XcalableMPの概要

李 珍泌（RIKEN AICS）

はじめに

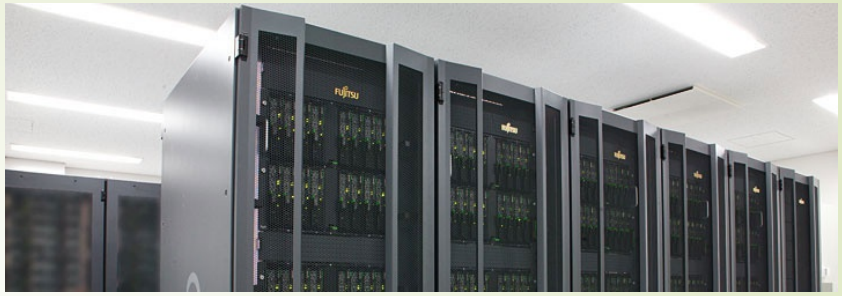

- 大規模シミュレーションなどの計算を行うためには、クラスタのような分散メモリシステムの利用が一般的
- 並列プログラミングの現状
  - 大半はMPI (Message Passing Interface)を利用
  - MPIはプログラミングコストが大きい
- 目標
  - 高性能と高生産性を兼ね備えた並列プログラミング言語の開発

並列プログラミング言語 XcalableMP

- 次世代並列プログラミング言語検討委員会 / PCクラスタコンソーシアムXcalableMP規格部会で検討中。
- MPIに代わる並列プログラミングモデル
- 目標:
  - 性能
  - 表現力
  - 最適化
  - 可読性

www.xcalablemp.org

XcalableMPの特徴（１）

- Fortran/Cの拡張 （指示文ベース）
  → 逐次プログラムからの移行が容易
- SPMDモデル
  - 各ノード（並列実行の主体）が独立に（重複して）実行を開始する。

XcalableMPの特徴（２）

- 2つのプログラミングモデル
  - **グローバルビュー**
  - ローカルビュー
- 明示的な並列化と通信
  - ワークマッピング（並列処理）、通信、および同期は「集団的」な指示文によって明示される。

  → チューニングが容易

XMPの実行モデル（SPMD）

- 各ノードは、同一のコードを独立に（重複して）実行する。
- 指示文の箇所では、全ノードが協調して動作する（集団実行）。
  - 通信・同期
  - ワークマッピング（並列処理）

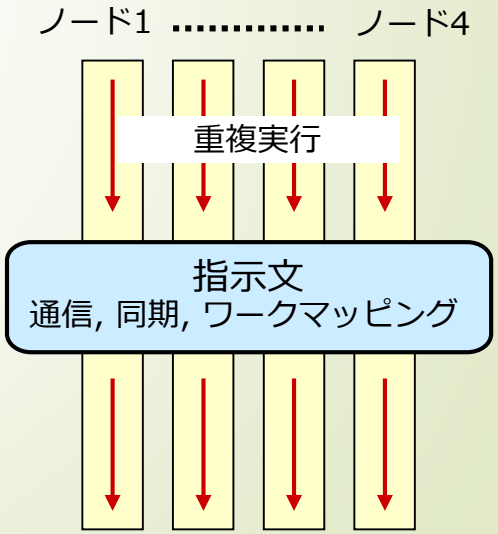

メモリモデル

- 各ノードは、自身のローカルメモリ上のデータ（ローカルデータ）のみをアクセスできる。
- 他のノード上のデータ（リモートデータ）にアクセスする場合は、特殊な記法による明示的な指定が必要。
  - 通信指示文
  - coarray
- 「分散」されないデータは、全ノードに重複して配置される。

XMPのグローバルビュー・プログラミング

ローカルビュー: 各ノードが解くべき問題を個別に示す。「ノード1は問題1～25を解け。ノード2は……」

- 解くべき問題全体を記述し、それをN個のノードが分担する方法を示す。
  - 「問題1～100を4人で分担して解け」
- 分かりやすい（基本的に指示文を挿入するだけ）。
- 「分担」を指定する方法
  - データマッピング
  - ワークマッピング
  - 通信・同期

