

計算科学演習 I

MPIを用いた並列計算 (II)

神戸大学大学院システム情報学研究科
横川 三津夫
yokokawa@port.kobe-u.ac.jp

今週の講義の概要

1. 前回課題 (M1-3) の解説
2. 計算時間の計測
3. 集団通信 (mpi_allreduce関数)

演習M1-3 プログラム例

```
program sum100_by_mpi
use mpi
implicit none
integer :: i, istart, iend, isum_local, isum_tmp, isum, src
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*25 + 1
iend   = (myrank+1)*25
isum_local = 0
do i = istart, iend
    isum_local = isum_local + i
enddo
if( myrank /= 0 ) then
    call mpi_send( isum_local, 1, MPI_INTEGER, 0, 100, MPI_COMM_WORLD, ierr )
else
    isum = isum_local
    do src = 1, 3
        call mpi_recv( isum_tmp, 1, MPI_INTEGER, src, 100, MPI_COMM_WORLD, istat, ierr )
        isum = isum + isum_tmp
    end do
end if
if( myrank == 0 ) print *, 'sum =', isum
call mpi_finalize( ierr )
end program sum100_by_mpi
```

解答例

```
if( myrank == 1 ) then
  call mpi_send( isum_local, 1, MPI_INTEGER, 0, 100, MPI_COMM_WORLD, ierr )
end if

if( myrank == 2 ) then
  call mpi_send( isum_local, 1, MPI_INTEGER, 0, 200, MPI_COMM_WORLD, ierr )
end if

if( myrank == 3 ) then
  call mpi_send( isum_local, 1, MPI_INTEGER, 0, 300, MPI_COMM_WORLD, ierr )
end if

if( myrank == 0 ) then
  call mpi_recv( isum_tmp1, 1, MPI_INTEGER, 1, 100, MPI_COMM_WORLD, istat, ierr )
  call mpi_recv( isum_tmp2, 1, MPI_INTEGER, 2, 100, MPI_COMM_WORLD, istat, ierr )
  call mpi_recv( isum_tmp3, 1, MPI_INTEGER, 3, 100, MPI_COMM_WORLD, istat, ierr )
end if
```

実行時間の計測

- 並列計算の目的は、計算時間の短縮にある。
 - ◆ 大規模問題を解くためにメモリ容量を増やすことも目的の一つ
- 同じ結果が得られるが、アルゴリズムや書き方が異なったプログラムのうち、どれが一番良いか？
 - ◆ 一つの基準として、（正しい結果が得られるならば）計算時間の短いものが良い。
- 計算時間を計って比較する。

計算時間を計測する方法

```
real(DP) :: time0, time2
```

```
·  
·
```

```
call mpi_barrier( MPI_COMM_WORLD, ierr )  
time0 = mpi_wtime()
```

(計測する部分)

```
call mpi_barrier( MPI_COMM_WORLD, ierr )  
time1 = mpi_wtime()
```

(time1-time0 を出力する)

