Quad Core Opteron: ccNUMA Arch.

- AMD Quad Core Opteron 2.3GHz
  - Quad Coreのソケット×4 ⇒ 1ノード（16コア）
- 各ソケットがローカルにメモリを持っている
  - NUMA：Non-Uniform Memory Access
    - ローカルのメモリをアクセスして計算するようなプログラミング，データ配置，実行時制御（numactl）が必要
  - cc： cache-coherent
    - キャッシュ同期：Thread並列

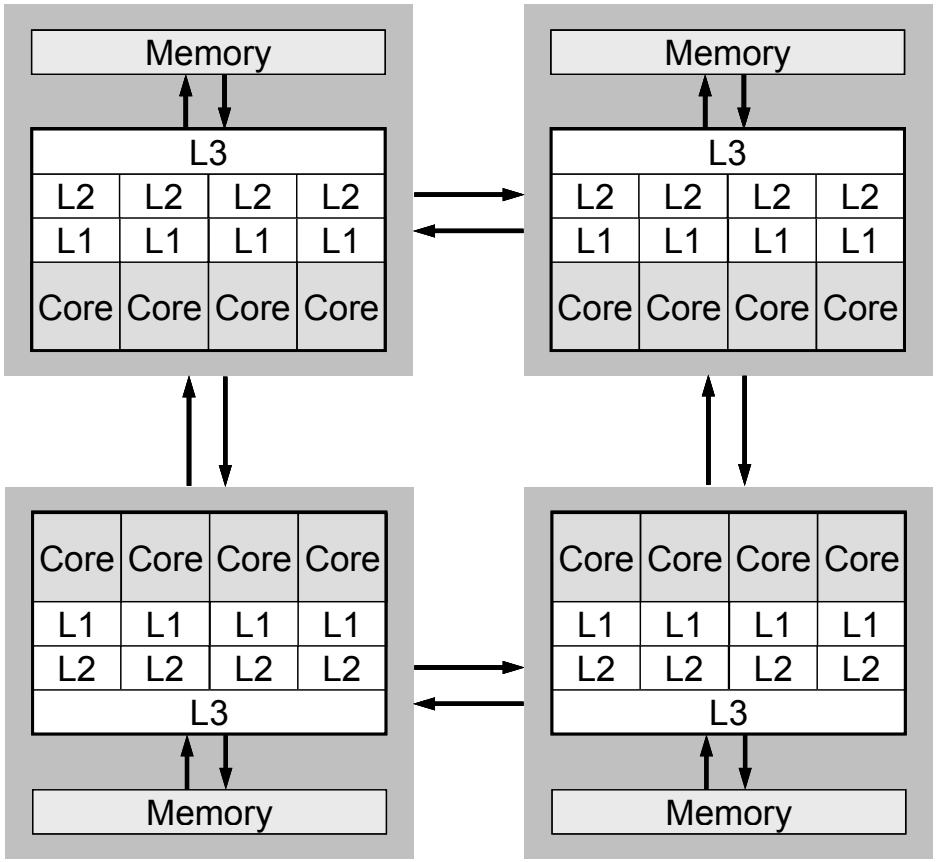

ccNUMA Architecture

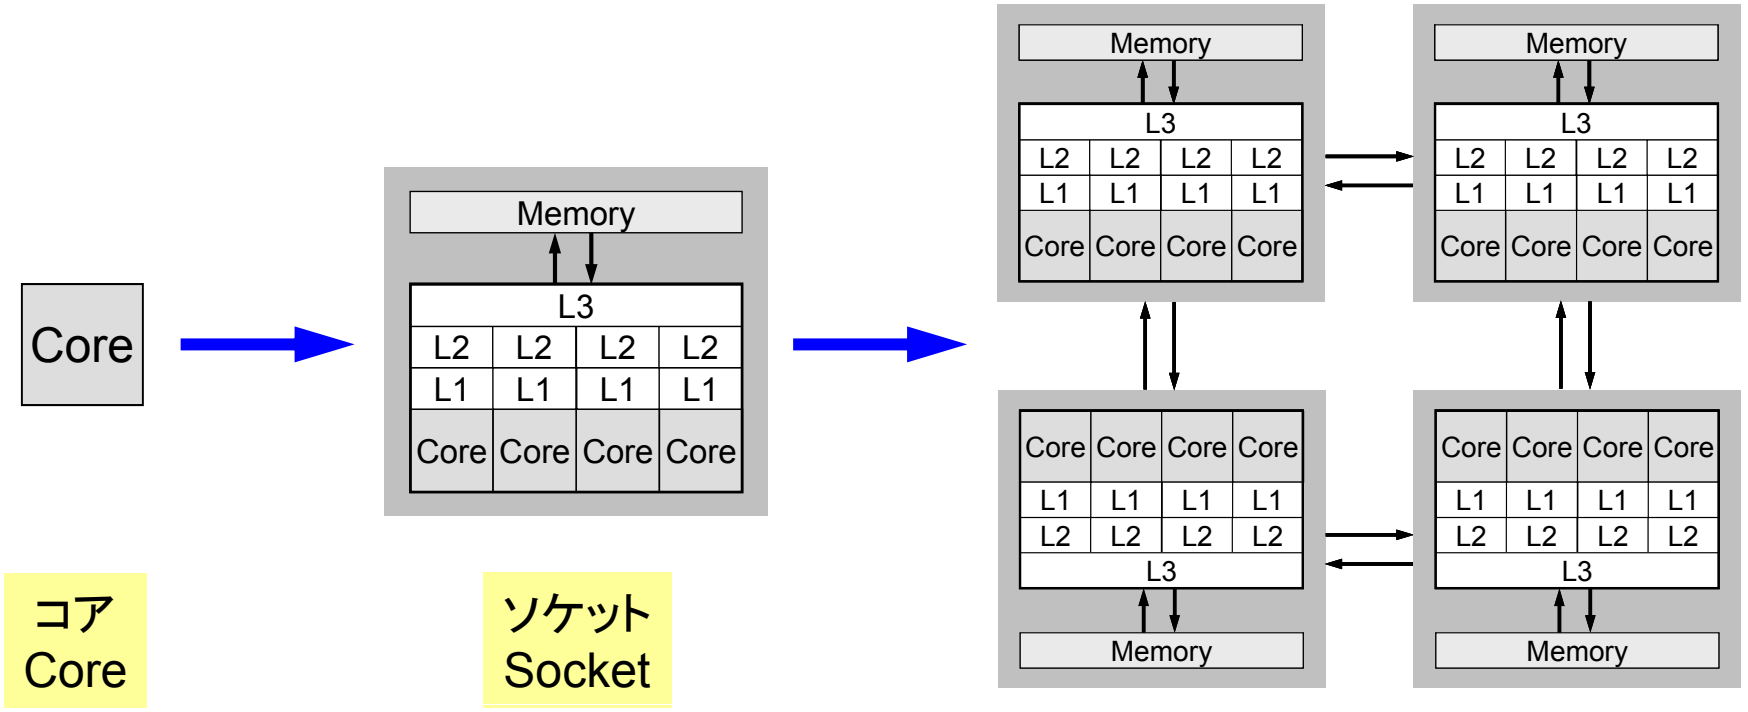

numactl

```
>$ numactl --show

policy: default
preferred node: current
physcpubind: 0 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15    コア
cpubind: 0 1 2 3                                      ソケット
nodebind: 0 1 2 3                                     ソケット
membind: 0 1 2 3                                      メモリ
```

- NUMA(Non Uniform Memory Access) 向けのメモリ割付のためのコマンドライン：Linuxでサポート
- 使うコアとメモリの関係指定：ローカルなメモリ上のデータを使うのが得策

