSE. Все операции над открытым файлом работают с файлом через его дескриптор

MPI-2 I/O: Базовый алгоритм работы

- Определение необходимых переменных и типов данных
- Открытие файла (MPI_File_open)
- Установка вида файла (MPI_File_set_view)
- Запись/чтение (MPI_File_write, MPI_File_read)
- Для неблокирующих операций, ожидание их завершения (напр., MPI_Wait)
- Закрытие файла (MPI_File_close)

Базовый алгоритм для работы с файлами

```
MPI_File fh;
MPI_Datatype filetype;
MPI_Status status;
MPI_Offset offset;
int mode;
float data[100];

/* other code */
/* set offset and filetype */

mode = MPI_MODE_CREATE|MPI_MODE_RDWR;
 MPI_File_open(MPI_COMM_WORLD, "myfile", mode, MPI_INFO_NULL, &fh);
MPI_File_set_view(fh, offset, MPI_FLOAT, filetype, "native", MPI_INFO_NULL);
MPI_File_write(fh, data, 100, MPI_FLOAT, &status);
MPI_File_close(&fh);
```

Открытие файла

- int MPI_File_open(MPI_Comm comm, char *filename, int amode, MPI_Info info, MPI_File *fh)
  - IN *comm* коммуникатор (дескриптор)
  - IN *filename* имя открываемого файла (строка)
  - IN *amode* тип доступа к файлу (целое)
  - IN *info* информационный объект (дескриптор)
  - OUT *fh* новый дескриптор файла (дескриптор)
- открывает файл с именем *filename* для всех процессов из группы коммуникатора comm
- все процессы должны обеспечивать одинаковое значение *amode* и имена файлов, указывающие на один и тот же файл
- info используется как «подсказка» (шаблоны доступа)

Типы доступа

- 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 -- ошибка, если создаваемый файл уже существует,
- MPI_MODE_DELETE_ON_CLOSE -- удалять файл при закрытии,
- MPI_MODE_UNIQUE_OPEN -- файл не будет параллельно открыт где-либо еще,
- MPI_MODE_SEQUENTIAL -- файл будет доступен лишь последовательно,
- MPI_MODE_APPEND -- установить начальную позицию всех файловых указателей на конец файла.

Закрытие файла

- int MPI_File_close(MPI_File *fh)
  - INOUT *fh* дескриптор файла (дескриптор)
- сначала синхронизирует состояние файла затем закрывает файл, ассоциированный с *fh*
- пользователь должен обеспечить условие, чтобы все ожидающие обработки неблокирующие запросы и разделенные коллективные операции над *fh*, производимые процессом, были выполнены до вызова MPI_FILE_CLOSE

Установка индивидуального указателя файла

int MPI_File_seek(MPI_File fh, MPI_Offset offset, int whence)

- IN *fh* дескриптор файла (дескриптор)
- Offset
- Whence – MPI_SEEK_SET – начало файла

Файловые виды (1)

- int MPI_File_set_view(MPI_File fh, MPI_Offset disp, MPI_Datatype etype, MPI_Datatype filetype, char *datarep, MPI_Info info)
  - INOUT *fh* дескриптор файла (дескриптор)
  - IN *disp* смещение (целое)
  - IN *etype* элементарный тип данных (дескриптор)
  - IN *filetype* тип файла (дескриптор)
  - IN *datarep* представление данных (строка)
  - IN *info* информационный объект (дескриптор)

Файловые виды (2)

- int MPI_File_get_view(MPI_File fh, MPI_Offset *disp, MPI_Datatype *etype, MPI_Datatype *filetype, char *datarep)
  - IN *fh* дескриптор файла (дескриптор)
  - OUT *disp* смещение (целое)
  - OUT *etype* элементарный тип данных (дескриптор)
  - OUT *filetype* тип файла (дескриптор)
  - OUT *datarep* представление данных (строка)