計測のための変数を倍精度実数型で宣言する。

MPI_barrier関数で、計測開始の足並みを揃える。
mpi_wtime関数で開始時刻をtime0に設定

全プロセスで終了の足並みを揃える。
mpi_wtime関数で終了時刻をtime1に設定

time1-time0が計測した部分の計算時間となる。

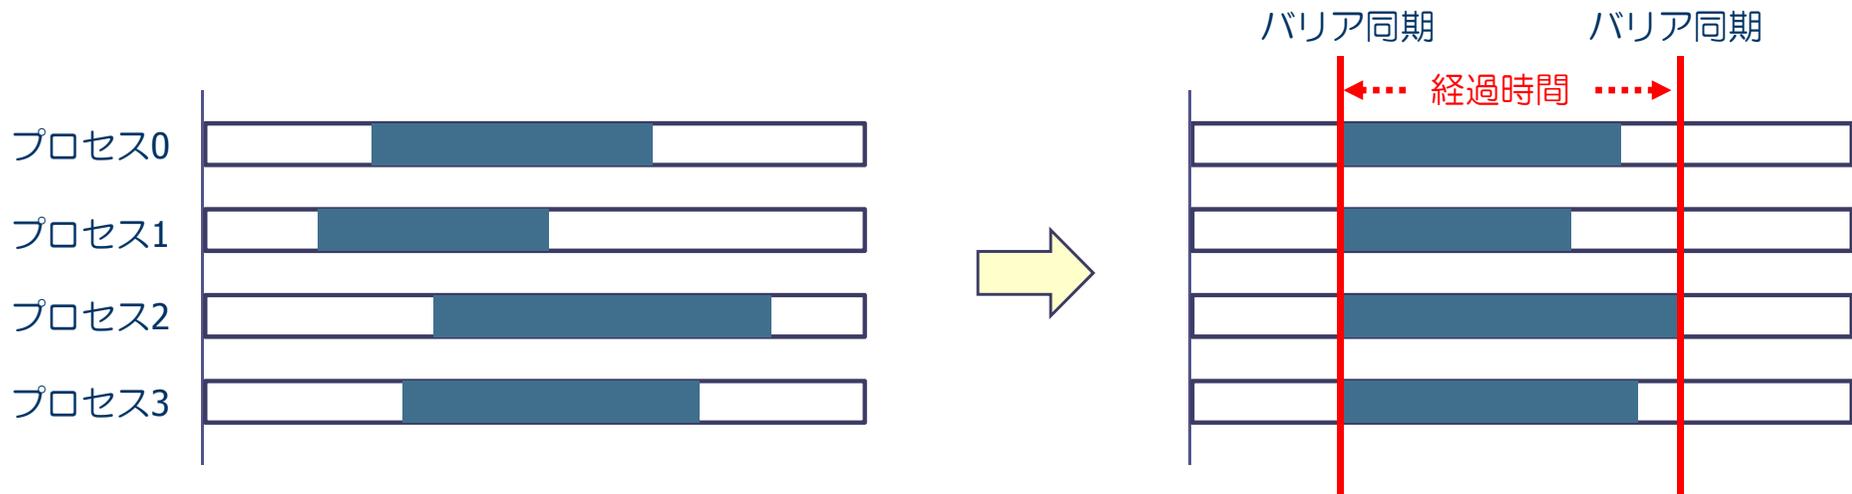
mpi_barrier(comm, ierr) : バリア同期関数

- ◆ comm: コミュニケータ (例えば, MPI_COMM_WORLD)
- ◆ ierr: 戻りコード (整数型)

var = mpi_wtime() : 倍精度実数を返す関数

時間計測のイメージ

- 各プロセスでの計算時間の測定関数
 - ◆ `mpi_wtime()`
 - ある時点を基準とした経過秒数を倍精度実数型で返す関数
- プログラムのある区間の計算時間の測定
 - ◆ プログラムの実行は各プロセスで独立なので、開始時間や終了時間が異なる。
 - ◆ ある部分の計算時間の計測では、**バリア同期** (MPI_barrier) により測定開始と測定終了の**足並みを揃えて**、計測する。



演習M2-1

- 演習M1-5で作成したプログラムM-4について、次の区間の計算時間をプロセス数を変えて計測せよ。
 - ◆ mpi_bcastの開始からmpi_reduceの終了までの時間
 - ◆ 計測した時間は、ランク0のプロセスに出力させる。
 - ◆ $n=10,000,000$ として、1, 2, 4, 8プロセスで実行し、それぞれ結果が正しいことを確かめる。
 - ◆ 計算時間を、gnuplotを使って図示せよ。
 - Xming, ssh forwarding を使う。
 - x軸をプロセス数, y軸を計算時間とする。
 - x軸, y軸とも対数スケールにする。 `$ set logscale xy`

※ /tmp/mpi2 /M-4/dsumn.f90 を参考にせよ。

集団通信（mpi_allreduce関数）

- mpi_reduce関数は、ひとつのプロセスに、すべてのプロセスの同じ変数のデータを集め、（足し算や掛け算などの）リダクション演算を行った結果を得る関数
- すべてのプロセスで、この結果を共有したいときは、どうすれば良いか？
- プログラム方針
 - ① mpi_reduce関数により、ひとつのプロセスで結果をもとめ、その結果を mpi_bcastで全プロセスに放送する。
 - ② mpi_allreduce関数を使う。

集団通信 — mpi_allreduce()

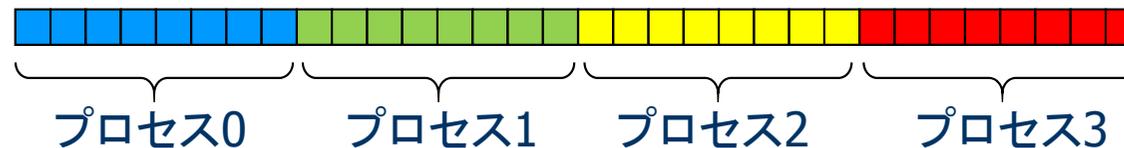
```
mpi_allreduce( sendbuff, recvbuff, count, datatype, op, comm, ierr )
```

