MPI（片方向通信）

2018年3月16日

神戸大学大学院システム情報学研究科計算科学専攻
横川三津夫

分散メモリ型並列計算機

- 複数のプロセッサがネットワークで接続されており，れぞれのプロセッサ（PE）が，メモリを持っている.
  - 各PEが自分のメモリ領域のみアクセス可能

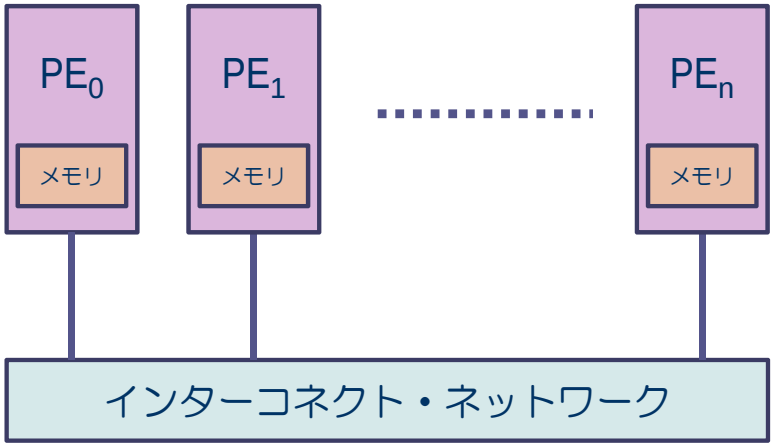

- 特徴
  - 数千から数万PE規模の並列システムが可能
  - PEの間のデータ分散を意識したプログラミングが必要.

- プログラミング技術
  - メッセージ・パシング・インターフェイス（MPI）によるプログラミング

MPIの実行モデル：SPMD（Single Program, Multiple Data）

- 複数のプロセスにより並列実行
- 実行開始から終了まで，全プロセスが同じプログラムを実行
- 各MPIプロセスは固有の番号（ランク番号）を持つ
  - P個のプロセスで実行する場合，プロセス番号は0から(P-1)までの整数

- 各プロセスで処理を変えたいときは，ランク番号を使った分岐により，各プロセスの処理を記述する．

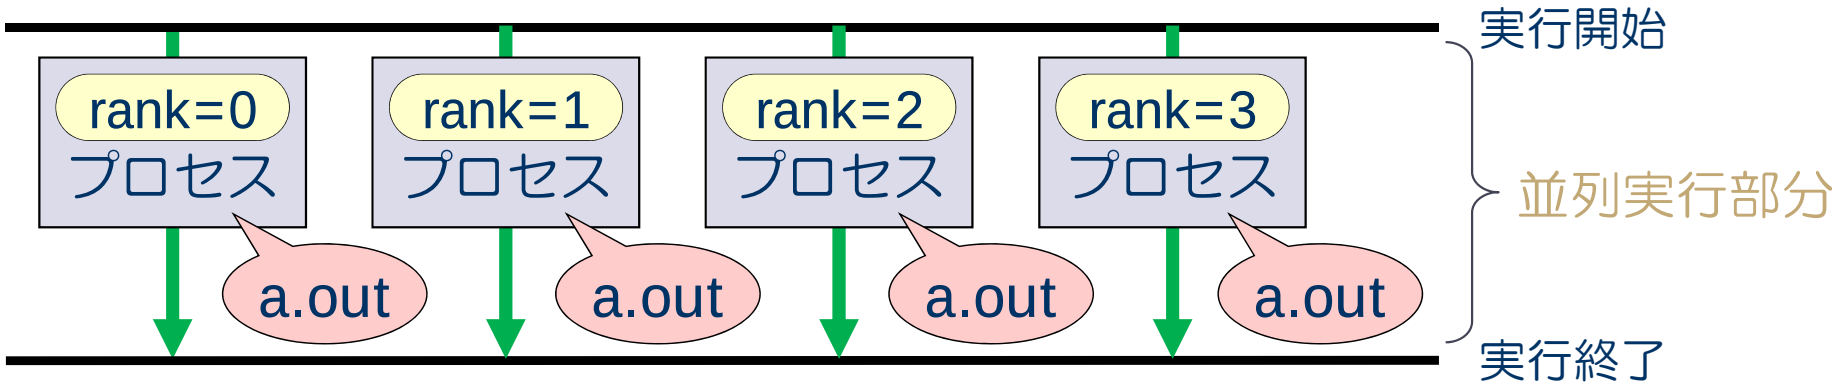

MPIの実行モデル（続き）

- メモリ空間
  - プロセスごとに独立したメモリ空間を保持
    - プログラム中で定義された変数や配列は，同じ名前で独立に各プロセスのメモリ上に割り当てられる．
    - 同じ変数や配列に対して，プロセスごとに違う値を与えることが可能
    - 他のプロセスの持つ変数や配列には，直接にアクセスできない．