XcalableMP指示文の記法

- XMPの指示文は、「#pragma xmp」または「!$xmp」から始まる。

例

[C]
```
#pragma xmp align a[i] with t[i]
```

[F]
```
!$xmp align a(i) with t(i)
```

プログラム例（MPIとの比較）

XMP/Cプログラム

```
int array[MAX];
#pragma xmp nodes p[*]
#pragma xmp template t[MAX]
#pragma xmp distribute t[block] onto p
#pragma xmp align array[i] with t[i]

main(){
#pragma xmp loop on t[i] reduction(+:res)
   for (i = 0; i < MAX; i++){
      array[i] = func(i);
      res += array[i];
   }
}
```

- 逐次コードと互換性
- データ並列に対応
- 典型的なパターンを指示文で記述

MPIプログラム

```
int array[MAX];

main(int argc, char **argv){
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &size);

    dx = MAX/size;
    llimit = rank * dx;
    if (rank != (size -1)) ulimit = llimit + dx;
    else ulimit = MAX;
    temp_res = 0;

    for (i = llimit; i < ulimit; i++){
       array[i] = func(i);
       temp_res += array[i];
    }

    MPI_Allreduce(&temp_res, &res, 1, MPI_INT,
                  MPI_SUM, MPI_COMM_WORLD);

    MPI_Finalize( );
}
```