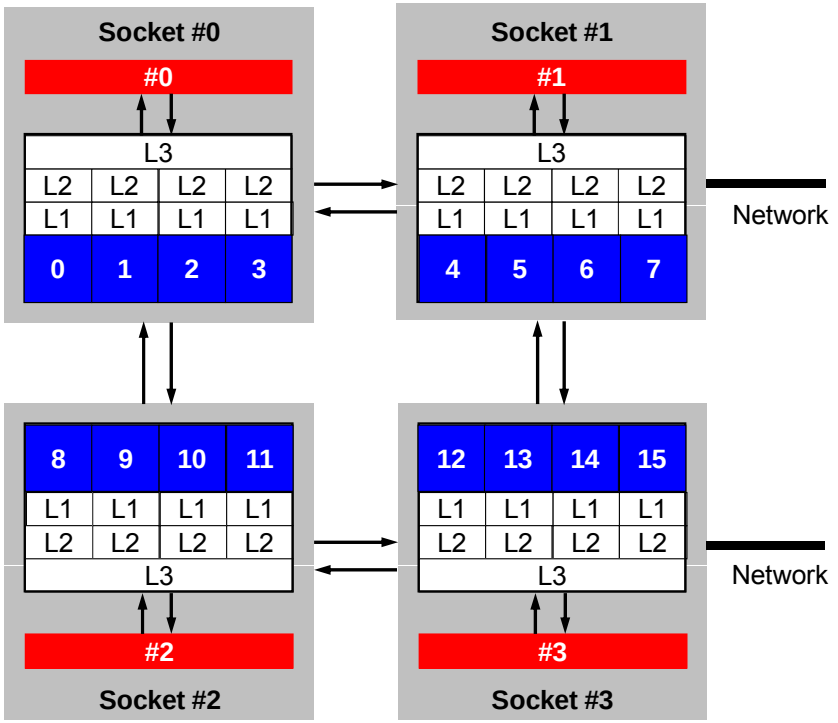

numactlの影響

- T2K，有限要素法アプリケーション，Strong Scaling，Flat MPI
- 128コア：1コアあたりの問題サイズは512コアの4倍
  - メモリへの負担大
- Policy=0：何も指定しない場合
- 相対性能：大きいほど良い—128ノードで影響大

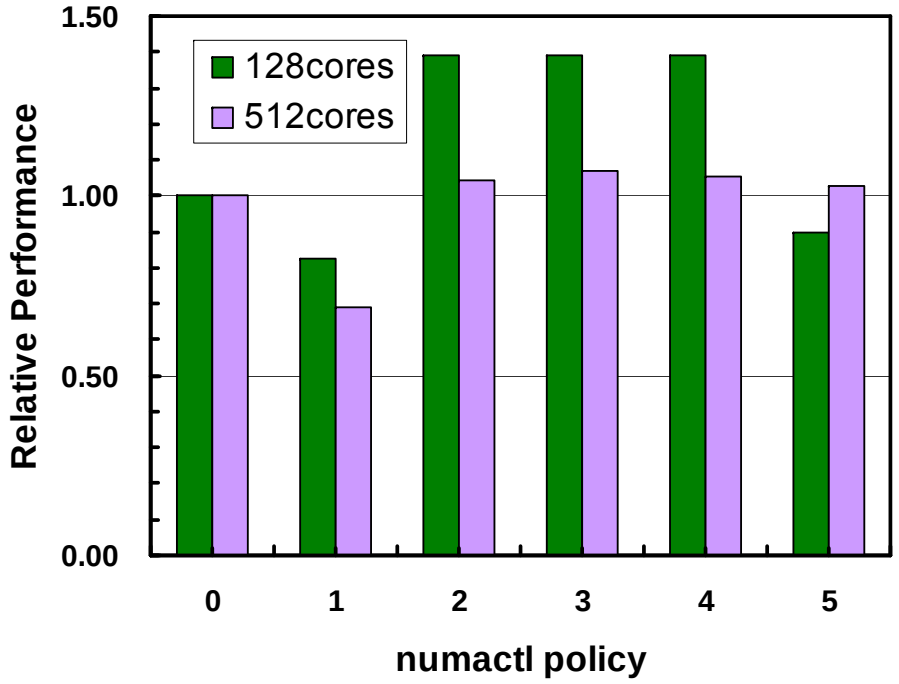


```
#@$-r HID-org
#@$-q h08nkl32
#@$-N 24
#@$-J T16
#@$-e err
#@$-o x384-40-1-a.lst
#@$-lM 27GB
#@$-lE 03:00:00
#@$-s /bin/sh
#@$
cd $PBS_O_WORKDIR
mpirun ./numarun.sh ./sol
exit
```

numarun.shの中身

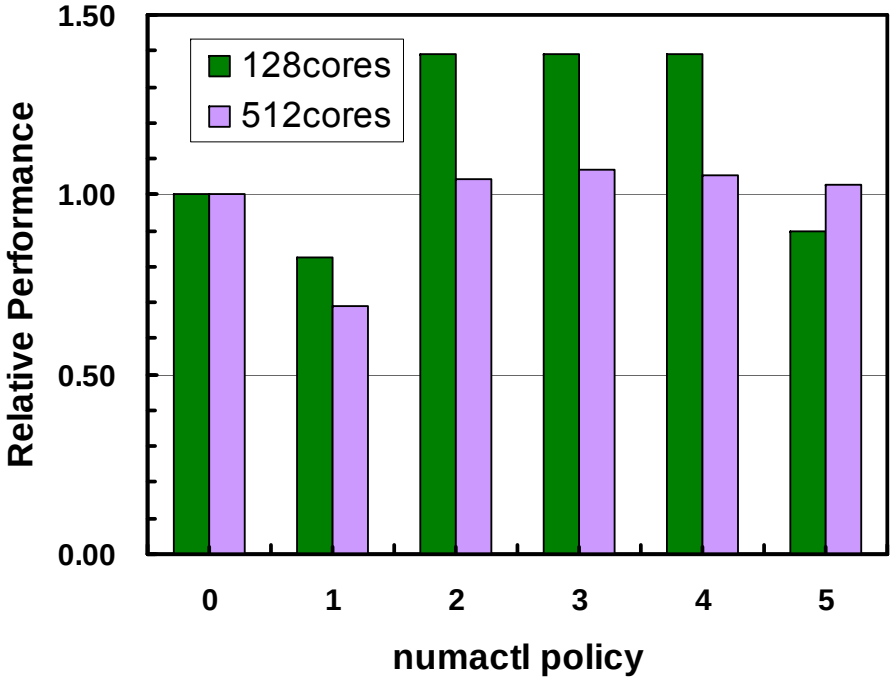

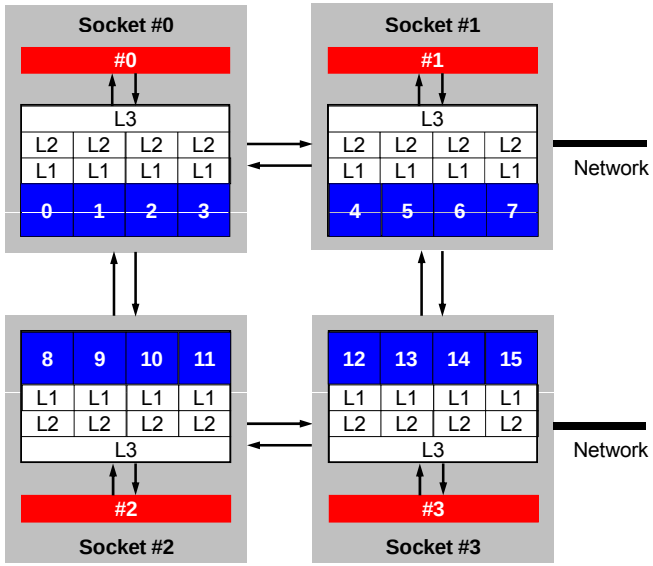

Policy:1
```
#!/bin/bash
MYRANK=$MXMPI_ID MPIのプロセス番号
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
numactl --cpunodebind=$SOCKET --interleave=all $@
```