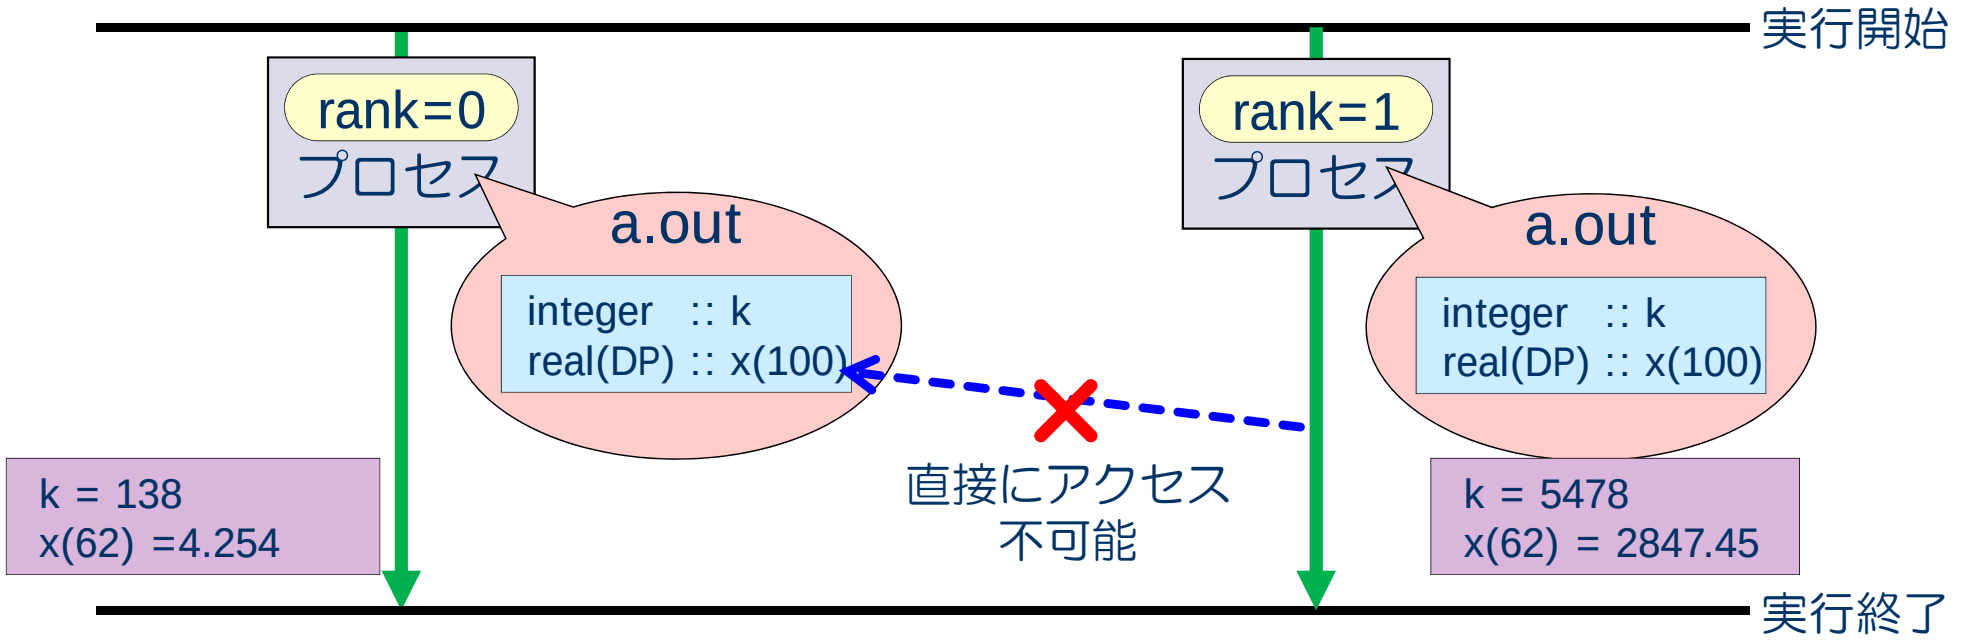

MPIの実行モデル（続き）

- プロセス間通信
  - 他のプロセスの持つ変数や配列のデータにアクセスできない.
    ⇒ プロセス間通信によりデータを送ってもらう.
  - メッセージパッシング方式：メッセージ（データ）の送り手と受け手
  - この方式によるプロセス間通信関数の集合 ≒ MPI

