

アクセラレータクラス向け PGAS言語XcalableACCの実装状況報告

田渕晶大^{†1}、中尾昌広^{†2}、村井均^{†2}、朴泰祐^{†1,3}、佐藤三久^{†1,2}

^{†1} 筑波大学大学院システム情報工学研究科

^{†2} 国立研究開発法人理化学研究所計算科学研究機構

^{†3} 筑波大学計算科学研究センター

概要

- 背景・目的
- XcalableACC (XACC)
- Omni XACC compiler
- Omni XACC compiler の実装状況
- 評価
 - 姫野ベンチマーク
 - NPB-CG
- まとめ・今後の予定

背景と目的

- アクセラレータ (GPU, MIC など) をもつクラスタが増加
- アクセラレータのプログラミング
 - CUDA、OpenCL
 - OpenACC、OpenMP 4.0 (指示文ベース)
- ノード間通信・同期のプログラミング
 - MPI
 - XcalableMP (XMP) (指示文ベース)
- ハイブリッドプログラミング
 - MPI + CUDA ... MPI, CUDAともに記述が煩雑
 - XMP + OpenACC ... 指示文で簡易に記述できるが、アクセラレータ間の通信指示文がない




アクセラレータクラスタ向けに性能・生産性の高いプログラミングモデルが必要

XcalableACC (XACC)

- XMP と OpenACC を統合した PGAS 言語
 - 理研・筑波大で開発中
 - XMP・・・分散メモリプログラミング
 - OpenACC・・・アクセラレータプログラミング
 - 単に XMP + OpenACC ではない


- デバイスメモリ間の通信
 - ホストを介さない通信が可能

- 複数デバイスサポート
 - OpenACCでは書きにくい
1プロセスから複数デバイスの利用が簡単に可能



XACC の機能 - デバイス間通信

- XMPの通信の拡張
 - `#pragma xmp [reflect|gmove|reduction|bcast] ... acc`
- 記述が簡易
- 実装が適切な通信を発行可能 (e.g. GPUDirect for RDMA)



XACC の機能 - デバイス間通信

- Coarray にも対応
 - OpenACC の仕様にはまだ Fortran の Coarray に関する記述はない

Fortran


```
real a(N)[*]  
!$acc declare create(a)  
...  
if(this_image() == 1) then  
    !$acc host_data use_device(a)  
    a(:)[2] = a(:)  
end if
```

C

```
double a[N]:[*];  
#pragma acc declare create(a)  
...  
if( xmp_node_num() == 1){  
    #pragma acc host_data use_device(a)  
    a[:,2] = a[:];  
}
```

Omni XACC compiler

- Omni compiler で実装した XACC コンパイラ
 - Omni XMP compiler の拡張
 - ソースtoソースコンパイラ: XACC → OpenACC
 - 一般的な OpenACC コンパイラを利用可能



- 使用方法

```
$ ./configure ... --enable-xacc  
$ xmpcc ... -xacc
```

Omni XACC compiler の実装状況

- コード変換 (translator)
 - 指示文の変換は実装済み
 - Coarray の変換は C のみ対応
- デバイス間通信 (runtime library)
 - 現在は NVIDIA GPU のみ対象
 - MPI 版
 - CUDA aware MPI を想定
 - おおよそ実装済み (次のスライドに詳細)
 - TCA 版
 - reflect のみ
 - MPI + TCA 版
 - reflect, reduction のみ

MPI版デバイス間通信

- 実装済み機能

通信	C	Fortran
reflect	○	○
reduction	○	○
bcast	○	×
gmove	△	×
Coarray	○	×

性能評価

- ベンチマーク
 - Himeno Benchmark
 - NAS Parallel Benchmarks CG (NPB-CG)
- 3種類のコードを比較
 - MPI + OpenACC (MPI+ACC)
 - XACC global-view (XACC-G)
 - XACC local-view (XACC-L)

- HA-PACS/TCAで評価
 - 1GPU / MPIプロセス

HA-PACS/TCA の構成

CPU	Intel Xeon-E5 2680v2 2.8GHz x 2
Memory	DDR3 1866MHz, 128GB
GPU	Tesla K20X x 4
Interconnect	InfiniBand Mellanox Connect-X3 Dual-port QDR
Compiler	GCC 4.4.7, CUDA 7.5, MVAPICH2-GDR 2.2rc1 Omni Compiler 1.0.3 相当

Himeno Benchmark

- 非圧縮流体解析コードのベンチマーク
- サイズ:
 - Large (256 x 256 x 512)
- 分割
 - i, j次元の2次元分割
- 主な処理
 - 演算: 19点ステンシル
 - 通信: 袖通信
- 反復回数は1000回


```
#pragma xmp template t(0:MKMAX-1, 0:MJMAX-1,
                      0:MIMAX-1)

#pragma xmp nodes n(1, NDY, NDX)
#pragma xmp distribute t(block, block, block) onto n
#pragma xmp align p[k][j][i] with t(i, j, k)
#pragma xmp shadow p[1:2][1:2][0:1]
...
#pragma acc data copy(p,...)
{
    ...
    #pragma xmp loop (k,j,i) on t(k,j,i)
    #pragma acc parallel loop reduction(+:gosa) collapse(2)
    gang
        for(i=1 ; i<imax-1 ; ++i)
            for(j=1 ; j<jmax-1 ; ++j)
                #pragma acc loop vector reduction(+:gosa)
                    for(k=1 ; k<kmax-1 ; ++k){
                        s0 = a[0][i][j][k]*p[i+1][j][k]+a[1][i][j][k] + ...;
                    }
    ...
    #pragma xmp reflect(p) width(1,1,0) acc
    ...
} //end of acc data ...
```