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

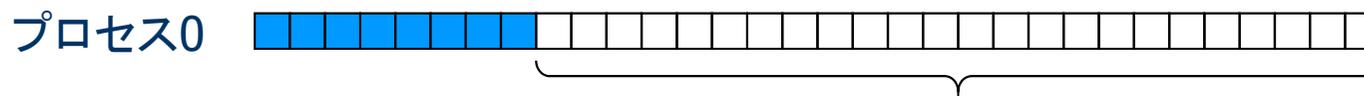
- ◆ sendbuff: 送信するデータの変数名（先頭アドレス）
- ◆ recvbuff: 受信するデータの変数名（先頭アドレス）
- ◆ count: データの個数（整数型）
- ◆ datatype: 送信するデータの型
 - MPI_INTEGER, MPI_REAL8, MPI_CHARACTER など
- ◆ op: 集まってきたデータに適用する演算の種類
 - MPI_SUM（総和）, MPI_PROD（掛け算）, MPI_MAX（最大値）など
- ◆ comm: コミュニケータ（例えば, MPI_COMM_WORLD）
- ◆ ierr: 戻りコード（整数型）

演習M2-2：ベクトルの正規化

- n 次元ベクトル x の第 i 要素を i とする ($x(i) = i$) .
- このとき, x を正規化したベクトル $x/\|x\|_2$ を求めるプログラムを作成せよ.
 - ◆ $\|x\|_2$ は x の各要素の2乗和の平方根である.
 - ◆ ベクトルは, ブロック分割で各プロセスに配置する.
- 各プロセスの担当する要素 ($nprocs$ はMPIプロセス数)
 - ◆ $istart = (n/nprocs)*myrank + 1$
 - ◆ $iend = (n/nprocs)*(myrank+1)$



- ベクトルの格納方法
 - ◆ 各プロセスは長さ n の配列を持ち, そのうち自分の担当部分のみを使う



プロセス0では, この部分が使われない

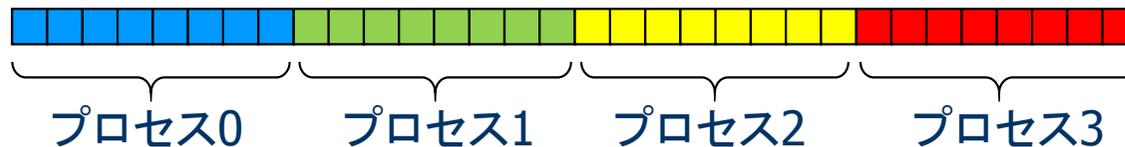
演習M2-2：ベクトルの正規化（方針）

- プログラムM-4をベースに修正する.
- まず、各プロセスが自分の担当分の要素について、2乗和を計算する.
- 全プロセスの総和を `mpi_allreduce`関数で求める.
- 各プロセスは `mpi_allreduce` の結果を用いて、自分の担当する要素について正規化を行う.
- $n=1000$ としてプロセス数を1, 2, 4, 8と変えて計算せよ.
- 正規化されたベクトルの要素は $\tilde{x}(i) = i/\sqrt{n(n+1)(2n+1)/6}$ であるので、これと比較をして、計算が正しくできていることを確かめよ.

データの分割方法

1. ブロック分割

- ◆ 全体のデータ（配列など）を，連続したアドレスの小部分に分割して，各プロセスに割り当てる方法



2. サイクリック分割

- ◆ 全体のデータを，要素1個ずつ，サイクリックに各プロセスに割り当てる方法



3. ブロックサイクリック分割

- ◆ 全体のデータを，複数の要素の塊にして，サイクリックに各プロセスに割り当てる方法

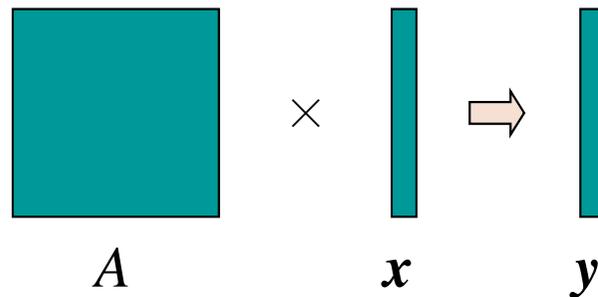


- 通信量，負荷分散などを考慮し，最適な分割を決める必要がある。

リダクション演算の応用：行列ベクトル積

■ 問題

- ◆ $n \times n$ 行列 A の第 (i, j) 要素を $i + j$ とする ($a_{i,j} = i + j$) .
- ◆ n 次元ベクトル x の第 i 要素を i とする ($x_i = i$) .
- ◆ このとき, $y = Ax$ を計算する.