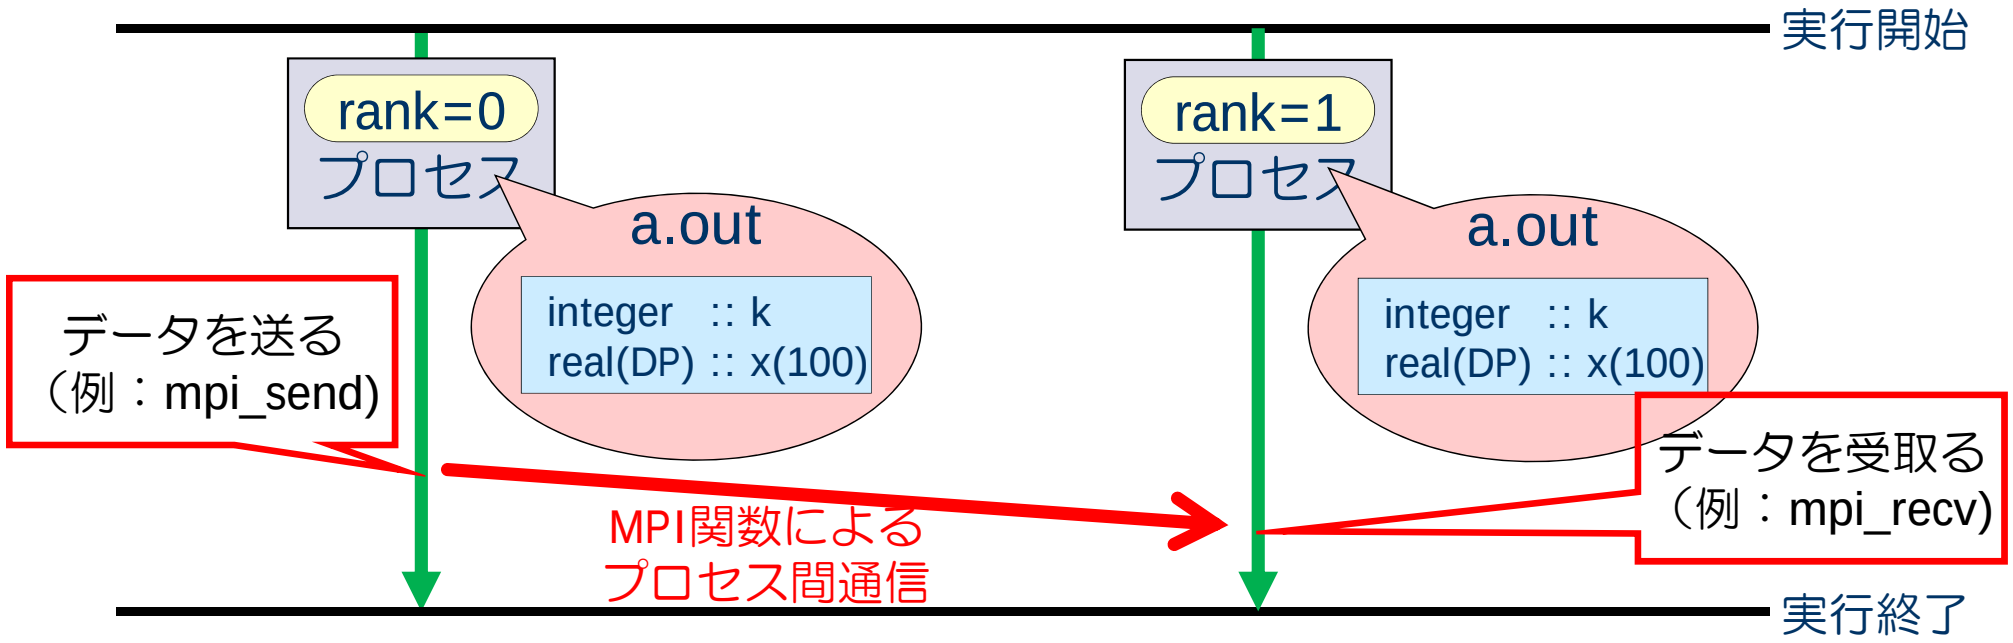

SPMDのイメージ

- それぞれの人が，本棚に一連のノートを持っている．
  - それぞれの人には，名前が付いている（人を区別できる）．
  - ノートには同じ名前が付けられているが，中身は違っている．
- 本棚のノートに対し，それぞれの人が，読んだり書いたり…
  - 大体は同じ作業をするが，最初のノートの中身が違うので，中身はそれぞれ違う．
  - ある人に，他の人とは違う作業をさせたい場合には，名前で作業と指示してあげる．
- 時々，他の人のノートを見たい．
  - 相手にノートの中身を送ってあげる．
  - 送られた人は，それを違う名前のノートに中身を書き写す．

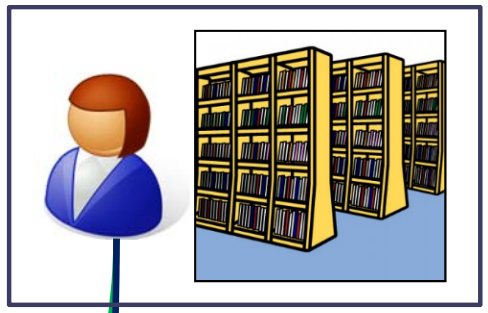

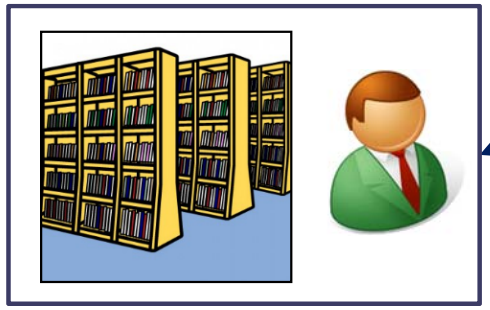

【必要な情報】
- ノートの名前
- 何冊
- 誰に
- 荷物のタグなど

MPIプログラムのスケルトン

```
program main
use mpi                                                    MPIモジュールの取り込み（おまじない1）
implicit none
integer :: nprocs, myrank, ierr                            MPIで使う変数の宣言

call mpi_init( ierr )                                      MPIの初期化（おまじない2）
call mpi_comm_size( MPI_COMM_WORLD, nprocs, ierr )         MPIで使うプロセス数を nprocs に取得
call mpi_comm_rank( MPI_COMM_WORLD, myrank, ierr )         自分のプロセス番号を myrank に取得


  (この部分に並列実行するプログラムを書く）



call mpi_finalize( ierr )                                  MPIの終了処理（おまじない3）

end program main
```

- それぞれのプロセスが何の計算をするかは，myrankの値で場合分けし，うまく仕事が振り分けられるようにする.

講義の内容

- メッセージ・パシング・インターフェイス（MPI）
- 双方向通信
- 片方向通信
- 演習問題

メッセージ・パシング・インターフェイス

- Message Passing Interface (MPI) とは．．．
  - 複数の独立したプロセス間で，並列処理を行うためのプロセス間メッセージ通信の標準規格
  - 1992年頃より米国の計算機メーカ，大学などを中心に標準化
  - MPI規格化の歴史
    - 1994　MPI-1
    - 1997　MPI-2（一方向通信など）
    - 2012　MPI-3
      - http://www.mpi-forum.org/docs/mpi-3.0/mpi30-report.pdf

