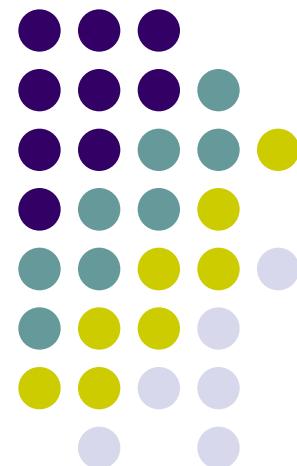


2013年度  
実践的並列コンピューティング  
第9回

---

GPUプログラミング (1)



遠藤 敏夫  
endo@is.titech.ac.jp  
2013年6月10日



# GPUコンピューティングとは

- グラフィックプロセッサ (GPU)は、グラフィック・ゲームの画像計算のために、進化を続けてきた
  - 現在、CPUのコア数は2~12個に対し、GPU中には数百コア
- そのGPUを一般アプリケーションの**高速化**に利用！
  - GPGPU (General-Purpose computing on GPU) とも言われる
- 2000年代前半から研究としては存在。2007年にNVIDIA社の**CUDA言語**がリリースされてから大きな注目





# TSUBAME2.0スーパーコンピュータ



Tokyo-Tech  
Supercomputer and  
UBiquitously  
Accessible  
Mass-storage  
Environment

「ツバメ」は東京工業大学の  
シンボルマークでもある

- TSUBAME1: 2006年～2010年に稼働したスパコン
- TSUBAME2.0: 2010年に作られたスパコン
  - 2010年には、世界4位、日本1位の計算速度性能
  - 現在、世界17位、日本3位