■ プログラムのカーネル（主要な部分）

- ◆ ベクトル y の要素を1個ずつ計算する.
- ◆ y の第 i 要素は, A の第 i 行とベクトル x との内積

$$y_i = \sum_j a_{i,j} x_j$$

逐次プログラム M-5 (mv_s.f90)

```
program mv
implicit none
integer, parameter :: n=100
integer :: i, j
real(kind=8), dimension(n,n) :: a
real(kind=8), dimension(n) :: x, y
real(kind=8) :: error, ans
do i = 1, n
  x(i) = i
end do
do i = 1, n
  do j = 1, n
    a(i,j) = dble(i+j)
  end do
end do
do i = 1, n
  y(i) = 0.0d0
  do j = 1, n
    y(i) = y(i) + a(i,j)*x(j)
  end do
end do
error = 0.0d0
do i = 1, n
  ans = dble( i*n*(n+1)/2 + n*(n+1)*(2*n+1)/6)
  error = error + abs( y(i) - ans )
end do
print *, 'error =', error
end program mv
```

x(i), a(i,j) の初期設定

y=Axの計算

結果の確認

abs() は絶対値関数

演習M2-3 : M-5プログラムの実行

- mv_s.f90 をコンパイルして, 実行せよ

```
$ cp /tmp/mpi2/M-5/mv_s.f90 ./
$ f95 -o mv_s mv_s.f90
$ ./mv_s
```

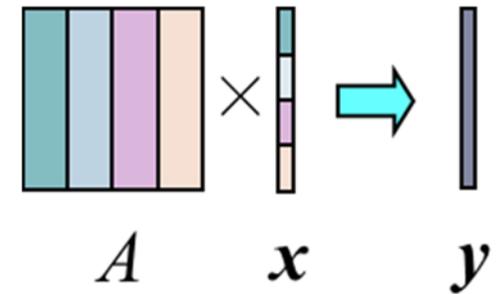
- 結果が正しいことを確認せよ.

```
$ ./mv_s
error = 0.000000000000000000
```

行列ベクトル積の並列化

■ 行列とベクトルの分割

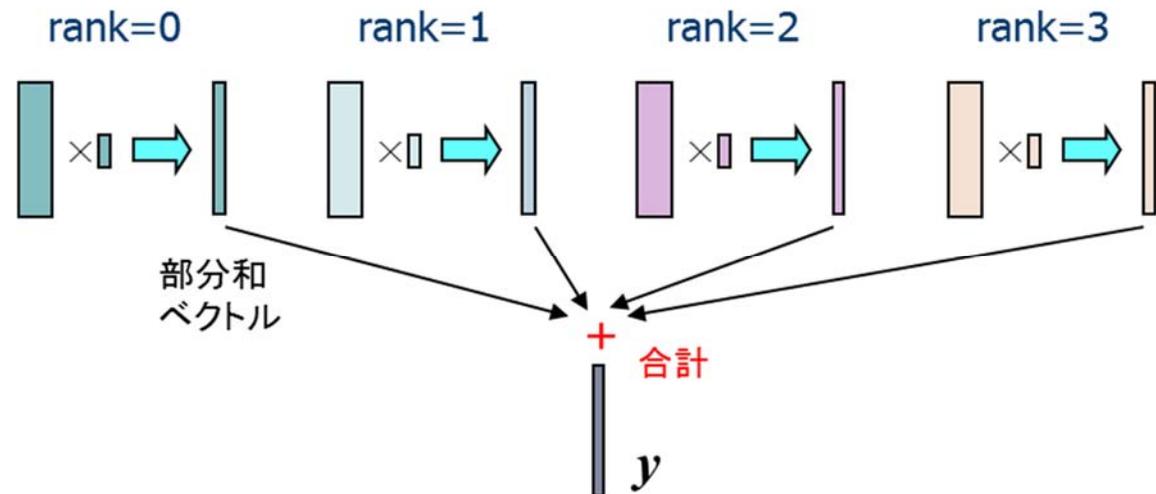
- ◆ A は列方向に短冊形に分割（ブロック列分割）する。
- ◆ x は行方向にブロック分割する。