Доступ к данным

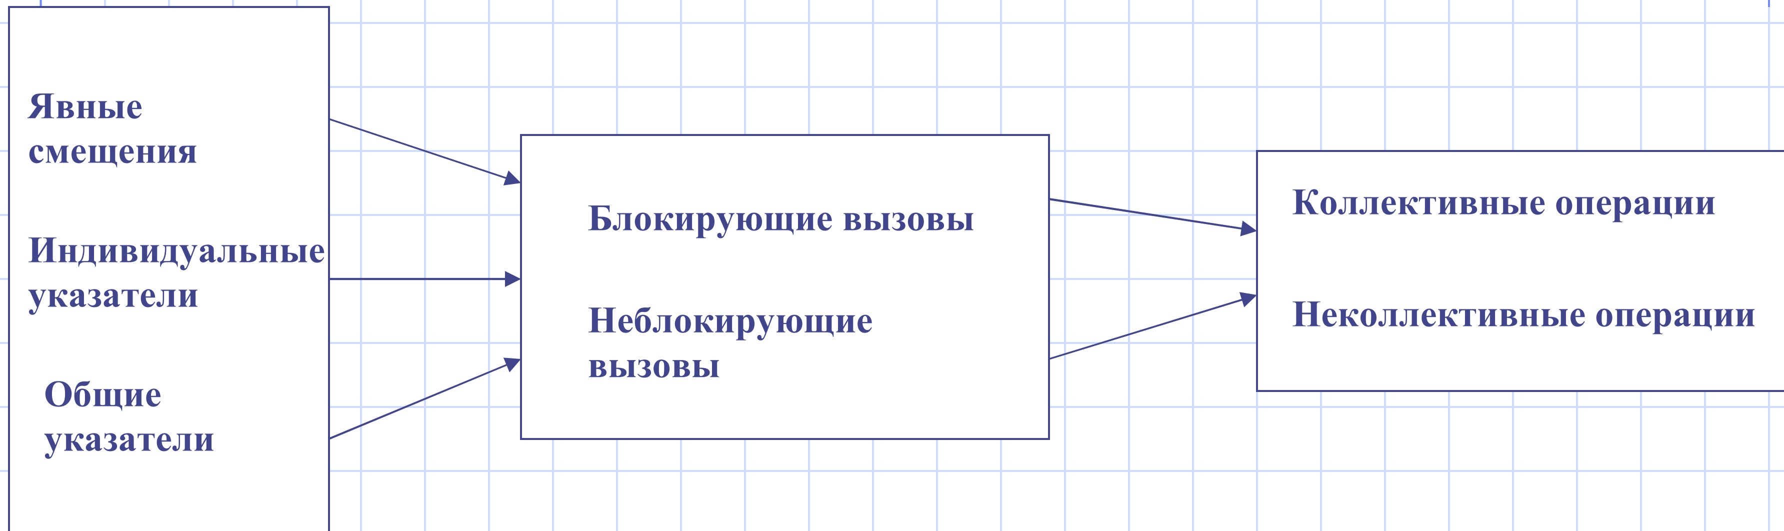

Позиционирование	Синхронизация	Координация	
		неколлективные	коллективные
Явные смещения	блокирующие	**MPI_FILE_READ_AT** **MPI_FILE_WRITE_AT**	**MPI_FILE_READ_AT_ALL** **MPI_FILE_WRITE_AT_ALL**
	неблокирующие и расщепленные коллетивные	**MPI_FILE_IREAD_AT** **MPI_FILE_IWRITE_AT**	**MPI_FILE_READ_AT_ALL_BEGIN** **MPI_FILE_READ_AT_ALL_END** **MPI_FILE_WRITE_AT_ALL_BEGIN** **MPI_FILE_WRITE_AT_ALL_END**
Индивидуальные указатели	блокирующие	**MPI_FILE_READ** **MPI_FILE_WRITE**	**MPI_FILE_READ_ALL** **MPI_FILE_WRITE_ALL**
	неблокирующие и расщепленные коллетивные	**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**
Общие указатели	блокирующие	**MPI_FILE_READ_SHARED** **MPI_FILE_WRITE_SHARED**	**MPI_FILE_READ_ORDERED** **MPI_FILE_WRITE_ORDERED**
	неблокирующие и расщепленные коллетивные	**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**

Доступ к данным

- int MPI_File_read(MPI_File fh, void *buf, int count, MPI_Datatype datatype, MPI_Status *status)
  - INOUT *fh* - дескриптор файла (дескриптор)
  - OUT *buf* - начальный адрес буфера (выбор)
  - IN *count* - количество элементов в буфере (целое)
  - IN *datatype* - тип данных каждого элемента буфера (дескриптор)
  - OUT *status* - объект состояния (Status)
- int MPI_File_write(MPI_File fh, void *buf, int count, MPI_Datatype datatype, MPI_Status *status)
  - INOUT *fh* - дескриптор файла (дескриптор)
  - IN *buf* - начальный адрес буфера (выбор)
  - IN *count* - количество элементов в буфере (целое)
  - IN *datatype* - тип данных каждого элемента буфера (дескриптор)
  - OUT *status* - объект состояния (Status)

Доступ к данным

- int MPI_File_read_at(MPI_File fh, MPI_Offset offset, void *buf, int count, MPI_Datatype datatype, MPI_Status *status)
  - INOUT *fh* - дескриптор файла (дескриптор)
  - OUT *buf* - начальный адрес буфера (выбор)
  - IN *count* - количество элементов в буфере (целое)
  - IN *datatype* - тип данных каждого элемента буфера (дескриптор)
  - OUT *status* - объект состояния (Status)
- int MPI_File_write_at(MPI_File fh, MPI_Offset offset, void *buf, int count, MPI_Datatype datatype, MPI_Status *status)
  - INOUT *fh* - дескриптор файла (дескриптор)
  - IN *buf* - начальный адрес буфера (выбор)
  - IN *count* - количество элементов в буфере (целое)
  - IN *datatype* - тип данных каждого элемента буфера (дескриптор)
  - OUT *status* - объект состояния (Status)