高性能の秘訣が  
GPUコンピューティング

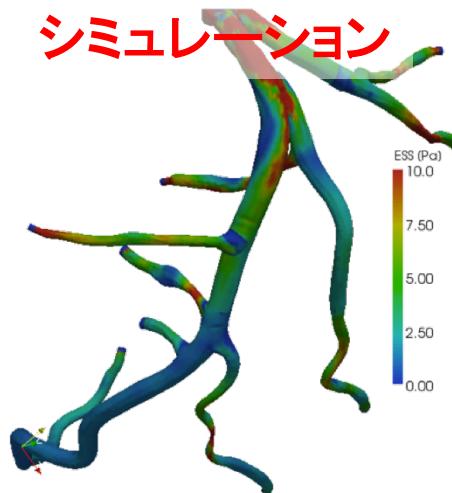
# TSUBAME2.0スパコン・GPUは様々な研究分野で利用されている



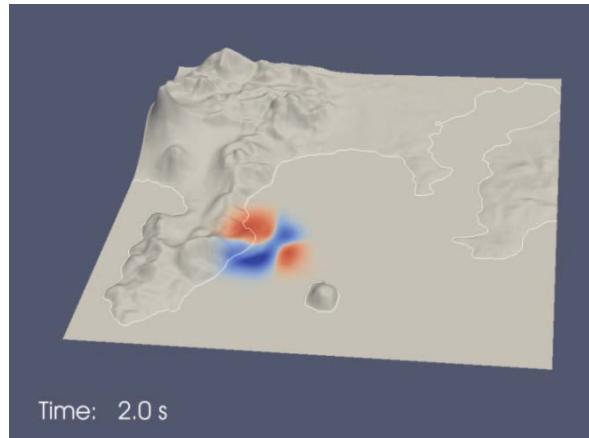
気象シミュレーション



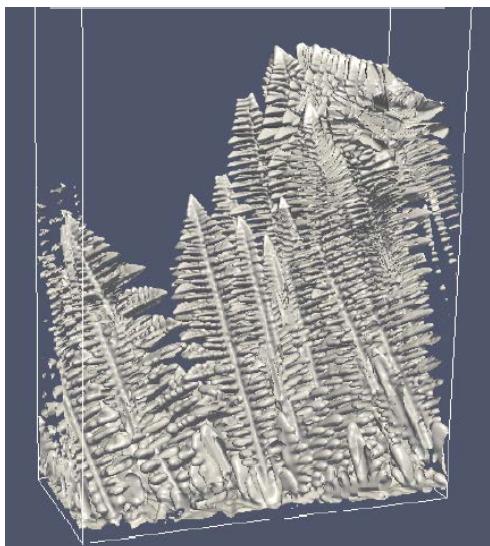
動脈血流  
シミュレーション



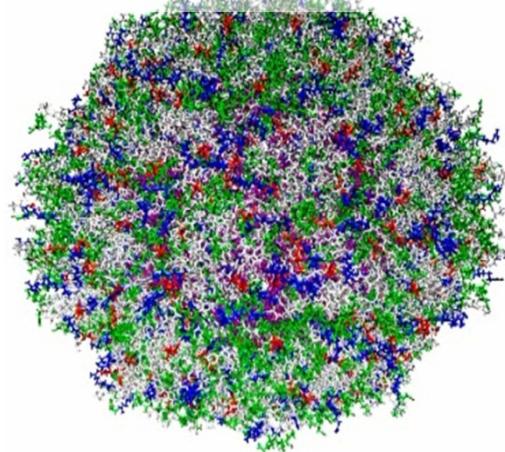
津波・防災  
シミュレーション



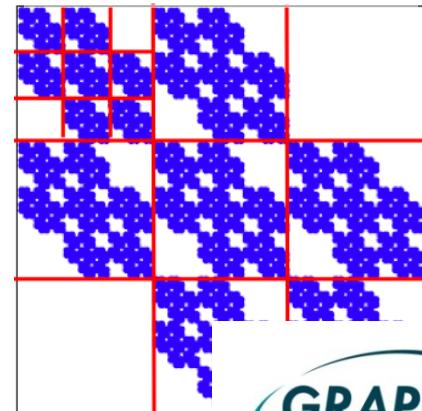
金属結晶凝固  
シミュレーション



ウィルス分子  
シミュレーション

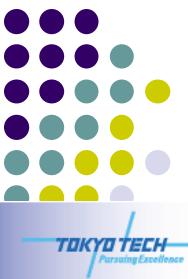


グラフ構造解析



GRAPH  
500

# TSUBAME 2.0 全体概要



## TSUBAME2.0: A GPU-centric Green 2.4 Petaflops Supercomputer

### Tsubame 2.0: "Tiny" footprint, very power efficient

- Floorspace less than 200m<sup>2</sup> (2,100 ft<sup>2</sup>)
- Top-class power efficient machine on the Green 500

System  
(42 Racks)  
1408 GPU Compute Nodes,  
34 Nehalem "Fat Memory" Nodes

Rack  
(8 Node Chassis)



2.4 PFLOPS  
80 TB

Node Chassis  
(4 Compute Nodes)



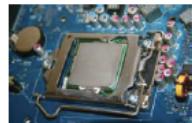
Chip  
(CPU ,GPU)



Compute Node  
(2 CPUs,3 GPUs)



1.6 TFLOPS  
55 GB/103 GB



CPU(Westmere EP)  
76.8 GFLOPS

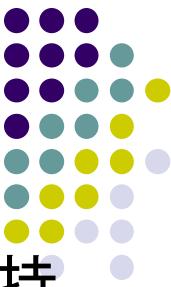


GPUs(Tesla M2050)  
515 GFLOPS  
3 GB

6.7 TFLOPS  
220 GB/412 GB

53.6 TFLOPS  
1.7 TB/3.2 TB

Integrated by NEC Corporation



# TSUBAME2.0の計算ノード

- TSUBAME2.0は、約1400台の計算ノード(コンピュータ)を持つ
- 各計算ノードは、CPUとGPUの両方を持つ
  - CPU: Intel Xeon 2.93GHz 6コア x 2CPU=12コア
  - GPU: NVIDIA Tesla M2050 3GPU

$$\text{CPU } 140\text{GFlops} + \text{GPU } 1545\text{GFlops} = 1685\text{GFlops}$$

GFlopsは計算速度の単位。  
9割の性能がGPUのおかげ!