双方向通信（one-to-one communication）

- 送信側と受信側で，対応する関数を呼ぶ．
- MPI_send，MPI_recvなどの組合せ

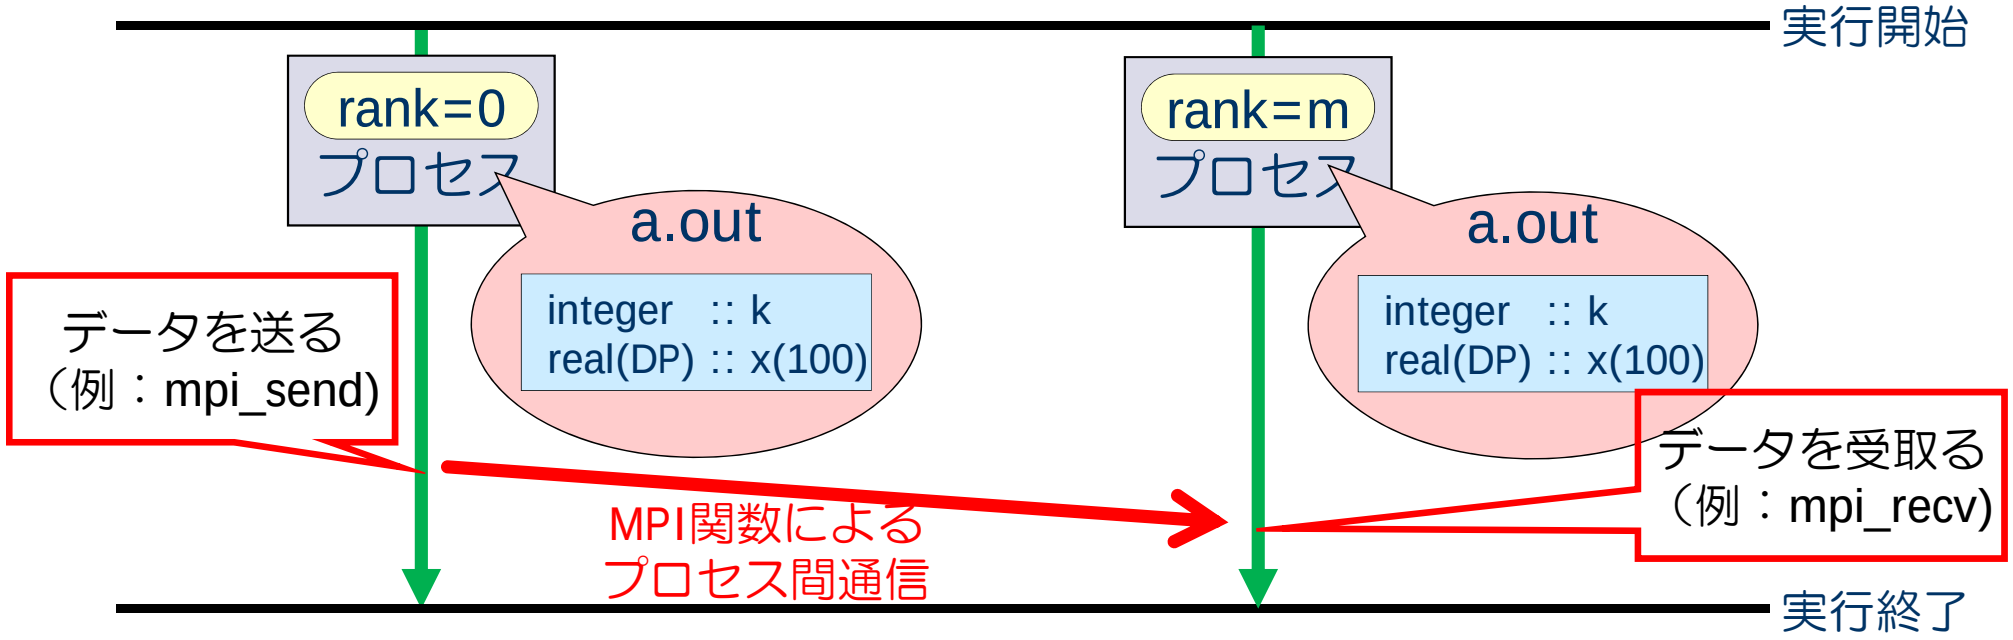

【復習】 1対1通信 – 送信関数（送り出し側）

```
mpi_send( buff, count, datatype, dest, tag, comm, ierr )
```

- buff:　　送信するデータの変数名（先頭アドレス）
- count:　　送信するデータの数（整数型）
- datatype:　送信するデータの型
  - MPI_INTEGER, MPI_DOUBLE_PRECISION, MPI_CHARACTER など
- dest:　　送信先のプロセス番号
- tag:　　メッセージ識別番号．送るデータを区別するための番号
- comm:　　コミュニケータ（例えば，MPI_COMM_WORLD）
- ierr:　　戻りコード（整数型）

【復習】 1対1通信 – 受信関数（受け取り側）

```
mpi_recv( buff, count, datatype, source, tag, comm, status, ierr )
```

- buff:　　受信するデータのための変数名（先頭アドレス）
- count:　　受信するデータの数（整数型）
- datatype:　受信するデータの型
  - MPI_INTEGER, MPI_DOUBLE_PRECISION, MPI_CHARACTER など
- source:　　送信してくる相手のプロセス番号
- tag:　　メッセージ識別番号．送られて来たデータを区別するための番号
- comm:　　コミュニケータ（例えば，MPI_COMM_WORLD）
- status:　　受信の状態を格納するサイズMPI_STATUS_SIZEの配列（整数型）
- ierr:　　戻りコード（整数型）

片方向通信（One-sided communication）

- 通信相手の状態に関係なく，他のプロセスのデータをアクセスする通信方法
  - Get　　相手のプロセスのデータを獲得
  - Put　　相手のプロセスにデータを挿入