Policy:2
```
#!/bin/bash
MYRANK=$MXMPI_ID
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
numactl --cpunodebind=$SOCKET --interleave=$SOCKET $@
```

Policy:3
```
#!/bin/bash
MYRANK=$MXMPI_ID
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
numactl --cpunodebind=$SOCKET --membind=$SOCKET $@
```

Policy:4
```
#!/bin/bash
MYRANK=$MXMPI_ID
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
numactl --cpunodebind=$SOCKET --localalloc $@
```

Policy:5
```
#!/bin/bash
MYRANK=$MXMPI_ID
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
numactl --localalloc $@
```

Policy-3の割り当て

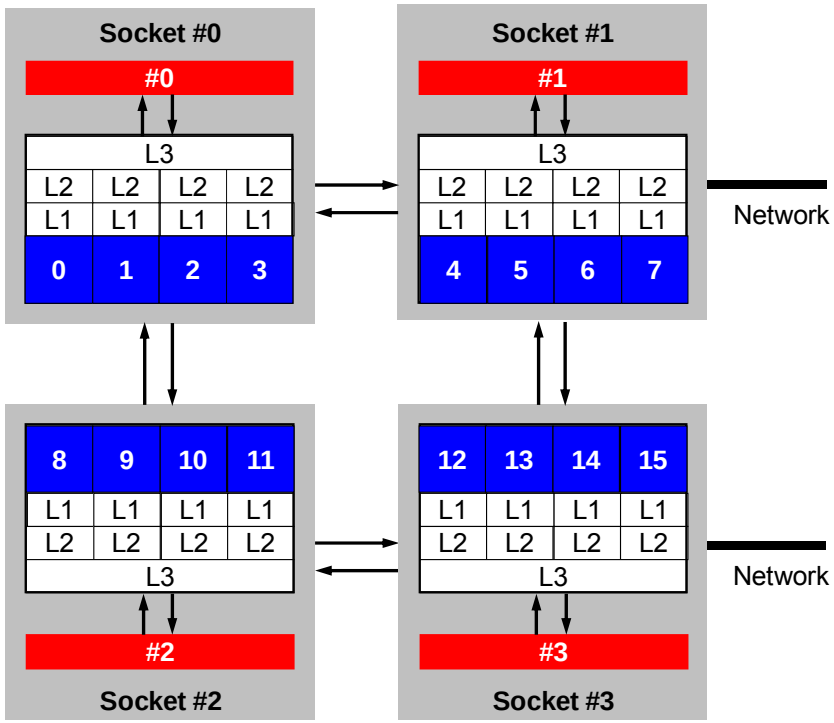

Policy:3

```
#!/bin/bash
MYRANK=$MXMPI_ID
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
numactl --cpunodebind=$SOCKET --membind=$SOCKET $@
```

MPI process	Socket	Memory	Core
0	0	0	
1	0	0	
2	0	0	
3	0	0	
4	1	1	
5	1	1	
6	1	1	
7	1	1	
8	2	2	
9	2	2	
10	2	2	
11	2	2	
12	3	3	
13	3	3	
14	3	3	
15	3	3	

Cyclicな割り付けも可能

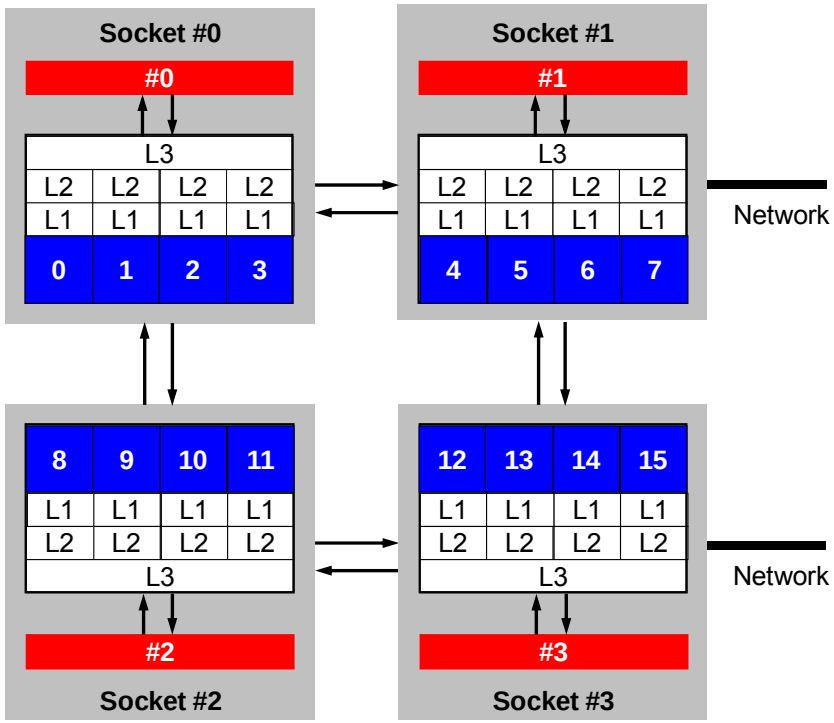


```
#!/bin/bash
MYRANK=$MXMPI_ID
SOCKET=$(expr $MYRANK % 4)
numactl --cpunodebind=$SOCKET --membind=$SOCKET $@
```

MPI process	Socket	Memory	Core
0	0	0	
1	1	1	
2	2	2	
3	3	3	
4	0	0	
5	1	1	
6	2	2	
7	3	3	
8	0	0	
9	1	1	
10	2	2	
11	3	3	
12	0	0	
13	1	1	
14	2	2	
15	3	3	

コアを指定することもできる

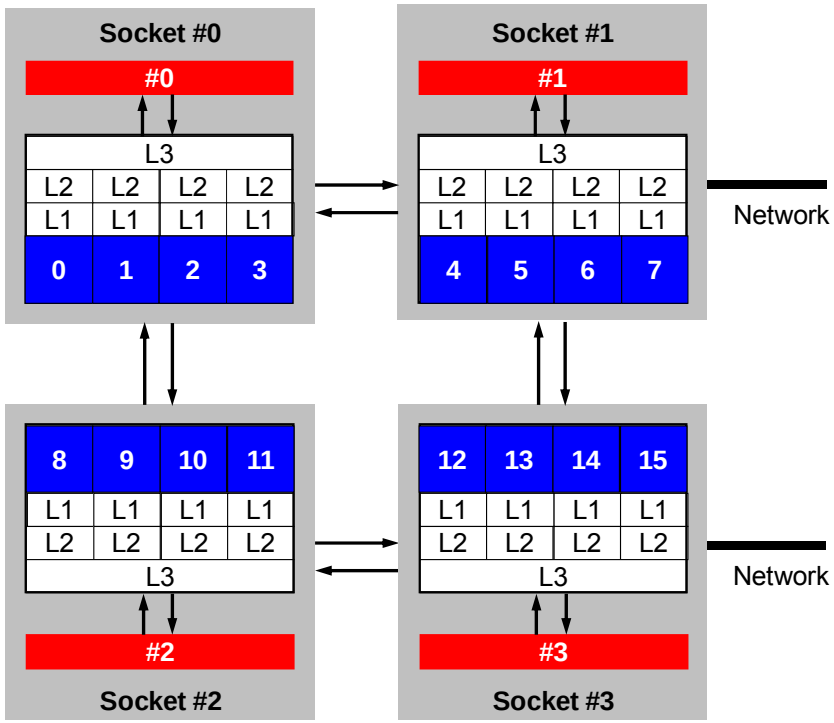


```
#!/bin/bash
MYRANK=$MXMPI_ID
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
CORE=$(expr $MYRANK % 16)
numactl --physcpubind=$CORE --membind=$SOCKET $@
```