XMPのデータマッピング

- 整列 + 分散による2段階の処理

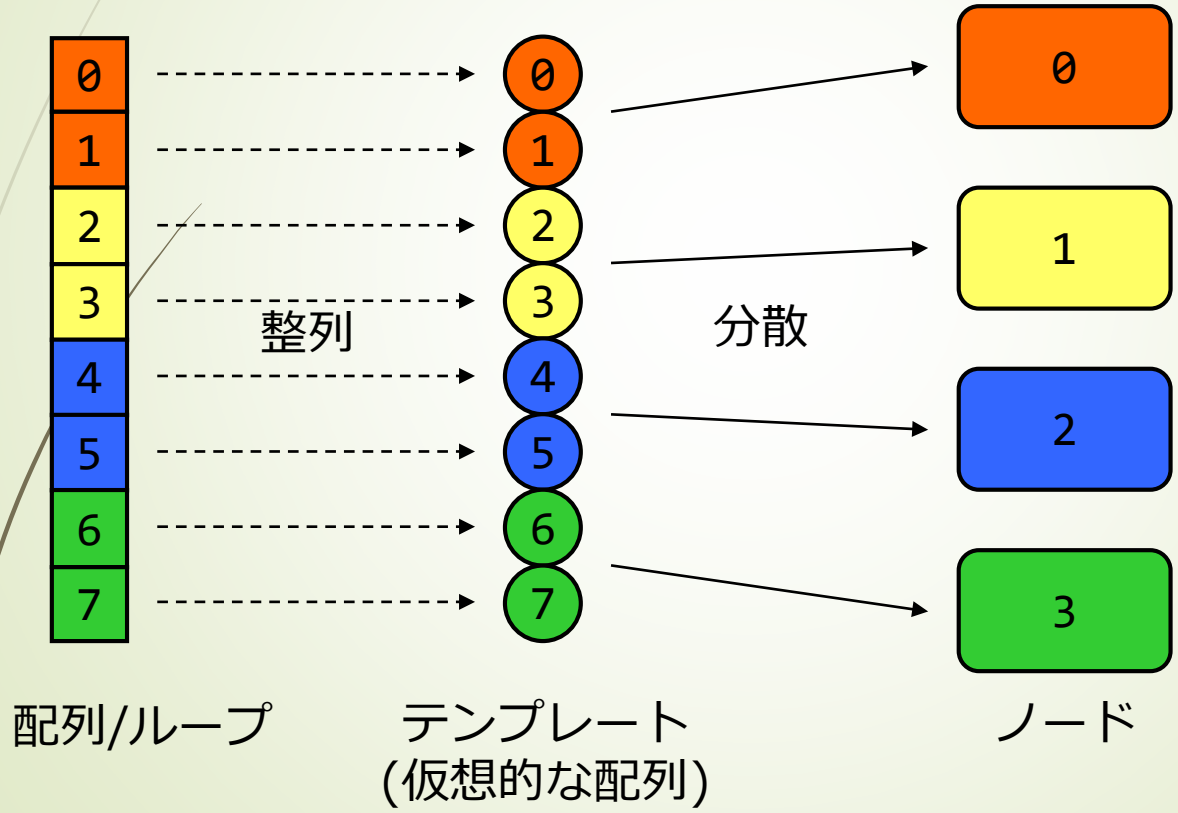

- 配列はテンプレートに整列され、
- テンプレートはノードに分散される。

データマッピング指示文（１）nodes指示文

- XMPプログラムの実行者である「ノード」のサイズと形状を宣言する。
  - データやワークを割り当てる対象。
  - プロセッサ（マルチコア可）とローカルメモリから成る。

[C]
```
#pragma xmp nodes p[4][4]
```

[F]
```
!$xmp nodes p(4,4)
```

動的なnodes指示文

- 実際のpのサイズは、実行時に決まる。
  - mpiexec コマンドの引数など。

[C]
```
#pragma xmp nodes p[*]
#pragma xmp nodes p[*][4]
```

[F]
```
!$xmp nodes p(*)
!$xmp nodes p(4,*)
```

最後の次元に「*」を指定できる。

データマッピング指示文（２）template指示文

- XMPプログラムの並列処理の基準である「テンプレート」のサイズと形状を宣言する。
  - データやワークの整列の対象。

[C]
```
#pragma xmp template t[64][64]
```

[F]
```
!$xmp template t(64,64)
```

データマッピング指示文（3）distribute指示文

- ノード集合pに、テンプレートtを分散する。

[C]
```
#pragma xmp distribute t[block] onto p
```

[F]
```
!$xmp distribute t(block) onto p
```

- 分散形式として、ブロック、サイクリック、ブロックサイクリック、不均等ブロックを指定できる。

データマッピングの例

例1: ブロック分散

```
#pragma xmp nodes p[4]
#pragma xmp template t[20]
#pragma xmp distribute t[block] onto p
```

ノード	インデックス
P[0]	0, 1, 2, 3, 4
P[1]	5, 6, 7, 8, 9
P[2]	10, 11, 12, 13, 14
P[3]	15, 16, 17, 18, 19

例2: サイクリック分散

```
#pragma xmp nodes p[4]
#pragma xmp template t[20]
#pragma xmp distribute t[cyclic] onto p
```

ノード	インデックス
P[0]	0, 4, 8, 12, 16
P[1]	1, 5, 9, 13, 17
P[2]	2, 6, 10, 14, 18
P[3]	3, 7, 11, 15, 19

多次元テンプレートの分散

```
#pragma xmp nodes p2[2][2]
#pragma xmp distribute t[block][block] onto p2
```

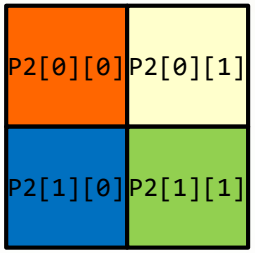


```
#pragma xmp nodes p1[4]
#pragma xmp distribute t[block][*] onto p1
```

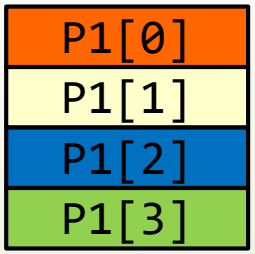

「*」は非分散を意味する。

データマッピング指示文（４）align指示文（１）

- 配列aの要素iを、テンプレートtの要素i-1に整列させる。

[C]
```
#pragma xmp align a[i] with t[i-1]
```

[F]
```
!$xmp align a(i) with t(i-1)
```

- 多次元配列も整列可能。

[C]
```
#pragma xmp align a[i][j] with t[i-1][j]
```

[F]
```
!$xmp align a(i,j) with t(i-1,j)
```

データマ

- 整列 + 分散による

```
#pragma xmp nodes p[4]
#pragma xmp template t[8]
#pragma xmp distribute t[block] onto p
float a[8];
#pragma xmp align a[i] with t[i]
```

