

# KOBE HPC サマースクール 2018 (初級)

## 9. 1対1通信関数, 集団通信関数

# MPIプログラム（M-2）：1対1通信関数

## 【問題】

1から100までの整数の和を2並列で求めなさい。

- プログラムの方針
  - ◆ プロセス0： 1から50までの和を求める。
  - ◆ プロセス1： 51から100までの和を求める。
  - ◆ プロセス1の結果をプロセス0に転送
  - ◆ プロセス0で、自分の結果と転送された結果を足して出力する。

# MPIプログラム M-2 (sum.c)

```
#include <stdio.h>
#include <mpi.h>
int main( int argc, char **argv )
{
    int start, end, i, sum_local, sum_recv;
    int nprocs, myrank, tag;
    MPI_Status status;

    MPI_Init( &argc, &argv );
    MPI_Comm_size( MPI_COMM_WORLD, &nprocs );
    MPI_Comm_rank( MPI_COMM_WORLD, &myrank );
    tag = 100;
    start = myrank *50 + 1;
    end   = (myrank+1)*50;
    sum_local = 0;
    for( i=start; i<=end; i++ ) {
        sum_local = sum_local + i ;
    }

    if( myrank == 1 ) {
        MPI_Send( &sum_local, 1, MPI_INT, 0, tag, MPI_COMM_WORLD ) ;
    } else {
        MPI_Recv( &sum_recv, 1, MPI_INT, 1, tag, MPI_COMM_WORLD, &status ) ;
    };
    if( myrank == 0 ) printf("Sum = %d\n", sum_local+sum_recv ) ;

    MPI_Finalize();
    return 0 ;
}
```

# MPIプログラム M-2 (sum.c)

```
#include <stdio.h>
#include <mpi.h>
int main( int argc, char **argv )
{
    int start, end, i, sum_local, sum_recv;
    int nprocs, myrank, tag;
    MPI_Status status;

    MPI_Init( &argc, &argv );
    MPI_Comm_size( MPI_COMM_WORLD, &nprocs );
    MPI_Comm_rank( MPI_COMM_WORLD, &myrank );
    tag = 100;
    start = myrank *50 + 1;
    end   = (myrank+1)*50;
    sum_local = 0;
    for( i=start; i<=end; i++ ) {
        sum_local = sum_local + i ;
    }

    if( myrank == 1) {
        MPI_Send( &sum_local, 1, MPI_INT, 0, tag, MPI_COMM_WORLD ) ;
    } else {
        MPI_Recv( &sum_recv, 1, MPI_INT, 1, tag, MPI_COMM_WORLD, &status ) ;
    }
    if( myrank == 0 ) printf("Sum = %d\n", sum_local+sum_recv ) ;

    MPI_Finalize();
    return 0 ;
}
```

- 青 : MPIプログラムのおまじない（既出）
- 緑 : プロセス番号（ランク）に応じた処理
- 赤 : MPI関数によるプロセス間通信

ランクの値から自分の計算範囲を求める

各プロセスが部分和を計算

プロセス1はプロセス0に自分の部分和を送信

プロセス0はプロセス1から部分和を受信（変数名が違うことに注意）

プロセス0 (rank 0) が、総和を出力

# 1対1通信 – 送信関数 MPI\_Send (送り出し側)

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

- ◆ buff: 送信するデータの変数名 (先頭アドレス)
  - ◆ count: 送信するデータの個数
  - ◆ datatype: 送信するデータの型
    - MPI\_CHAR, MPI\_INT, MPI\_DOUBLE など
  - ◆ dest: 送信先のMPIプロセス番号 (destination)
  - ◆ 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)
- ※ 関数の戻りコードは、エラーコード

# 1対1通信 – 受信関数 MPI\_Recv (受け取り側)

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

- ◆ buff: 送信するデータの変数名（先頭アドレス）
  - ◆ count: 送信するデータの個数
  - ◆ datatype: 送信するデータの型
    - MPI\_INT, MPI\_DOUBLE, MPI\_CHAR など
  - ◆ source: 送信先のMPI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）
  - ◆ status: 状況オブジェクト. **MPI\_Send**には、この引数は無いので注意.
- ※ 関数の戻りコードは、エラーコード

# 関数の引数に関する注意（共通）

## ■ buff

- ◆ 送信するデータは領域は、**メモリ上で連續アドレス**でなければならぬ。
  - “先頭アドレスから××バイトを送れ”という関数なので。
- ◆ 他の通信関数でも同じ。
- ◆ したがって、メモリ上で離れたところにある複数の変数を、1回の通信で同時に送りたい場合は、他の変数に連續してパック（pack）させてから、送る必要がある。