MPI process	Socket	Memory	Core
0		0	0
1		0	1
2		0	2
3		0	3
4		1	4
5		1	5
6		1	6
7		1	7
8		2	8
9		2	9
10		2	10
11		2	11
12		3	12
13		3	13
14		3	14
15		3	15

8コア使う場合はどうする？

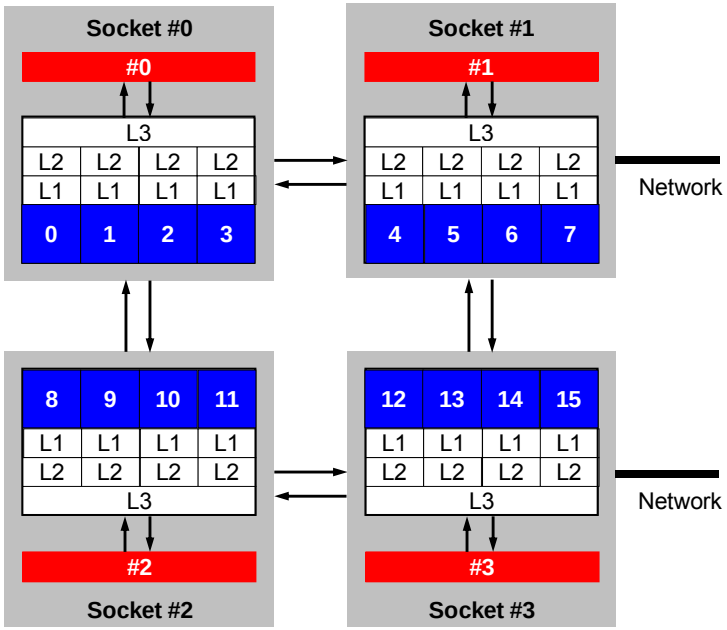

MPI process	Socket	Memory	Core
0		0	0
1		0	2
2		1	4
3		1	6
4		2	8
5		2	10
6		3	12
7		3	14

MPI process	Socket	Memory	Core
0		0	0
1		0	1
2		0	2
3		0	3
4		1	4
5		1	5
6		1	6
7		1	7

MPI process	Socket	Memory	Core
0		0	0
1		0	1
2		1	4
3		1	5
4		2	8
5		2	9
6		3	12
7		3	13

STREAM ベンチマーク

http://www.streambench.org/

- メモリバンド幅を測定するベンチマーク
  - Copy, Scale, Add, Triad（DAXPYと同じ）

```
-------------------------------------------------------------
 Double precision appears to have 16 digits of accuracy
 Assuming 8 bytes per DOUBLE PRECISION word
-------------------------------------------------------------
 Number of processors =           16
 Array size =    2000000
 Offset     =          0
 The total memory requirement is     732.4 MB (     45.8MB/task)
 You are running each test  10 times
 --
 The *best* time for each test is used
 *EXCLUDING* the first and last iterations
 -----------------------------------------------------
 -----------------------------------------------------
Function     Rate (MB/s)  Avg time   Min time  Max time
Copy:      18334.1898      0.0280      0.0279      0.0280
Scale:     18035.1690      0.0284      0.0284      0.0285
Add:       18649.4455      0.0412      0.0412      0.0413
Triad:     19603.8455      0.0394      0.0392      0.0398
```

ファイル：今回はFORTRANのみ

```
>$ cd <$FVM>/stream
>$ mpif90 –Oss –noparallel stream.f –o stream
```

今回はMPI版だが，OpenMP版もある

set-a0.sh：Policy-5相当

- プロセスが割り当てられたソケットのローカルメモリを使う
- ソケット番号は基本的にサイクリック（round-robin的）に割り当てられるが，異なる場合もある（実行ごとに性能が変動）

```
#@$-r stream
#@$-q lecture
#@$-N 1
#@$-J T16
#@$-e err
#@$-o a0-16-1.lst
#@$-lM 28GB
#@$-lT 00:05:00
#@$

cd $PBS_O_WORKDIR

mpirun numactl --localalloc ./stream
exit
```

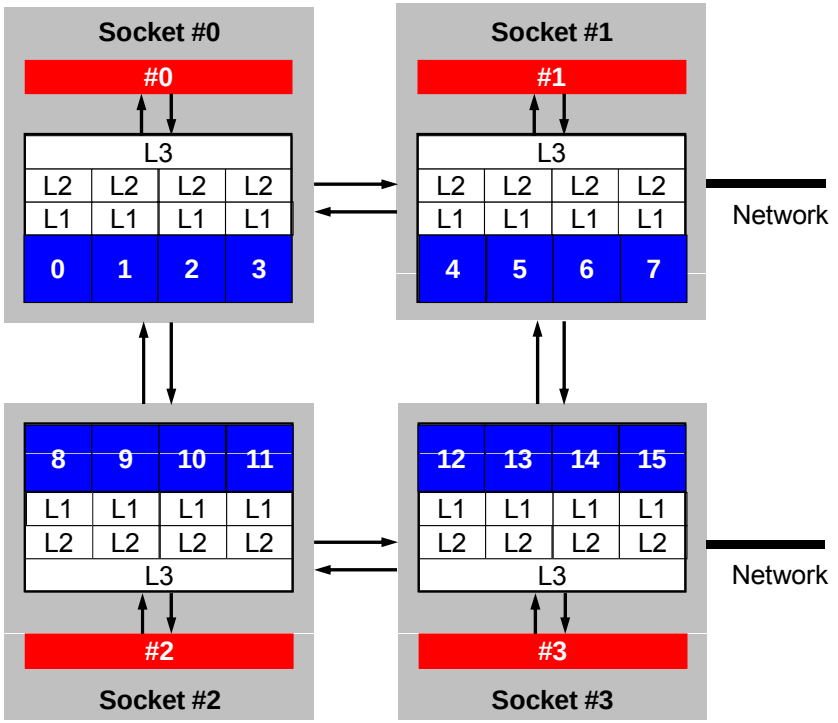

set-b1/b2.sh：Policy-3,4相当

- 各プロセスをソケット0番から順番に埋まるように割り当て，各ソケットのローカルメモリを使う
- b1とb2ではあまり差は無い

set-b1.sh

```
#@$-r stream
#@$-q lecture
#@$-N 1
#@$-J T8
#@$-e err
#@$-o b1-08-1.lst
#@$-lM 28GB
#@$-lT 00:05:00
#@$

cd $PBS_O_WORKDIR

mpirun ./b1.sh ./stream
exit
```

b1.sh：Policy-3相当

```
#!/bin/bash
MYRANK=$MXMPI_ID
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
numactl --cpunodebind=$SOCKET --membind=$SOCKET $@
```

b2.sh：Policy-4相当

```
#!/bin/bash
MYRANK=$MXMPI_ID
MYVAL=$(expr $MYRANK / 4)
SOCKET=$(expr $MYVAL % 4)
numactl --cpunodebind=$SOCKET --localalloc $@
```

set-x.sh

- 各プロセスが割り当てられたソケットのメモリを使う
- T2：0,1, T4：0,1,2,3
- T8：0,0,1,1,2,2,3,3
- T16：0,0,0,0,1,1,1,1,2,2,2,2,3,3,3,3

```
#@$-r stream
#@$-q lecture
#@$-N 1
#@$-J T16
#@$-e err
#@$-o x1-16-1.lst
#@$-lM 28GB
#@$-lT 00:05:00
#@$

cd $PBS_O_WORKDIR
```

```
mpirun numactl --cpunodebind=0,1,2,3 --localalloc ./stream
exit
```