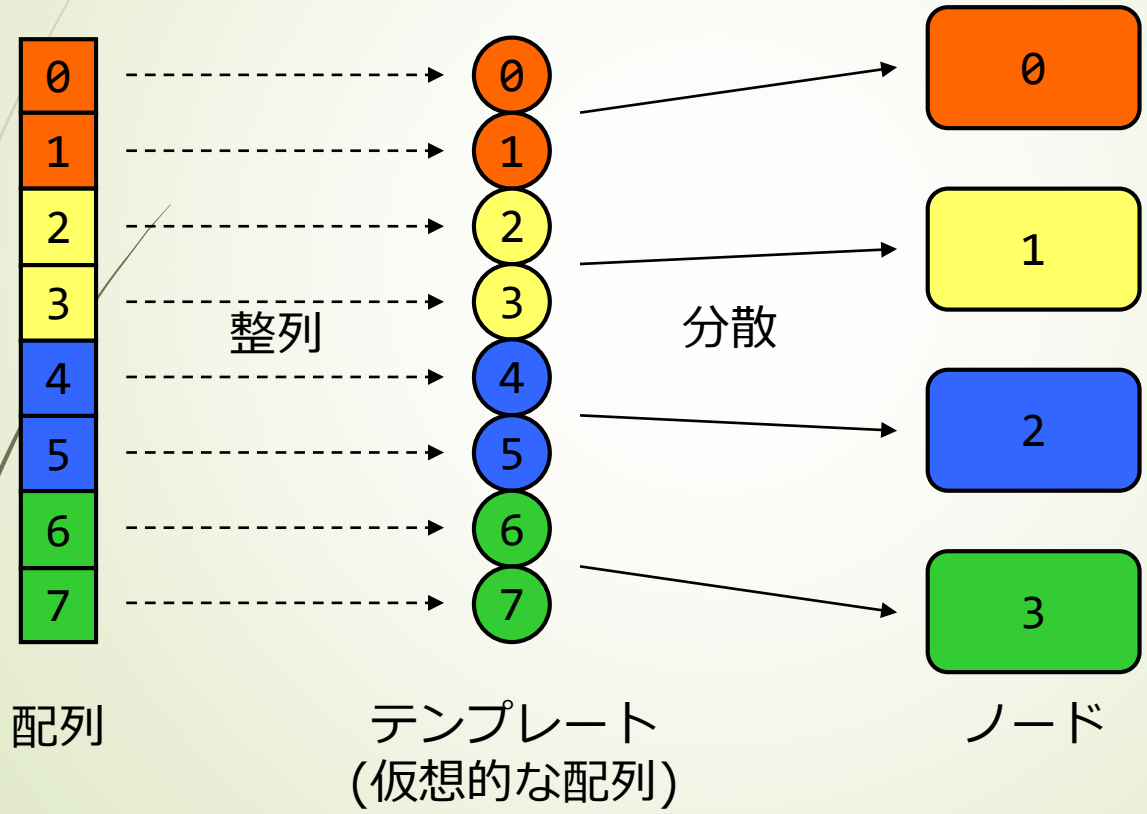

特殊な整列

- 縮退

```
#pragma xmp distribute t[block] onto p1
#pragma xmp align a[i][*] with t[i]
```

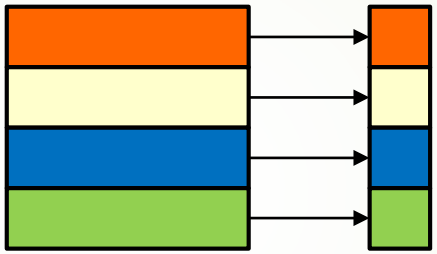

- 複製

```
#pragma xmp distribute t[block][block] onto p2
#pragma xmp align a[i] with t[i][*]
```