## ■ datatype : 予約語（決まっている）

- ◆ MPI\_INT（整数型）, MPI\_DOUBLE（倍精度実数型）, MPI\_CHAR（文字型）などが使用できる。
- ◆ バイト数を計算するために必要

## ■ tag

- ◆ 同じプロセスに対し、複数回メッセージを送るとき、メッセージを受取ったプロセスが、どのメッセージかを区別するために使用する。
- ◆ 受取側の MPI\_Recv では、メッセージに対応したtagで受け取らなければならない。
- ◆ 複数回のメッセージでも、送受信の順番などを区別できる場合は、同じtagでも良い。

# 演習9-1 1から100までの和を2並列で求めるプログラムの実行

- 1から100までの整数の和を2並列で求めるプログラム(`sum.c`)を2プロセスで実行し、結果を確認せよ。

## 【手順】

- ① `/tmp/Summer/M-2/sum.c` を適切なディレクトリにコピーする
- ② `/tmp/Summer/M-2/go.sh` をコピーして、ジョブを実行。
- ③ 結果 (`sum.onnnnnnn`) を確認する。
  - 正しい答え ( $\text{Sum} = 5050$ ) が出力されているか？
    - ☞ プロセス0 (rank 0) だけが出力していることに注意。

# 演習9-2（発展）

- 1から100までの整数の和を求めるプログラムを、4並列で実行できるよう修正し、4プロセスで実行せよ。
  - ◆ プロセス0が結果を出力する。
  - ◆ MPI\_Send, MPI\_Recv関数だけを使うこと。
- プログラム改良のヒント
  - ◆ 各プロセスの部分和を計算する範囲を、myrankをうまく使って求める。myrankは、0から3の整数である。



- ◆ myrank ≠ 0 以外のプロセスから、プロセス0 (myrank=0) に部分和を送信する。
- ◆ プロセス0 (myrank=0) は、他の3つのプロセスから送られた部分和を受信 (forループ) し、受信するごとに受信したデータを加え、全体の和を計算する。

# 集団通信関数

- 1対1通信関数の煩雑な点
  - ◆ プロセス数が多くなると、1対1通信関数を用いたプログラムは複雑
  - ◆ 煩雑になるとバグが入りやすい。
- もっと簡単な方法はないのか？ → **集団通信関数**
  - ◆ **MPI\_Bcast**
    - あるプロセスから、すべてのプロセスに値を一斉に配る関数
  - ◆ **MPI\_Reduce**
    - すべてのプロセスから、あるプロセス（例えば rank 0）に値を集め、何らかの演算 (+, ×, max, minなど) を適用する関数

# MPIプログラム sum\_reduction（集団通信関数を使う）

```
include <stdio.h>
#include <mpi.h>

int main( int argc, char **argv )
{
    int start, end, i, sum_local, sum, n ;
    int nprocs, myrank ;
    MPI_Status status;

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

    if( myrank == 0 ) n = 100 ;
    MPI_Bcast( &n, 1, MPI_INT, 0, MPI_COMM_WORLD );

    start = myrank * (n/nprocs) + 1;
    end   = (myrank+1)*(n/nprocs) ;
    sum_local = 0;
    for( i=start; i<=end; i++ ) {
        sum_local += i ;
    }

    sum = 0 ;
    MPI_Reduce( &sum_local, &sum, 1, MPI_INT, MPI_SUM, 0, MPI_COMM_WORLD );

    if( myrank == 0 ) printf("Sum = %d\n", sum ) ;

    MPI_Finalize();
    return 0 ;
}
```

# MPIプログラム sum\_reduction（集団通信関数を使う）

```
include <stdio.h>
#include <mpi.h>

int main( int argc, char **argv )
{
    int start, end, i, sum_local, sum, n ;
    int nprocs, myrank ;
    MPI_Status status;

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

    if( myrank == 0 ) n = 100 ;
    MPI_Bcast( &n, 1, MPI_INT, 0, MPI_COMM_WORLD );

    start = myrank * (n/nprocs) + 1;
    end   = (myrank+1)*(n/nprocs) ;
    sum_local = 0;
    for( i=start; i<=end; i++ ) {
        sum_local += i ;
    }

    sum = 0 ;
    MPI_Reduce( &sum_local, &sum, 1, MPI_INT, MPI_SUM, 0, MPI_COMM_WORLD );

    if( myrank == 0 ) printf("Sum = %d\n", sum ) ;

    MPI_Finalize();
    return 0 ;
}
```

