

MPI-IO

辻田 祐一
(RIKEN AICS)

講義・演習内容

- データ型
 - 基本データ型
 - 派生データ型
- 並列ファイルシステム
- MPI-IO
 - MPI-IOの基礎知識
 - 集団型I/O
 - MPI-IOの演習

データ型

- MPIで扱うデータ型
 - 基本データ型
 - 整数型・文字型や実数型などの基本となるデータ型
 - 派生データ型
 - 基本データ型の組合せにより新たに生成されるデータ型
 - 派生データ型生成を行う関数により作成可能

基本データ型

＜C言語(代表的なものを抜粋)＞

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

＜FORTRAN(代表的なものを抜粋)＞

MPI datatype	FORTRAN datatype
MPI_INTEGER	INTEGER
MPI_REAL	REAL
MPI_DOUBLE_PRECISION	DOUBLE PRECISION
MPI_COMPLEX	COMPLEX
MPI_LOGICAL	LOGICAL
MPI_CHARACTER	CHARACTER(1)
MPI_BYTE	
MPI_PACKED	

MPI datatype	C datatype	FORTRAN datatype
MPI_AINT	MPI_Aint	INTEGER (KIND=MPI_ADDRESS_KIND)
MPI_OFFSET	MPI_Offset	INTEGER (KIND=MPI_OFFSET_KIND)

派生データ型

- 派生データ型 (Derived Datatype)
 - 不連続なデータレイアウトをまとめたデータ型
 - 不連続なレイアウトにあるデータ群を1回の通信で処理が可能。高速化の対応を可能にする。
 - 基本データ型とオフセットの集合で表現される。
 - 派生データ型生成を行う関数により作成可能

2次元配列のブロック分割の例

- 多次元配列

- ある一つの次元のみデータの並びが連続
 - それ以外の次元での並びは不連続
-
- 簡単な例として、2次元配列のブロック分割を考えてみる。

0	1	2	3
4	5	6	7
8	9	10	11
12	13	14	15

ステンシル計算における隣接ブロックとの通信
(赤色のブロックが通信対象)



不連続なデータの通信が発生



一つのデータ型(派生データ型)にして、1回で通信できるようにすることを考える。

派生データ型の生成と登録および解放


- 派生データ型の作成に使われる関数群(抜粋)
 - MPI_Type_contiguous
 - MPI_Type_vector
 - MPI_Type_indexed
 - MPI_Type_create_indexed
 - MPI_Type_create_subarray
 - MPI_Type_create_darray
- 作成した派生データ型の登録(データ型作成後に必ずこれを行わないといけない！)
 - MPI_Type_commit
- 作成したデータ型の解放(不要になった際に解放するために使う。)
 - MPI_Type_free

MPI_Type_vector

```
C: int MPI_Type_vector(int count, int blklen, int stride,  
    MPI_Datatype otype, MPI_Datatype *ntype);
```

```
F: MPI_TYPE_VECTOR(count, blklen, stride, otype, ntype, ierr)
```

＜赤色の領域をアクセスする派生データ型の作成例＞



```
MPI_Datatype ntype;
```

```
MPI_Type_vector(3, 4, 6, MPI_DOUBLE,  
    &ntype);
```


MPI_Type_create_subarray

C: `int MPI_Type_create_subarray (int ndims, int array_of_sizes[],
int array_of_subsizes[], int array_of_starts[], int order,
MPI_Datatype otype, MPI_Datatype *ntype);`

F: `MPI_TYPE_CREATE_SUBARRAY (ndims, array_of_sizes,
array_of_subsizes, array_of_starts, order, otype, ntype, ierr)`

- `ndims`: ベースになる配列の次元数
- `array_of_sizes`: ベースになる配列の各次元の大きさ
- `array_of_subsizes`: 部分配列の大きさ
- `array_of_starts`: 部分配列の開始地点 (* 注意: FORTRANでも0から始まります。)
- `order`: `MPI_ORDER_C`または`MPI_ORDER_FORTRAN`

