

XcalableMP入門

中尾 昌広（理化学研究所 計算科学研究センター）

もくじ

- XcalableMP (XMP) の概要説明
- XMPプログラミング
- Lattice QCDの実装

XMP誕生の背景

- 分散メモリシステムに対するプログラミングにはMPIが一般的
 - MPIはライブラリベース
 - 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



XMPの概要 (1/2)


- PCクラスタコンソーシアムのXMP規格部会で仕様策定
- MPIに代わる並列プログラミングモデル
- FortranとCに対して、指示文とCoarray記法を用いた並列拡張
 - 指示文なので、既存の逐次コードからの移行が容易
 - C++にも対応中
- MPIとの連携機能もあるので、既存のMPIコードの部分的なXMP化も可能（OpenMPとの連携も可能）



<http://xcalablemp.org>

XMPの概要 (2/2)

- SPMD (Single Program Multiple Data)
 - MPIと同じ
 - 各実行主体 (XMPではノードと呼称, MPIのランクのようなもの) が同じコードを独立に重複して実行する
 - 通信は指示文やCoarray記法によって明示的に行われる
 - 通信箇所が明確なので, 性能チューニングが容易 (HPFの教訓)
- 2つのメモリモデル
 - 指示文によるグローバルビュー
 - Coarray記法によるローカルビュー



もくじ

- XcalableMP (XMP) の概要説明
- **XMPプログラミング**
- Lattice QCDの実装

グローバルビュープログラミング

- グローバルビュープログラミングは「解くべき問題全体を記述し、それを各ノードが分担する方法を示す」
 - 例：問題1～100を4人で分担して解け
- ローカルビュープログラミングは「各ノードが解くべき問題を個別に示す」（MPIはローカルビュー）
 - 例：ノード1は問題1～25を解け. ノード2は.....
- 基本的に指示文を挿入するだけなので、並列化は簡易
- グローバルビューのための指示文
 - データマッピング：分散配列の定義など
 - ワークマッピング：Loop文の分割など
 - 通信・同期

Example of XMP programming in C

```
int a[MAX], sum = 0;
#pragma xmp nodes p[*]
#pragma xmp template t[MAX]
#pragma xmp distribute t[block] onto p
#pragma xmp align a[i] with t[i]
:
#pragma xmp loop on t[i] reduction(+:sum)
for(int i = 0; i < MAX; i++){
    a[i] = foo(i);
    sum += a[i];
}
```

分散配列の定義. 配列a[]を
複数ノードにブロック分割する

ループ文の分割と集約演算

ほぼ同じ指示文を
CとFortranに提供

Example of XMP programming in F

```
integer :: a(MAX), sum = 0
!$xmp nodes p(*)
!$xmp template t(MAX)
!$xmp distribute t(block) onto p
!$xmp align a(i) with t(i)
:
!$xmp loop on t(i) reduction(+:sum)
  do i = 1, MAX
    a(i) = foo(i)
    sum = sum + a(i)
  enddo
```

分散配列の定義. 配列a[]を
複数ノードにブロック分割する

ループ文の分割と集約演算

ほぼ同じ指示文を
CとFortranに提供

XMPとMPIとの比較

XMP

```
int array[MAX], res = 0;
#pragma xmp nodes p[*]
#pragma xmp template t[MAX]
#pragma xmp distribute t[block] onto p
#pragma xmp align array[i] with t[i]

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

少しの手間で、逐次イメージを
残したまま、並列化できる

MPI

```
int array[MAX], res = 0;

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

    int dx = MAX/size;
    int llimit = rank * dx;
    int ulimit = (rank != (size - 1)) ? llimit + dx : MAX;
    int temp_res = 0;

    for(int 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();
    return 0;
}
```

loop指示文

- loop指示文はfor文の直前に挿入する

```
#pragma xmp loop on t[i]  
for(int i=0;i<16;i++){
```

```
#pragma xmp nodes p[4]  
#pragma xmp template t[16]  
#pragma xmp distribute t[block] onto p  
int a[16];  
#pragma xmp align a[i] with t[i]
```




各ノードは赤いセルを並列に処理する。

loop指示文

- loop指示文はfor文の直前に挿入する

```
#pragma xmp loop on t[i]  
for(int i=2;i<11;i++){
```

```
#pragma xmp nodes p[4]  
#pragma xmp template t[16]  
#pragma xmp distribute t[block] onto p  
int a[16];  
#pragma xmp align a[i] with t[i]
```



各ノードは赤いセルを並列に処理する。

多次元のloop指示文

[C]

```
#pragma xmp nodes p[4][2]
#pragma xmp template t[20][20]
#pragma xmp distribute t[block][block] onto p
int a[20][20];
#pragma xmp align a[i][j] with t[i][j]

#pragma xmp loop on t[i][j]
for(int i=0;i<20;i++){
    for(int j=0;j<20;j++){
        a[i][j] = func(i, j);
    }
}
```

[F]

```
!$xmp nodes p(2,4)
!$xmp template t(20,20)
!$xmp distribute t(block,block) onto p
integer :: a(20,20);
!$xmp align a(j,i) with t(j,i)