Triadの結果：Policy-5@T1の性能を1.00

- Policy-5: set-a0，Policy-4: set-b2
- 0,1,2,3:　set-x
- 16コア使った場合，メモリの性能は5倍強にしかなっていない

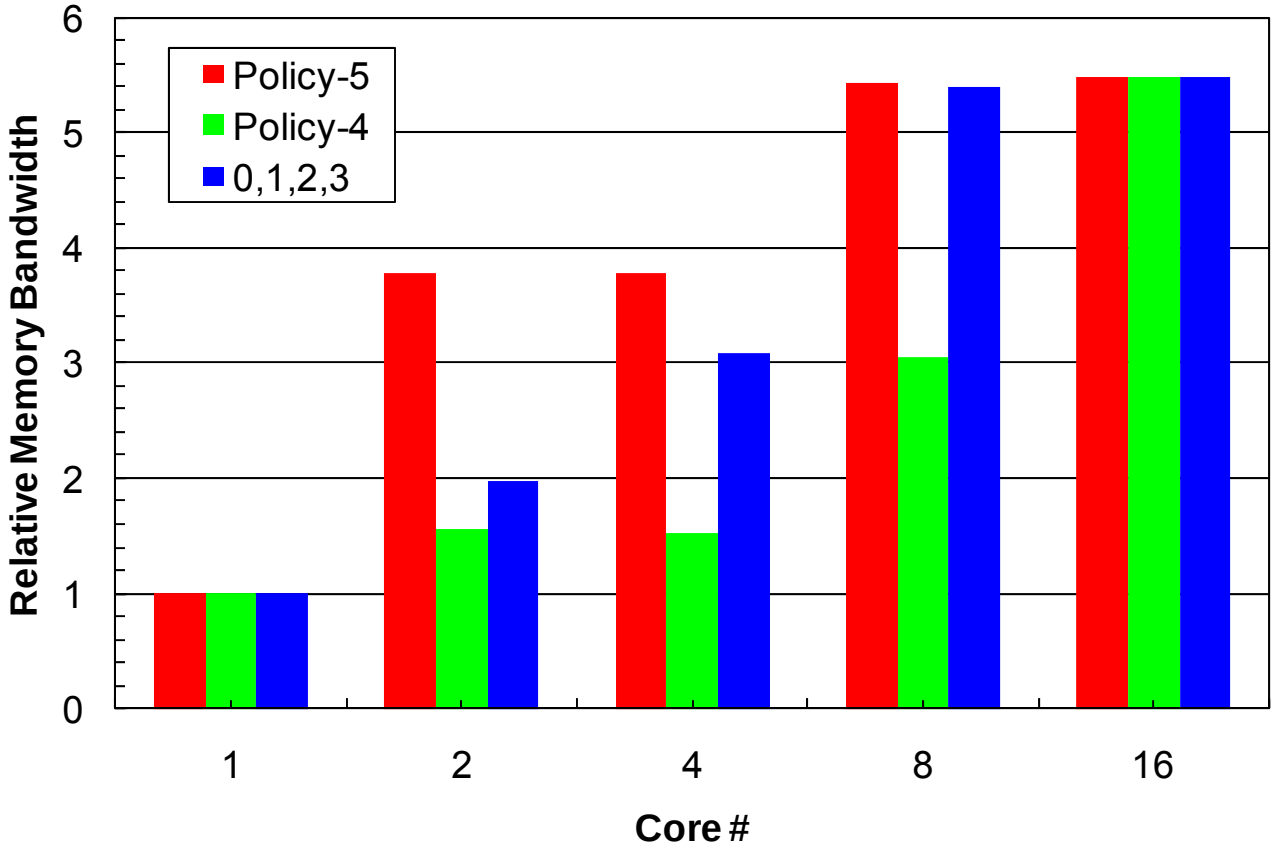

Triadの性能：T2

- Policy-4
  - 1コアのときの2倍までは行かないが性能は向上
  - 2コアで1つのメモリを共有するため，多少の競合が生じている
- 0,1,2,3
  - ほぼ100%近い性能向上
  - 各コアでローカルメモリを占有