MPI_Type_create_subarray(続き)



赤い部分配列をアクセスする
派生データ型の作成例

```
int o_sizes[2];  
int n_sizes[2];  
int starts[2];  
MPI_Datatype ntype;  
  
o_sizes[0] = o_sizes[1] = 10;  
n_sizes[0] = n_sizes[1] = 8;  
starts[0] = starts[1] = 1;  
  
MPI_Type_create_subarray(2, o_sizes,  
    n_sizes, starts, MPI_ORDER_C,  
    MPI_DOUBLE, &ntype);
```

MPI_Type_commit/MPI_Type_free

C: `int MPI_Type_commit (MPI_Datatype type);`

F: `MPI_TYPE_COMMIT (type, ierr)`

- 作成したデータ型は必ずMPI_Type_commitにより登録する。
- 以後、このデータ型を用いた通信・I/Oなどが利用可能。


C: `int MPI_Type_free (MPI_Datatype *type);`

F: `MPI_TYPE_FREE (type, ierr)`

- 必要なくなったら作成したデータ型をMPI_Type_freeにより解放。
- 以後、このデータ型は使えなくなる。

派生データ型における内部処理

- 送信側： 不連続なデータを連続なデータに並び替え（Pack処理）した後に送信
- 受信側： 受け取ったデータを元の不連続なデータに並べ替え（Unpack処理）



派生データ型のまとめ

- 基本データ型から派生データ型を作成
- 派生データ型作成後に必ずMPI_Type_commitで登録
- 作成された派生データ型はMPIでの通信・I/Oで利用可能
- 不連続なデータを一纏めに扱うことにより、性能向上の可能性あり。
- 不要になった派生データ型はMPI_Type_freeで解放する。

並列ファイルシステム


- 並列ファイルシステムが有する機能・特徴の例
 - データブロックの分散配置
 - メタデータ管理手法の最適化
 - データの信頼性と回復可能性
 - キャッシュ一貫性
 - 高い利用可能性
 - スケーラブルな容量と性能



ローカルファイルシステムと同じ使用イメージを提供しつつ、
高いI/O性能を実現

並列ファイルシステムの構成

- ネットワークを介してディスクアレイの複数のディスクにストライピングアクセスすることで高いI/O性能を実現。
- ネットワーク通信では、小さいサイズの通信は遅くなるため、ネットワークを介してアクセスする並列ファイルシステムでは、分割されるファイルサイズを小さくすると性能が低下する。よってある程度大きな単位で分割させる方が高い性能を得やすい。



並列ファイルシステムの必要性

- 広く利用されている分散ファイルシステムであるNFS
 - I/O性能が出ない
 - 大規模データのI/Oに不向き
- 並列ファイルシステムの利用
 - 計算ノードの数に比例するI/Oバンド幅
 - 複数のディスク間でストライピングすることで高い性能を実現
 - MPI-IOを用いた高速並列I/Oも利用可能

(参考) 神戸大のFX10の並列ファイルシステム

- FEFS (Fujitsu Exabyte File System) という Lustre をベースとした 並列ファイルシステム
 - 基本機能は Lustre と同じ
 - 扱えるファイル容量の増加や性能向上へのチューニングなど富士通が独自に改良を加えている。
 - 京や FX10、FX100 などでも利用されている。

例えば、`lfs df` でファイルシステムの構成 (MDT および OST の構成) が分かる。

```
[tsujita@pi NPB3.3-MPI_ext_pi]$ lfs df
```