!$xmp loop on t(j, i)
do i=1, 20
    do j=1, 20
        a(j,i) = func(j,i)
    end do
end do
```

XMP指示文 + OpenMP指示文

[C]

```
#pragma xmp loop on t[i]
#pragma omp parallel for
for(int i=0;i<20;i++){
    a[i] = i;
}
```

[F]

```
!$xmp loop on t(i)
!$omp parallel do
do i=1, 20
    a(i) = i
end do
!$omp end parallel do
```

[C]

```
#pragma omp parallel for
#pragma xmp loop on t[i]
for(int i=0;i<20;i++){
    a[i] = i;
}
```

[F]

```
!$omp parallel do
!$xmp loop on t(i)
do i=1, 20
    a(i) = i
end do
!$omp end parallel do
```

指示文の順序は、どちらが先でも構わない

bcast指示文とreduction指示文

- bcast指示文

- 全ノードに任意のローカル変数を放送する (MPI_Bcastに相当)

[C]

```
#pragma xmp bcast (b)  
#pragma xmp bcast (b) from p[2]
```

[F]

```
!$xmp bcast (b)  
!$xmp bcast (b) from p(3)
```

- reduction指示文

- ノード間で集約処理を行う (MPI_Allreduceに相当)

[C] #pragma xmp reduction (+:b)

[F] !\$xmp reduction (+:b)





gmove指示文

- 分散配列に対する通信
 - 分散配列のある要素がどのノードが持っているかを知らなくてよい

```
#pragma xmp gmove [C]  
a[2:4] = b[3:4];
```

array-name[base : length];





gmove指示文

- 分散配列に対する通信
 - 分散配列のある要素がどのノードが持っているかを知らなくてよい

```
!$xmp gmove [F]  
a(3:6) = b(4:7)
```

array-name(base : end)



shadow/reflect指示文

- ステンシルアプリケーションを作成するときに便利な機能
- **shadow**指示文は分散配列に袖領域を追加する
- **reflect**指示文は隣接ノードが持つ端の値を自ノードにコピーする


[C]

```
#pragma xmp nodes p[3]
#pragma xmp template t[9]
#pragma xmp distribute t[block] onto p
int a[9];
#pragma xmp align a[i] with t[i]
#pragma xmp shadow a[1:1]
...
#pragma xmp reflect (a)
```

[F]

```
!$xmp nodes p(3)
!$xmp template t(9)
!$xmp distribute t(block) onto p
integer :: a(9)
!$xmp align a(i) with t(i)
!$xmp shadow a(1:1)
...
!$xmp reflect (a)
```


lower-bound : upper-bound



p[0]



p[1]



p[2]

shadow指示文は
袖領域（灰色のセル）
を追加する

shadow/reflect指示文

- ステンシルアプリケーションを作成するときに便利な機能
- **shadow**指示文は分散配列に袖領域を追加する
- **reflect**指示文は隣接ノードが持つ端の値を自ノードにコピーする


[C]

```
#pragma xmp nodes p[3]
#pragma xmp template t[9]
#pragma xmp distribute t[block] onto p
int a[9];
#pragma xmp align a[i] with t[i]
#pragma xmp shadow a[1:1]
...
#pragma xmp reflect (a)
```

[F]

```
!$xmp nodes p(3)
!$xmp template t(9)
!$xmp distribute t(block) onto p
integer :: a(9)
!$xmp align a(i) with t(i)
!$xmp shadow a(1:1)
...
!$xmp reflect (a)
```

lower-bound : upper-bound



reflect指示文は隣接ノードの端の値を袖領域にコピーする



shadow/reflect指示文

[C]

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

[F]

```
!$xmp loop on t(i)
do i = 2, 8
    b(i) = a(i-1) + a(i) + a(i+1)
end do
```




shadow/reflect指示文

[C]

```
#pragma xmp shadow a[1:1]
...
#pragma xmp reflect (a)
#pragma xmp loop on t[i]
for(int i=1;i<9;i++){
    b[i] = a[i-1] + a[i] + a[i+1];
}
```

[F]

```
!$xmp shadow a(1:1)
...
!$xmp reflect (a)
!$xmp loop on t(i)
do i = 2, 8
    b(i) = a(i-1) + a(i) + a(i+1)
end do
```



ローカルビュープログラミング

- グローバルビュープログラミングは「解くべき問題全体を記述し、それを各ノードが分担する方法を示す」
 - 例：問題1～100を4人で分担して解け
- ローカルビュープログラミングは「各ノードが解くべき問題を個別に示す」（MPIはローカルビュー）
 - 例：ノード1は問題1～25を解け、ノード2は.....
- 自由度が高い分、グローバルビュープログラミングと比較してやや難しい
- ローカルビュープログラミングのための機能として、Fortran 2008から導入したcoarray記法をXMP/Cでもサポート

Coarray記法 in XMP/C

- Coarrayに対して他ノードからの片側通信 (Put/Get) を実行できる