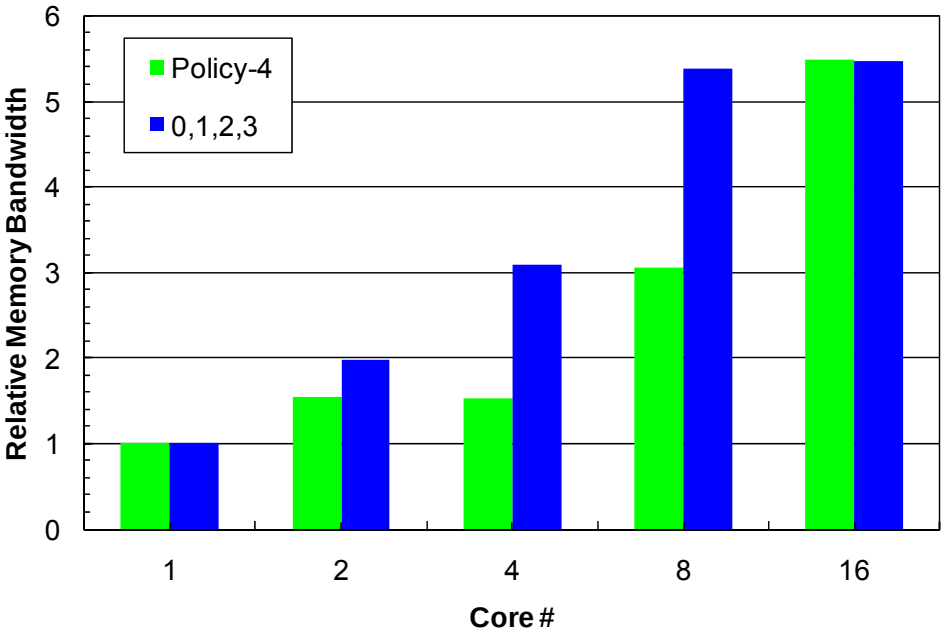

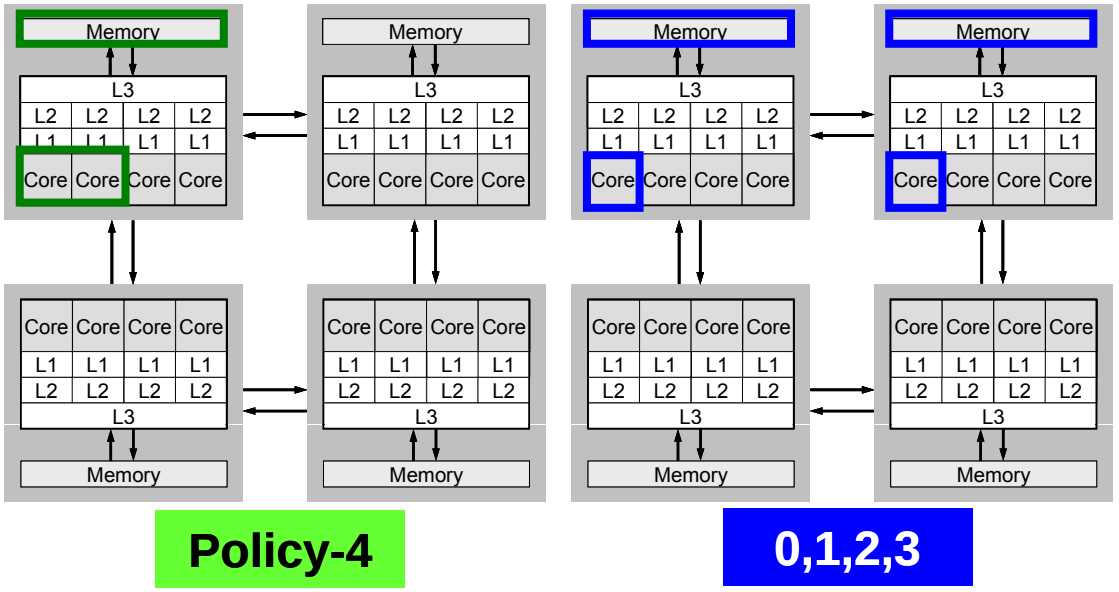

Triadの性能：T4

- Policy-4
  - T2のときとほとんど変わらない，つまり1コア当たりのメモリ性能は半分に落ちている
  - 飽和状態
- 0,1,2,3
  - T1の4倍までは行かないが順調にスケール
  - Cache-Coherency
  - 通信の影響もあり

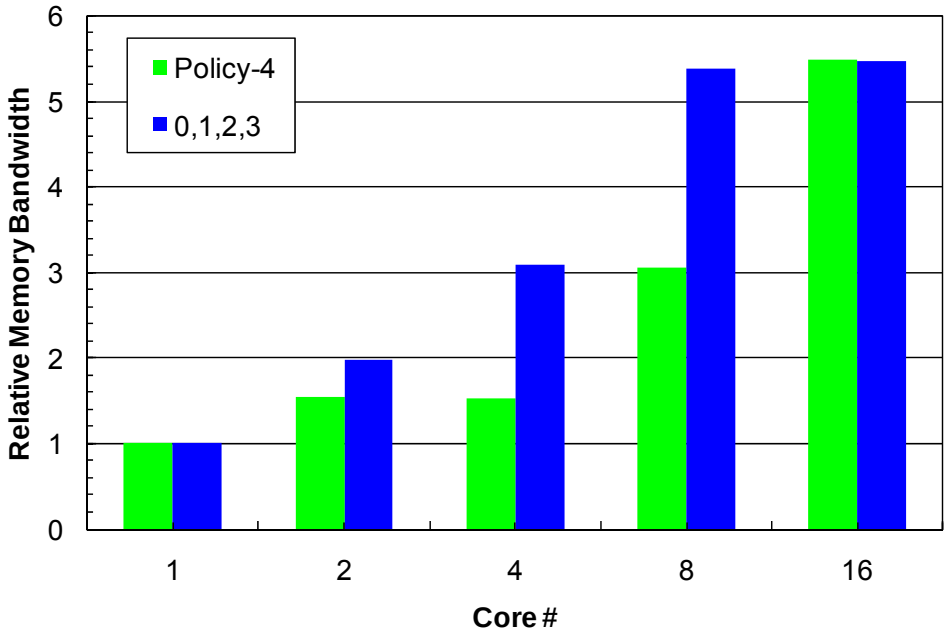

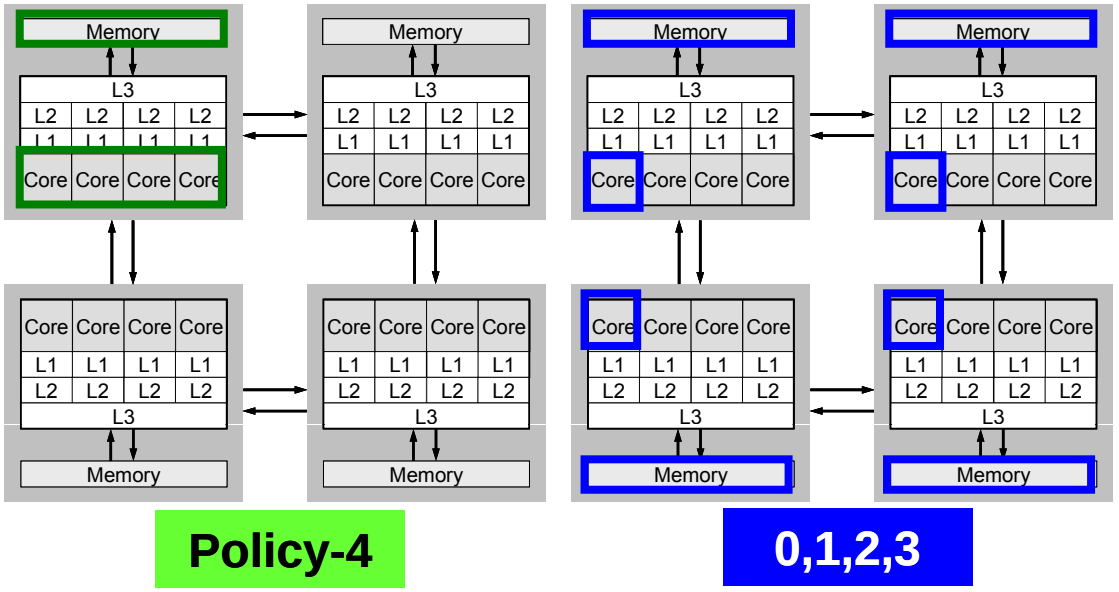

Triadの性能：T8，T16

- Policy-4
  - T8
    - T4の約2倍弱
  - T16
    - T8の約2倍弱
- 0,1,2,3
  - T8
    - T4の約2倍弱
  - T16
    - T8とほぼ同じ
    - Policy-4におけるT2→T4と同じ