UUID	1K-blocks	Used	Available	Use%	Mounted on
home-MDT0000_UUID	553577888	50718552	474285640	9%	/home[MDT:0] ← MDT
home-OST0000_UUID	15270269408	2148166252	12357848348	14%	/home[OST:0]
home-OST0001_UUID	15270269408	2104385764	12401628724	13%	/home[OST:1]
home-OST0002_UUID	15270269408	2169024088	12336990540	14%	/home[OST:2]
home-OST0003_UUID	15270269408	2125603924	12380410744	13%	/home[OST:3]
home-OST0004_UUID	15270269408	2139166088	12366848564	14%	/home[OST:4]
home-OST0005_UUID	15270269408	2093410696	12412603812	13%	/home[OST:5]
home-OST0006_UUID	15270269408	2090395876	12415618744	13%	/home[OST:6]
home-OST0007_UUID	15270269408	2155104296	12350910332	14%	/home[OST:7]
home-OST0008_UUID	15270269408	2098221712	12407792800	13%	/home[OST:8]
home-OST0009_UUID	15270269408	2156946792	12349067864	14%	/home[OST:9]
home-OST000a_UUID	15270269408	2131663116	12374351392	13%	/home[OST:10]
home-OST000b_UUID	15270269408	2160262008	12345752632	14%	/home[OST:11]
home-OST000c_UUID	15270269408	2126495752	12379518896	13%	/home[OST:12]
home-OST000d_UUID	15270269408	2113170988	12392843516	13%	/home[OST:13]
home-OST000e_UUID	15270269408	2166148192	12339866480	14%	/home[OST:14]
home-OST000f_UUID	15270269408	2099631916	12406382076	13%	/home[OST:15]


MDTが1個、OSTが16個
あるのが分かる。

```
filesystem summary: 244324310528 34077797460 198018435464 13% /home
```

MPI-IO

- MPI-IO

- MPI Standardにおける並列I/Oを含むI/Oインタフェース群
- 実装としてROMIOやOMPIOが広く利用されている。
- HDF5やParallel netCDFなどのアプリ向けI/Oライブラリで並列I/O機能の基盤システムとして利用



MPI-IOによるオープンおよびクローズ

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

```
F: MPI_FILE_OPEN(comm, filename, amode, info, fh, ierr)  
    MPI_FILE_CLOSE(fh, ierr)
```

- 集団操作のため、引数に与える**コミュニケータに属するプロセスで同じ関数を呼び出す**必要あり。
- amode: アクセスモード(詳細は次のスライド)
- info: MPI-IOに関するヒント
- fh: ファイルハンドル(これを用いてファイル操作を行う。)

* オープンしたら必ずクローズすること。

アクセスモード

- 以下の定義済みのビットのORでアクセスモードを定義する。

- MPI_MODE_RDONLY — 読込のみ可能
- MPI_MODE_RDWR — 読込みと書き込みの両方可能
- MPI_MODE_WRONLY — 書込みのみ可能
- MPI_MODE_CREATE — ファイルが無い場合、新規作成
- MPI_MODE_EXCL — 既にファイルがある場合にエラーを返す
- MPI_MODE_DELETE_ON_CLOSE — ファイルを閉じる際に消去
- MPI_MODE_UNIQUE_OPEN — 同時にファイルをオープンしない
- MPI_MODE_SEQUENTIAL — 逐次的なファイルのオープン
- MPI_MODE_APPEND — 全てのファイルポインタをファイル終端にセット

ファイル情報の設定

```
C: MPI_File_set_info (MPI_File fh, MPI_info info);  
    MPI_File_get_info(MPI_File fh, MPI_Info *info_used);
```

```
F: MPI_FILE_SET_INFO (fh, info, ierr)  
    MPI_FILE_GET_INFO (fh, info_used, ierr)
```

- MPI_File_set_info: ファイルI/Oに関する情報をkey,value対で設定
- MPI_File_get_info: 設定済みのファイルI/Oに関する情報を取得

