

マルチノードマルチコア向け分散共有メモリにおけるデータ分散配置機能稼働実験

白澤 卓磨 緑川 博子 (成蹊大)


マルチスレッド・マルチノードプログラミングのための分散共有メモリシステム (M-SMS)

ノード内並列 (OpenMP/pthread マルチスレッドプログラム) + ノード間並列 (クラスタにおけるPGAS・共有メモリプログラミング) を提供する新しいページベースの分散共有メモリシステム [1]

- 従来のMPI+OpenMPハイブリッドプログラミング: MPIではデータをローカルビューで扱う → 並列プログラムの生産性が低くなる
- 共有するデータを全ノードが認識するグローバルビューの提供
- 共有データの各ノードへの分散配置機能 (分散マッピング) [2] → 応用プログラムのデータアクセス局所性を利用した性能向上

ページベース分散共有メモリ

共有データの仮想共有メモリシステムへの分散配置



ノード間で共有するデータは各ノードに分散して管理
Owner: 各ノードが管理する共有データ
Cache: 他ノードのOwnerページのコピー領域


sms_mapalloc関数

```
void* sms_mapalloc( int dim[], int div[],
size_t data_size, int start_node, int num_node );
dim[]...各次元の要素数, div[]...各次元の分割数
data_size...型の大きさ, start_node...始点ノードランク
num_node...利用ノード数
```

```
int num=4096,dim[3]={num,num,-1},div[3]={4,1,-1};
int(*array)[num];
...
array=(int (*)[num])sms_mapalloc(dim,div,sizeof(int),0,4);
...
#pragma omp parallel for private(j)
for( i=sms_rank*(num/4); i<(sms_rank+1)*(num/4); i++) {
for(j=0;j<num;j++){
array[i][j]=i+j;
}
}
```

変換後

マルチノード・マルチスレッド共有メモリプログラミングのイメージ




分散マッピング例 (二次元配列)

例A	4096	例B	2048	4096
0	Node0	0	Node0	Node1
1024	Node1			
2048	Node2	2048	Node2	Node3
3072	Node3			
4096		4096		


分散データマッピングAPI (Mpc) [2]による記述 (組み込み予定)
shared int arrayA[4096][4096]::[4][1]; //例A
shared int arrayB[4096][4096]::[2][2]; //例B

稼働実験

配列処理: 各ノードで共有データ配列への代入を行う




データ確認: 共有データを1ノードに集めて実行



ベンチマーク

共有データ配列に対する代入処理
→ノード1つに共有データを集めてデータが正しいか確認

共有データ (int 1024x1204) 割付方法
sms_alloc関数 → ノード0のみ
sms_mapalloc関数 → 例Aのように割付



CPU	Intel Xeon E5-2687W 3.10GHz, 2CPU x 8Core / node
Memory	128GB/node (2node) or 256GB/node (4node)
Network	Infiniband singleFDR (56Gbps)
OS	CentOS 7.1.1503
Compiler	gcc version 4.8.3

今後の展開

- システムの安定稼働 (正しい共有データの反映、システムが止まってしまう原因の調査)
- プログラムインターフェース、API: 既存開発のSMSシステム、Mpc[2]、SMS[3]のAPIを踏襲
- 共有メモリー一貫性と別経路による遠隔メモリー・ローカルメモリー間直接コピー操作Get/Putの実装
- メモリー一貫性実装方式の検討 (現在はall-invalidate方式)
- アクセス局所性を考慮した応用アルゴリズムによる性能評価

[1] 緑川, 岩井田: "マルチスレッド対応分散共有メモリシステムの設計と実装", HPCS2015, HPCS2015論文集, (2015, 5-19)
[2] Mpcインターフェース: 緑川他"メタプロセスモデルに基づくポータブルな並列プログラミングインターフェースMpc", 情処論文誌: Vol.46 No.SIG4(ACS9), pp.69-85, (2005, 3)
[3] 緑川, 塚塚: "ユーザレベル・ソフトウェア分散共有メモリSMSの設計と実装", 情処論文誌, Vol.42, No.SIG9(HPS 3), pp.170-190 (2001, 8)