```
real a(8)
real b(8)[*]
```

Fortran2008

```
if(this_image() == 1) then
  b(6)[2] = b(4)
  a(0) = b(3)[2]
end if
```

```
sync all
```

b()をcoarrayとして宣言

image 1は b(4)をimage 2の b(6)にPutする

image 1はimage 2の b(3)を a(0)にGetする

同期 (今までに実行した片側通信の終了を待つ)

```
double a[8];
double b[8]:[*];
```


XMP/C

```
if(xmpc_this_image() == 1){
  b[6]:[2] = b[4];
  a[0] = b[3]:[2];
}
```


```
xmpc_sync_all(NULL);
```


部分配列 in XMP/C

- XMP/Cにおいて複数の要素に対する片側通信のために，部分配列を導入
- Intel Cilk や OpenACCと同等




Omni Compiler



```
$ xmpcc a.c -o a.out
```

- XMP指示文を含むユーザコードは，ランタイムの呼び出しに変換する
- ランタイムはCとMPIで実装（つまりMPI対応の並列計算環境で動作する）
- 変換されたコードは，GNU・Intel・PGIなどのネイティブコンパイラで翻訳
- オープンソース

<https://omni-compiler.org>




もくじ

- XcalableMP (XMP) の概要説明
- XMPプログラミング
- Lattice QCDの実装

Lattice QCD (LQCD) ミニアプリケーション

- HPC分野で重要なアプリケーションの1つ
- QCD (Quantum Chromo-Dynamics : 量子色力学) は物質の最小単位であるクォークと、クォーク間における相互作用を結ぶグルーオンを表す基本方程式
- LQCDは4次元 (時間+XYZ軸) の格子で行うQCDのシミュレーション
- LQCDミニアプリケーション
 - C言語, 逐次コード, 850行くらい by KEK 松古さん
 - 実アプリケーションBridge++のカーネル部分を抽出



Overview of algorithm

- Pseudo-code (CG method is used)

```
S = B           // COPY
R = B           // COPY
X = B           // COPY
sr = norm(S)    // NORM
T = WD(U,X)     // Main Kernel
S = WD(U,T)     // Main Kernel
R = R - S       // AXPY
P = R           // COPY
rrp = rr = norm(R) // NORM
do{
  T = WD(U,P)   // Main Kernel
  V = WD(U,T)   // Main Kernel
  pap = dot(V,P) // DOT
  cr = rr/pap
  X = cr * P + X // AXPY
  R = -cr * V + R // AXPY
  rr = norm(R)   // NORM
  bk = rr/rrp
  P = bk * P     // SCAL
  P = P + R      // AXPY
  rrp = rr
}while(rr/sr > 1.E-16)
```

WD() is the Wilson-Dirac operator

$$D_{x,y} = \delta_{x,y} - \kappa \sum_{\mu=1}^4 \{ (1 - \gamma_{\mu}) U_{\mu}(x) \delta_{x+\hat{\mu},y} + (1 + \gamma_{\mu}) U_{\mu}^{\dagger}(x - \hat{\mu}) \delta_{x-\hat{\mu},y} \}$$


- Main kernel (most costly)
- Stencil calculation

```
#pragma xmp reflect (X) width(/periodic/..) orthogonal
WD(X, ...);
```



```
void WD(Quark_t X[NT][NZ][NY][NX], ... ){
  :
  #pragma xmp loop on t[t][z]
  #pragma omp parallel for collapse(4)
  for(int t=0;t<NT;t++){
    for(int z=0;z<NZ;z++){
      for(int y=0;y<NY;y++){
        for(int x=0;x<NX;x++){
          :
        }
      }
    }
  }
```

reflect指示文


#pragma xmp reflect (a)



#pragma xmp reflect (a) orthogonal



#pragma xmp reflect (a) width(/periodic/1, ..) ≠
orthogonal



(orthogonalは実装中)

Performance Evaluation on cluster



- Oakforest-PACS and COMA
 - One process per compute node on Oakforest-PACS
 - Two processes per compute node on COMA because it has two CPU sockets
- Problem size is (32,32,32,32) as (NT,NZ,NY,NX) with strong scaling



Performance Evaluation

● Oakforest-PACS


● COMA




Performances of **Omni compiler** achieve 94 - 105% of those of **Intel compiler**.

Productivity Evaluation

- Source lines of codes (SLOC)



- Delta SLOC How many lines the code changed from a base code to a parallel code



まとめ

- 並列言語XMPの紹介
- Lattice QCDの実装と評価
 - 十分な性能と高い生産性を達成
 - 今回紹介しませんでしたでしたが、色々なベンチマークやミニアプリも実装しています。その内のいくつかは、下記のGitHubで公開中
 - <https://github.com/omni-compiler/XMP-Applications>
- 色々なXMPの拡張
 - PythonのためのXMPモジュール
 - アクセラレータ用言語OpenACCとの連携
 - $\text{XMP} + \text{OpenACC} + \alpha = \text{XcalableACC}$
 - アクセラレータを搭載したクラスタシステム用言語
 - アクセラレータ間の直接通信にも対応