<MPI-IOに関連するkey,value対の例(他にも様々なkey,value対があります。)>

key	Value(デフォルト値)	意味
cb_buffer_size	4194304 (対象ファイルシステムによって変わる可能性あり。) (例: LustreやFEFS → ストライプサイズに設定される。)	集団型I/Oの内部でI/O処理で使う一時バッファの大きさ
cb_nodes	ノード数	集団型I/OでI/O処理を行うプロセス数

- MPI_Info_setによりkey,value対が設定されたinfoをMPI_File_set_infoに与える。

ファイルビューの定義

C: MPI_File_set_view (MPI_File fh, MPI_Offset disp,
MPI_Datatype etype, MPI_Datatype ftype,
char *datarep, MPI_Info info);

F: MPI_FILE_SET_VIEW (fh, disp, etype, ftype, datarep, info, ierr)

- 集団操作: 全プロセスで呼び出しする。
- fh: 当該ファイルのファイルハンドル
- disp: オフセット値
- etype: ファイルビューを表すftypeを生成する基になるデータ型
- ftype: ファイルビューを表すデータ型
- datarep: 以下の3種類の内のどれかを指定
 - native: メモリ中のバイナリデータ表現と同じ表現
 - internal: 同一システム内で互換するデータ表現
 - external32: 異なるシステム間でも互換性のあるデータ表現
- info: MPI_Infoオブジェクト(key,valueペアで指定されたパラメタ群)
(特に設定するものが無い場合、MPI_INFO_NULLを引数に与える。)


ファイルビューにおけるデータ型に関して

- etype
 - ファイルアクセスの単位となるデータ型
 - データ型のベースとなるデータ型がI/O処理で使われるデータ型と同じである必要あり。
- ftype
 - ファイルビューを表すデータ型
- datarep: 以下の3種類の内のどれかを指定
 - native:
 - メモリ中のバイナリデータ表現と同じ
 - 同一計算機内での利用を想定したデータ表現
 - internal:
 - 同一システム内で互換するデータ表現
 - external32:
 - 異なるシステム間でも互換性のあるデータ表現

MPI_File_openとMPI_File_set_view

- MPI_File_set_viewによるファイルビュー生成はMPI_File_openでファイルハンドルを取得後に行う。

etype:



ftype (rank=0):



ftype (rank=1):



ファイル上のアクセスパターン

↑
disp

通信・I/Oにおけるデータ型に関する操作

```
C: MPI_Get_count(MPI_Status *status, MPI_Datatype datatype,  
    int *count);  
    MPI_Get_elements(MPI_Status *status, MPI_Datatype datatype,  
    int *count);
```

```
F: MPI_GET_COUNT (status, datatype, count, ierr)  
    MPI_GET_ELEMENTS(status, datatype, count, ierr)
```

- 引数に与えるstatus: 通信やI/Oでのstatus
 - 与えられたstatusに関連する通信あるいはI/Oに関してMPI_Get_countあるいはMPI_Get_elementが実行される。
- datatype: 通信あるいはI/Oに用いられる派生データ型
- count:
 - 受信あるいはI/Oを行ったデータの個数(MPI_Get_count)
 - 受信あるいはI/Oを行ったデータの基本データ型の個数(MPI_Get_elements)

使用例

...

```
MPI_Type_create_subarray(2, gsizes, lsizes, lstarts, MPI_ORDER_C,  
    MPI_DOUBLE, &ftype);  
MPI_Type_commit(&ftype);
```

```
MPI_File_open(MPI_COMM_WORLD, "./example.dat",  
    MPI_MODE_CREATE | MPI_MODE_RDWR, MPI_INFO_NULL, &fh);  
MPI_File_set_view(fh, 0, MPI_DOUBLE, ftype, "native", MPI_INFO_NULL);
```

```
MPI_File_write_all(fh, &(buf[0][0]), local_size, MPI_DOUBLE, &status);
```

```
MPI_Get_count(status, ftype, &d_count);
```

```
MPI_Get_elements(status, ftype, &d_element);
```

MPI_File_write_allで書き込んだデータに
おける派生データ型ftypeに関する情報
を取得

...