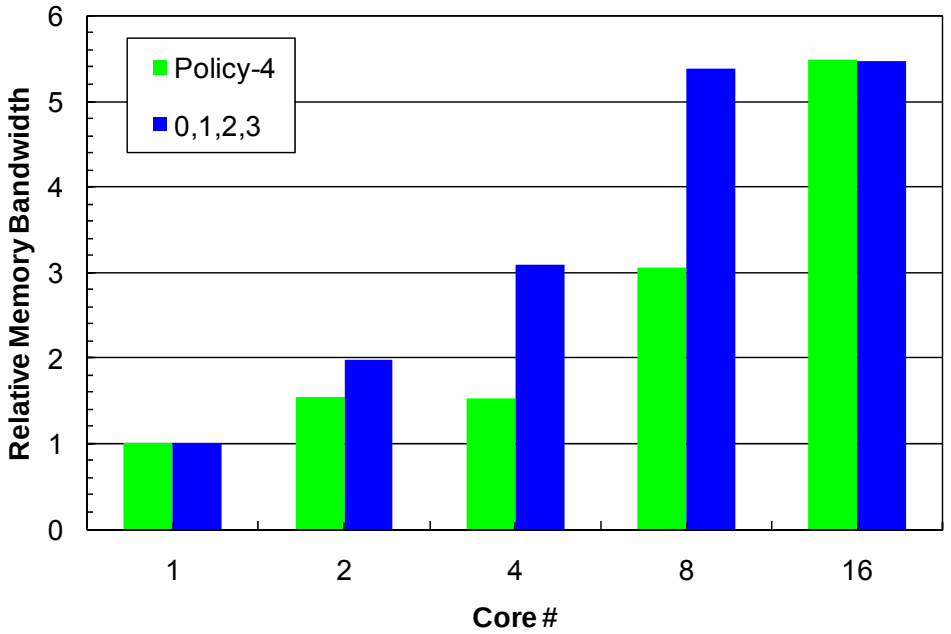

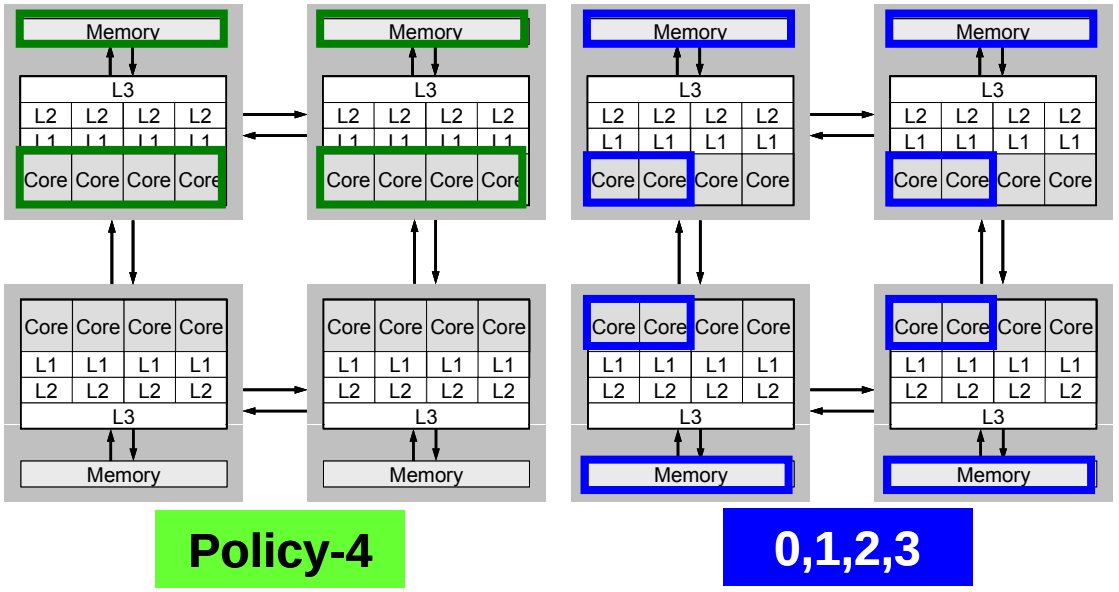

T2Kの性能

- 実は余りノード内の性能について細かく測定したことは無い
  - 1ノードが最低単位

- メモリの性能（の悪さ）に充分注意する必要がある
  - Strong Scaling（同じ問題をコア数を変えて解く）の場合，基準を1ノードあるいは1ソケット（Policy-2,3,4のようにする）にする

疎行列ソルバーの性能：三次元弾性問題

ICCG法，T2K・SR11000　1ノード：メモリバンド幅が効く

Hitachi SR11000/J2
Power 5+ 2.3GHz x 16
147.2 GFLOPS/node
100 GB/s for STREAM/Triad
L3 cache: 18MB/core

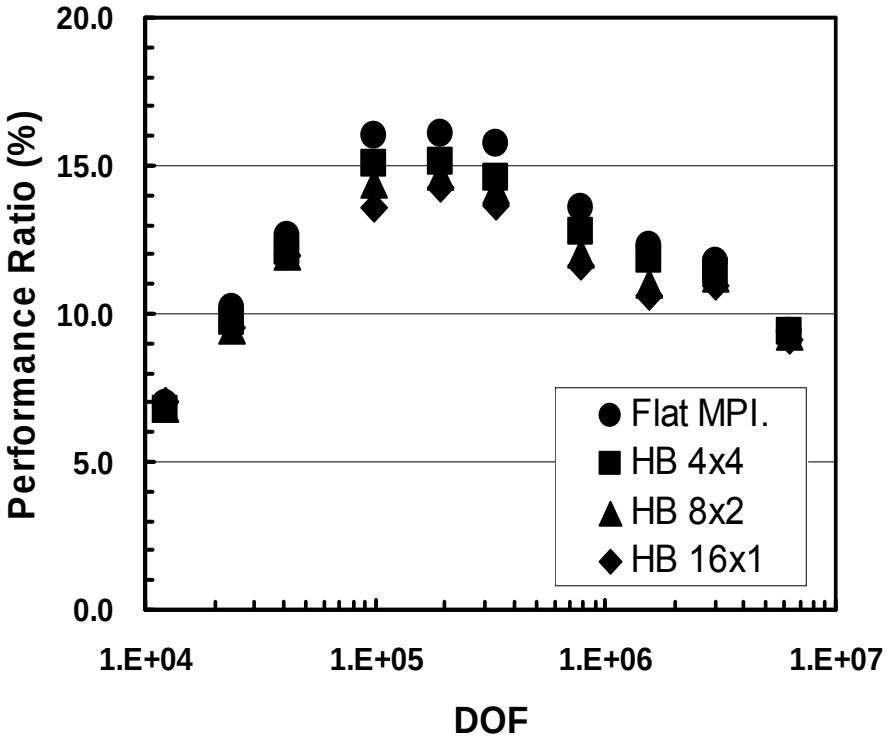

T2K/Tokyo
Opteron 2.3GHz x 16
147.2 GFLOPS/node
20 GB/s for STREAM/Triad
L3 cache: 0.5MB/core

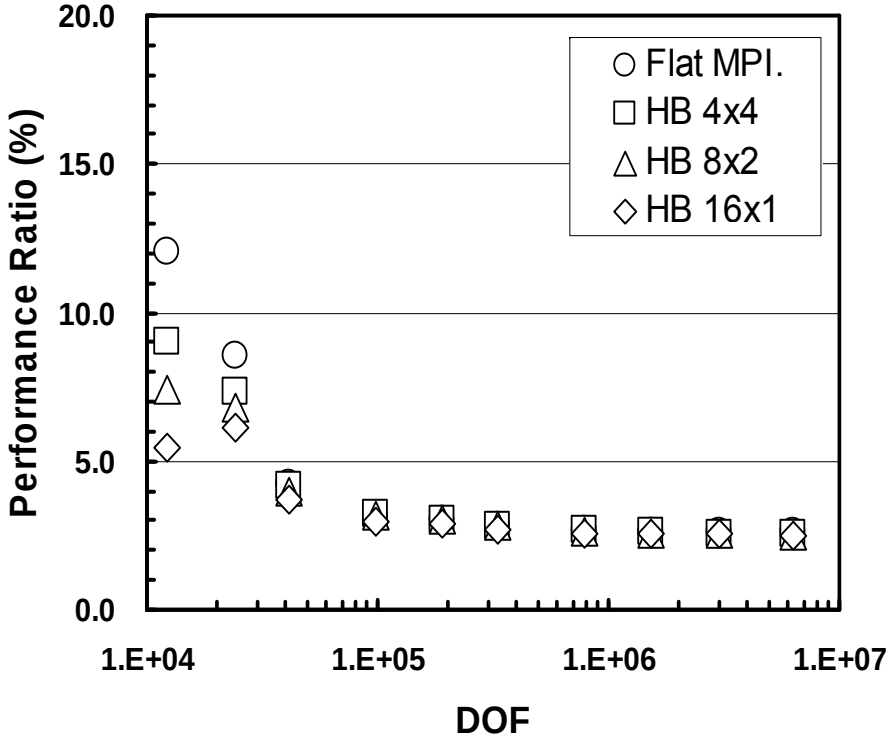

Hitachi SR11000/J2

- IBM POWER5+ 2.3GHz (9.2GFLOPS)
- Dual Core×4 ⇒「MCM（Multi Core Module）」×2 ⇒ 1node（16cores）
- based on NUMA architectures, but small latency of memory, huge cache