Поддержка целостности

- int MPI_File_set_atomicity(MPI_File fh, int flag) - все записи в файл немедленно записываются на диск; коллективная операция
  - INOUT fh Дескриптор файла (дескриптор)
  - IN flag true для установки атомарного режима, false для отмены атомарного режима (логическая)
- int MPI_File_get_atomicity(MPI_File fh, int *flag) - возвращает текущее значение семантики непротиворечивости для операций доступа к данным
  - IN fh Дескриптор файла (дескриптор)
  - INOUT flag true при атомарном режиме, false при неатомарном режиме (логическая)

Коллективные операции I/O MPI-2

- MPI_File_read_all, MPI_File_read_at_all, etc
- _all означает, что все процессы, входящие в группу, заданную коммуникатором при открытии файла, должны вызвать эту функцию
- Каждый процесс определяет свою собственную информацию для выполнения этой функции -- список параметров такой же, как и для неколлективных операций

Коллективные операции I/O

- Используя коллективные функции I/O пользователь полагается на оптимизацию их выполнения
- Реализация коллективных функций I/O может быть выполнена с условием объединения
- Рекомендуется использовать в случае, когда доступ к файлу от разных процессов производится в произвольном порядке и может пересекаться по времени

Пример:коллективные операции

```
/* noncontiguous access with a single collective I/O function */
#include "mpi.h"

#define FILESIZE      1048576
#define INTS_PER_BLK  16

int main(int argc, char **argv)
{
    int *buf, rank, nprocs, nints, bufsize;
    MPI_File fh;
    MPI_Datatype filetype;

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

    bufsize = FILESIZE/nprocs;
    buf = (int *) malloc(bufsize);
    nints = bufsize/sizeof(int);

    MPI_File_open(MPI_COMM_WORLD, "/pfs/datafile", MPI_MODE_RDONLY,
                  MPI_INFO_NULL, &fh);
```

Пример:коллективные операции

```
    MPI_Type_vector(nints/INTS_PER_BLK, INTS_PER_BLK,
                    INTS_PER_BLK*nprocs, MPI_INT, &filetype);
    MPI_Type_commit(&filetype);
    MPI_File_set_view(fh, INTS_PER_BLK*sizeof(int)*rank, MPI_INT,
                      filetype, "native", MPI_INFO_NULL);

    MPI_File_read_all(fh, buf, nints, MPI_INT, MPI_STATUS_IGNORE);
    MPI_File_close(&fh);

    MPI_Type_free(&filetype);
    free(buf);
    MPI_Finalize();
    return 0;
}
```

Неблокирующие коллективные операции I/O

- Ограниченная форма неблокирующих коллективных операций I/O
- Только **ОДНА** активная коллективная неблокирующая операция может выполняться в данный момет времени над заданным файловым указателем
- Не требуется request

```
MPI_File_write_all_begin(fh, buf, count, datatype);

for (i=0; i<1000; i++) {
    /* perform computation */
}

MPI_File_write_all_end(fh, buf, &status);
```

Разделяемый файловый указатель

- Функции для работы с разделяемым указателем:
  - MPI_File_read_shared
  - MPI_File_write_shared
  -MPI_File_seek_shared
  - MPI_File_iread_shared
  - MPI_File_iwrite_shared
- Коллективные упорядоченные операции:
  -MPI_File_read_orderded
  …………………..
- Разделенные коллективные упорядоченные операции:
  - MPI_File_read_orderded_begin
  - MPI_File_read_orderded_end

…………………………………………

Поддержка целостности

- Определяет результат выполнения нескольких операций I/O
- Специальные действия не требуются, если:

  - read-only доступ

  - работа с разными файлами
- Синхронизация нужна, например, при работе с общим файлом, открытым с коммуникатором MPI_COMM_WORLD
- Способы обеспечения целостности:

  -установка атомарности (MPI_File_set_atomicity)

  -закрытие и открытие файла заново

  -выполнение синхронизации

Поддержка целостности

int MPI_File_sync(MPI_File fh)

– записывает все буферизованные изменения, инициированные процессом, на диск – операция **КОЛЛЕКТИВНАЯ!!**

- INOUT fh Дескриптор файла (дескриптор)

int MPI_File_close(MPI_File fh)

– записывает все буферизованные изменения на диск перед закрытием файла

Переносимость (interoperability)

Означает:

- MPI-файл может использоваться обычной файловой системой
- MPI-файл может переноситься с одной вычислительной системы на другую
- MPI-файл, записанный на одной системе, может быть прочитан на другой, используя различные способы представления данных

Переносимость

Обеспечивается:

- Использование datarep параметра функции MPI_File_set_view:

  - native
  - internal
  - external32 – 32-bit big-endian IEEE формат

- Использование производных MPI-типов

Ссылки

- Message Passing Interface Forum.
  http://www.mpi-forum.org/docs
- William Gropp, Ewing Lusk, Rajjeev Thakur
  Using MPI-2: advanced features of the Message-Passing Interface. The MIT Press

Благодарность

- Приношу свою благодарность

  Вере Вороновой – выпускнице факультета ВМиК за помощь в подготовке материалов лекции