MPI-IO関数の分類

positioning	synchronism	coordination	
		noncollective	collective
explicit offsets	blocking	MPI_File_read_at MPI_File_write_at	MPI_File_read_at_all MPI_File_write_at_all
	nonblocking	MPI_File_iread_at MPI_File_iwrite_at	MPI_File_iread_at_all MPI_File_iwrite_at_all
	split collective	N/A	MPI_File_read_at_all_begin/end MPI_File_write_at_all_begin/end
individual file pointers	blocking	MPI_File_read MPI_File_write	MPI_File_read_all MPI_File_write_all
	nonblocking	MPI_File_iread MPI_File_iwrite	MPI_File_iread_all MPI_File_iwrite_all
	split collective	N/A	MPI_File_read_all_begin/end MPI_File_write_all_begin/end
shared file pointer	blocking	MPI_File_read_shared MPI_File_write_shared	MPI_File_read_ordered, MPI_File_write_ordered
	nonblocking	MPI_File_iread_shared MPI_File_iwrite_shared	N/A
	split collective	N/A	MPI_File_read_ordered_begin/end MPI_File_write_ordered_begin/end

“MPI: A Message-Passing Interface Standard Version 3.1” (June 2016)から引用


* MPI-3.1から追加：実装によっては、まだサポートされていない。

MPI-IO関数の選択

- Noncollective / Collective
- File view
- File pointer (independent / shared)
- Blocking / nonblocking


並列ファイルシステムと並列プログラムの特性

- 並列ファイルシステム
 - ディスクの数を増やすことで、高バンド幅、大容量のI/Oを実現
 - I/Oサイズを大きくしないと高い性能が望めない。
- 並列プログラム
 - Weak scaling: プロセスあたりのデータサイズは一定。プロセス数に比例して全体で扱うデータサイズが増大
 - Strong scaling: プロセス全体で扱うデータサイズが一定。プロセス数の増加に伴い、プロセスあたりのデータサイズが縮小
 - プロセス数が増える程、並列I/Oにおける性能向上が望めなくなる。



集団型I/O

- プロセス全体でI/O処理を行う。
- プロセス数の増加により、より大きなデータのI/Oが可能。
- 派生データ型を用いて不連続なデータの並びに対し、一度に多くのデータを扱うことが可能。
- I/Oを行うデータをファイル上で連続に並べ替えることで高いI/O性能が期待できる。(ファイルI/O性能向上が通信コスト増を大幅に上回る)



派生データ型による集団型I/O

- BTIOベンチマーク: NAS Parallel Benchmarks(NPB)のベンチマーク群の1つ
 - Class: ベンチマークの問題サイズ: $A < B < C < D$
 - Subtype
 - Simple: Noncollective
 - Full: Collective
- ベンチマーク結果の例(16プロセス@4ノードPCクラスタでの評価)
 - Intel Xeon E3-1280 V2(1ソケット/ノード)
 - メモリ: 32GiB
 - Interconnect: InfiniBand FDRx4 (1 HCA/ノード)
 - Lustre File system
 - 1 MDS, 4 OSTs (2 OSTs/OSS)

I/Oパターン	Class-B	Class-C
noncollective	16485.00	17133.45
collective	32200.14	38271.68


Collectiveの方が高い性能を実現(表内の数字の単位はMop/s)

- 集団型I/Oの問題点: 集団型I/Oの方が非集団型に比べてコードが複雑かつ長くなりやすい。
 - アクセス領域のプロセス間調整
 - 派生データ型の事前準備、等々


ファイルポインタに関する注意点

- 逐次プロセスの場合： ファイルポインタは1個（プロセス内で一意的）で、扱いは容易。
- 並列プロセスの場合： プロセス間でファイルポインタの動きを把握する必要あり。