青木，中村，助川，齋藤，深川，中川，五百木（2005）
スーパーテクニカルサーバーSR11000 モデルJ1のノードアーキテクチュアと性能評価
情報処理学会論文誌：コンピューティングシステム 45-SIG12（ACS11），27-36 より作成

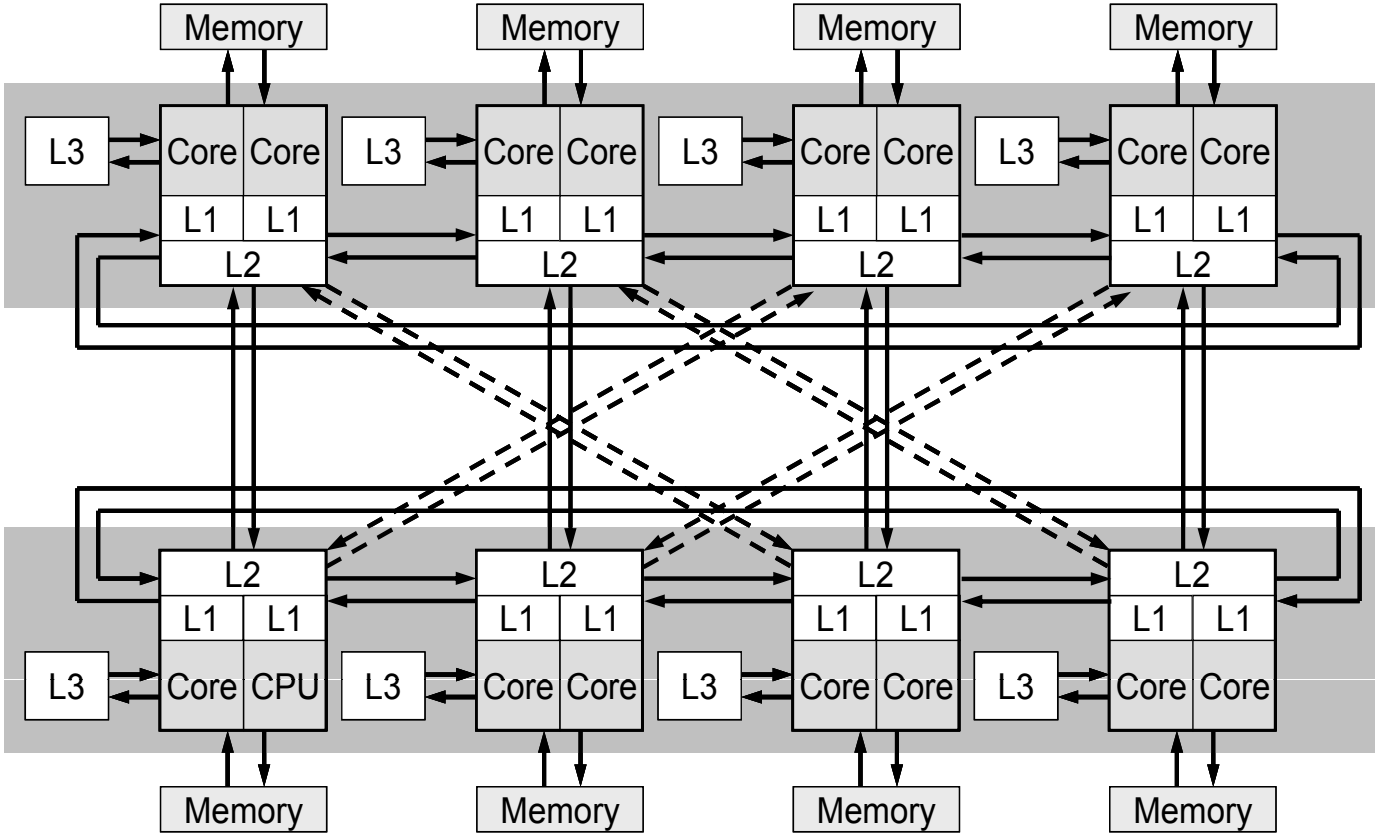

台形積分：T2K（東大）における並列効果

- ◆：N=10^6, ●：10^7, ▲：10^9
- ー：理想値
- 1コアにおける計測結果（sec.）からそれぞれ算出

```
#@$-r test
#@$-q lecture
#@$-N 1
#@$-J T4
#@$-e err
#@$-o hello.lst
#@$-lM 28GB
#@$-lT 00:05:00
#@$

cd $PBS_O_WORKDIR
mpirun numactl --localalloc ./a.out
```

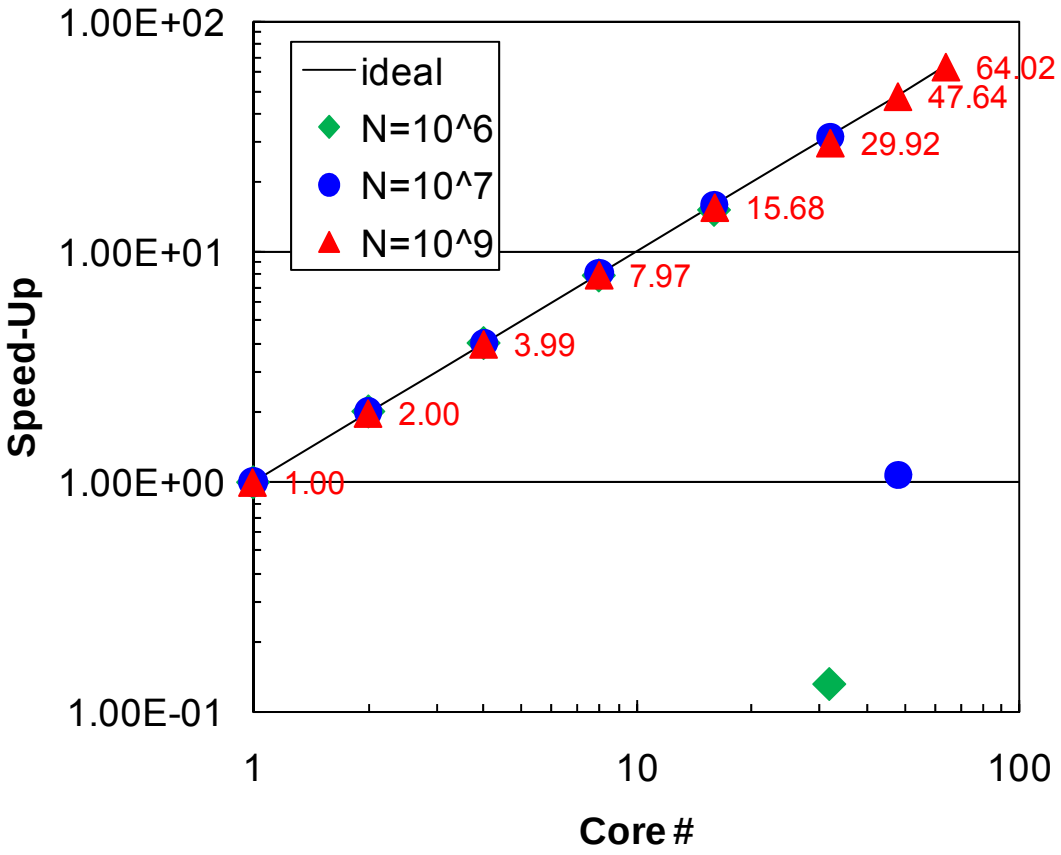

- 赤字部分の影響
- 1ノードより多いと変動あり
- メモリに負担のかからない計算