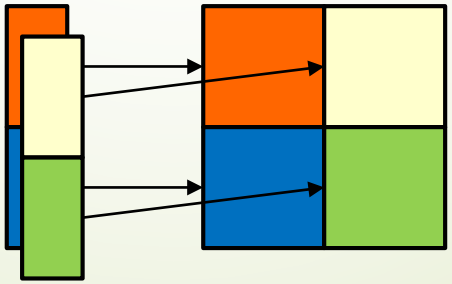

a[0]の実体は、p2[0][0]とp2[0][1]に存在する。値の一致は保証されない。

動的な配列の整列

- ポインタまたは割付け配列として宣言。
- 実際の「整列」の処理は、続くxmp_malloc またはallocate文において実行される。

[C]
```
int *a;
#pragma xmp align a[i] with t[i]
...
a = (int *)xmp_malloc(xmp_desc_of(a), 100);
```

[F]
```
integer, allocatable :: a(:)
!$xmp align a(i) with t(i)
...
allocate (a(100))
```

ワークマッピング指示文（１）
loop指示文（１）

- ループの並列化を指示する。
  - t[i][j]を持つノードが、繰り返しi,jにおいて a[i][j]への代入を実行する。

```
#pragma xmp loop (i,j) on t[i][j]
for (i = 0; i < n; i++)
  for (j = 0; j < n; j++)
    a[i][j] = ...;
```

loop指示文（２）

- アクセスされるデータが、その繰り返しを実行するノードに割り当てられていなければならない。
  - 下の例では、t[i][j]を持つノードが、a[i][j]を持たなければならない。
  - そうでない場合、事前に通信を行っておく。

```
#pragma xmp loop (i,j) on t[i][j]
for (i = 0; i < n; i++)
  for (j = 0; j < n; j++)
    a[i][j] = ...;
```

loop指示文（３）

- reduction節
  - 並列ループの終了時に、各ノードの値を「集計」する。
  - 提供している演算は+, max, minなど。

```
#pragma xmp loop on t[i] reduction(+:sum)
   for (i = 0; i < 20; i++)
      sum += i;
```

各ノード上のsumの値を合計した値で、
各ノード上のsumを更新する。

ワークマッピング指示文（２）task指示文

- 直後の処理を、指定したノードが実行する。

```
#pragma xmp task on p[0]
{
   func_a();
}

#pragma xmp task on p[1]
{
   func_b();
}
```

P[0]がfunc_aを実行する。

p[1]がfunc_bを実行する。

通信指示文（１）
shadow/reflect指示文

aの上下端に幅1のシャドウを付加する。

```
#pragma xmp distribute t[block] onto p
#pragma xmp align a[i] with t[i]
#pragma xmp shadow a[1:1]
...
#pragma xmp reflect (a)
```

aに対する隣接通信を実行する。

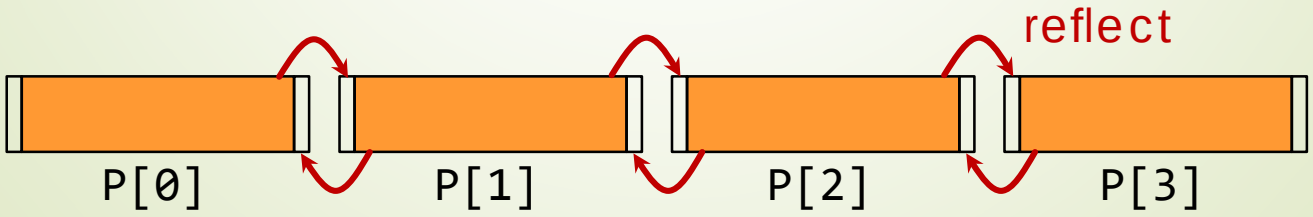

shadow/reflect指示文の例

```
#pragma xmp loop on t[i]
for (i = 1; i < 9; i++)
   b[i] = a[i-1] + a[i] + a[i+1];
```