逐次プロセス



並列プロセス



このようになる保証は無い！

ファイルポインタの種類によって適切な対応を行う必要あり

MPI-IOにおけるオフセットの取り扱い

- 直接オフセットを指定してI/Oを行う
 - 例: `MPI_File_write_at`, `MPI_File_read_at`

`write_at("abc",0)`
`write_at("def",3)`

`write_at("ghi", 6)`
`write_at("jkl", 9)`

0	1	2	3	4	5	6	7	8	9	10	11
a	b	c	d	e	f	g	h	i	j	k	l

- プロセス個々にファイルポインタを保持: 独立ファイルポインタ (Independent file pointer)

`seek(0)`
`write("abc")`
`write("def")`

`seek(6)`
`write("ghi")`
`write("jkl")`

0	1	2	3	4	5	6	7	8	9	10	11
a	b	c	d	e	f	g	h	i	j	k	l

- プロセス間で一つのファイルポインタを共有
 - 例: `MPI_File_write_shared`, `MPI_File_read_shared`

`barrier()`
`seek(0)`
`write("abc")`

`write("def")`
`barrier()`

`barrier()`
`barrier()`

`write("ghi")`
`write("jkl")`

0	1	2	3	4	5	6	7	8	9	10	11
a	b	c	d	e	f	g	h	i	j	k	l

ファイルポインタに対する操作

```
C: MPI_File_seek (MPI_File fh, MPI_Offset offset, int whence);  
    MPI_File_seek_shared(MPI_File fh, MPI_Offset offset, int whence);  
    MPI_File_get_position(MPI_File fh, MPI_Offset *offset);  
    MPI_File_get_position_shared(MPI_File fh, MPI_Offset *offset);
```

```
F: MPI_FILE_SEEK (fh, offset, whence, ierr)  
    MPI_FILE_SEEK_SHARED(fh, offset, whence, ierr)  
    MPI_FILE_GET_POSITION(fh, offset, ierr)  
    MPI_FILE_GET_POSITION_SHARED(fh, offset, ierr)
```

- 2種類のファイルポインタ(独立および共有)のそれぞれに対応する操作を行う関数が用意されている。(共有ファイルポインタ向けには関数名にsharedがある。)
- whenceに与える引数
 - MPI_SEEK_SET: offsetが指す位置にポインタを移動
 - MPI_SEEK_CUR: ポインタが現在指す位置+offsetにポインタを移動
 - MPI_SEEK_END: ファイルの終端+offsetの位置にポインタを移動

オフセット付I/O処理

```
C: MPI_File_write_at_all (MPI_File fh, MPI_Offset offset, void *buf,  
    int count, MPI_Datatype datatype, MPI_Status *status);  
    MPI_File_read_at_all (MPI_File fh, MPI_Offset offset, void *buf,  
    int count, MPI_Datatype datatype, MPI_Status *status); など
```

```
F: MPI_FILE_WRITE_AT_ALL (fh, offset, buf, count, datatype, status, ierr)  
    MPI_FILE_READ_AT_ALL(fh, offset, buf, count, datatype, status, ierr) など
```

- オフセット付きでI/Oを行う関数の場合、引数にファイルハンドルを与えるが、I/O処理ではファイルポインタを使わない。
- 指定されたオフセット値のところから、datatypeの型をcount分だけI/Oを行う。

ファイル操作

```
C: MPI_File_delete (char *filename, MPI_Info info);  
    MPI_File_preallocate (MPI_File fh, MPI_Offset size);  
    MPI_File_get_size(MPI_File fh, MPI_Offset *size);
```

```
F: MPI_FILE_DELETE (filename, info, ierr)  
    MPI_FILE_PREALLOCATE (fh, size, ierr)  
    MPI_FILE_GET_SIZE(fh, size, ierr)
```