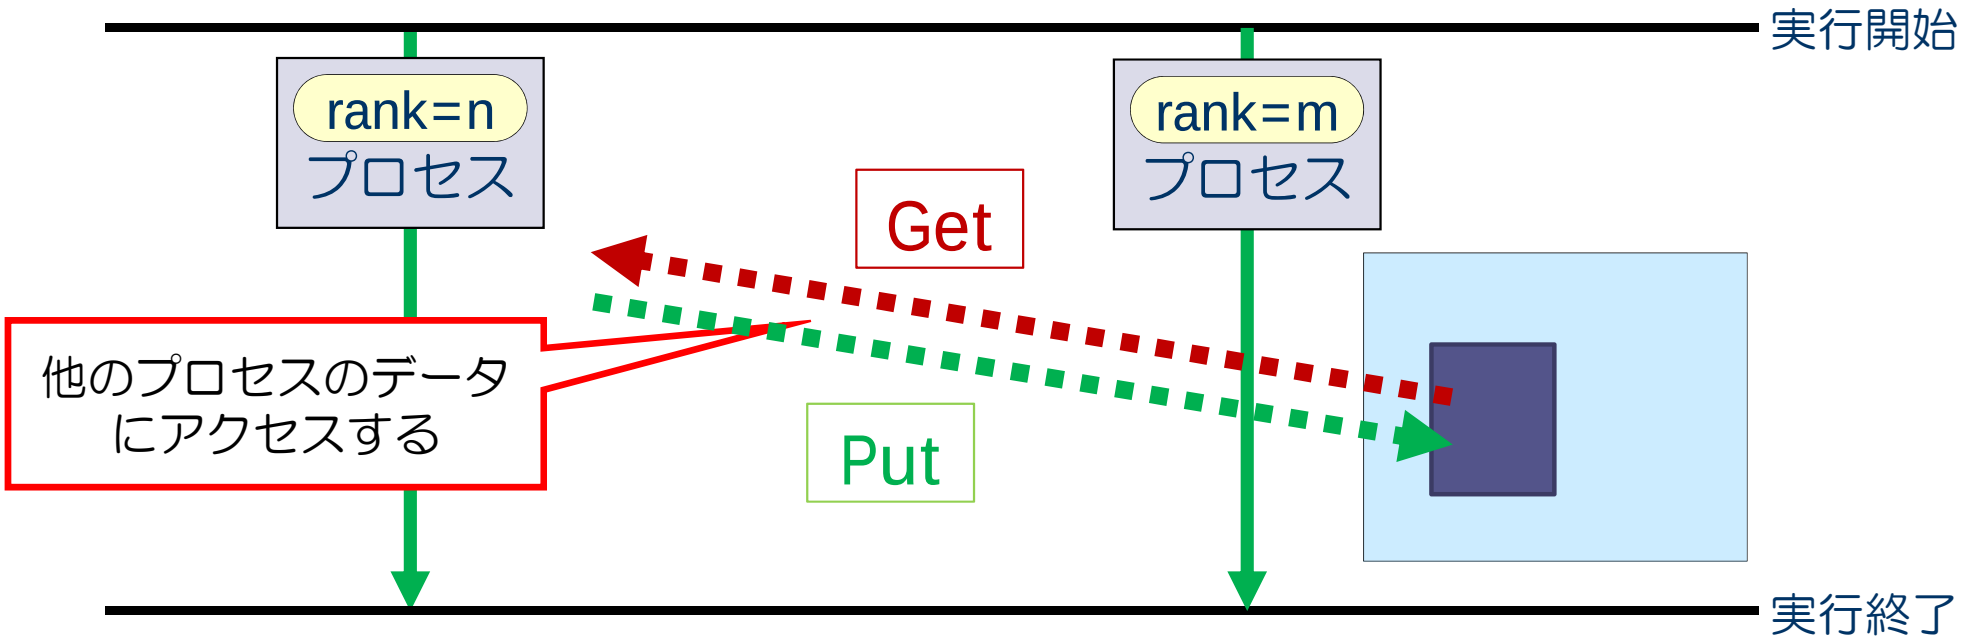

片方向通信の利点

- プロセス間の同期待ちを削減
  - 性能向上の可能性
- データコピーの回数を削減
  - 双方向通信は，データの中間バッファを用いた実装
- RDMA（Remote Direct Memory Access）機構を持つシステムでは，高速実行が可能となる.
  - 計算とデータ通信のオーバーラップ
- 大きなデータ通信において高速実行される場合がある.

Windowオブジェクトの生成

```
【F】mpi_win_create( base, size, disp_unit, info, comm, win, ierr )

【C】int MPI_Win_create(void *base, MPI_Aint size, int disp_unit,
                        MPI_INfo info, MPI_Comm comm, MPI_Win *win )
```

RMA操作に必要なWindowオブジェクトを生成する.

[Input]

- base: windowの先頭アドレス
- size: windowのサイズ（整数型，バイト単位で指定）
  - Fortranの場合，integer(kind=MPI_ADDRESS_KIND):: size とする.
- disp_unit: ずれ当りのサイズ（整数型，バイト単位で指定）
  - MPI_INTEGER，MPI_REALなどではない.
- info: 情報（整数型）
  - Cの場合，MPI_INFO_NULL
- comm: コミュニケータ（例えば，MPI_COMM_WORLD）

[Output]

- win: Windowオブジェクト（Fortranの場合，整数型）
  - MPI_getなどで利用
- ierr: 戻りコード（整数型）

Windowオブジェクトの開放

```
【F】mpi_win_free( win, ierr )

【C】int MPI_Win_free( MPI_Win *win )
```

生成したWindowオブジェクトを開放する.

[Input/Output]

- win:　　生成したwindowオブジェクト

[Output]

- ierr:　　戻りコード（整数型）

リモートプロセスのデータの獲得

```
【F】mpi_get( oaddr, ocount, odatetype, target_rank, tdisp, tcount, tdatatype,
              win, ierr )

【C】int MPI_Get( void *oaddr, int ocount, MPI_Datatype odatatype,
                  int target_rank, MPI_Aint target_disp, int tcount,
                  MPI_Datatype tdatatype, MPI_Win win)
```

[Input/Output]

- oaddr: 自分のプロセスの，データを格納する変数の先頭アドレス
- ocount: データの個数（整数型）
- odatatype: データの型（整数型）
- target_rank: リモートプロセスのMPIランク番号
- tdisp: 先頭からのずれ（整数型）
  - 獲得する変数の先頭アドレスは，base ＋ tdisp×disp_unit
  - Fortranの場合，integer(kind=MPI_ADDRESS_KIND):: tdisp と宣言する．
- tcount: ターゲット側のデータの個数（整数型）
- tdatatype: ターゲット側のデータの型（整数型）
- win: 通信するwindowオブジェクト

[Output]

- ierr: 戻りコード（整数型）

リモートプロセスへのデータの書込み

```
【F】mpi_put( oaddr, ocount, odatetype, target_rank, tdisp, tcount, tdatatype,
              win, ierr )

【C】int MPI_Put( const void *oaddr, int ocount, MPI_Datatype odatatype,
                  int target_rank, MPI_Aint target_disp, int tcount,
                  MPI_Datatype tdatatype, MPI_Win win)
```

[Input/Output]

- oaddr: 自分のプロセスの，書き込むデータの先頭アドレス
- ocount: データの個数（整数型）
- odatatype: データの型（整数型）
- target_rank: リモートプロセスのMPIランク番号
- tdisp: 先頭からのずれ（整数型）
  - 獲得する変数の先頭アドレスは，base ＋ tdisp×disp_unit
  - Fortranの場合，integer(kind=MPI_ADDRESS_KIND):: tdisp と宣言する．
- tcount: ターゲット側のデータの個数（整数型）
- tdatatype: ターゲット側のデータの型（整数型）
- win: 通信するwindowオブジェクト

[Output]