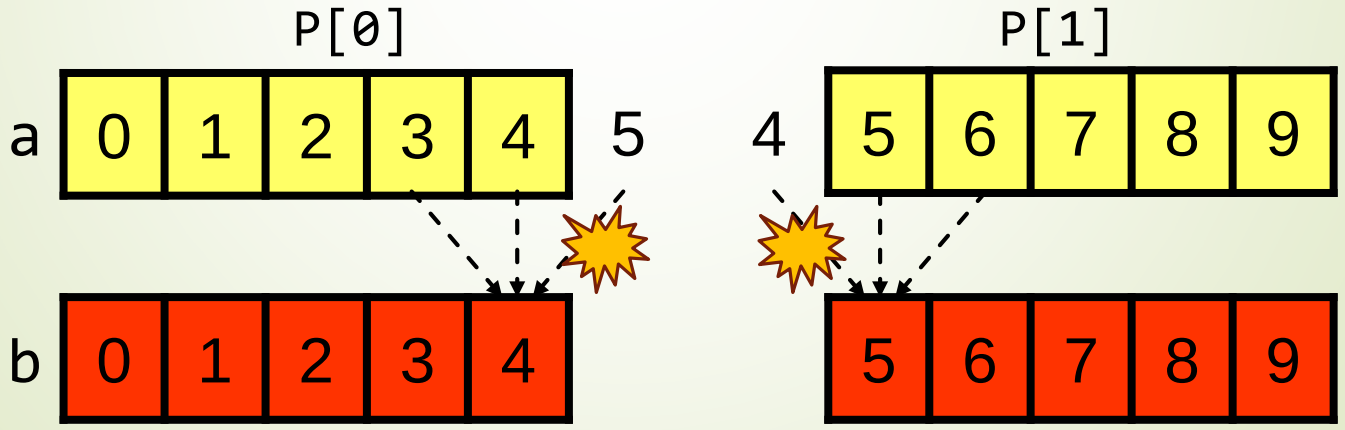

shadow/reflect指示文の例

```
#pragma xmp shadow a[1:1]

#pragma xmp reflect (a)
#pragma xmp loop on t[i]
for (i = 1; i < 9; i++)
   b[i] = a[i-1] + a[i] + a[i+1];
```