- 青：MPIプログラムのおまじない（既出）
- 緑：プロセス番号（ランク）に応じた処理
- 赤：MPI関数によるプロセス間通信

プロセス0が nの値をセットする

nの値を全プロセスに放送

ランクの値から自分の計算範囲を求める

各プロセスが  
部分和を計算

部分和の総和を計算  
(プロセス0に集める)

プロセス0だけが結果を出力

# 集団通信 — broadcast

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

※ rootが持つbuffの値を、 commで指定された他のプロセスのbuffに配布する。

- ◆ buff: 送り主 (root) が送信するデータの変数名 (先頭アドレス)  
他のMPIプロセスは、同じ変数名でデータを受け取る。
- ◆ count: データの個数
- ◆ datatype: 送信するデータの型
  - MPI\_INT, MPI\_DOUBLE, MPI\_CHAR など
- ◆ root: 送り主のMPIプロセス番号
- ◆ comm: コミュニケータ (例えば, MPI\_COMM\_WORLD)

※ 関数の戻りコードは、エラーコードを表す。

# 集団通信 – reduction

```
int MPI_Reduce(void *sendbuff, void *recvbuff, int count,
               MPI_Datatype datatype, MPI_Op op, int root, MPI_Comm comm)
```

※ commで指定されたすべてのプロセスからデータをrootが集め、演算（op）を適用する。

- ◆ sendbuff: 送信するデータの変数名（先頭アドレス）
- ◆ recvbuff: 受信するデータの変数名（先頭アドレス）
- ◆ count: データの個数
- ◆ datatype: 送信するデータの型
  - MPI\_INT, MPI\_DOUBLE, MPI\_CHAR など
- ◆ op: 集まってきたデータに適用する演算の種類
  - MPI\_SUM (総和), MPI\_PROD (掛け算), MPI\_MAX (最大値) など
- ◆ root: データを集めるMPIプロセス番号
- ◆ comm: コミュニケータ（例えば, MPI\_COMM\_WORLD）

※ 関数の戻りコードは、エラーコードを表す。

# リダクション演算とは

## ■ リダクション演算

- ◆ 加算, 乗算, 最大値のように, 複数のデータを入力として1個の出力データを求める演算

## ■ MPIで使えるリダクション演算

- ◆ MPI\_SUM (和) , MPI\_PROD (積) ,
  - ◆ MPI\_MAX (最大値) , MPI\_MIN (最小値)
- ※他にも論理和などがある

## ■ ベクトルに対するリダクション演算も可能

- ◆ ベクトルの各要素に対してリダクション演算を行い, その結果を要素とするベクトルを生成
- ◆  $m$  個のベクトル  $x_1, x_2, x_3, \dots, x_m$  をそれぞれ長さ  $n$  のベクトルとするとき, それらの和  $x = x_1 + x_2 + x_3 + \dots + x_m$  を求める計算
- ◆ 引数 count には, ベクトルの長さ  $n$  を指定すればよい.

# 演習9-3 集団通信関数を使ったプログラムの実行

- プログラム `sum_reduction.c` を, 2 MPIプロセス, 4 MPIプロセスで実行し, 結果を確認せよ.

## 【手順】

- ① `/tmp/Summer/M-2/sum_reduction.c` を適切なディレクトリにコピーする
- ② `go.sh` を修正して, ジョブを実行.
- ③ 結果 (`sum.onnnnnnn`) を確認する.
  - 出力に正しい答え (Sum = 5050) が出力されているか?

# 演習9-4（発展1）

- プロセス毎に部分和を出力した後、すべてのプロセスで総和を計算し、プロセス毎に総和結果を出力をせよ。
  - ◆ それぞれのプロセスが出力する総和が同じであることを確認する）。
  - ◆ 出力のイメージ
    - Rank: n -> Local sum = xxxx
    - Rank: n -> Total sum = xxxx
- プログラム改良のヒント
  - ◆ MPI\_Reduce, MPI\_Bcast を順に使う。
  - ◆ 各プロセスで、printf で出力させる。

```
printf("Rank: %d -> Local sum = %d", myrank, local_sum);
```
- 同じ処理をする関数 **MPI\_Allreduce** がある。