- ierr: 戻りコード（整数型）

片方向通信関数の引数の意味

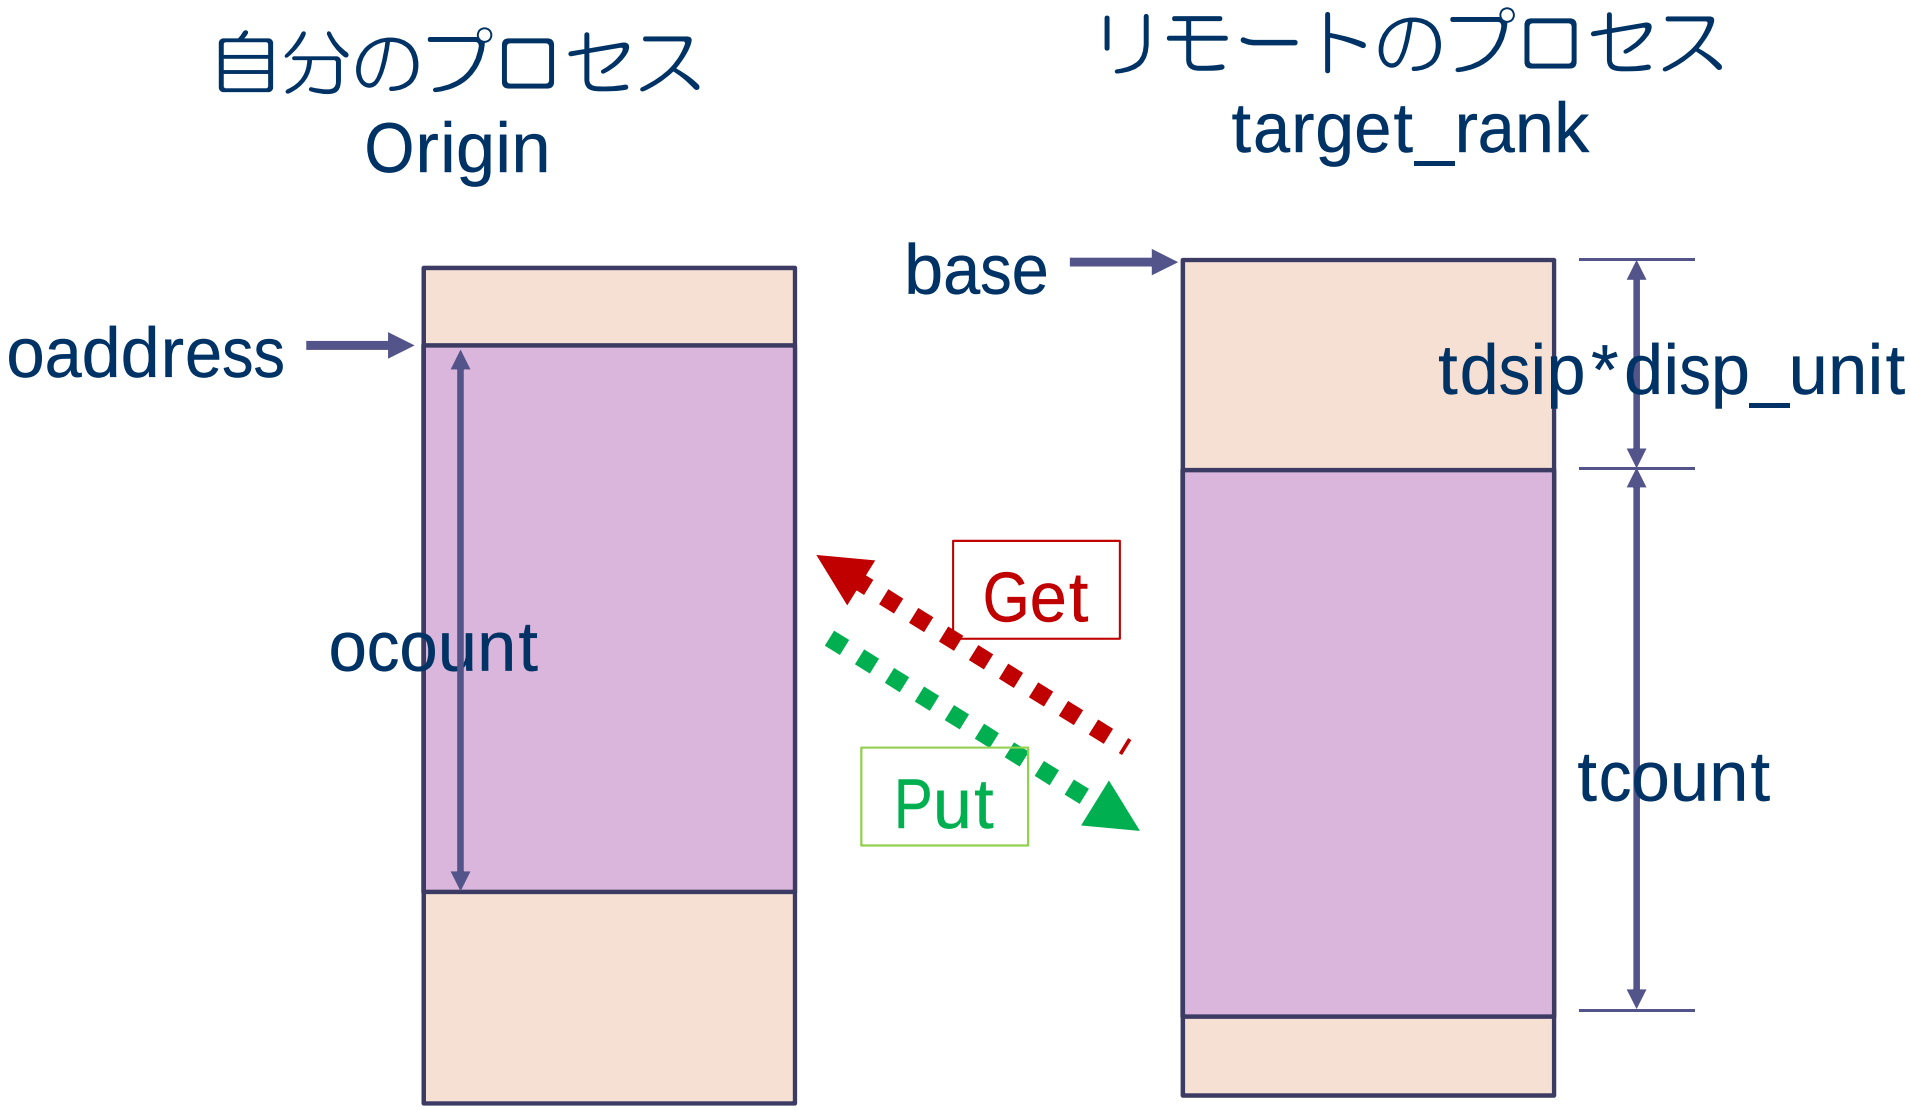

片方向通信の同期

```
【F】mpi_win_fence( assert, win, ierr )

【C】int MPI_Win_fence( int assert, MPI_Win win )
```

winオブジェクトの片方向通信関数の同期を取る．fence関数の前に片方向通信が終了している．

[Input/Output]