- メインメモリ(CPU側メモリ): 54GB
- SSD: 120GB
- ネットワーク: QDR InfiniBand x 2 = 80Gbps
- OS: SUSE Linux 11 (**Linux**の一種)





# GPUの特徴 (1)

- コンピュータにとりつける増設ボード  
⇒単体では動作できず、CPUから指示を出してもらう
- 448コアを用いて計算  
⇒多数のコアを活用するために、多数のスレッドが協力して計算
- メモリサイズ3GB (実際使えるのは約2.5GB)  
⇒CPU側のメモリと別なので、「データの移動」もプログラミングする必要

上記のコア数・メモリサイズ  
は、M2050 GPU 1つあたり。  
製品によっても違う





# GPUの特徴 (2)

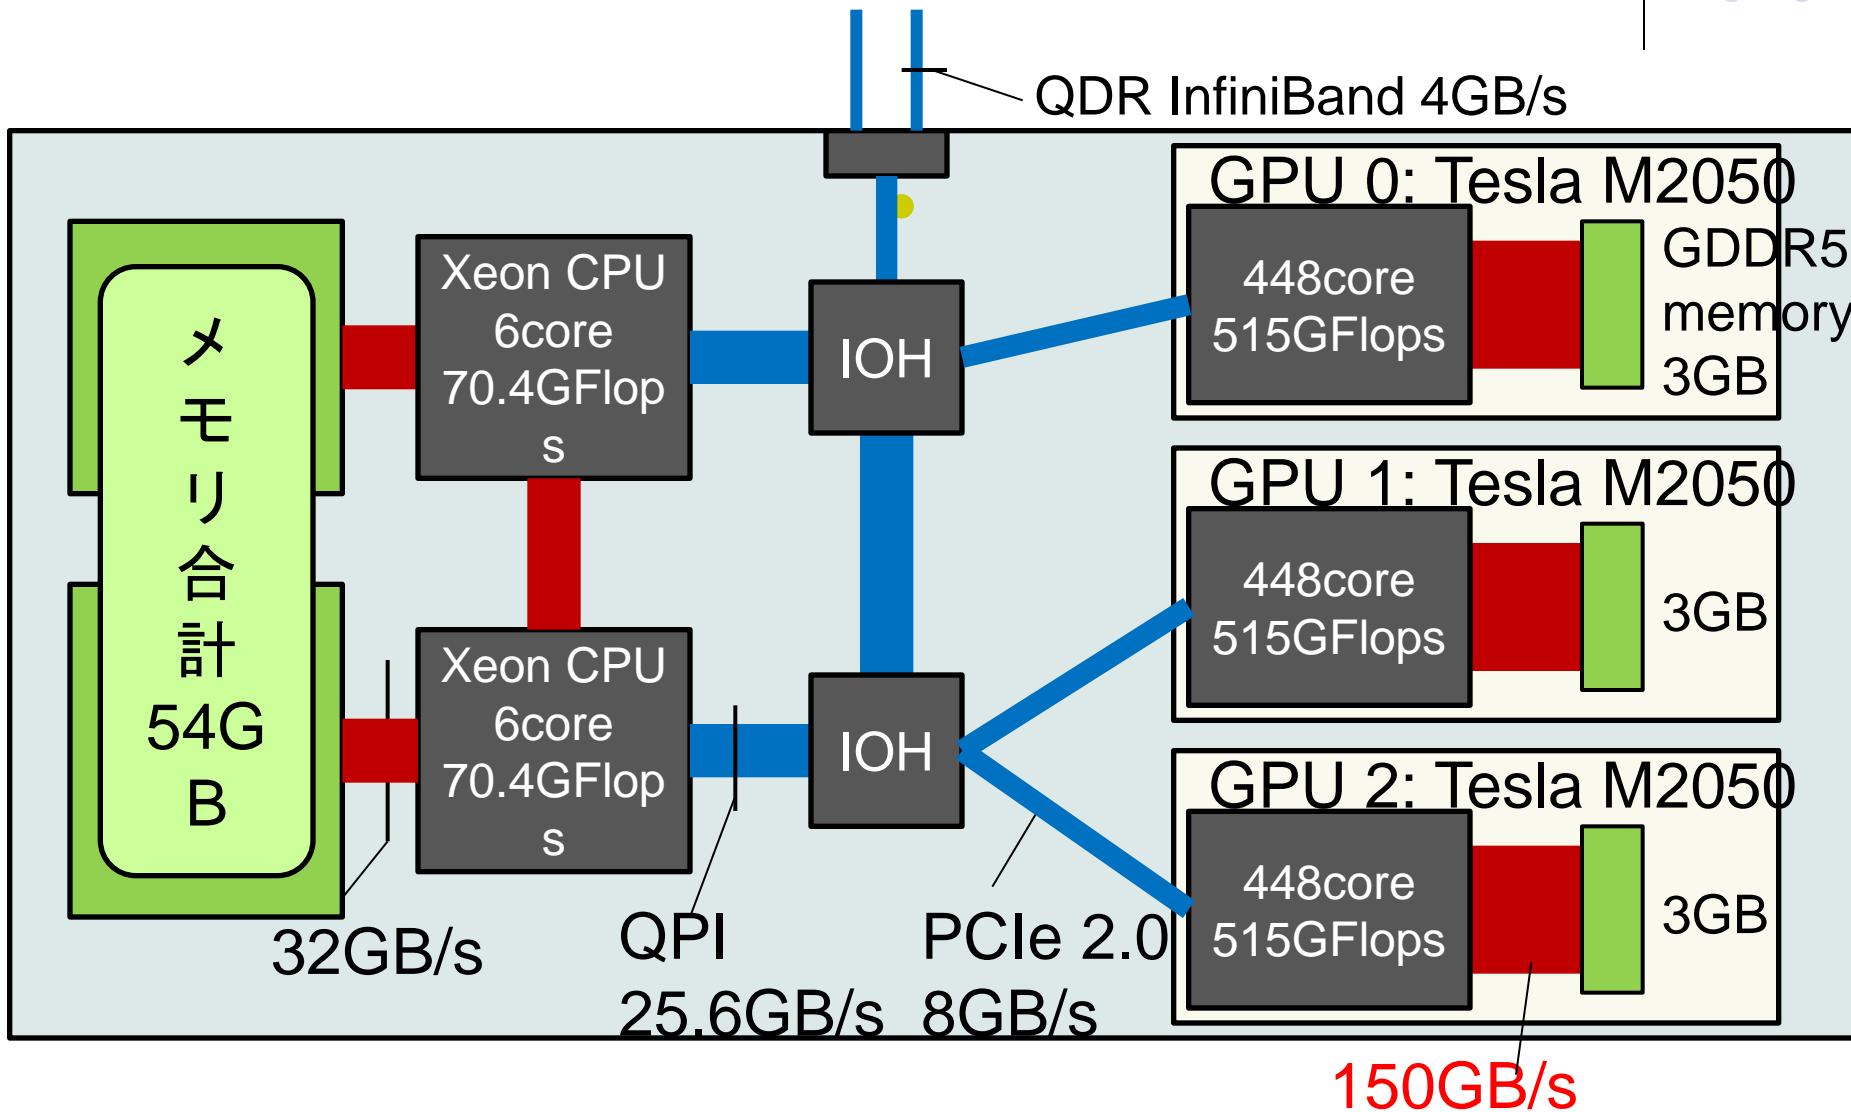
M2050 GPU 1つあたりの性能

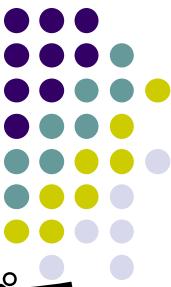
- 計算速度: 515 GFLOPS
  - CPUは20～100GFlops程度
- メモリバンド幅: 約150 GB/s
  - CPUは10～32GB/s程度
- その他の特徴
  - ハードウェアキャッシュ
  - C++サポート
  - ECC

以前のGPUにはキャッシュ  