# 集団通信 — MPI\_Allreduce

```
int MPI_Allreduce( void *sendbuff, void *recvbuff, int count,
                   MPI_Datatype datatype, MPI_Op op, MPI_Comm comm )
```

※ MPI\_ReduceとMPI\_Bcastを同時に使える関数。すべてのプロセスで同じ結果（総和など）が得られる。

- ◆ sendbuff: 送信するデータの変数名（先頭アドレス）
- ◆ recvbuff: 受信するデータの変数名（先頭アドレス）
- ◆ count: データの個数
- ◆ datatype: 送信するデータの型
  - MPI\_INT, MPI\_DOUBLE, MPI\_CHAR など
- ◆ op: 集まってきたデータに適用する演算の種類
  - MPI\_SUM（総和）, MPI\_PROD（掛け算）, MPI\_MAX（最大値）など
- ◆ comm: コミュニケータ（例えば, MPI\_COMM\_WORLD）

※ 関数の戻りコードは、エラーコードを表す。

## 演習9-5（発展2）

- MPI\_Reduce, MPI\_Bcast の組を MPI\_Allreduce で書き換えよ。
  - ◆ 出力のイメージは、書き換え前と同じ。  
Rank: n -> Local sum = xxxx  
Rank: n -> Total sum = xxxx
- プログラム改良のヒント
  - ◆ MPI\_Allreduceの引数である sendbuff, recvbuff をうまく指定する。

# 参考：Fortran版

# MPIプログラム (sum.f90)

```
program sum100_by_mpi
use mpi
implicit none
integer :: i, istart, iend, isum_local, isum_tmp
integer :: nprocs, myrank, ierr
integer :: istat(MPI_STATUS_SIZE)
call mpi_init( ierr )
call mpi_comm_size( MPI_COMM_WORLD, nprocs, ierr )
call mpi_comm_rank( MPI_COMM_WORLD, myrank, ierr )
istart = myrank*50 + 1
iend   = (myrank+1)*50
isum_local = 0
do i = istart, iend
    isum_local = isum_local + i
enddo
if( myrank == 1 ) then
    call mpi_send( isum_local, 1, MPI_INTEGER, 0, 100, MPI_COMM_WORLD, ierr )
else
    call mpi_recv( isum_tmp, 1, MPI_INTEGER, 1, 100, MPI_COMM_WORLD, istat, ierr )
end if
if( myrank == 0 ) print *, 'sum =', isum_local+isum_tmp
call mpi_finalize( ierr )
end program sum100_by_mpi
```

# MPIプログラム (sum.f90) の説明

```
program sum100_by_mpi
use mpi
implicit none
integer :: i, istart, iend, isum_local, isum_tmp
integer :: nprocs, myrank, ierr
integer :: istat(MPI_STATUS_SIZE)
call mpi_init( ierr )
call mpi_comm_size( MPI_COMM_WORLD, nprocs, ierr )
call mpi_comm_rank( MPI_COMM_WORLD, myrank, ierr )
istart = myrank*50 + 1
iend   = (myrank+1)*50
isum_local = 0
do i = istart, iend
  isum_local = isum_local + i
enddo
if( myrank == 1 ) then
  call mpi_send( isum_local, 1, MPI_INTEGER, 0, 100, MPI_COMM_WORLD, ierr )
else
  call mpi_recv( isum_tmp, 1, MPI_INTEGER, 1, 100, MPI_COMM_WORLD, istat, ierr )
end if
if( myrank == 0 ) print *, 'sum =', isum_local+isum_tmp
call mpi_finalize( ierr )
end program sum100_by_mpi
```

- 青 : MPIプログラムのおまじない（既出）
- 緑 : プロセス番号（ランク）に応じた処理
- 赤 : MPI関数によるプロセス間通信

ランクの値から自分の計算範囲を求める

各プロセスが  
部分和を計算

プロセス1はプロセス0に自分  
の部分和を送信

プロセス0はプロセス1から部  
分和を受信（変数名が違うこ  
とに注意）

# 1対1通信 – 送信関数 mpi\_send (送り出し側)

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

※ ランク番号destのプロセスに、変数buffの値を送信する。

- ◆ 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\_REAL, MPI\_DOUBLE\_PRECISIONなど
- ◆ dest: 送信先プロセスのランク番号
- ◆ 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）

# 1対1通信 – 受信関数 mpi\_recv (受け取り側)

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

※ ランク番号sourceのプロセスから送られたデータを、変数buffに格納する。

- ◆ **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\_REAL, MPI\_DOUBLE\_PRECISIONなど
- ◆ **source:** 送信してくる相手プロセスのランク番号
- ◆ **tag:** メッセージ識別番号。送られてき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）