- assert: Windowの状態の確認用．
  通常は 0でよい．MPI_MODE_NOPRECEDEなど
- win: windowオブジェクト

[Output]

- ierr: 戻りコード（整数型）

問題：次のプログラムを作れ

- 2つのMPIプロセスにおいて，
  - step 1: 長さ 2nの配列を用意する．どんな型でも良い．
  - step 2: 最初の状態として，プロセス0では配列に1を代入．プロセス1では配列に2を代入．
  - step 3: プロセス0の配列の前半部分（長さn）をプロセス1の配列の後半（長さn）にコピーし，プロセス1の配列の前半部分（長さn）をプロセス0の配列の後半（長さn）にコピーする．

- この作業について，send-recvの組合せと，put-getの組合せの2つのプログラムを作り，結果を確認する．

- n=10くらいでやると出力で確認できる．

プログラムの処理イメージ

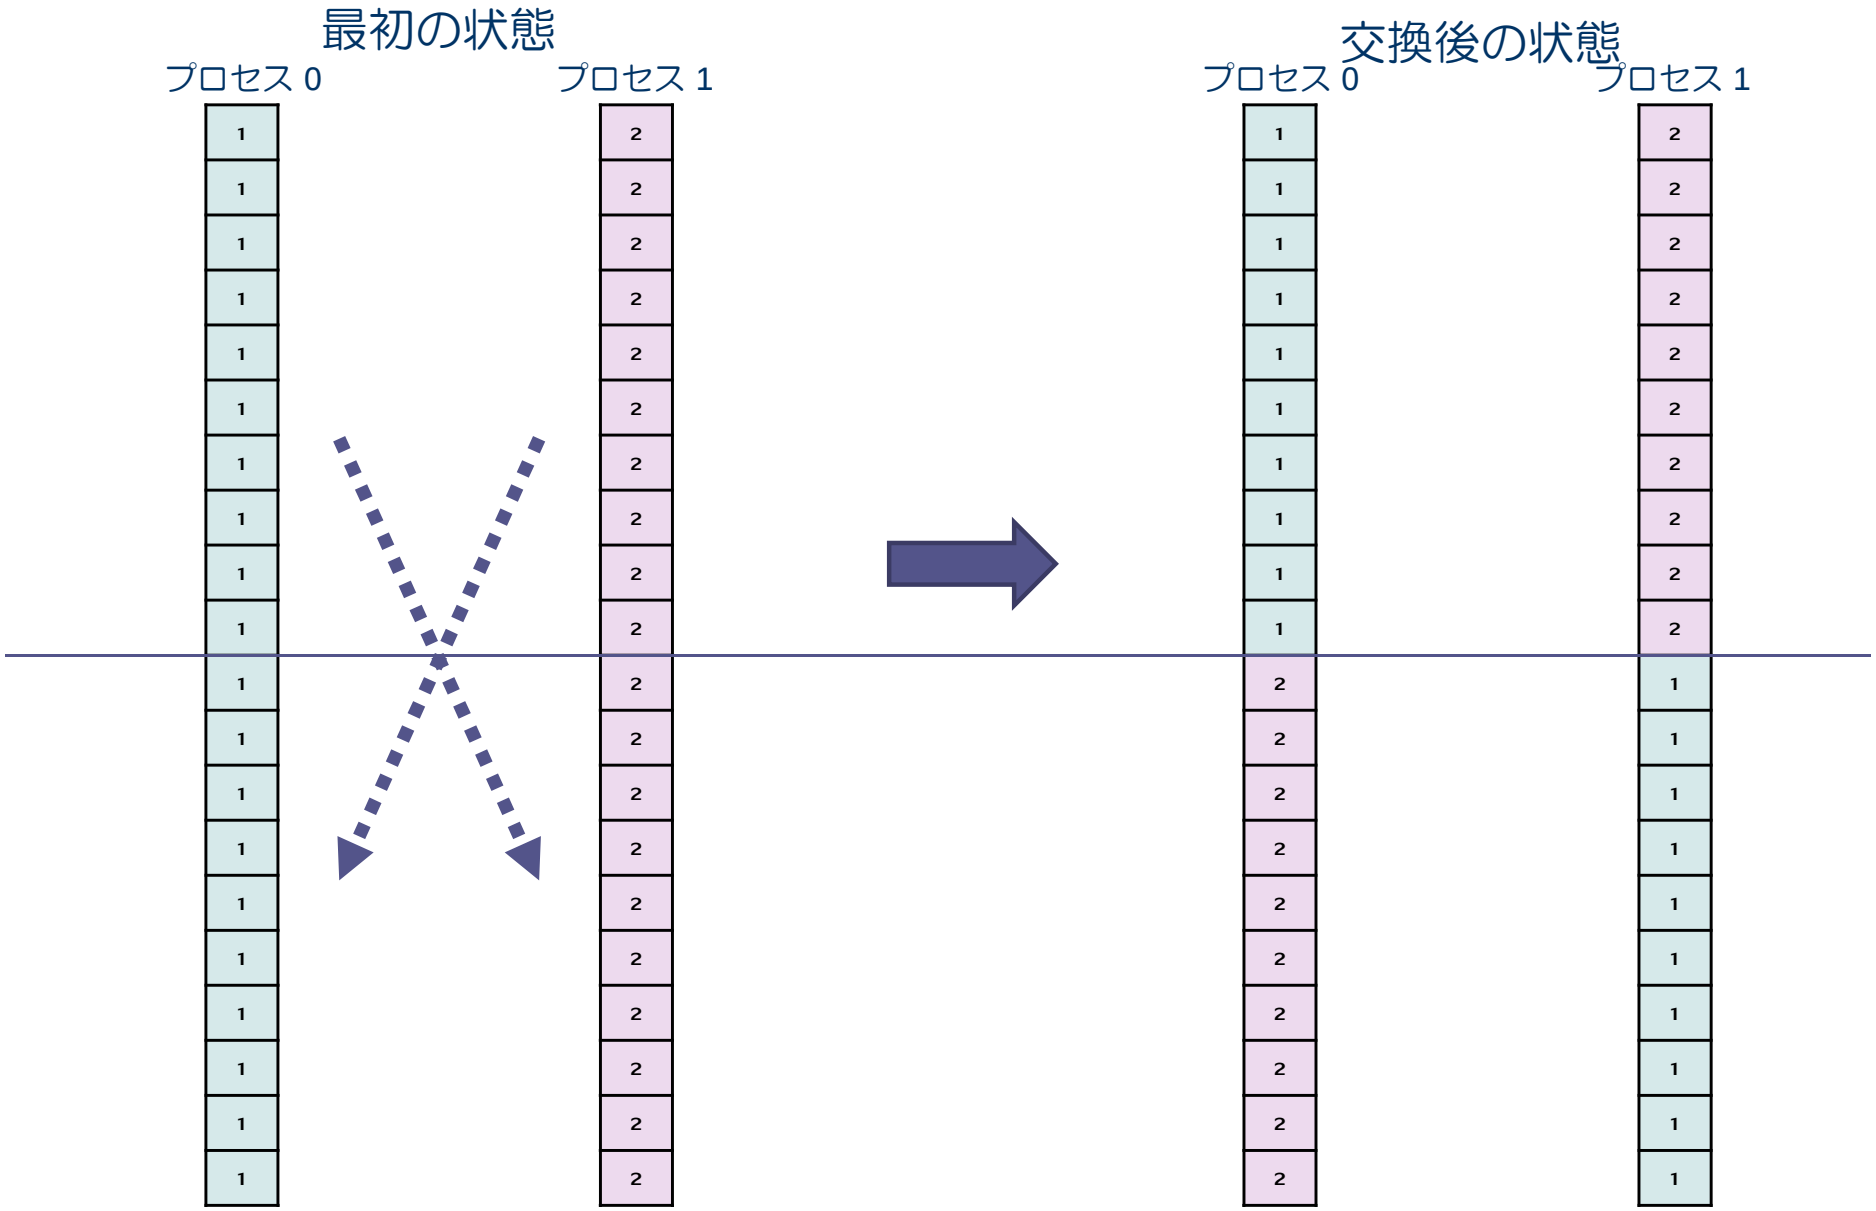

プログラム・スケルトン

send-recv

```
# ヘッダ

# mpiの初期化

# 配列を準備




if( myrank == 0 ) then

   rank = 0 の処理（sendして，recvする）

else

   rank = 1 の処理（recvして，sendする）

endif



# 結果の確認

# MPIの終了
```

put-get

```
# ヘッダ

# mpiの初期化

# 配列を準備

# put，get用のWindowをセット

# プロセス0側だけから操作

if( myrank == 0 ) then

     プロセス0の配列の前半部分を，プロセス1の配
     列の後半部分に書き込む

     プロセス1の配列の前半部分をもらい，プロセ
     ス0の配列の後半部分に書き込む

endif

# put，getの同期待ち．MPI_Win_fence

# 結果の確認

# MPIの終了
```

Skeltonのディレクトリ，ファイル

- Fortranの場合
  - /tmp/OneSided-Skelton/F_Skelton
    - exchg-sr-skelton.f90
    - exchg-pg-skelton.f90
    - job.sh
- Cの場合
  - /tmp/OneSided-Skelton/C_Skelton
    - exchg-sr-skelton.c
    - exchg-pg-skelton.c
    - job.sh

プログラム・スケルトン

send-recv

```
# ヘッダ
# mpiの初期化
# 配列を準備



if( myrank == 0 ) then
   rank = 0 の処理（sendして，recvする）
else
   rank = 1 の処理（recvして，sendする）
endif


# 結果の確認
# MPIの終了
```

put-get

```
# ヘッダ
# mpiの初期化
# 配列を準備
# put，get用のWindowをセット
# プロセス0側だけから操作
if( myrank == 0 ) then