■ プログラムの方針

- ◆ 各プロセスが持つ自分の要素のみを使って、部分和ベクトルを計算
- ◆ 部分和ベクトルを `mpi_reduce`関数によりプロセス0で集計する。

$$\begin{aligned} y_i &= \sum_{\text{rank}=0} a_{i,j} x_j + \sum_{\text{rank}=1} a_{i,j} x_j \\ &+ \sum_{\text{rank}=2} a_{i,j} x_j + \sum_{\text{rank}=3} a_{i,j} x_j \end{aligned}$$



演習M2-4 : M-5 (mv_s.f90) を並列化せよ

■ プログラム書き換えの方針

◆ MPIの定義, 初期化, 終了処理を忘れないこと.

◆ 各プロセスの計算範囲を求める

- $istart = (n/nprocs) * myrank + 1$
- $iend = (n/nprocs) * (myrank + 1)$

◆ A , x について, 各プロセスが担当する部分のみ初期化する.

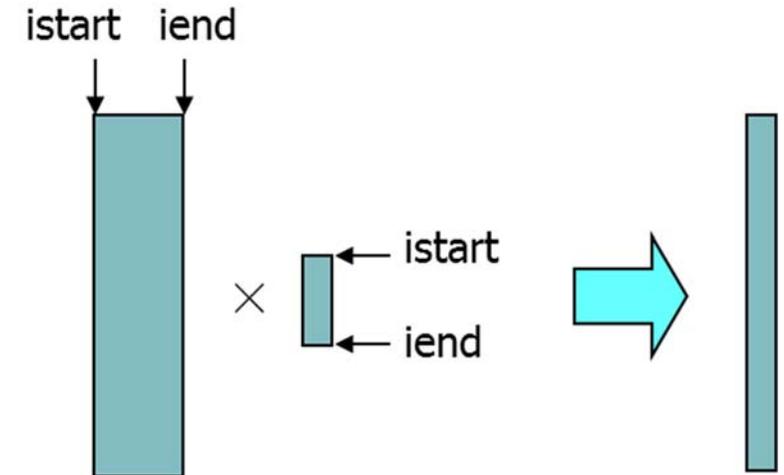
- A : 第 $istart$ 列 ~ 第 $iend$ 列
- x : 第 $istart$ 要素 ~ 第 $iend$ 要素

◆ 部分和ベクトルは, 各プロセスの持つ要素のみを使って計算

- 部分和ベクトルは, 別の配列 (例えば y_tmp) を用いる.

◆ 部分和ベクトルの合計

- `mpi_reduce` 関数により, ランク0のプロセスで, 配列 y_tmp の合計を配列 y に入れる.
- `mpi_reduce` 関数の第3引数 (`count`) に注意 (前回資料 29ページ)



演習M2-4：続き

- $n=1000$ として、プロセス数1, 2, 4, 及び8と変化させて実行させ、結果が正しいことを確認せよ。
- そのときの計算時間の変化を調べよ。
 - ◆ 初期設定、結果の確認部分は、計測範囲に含めないこと。
 - ◆ プロセス数 (n) , 計算時間 (T_n) , 加速率 ($S_n = T_1/T_n$) をまとめる。

n	T_n	S_n
1	XXXXXXXX	1.000
2	XXXXXXXX	XXXXXXXX
4	XXXXXXXX	XXXXXXXX
8	XXXXXXXX	XXXXXXXX

課題の提出方法と提出期限

■ 演習M2-2 , M2-4 の提出方法

- ① **課題ごと**に修正したプログラム, 実行結果, M2-4については加速率などを一つのファイルにまとめる.

```
$ cat program.f90 > report-xx.txt  
$ cat xxxxx.onnnnn >> report-xx.txt
```

- ② 以下の方法で, メールにより提出

```
$ nkf -Lu report-xx.txt | mail -s "2-n:アカウント" yokokawa@port.kobe-u.ac.jp
```

Note) **アカウント**は自分のログインID
番号 (2-n) は, 演習課題番号

※ プログラムがうまく動かない場合でも, 途中結果を提出せよ.

- 期限: **7月5日 (火) 午後5時**