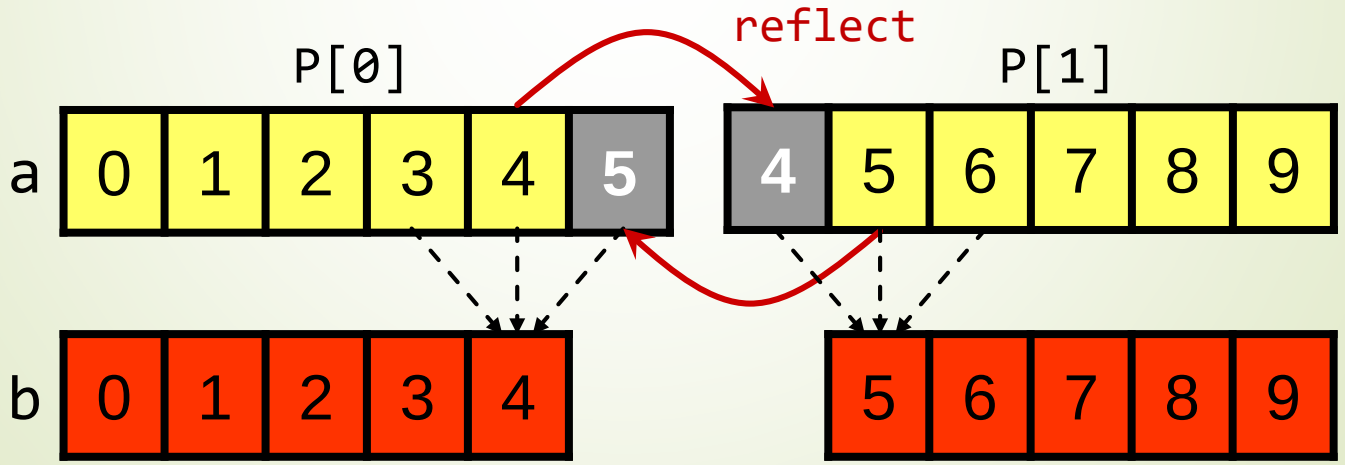

通信指示文（2）
gmove指示文

- 通信を伴う任意の代入文を実行する。

```
#pragma xmp gmove
a[:][:] = b[:][:];
```

※ Cで「部分配列」も記述できる。

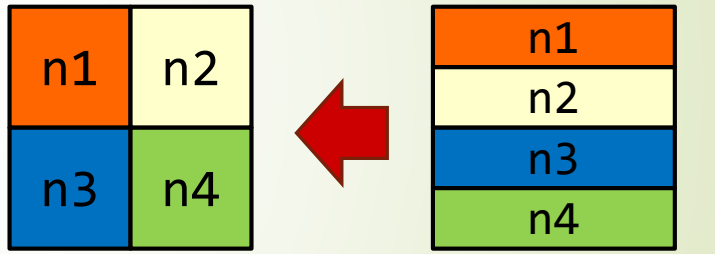

a[block][block]　　b[block][*]

通信指示文（３）

- bcast指示文
  - 特定のノードが、指定したデータを他のノードへブロードキャストする（ばらまく）。

```
#pragma xmp bcast (s) from p[0]
```

※ from p[0] は省略可

- barrier指示文
  - ノードが互いに待ち合わせる（バリア同期）。

```
#pragma xmp barrier
```

XcalableMPプログラムの例

```
!$xmp nodes p(npx,npy,npz)

!$xmp template (lx,ly,lz) :: t
!$xmp distribute (block,block,block) onto p :: t

!$xmp align (ix,iy,iz) with t(ix,iy,iz) ::
!$xmp&        sr, se, sm, sp, sn, sl, ...

!$xmp shadow (1,1,1) ::
!$xmp&        sr, se, sm, sp, sn, sl, ...

      lx = 1024

!$xmp reflect (sr, sm, sp, se, sn, sl)

!$xmp loop on t(ix,iy,iz)
      do iz = 1, lz-1
      do iy = 1, ly
      do ix = 1, lx
         wu0 = sm(ix,iy,iz  ) / sr(ix,iy,iz  )
         wu1 = sm(ix,iy,iz+1) / sr(ix,iy,iz+1)
         wv0 = sn(ix,iy,iz  ) / sr(ix,iy,iz  )
         ...
```

ノード集合の宣言

テンプレートの宣言と分散の指定

整列の指定

シャドウの指定

重複実行される

隣接通信の指定

ループの並列化の指定

XMPのローカルビュー・プログラミング

- 各ノードが解くべき問題を個別に示す。
  - 「ノード1は問題1～25を解け。ノード2は……」
- 自由度が高いが、やや難しい。
- ローカルビューのための機能として、Fortran 2008から導入したcoarrayをサポート。

coarray宣言と通信

- 「coarray」として宣言されたデータは、代入文の形式で他のノードからもアクセスできる。

ノード2が持つb[3:3]のデータをa[0:3]に代入

```
float b[100]:[*];

if (xmpc_this_image() == 0)
  a[0:3] = b[3:3]:[1];
```

配列bはcoarrayであると宣言

コロンの後の[]はノード番号を表す

base　length 「0からの3要素」

通信の同期

- 通信が正常に終わることを保証

sync all

sync images

```
float b[100]:[*];

if (xmpc_this_image() == 0)
  a[0:3] = b[3:3]:[1];
sync_all();
```

sync all:
すべてのimageが同期をとり、
通信を終了

すべてのimage（ノード）が
ここで待つ

通信の同期

- 通信が正常に終わることを保証

sync all

sync images

```
if (xmpc_this_image() == 0) {
  a[0:3] = b[3:3]:[1];
  sync_image(1);
}

if (xmpc_this_image() == 1)
  sync_image(0);
```

sync image:
指定された相手と同期

image 0, 1だけ同期を行う

Questions?