     プロセス0の配列の前半部分を，プロセス1の配列の後半部分に書き込む
     プロセス1の配列の前半部分をもらい，プロセス0の配列の後半部分に書き込む
endif
# put，getの同期待ち．MPI_Win_fence
# 結果の確認
# MPIの終了
```

```
>$ mpifrtpx -Kfast hello.f
>$ mpifccpx -Kfast hello.c
```

Fortran

```
$> mpifrtpx -Kfast hello.f
```

"mpifrtpx" :
Fortran90＋MPIによってプログラムをコンパイルする際に
必要なコンパイラ，ライブラリ等がバインドされているコマンド

C言語

```
$> mpifccpx -Kfast hello.c
```

"mpifccpx" :
C＋MPIによってプログラムをコンパイルする際に
必要な，コンパイラ，ライブラリ等がバインドされているコマンド

- スケジューラへの指令 ＋ シェルスクリプト

```
#!/bin/sh
#PJM -L "node=1"                ノード数
#PJM -L "elapse=00:00:10"       実行時間
#PJM -L "rscgrp=small"          実行キュー名
#PJM -j
#PJM --mpi "proc=2"             MPIプロセス数

mpiexec ./a.out                 実行ファイル名
```

参考：C言語のsend, receive

【復習】 1対1通信 – 送信関数（送り出し側）

```
mpi_send( buff, count, datatype, dest, tag, comm, ierr )
```

- buff:　　送信するデータの変数名（先頭アドレス）
- count:　　送信するデータの数（整数型）
- datatype:　送信するデータの型
  - MPI_INTEGER, MPI_DOUBLE_PRECISION, MPI_CHARACTER など
- dest:　　送信先のプロセス番号
- tag:　　メッセージ識別番号．送るデータを区別するための番号
- comm:　　コミュニケータ（例えば，MPI_COMM_WORLD）
- ierr:　　戻りコード（整数型）

【復習】 1対1通信 – 受信関数（受け取り側）

```
mpi_recv( buff, count, datatype, source, tag, comm, status, ierr )
```

- buff: 受信するデータのための変数名（先頭アドレス）
- count: 受信するデータの数（整数型）
- datatype: 受信するデータの型
  - MPI_INTEGER, MPI_DOUBLE_PRECISION, MPI_CHARACTER など
- source: 送信してくる相手のプロセス番号
- tag: メッセージ識別番号．送られて来たデータを区別するための番号
- comm: コミュニケータ（例えば，MPI_COMM_WORLD）
- status: 受信の状態を格納するサイズMPI_STATUS_SIZEの配列（整数型）
- ierr: 戻りコード（整数型）