# MPIプログラム sum\_reduction.f90

```
program sum_by_reduction
use mpi
implicit none
integer :: n, i, istart, iend, isum_local, isum
integer :: nprocs, myrank, ierr

call mpi_init( ierr )
call mpi_comm_size( MPI_COMM_WORLD, nprocs, ierr )
call mpi_comm_rank( MPI_COMM_WORLD, myrank, ierr )
if( myrank==0)  n=10000
call mpi_bcast( n, 1, MPI_INTEGER, 0, MPI_COMM_WORLD, ierr )
istart = (n/nprocs)*myrank + 1
iend   = (n/nprocs)*(myrank+1)
isum_local = 0
do i = istart, iend
    isum_local = isum_local + i
enddo
call mpi_reduce( isum_local, isum, 1, MPI_INTEGER, MPI_SUM, 0, &
                 MPI_COMM_WORLD, ierr )
if( myrank == 0 ) print *, 'sum (by reduction function) =', isum

call mpi_finalize( ierr )
end program sum_by_reduction
```

- 青 : MPIプログラムのおまじない（既出）
- 緑 : プロセス番号（ランク）に応じた処理
- 赤 : MPI関数によるプロセス間通信

プロセス0がnの値をセットする

nの値を放送

ランクの値から自分の計算範囲を求める

各プロセスが  
部分和を計算

部分和の総和を計算  
(プロセス0に集める)

プロセス0だけが結果を出力

# 集団通信 – broadcast

```
mpi_bcast( buff, count, datatype, root, comm, ierr )
```

※ ランク番号rootのプロセスが持つbuffの値を, commで指定された他のすべてのプロセスのbuffに配布する。

- ◆ buff: 送り主 (root) が送信するデータの変数名（先頭アドレス）  
他のMPIプロセスは、同じ変数名でデータを受け取る。
- ◆ count: データの個数（整数型）
- ◆ datatype: 送信するデータの型
  - MPI\_INTEGER, MPI\_REAL, MPI\_DOUBLE\_PRECISION , MPI\_REAL8など
- ◆ root: 送り主のMPIプロセス番号
- ◆ comm: コミュニケータ（例えば, MPI\_COMM\_WORLD）
- ◆ ierr: 戻りコード（整数型）

# 集団通信 – reduction

```
mpi_reduce( sendbuff, recvbuff, count, datatype, op, root, comm, ierr )
```

※ `comm`で指定されたすべてのプロセスからデータを、ランク番号 `root` のプロセスに集め、演算 (`op`) を適用した結果を`recvbuff`に設定する。

- ◆ `sendbuff`: 送信するデータの変数名（先頭アドレス）
- ◆ `recvbuff`: 受信するデータの変数名（先頭アドレス）
- ◆ `count`: データの個数（整数型）
- ◆ `datatype`: 送信するデータの型
  - `MPI_INTEGER`, `MPI_REAL`, `MPI_DOUBLE_PRECISION`, `MPI_REAL8`など
- ◆ `op`: 集まってきたデータに適用する演算の種類
  - `MPI_SUM`（総和）, `MPI_PROD`（掛け算）, `MPI_MAX`（最大値）など
- ◆ `root`: データを集めるMPIプロセス番号
- ◆ `comm`: コミュニケータ（例えば, `MPI_COMM_WORLD`）
- ◆ `ierr`: 戻りコード（整数型）

# 集団通信 – mpi\_allreduce()

```
mpi_allreduce( sendbuff, recvbuff, count, datatype, op, comm, ierr )
```

※ `mpi_reduce`と`mpi_bcast`を同時に使える関数。すべてのプロセスで同じ結果（総和など）が得られる。

- ◆ `sendbuff`: 送信するデータの変数名（先頭アドレス）
- ◆ `recvbuff`: 受信するデータの変数名（先頭アドレス）
- ◆ `count`: データの個数（整数型）
- ◆ `datatype`: 送信するデータの型
  - `MPI_INTEGER`, `MPI_REAL8`, `MPI_CHARACTER` など
- ◆ `op`: 集まってきたデータに適用する演算の種類
  - `MPI_SUM`（総和）, `MPI_PROD`（掛け算）, `MPI_MAX`（最大値）など
- ◆ `comm`: コミュニケータ（例えば, `MPI_COMM_WORLD`）
- ◆ `ierr`: 戻りコード（整数型）