ステンシル計算

袖通信

Himeno Benchmark の性能



XACC-L (Coarray)の性能低下

- 両側プロセスとの袖通信が同時にされていない
 - 例 (j次元方向の通信)

```
xmp_sync_images(num_npy, npy, NULL); // 両側プロセスと同期
lo_recvbuf[0:len] = lo_sendbuf[0:len]:[mez][mey-1][mex]; // get
hi_recvbuf[0:len] = hi_sendbuf[0:len]:[mez][mey+1][mex]; // get
xmp_sync_images(num_npy, npy, NULL);
```



```
xmp_sync_images(num_npy, npy, NULL);
_XMP_coarray_shortcut_get( .., _DESC_lo_recvbuf, ..); // 関数callに置き換え
_XMP_coarray_shortcut_get( .., _DESC_hi_recvbuf, ..); // 関数callに置き換え
xmp_sync_images(num_npy, npy, NULL); // そのまま
```

MPI_Get(..., win);
MPI_Win_flush_local(..., win);


- 本来はコンパイラが2つの通信に依存がないことを解析して同時に発行すべき
- Omni では単純に置き換えるため、関数内では put/get の直後にそのローカルでの完了を待つようにしている
 - 通信に用いたローカル変数を読み書きする可能性があるため

XACC-L (Coarray)の改善案

- Coarray 通信のローカルでの完了を待たないようにする指示文があるとよい
 - 例: Cray compiler の独自機能 `#pragma pgas defer_sync`
- 試験的に環境変数 `XMP_COARRAY_ASYNC=1` の時は通信発行後にローカルの完了待たないようにした
 - もちろん `sync_image` で通信の完了は保証される

Himeno Benchmark の性能 (Coarray 改良版)

相対性能が一番低い部分で 92% → 95% に改善



NPB-CG

- 疎行列の最小固有値を共役勾配法で求めるベンチマーク
- 問題サイズ
 - Class D (1,500,000 x 1,500,000)
- 行と列の2次元分割
- 主な処理
 - 演算: SpMV
 - 通信: 配列リダクション、行分割配列→列分割配列


```
#pragma xmp nodes p(NUM_COLS, NUM_ROWS)
#pragma xmp template t(0:NA-1,0:NA-1)
#pragma xmp distribute t(block, block) onto p
#pragma xmp align w[i] with t(*,i)
#pragma xmp align q[i] with t(i,*)
double a[NZ];
int rowstr[NA+1], colidx[NZ];
...
#pragma acc data copy(p,q,r,w, a[0:NZ], ...)
{
    ...
    #pragma xmp loop on t(*,j)
    #pragma acc parallel loop gang
        for(j=0; j < NA; j++){
            double sum = 0.0;
            #pragma acc loop vector reduction(+:sum)
                for (k = rowstr[j]; k < rowstr[j+1]; k++)
                    sum = sum + a[k]*p[colidx[k]];
            w[j] = sum;
        }
    #pragma xmp reduction(+:w) on p(:,*) acc
    #pragma xmp gmove acc
        q[:] = w[:];
} //end acc data
```

SpMV

リダクション


列分割←行分割

NPB-CG の性能



配列リダクションの性能低下 (1)


- 処理する配列サイズの違い
 - MPI + OpenACC 版では直後の行分割→列分割の通信に必要な部分のみリダクション
 - 例: (列分割数) == (行分割数) × 2



- XACC-G では全体をリダクション
 - reduction 指示文では同様の処理を記述できない

配列リダクションの性能低下 (2)

- リダクションの方法の違い
 - MPI + OpenACC は MPI_Isend/Recv と加算ループにより GPU 上で Recursive-Doubling 法
 - XACC-G は MPI_Allreduce
 - MV2 ではホストにコピーしてリダクション
 - CG の Class D のサイズだと MPI_Allreduce の方が遅い



まとめ

- XACC
 - XMP と OpenACC の統合
 - デバイス間通信をサポート
- Omni XACC compiler
 - [C]は指示文・Coarray ともにおおよそ実装済
 - [F]は一部の指示文のみ対応
- 性能
 - Himeno Bench, NPB-CG では 適切な記述を用いれば MPI + OpenACC と同等の性能
 - Coarray は複数通信時の改善が必要

今後の予定

- デバイス間通信(GPU)の実装を継続
 - MPI版はgmove ,coarrayの実装
 - TCA版は未定。GASNet/TCA の利用？
 - アプリの実装を通してさらに性能を改善する
- 各種アクセラレータへの対応
 - 現在開発中の Omni OpenACC for PEZY-SC を用いて PEZY-SC でも XACC を利用可能にする