- MPI_File_delete: 指定したファイルの削除
- MPI_File_preallocate: 指定したファイルに対し、引数で与えたサイズ分の領域をI/O処理を行う前に確保する。
- MPI_File_get_size: 指定したファイルのサイズを取得する。

MPI-IOのまとめ

- 集団型I/O
 - 全プロセスでI/O処理を実施
 - 派生データ型を使った集団型I/Oで高速化が期待できる。
- 3種類のファイルアクセス場所の指定方法
 - オフセット付きアクセス(ファイルポインタは使わない)
 - 独立ファイルポインタによるアクセス
 - File viewの指定が可能
 - 共有ファイルポインタによるアクセス
 - 逐次的に処理されるので、高い性能は望めない。

タイマ関数

```
C: double MPI_Wtime (void);
```

```
F: DOUBLE PRECISION MPI_WTIME ( )
```

- 秒単位での現時刻値を倍精度実数型の値で返す。

➤ 使用例

```
...  
double  time;  
...  
time = MPI_Wtime ();  
計算や通信・I/O処理など  
time = MPI_Wtime() - time;
```


- 計測対象をMPI_Wtime()で挟み込み、取得した時間情報の差分を取ることで、経過時間を計測できる。

参考文献

- MPI Forum
<http://www.mpi-forum.org/>
MPI仕様策定をしているコミュニティのページ
ここから様々な仕様書等が取得可能
最新の仕様書の版はMPI-3.1 (2016年2月現在)
- MPI-2.2仕様書 (日本語訳)
<http://www.pccluster.org/ja/mpi.html>
公開されている日本語訳では、現段階でこれが最新
- W. Gropp, E. Lusk, A. Skjellum, “Using MPI” (MIT Press)
- W. Gropp, E. Lusk, R. Thakur, “Using MPI-2” (MIT Press)
- W. Gropp, T. Hoefler, R. Thakur, E. Lusk, “Using Advanced MPI,” (MIT Press)
- P. Pacheco著, 秋葉博 訳, ”MPI並列プログラミング”(培風館)

演習課題1

- 4プロセス(ランク)の各々が、下の図にあるような部分配列を持っているとする。各プロセスが持つデータを図のファイル上の並び(図の番号順)になるようにMPI-IOで書き込みを行うプログラムを作成せよ。



配列全体の大きさは50×50でデータ型はMPI_DOUBLEとする。



<ファイル上の並び>

演習課題1(続き)

- プログラム作成にあたっては、以下のMPI関数を用いること。
 - MPI_Type_create_subarray
 - MPI_File_set_view
 - MPI_File_write_at_all
- また、部分配列の各要素の値は以下のようにランクごとに設定しておくこと。
 - rank=0 11.0
 - rank=1 13.0
 - rank=2 15.0
 - rank=3 17.0
- 出力されたファイルの中身をodコマンドで確認し、派生データ型の通りに書き込まれていることを確認せよ。
(例えば、od -xv ファイル名 | less で見て、先頭から正しい値が書き込まれていることを確認できるはず。)

演習課題2

- 4プロセスでストライプサイズを16MB、ストライプカウントが4となるファイル（ファイル名は適当に決めて良い。）を作成せよ。なおファイル生成のみでデータのI/Oは行わなくて良い。
- プログラムを実行し、ファイルが作成されたら、以下のようにしてストライプカウントとストライプサイズを確認し、正しく設定されていることを確認すること。（`lfs getstripe ファイル名` で情報が表示されます。）
- ヒント： ストライプサイズおよびストライプカウントは、`MPI_Info_set`でinfoオブジェクトに設定し、ファイルのオープン時にこれを反映させる必要があります。なおストライプサイズおよびストライプカウントのkeyは以下の通りです。
 - ストライプサイズ: `striping_unit`
 - ストライプカウント: `striping_factor`

補足： 神戸大のFX10では、デフォルトで以下のようになっているようです。

- ストライプサイズ: 2GB (2147483648)
- ストライプカウント: 16