メモリが無かったので、高  
速なプログラム作成がより  
大変だった



# 参考: 2CPUと3GPUを持つ TSUBAME2.0計算ノードの構成





# 様々なGPUやアクセラレータ

## • NVIDIA GPU

- GeForceシリーズ: 一般のPCに搭載されているタイプで、比較的安価。パソコンショップで売っている
- Teslaシリーズ: GPUコンピューティング専用ハードウェア。**TSUBAME2.0**に搭載されているのはTesla M2050
- Titan, Tianhe-1A, Nebulaeスパコン等

## • AMD/ATI GPU

## • 東芝・Sony・IBM Cellプロセッサ

- プレイステーション3に搭載
- Roadrunnerスパコン

## • Intel MICアーキテクチャ

- Xeon Phi: 約60コアプロセッサのボード
- ボード上でLinux OSが動き、OpenMPも動く
- Stampedeスパコン等



# 様々なGPU向けプログラミング言語

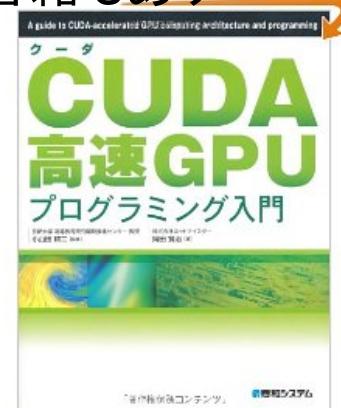
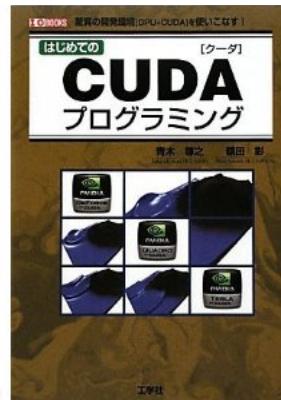
- CUDA (本講義でとりあげる)
  - NVIDIA GPU向けのプログラミング言語
- OpenCL
  - NVIDIA GPU, AMD GPU, 普通のIntelマルチコアCPUでも動く
  - ただし、CUDAよりさらに複雑な傾向
- OpenACC
  - お手軽なGPUプログラミングのために最近提案された
  - CPU用プログラムに、「ヒント」を追加



# プログラミング言語CUDA

- NVIDIA GPU向けのプログラミング言語
  - 2007年2月に最初のリリース
  - TSUBAME2.0で使えるのはV5.0
  - Linux, Windows, MacOS対応。本講義ではLinux版
- 標準C言語サブセット+GPGPU用拡張機能
  - C言語の基本的な知識(特にポインタ)は必要となります
  - Fortran版もあり
- nvccコマンドを用いてコンパイル
  - ソースコードの拡張子は.cu

CUDA関連書籍もあり



著者は東工大の  
青木先生・額田さん



# CUDAプログラムのコンパイルと実行例

- ~endo-t-ac/ppcomp/13/cuda ディレクトリ
- サンプルプログラム inc\_seq.cu を利用
- 以下のコマンドをターミナルから入力し、CUDA プログラムのコンパイル、実行を確認してください
- “\$” はコマンドプロンプトです

```
$ nvcc inc_seq.cu -arch sm_21 -o inc_seq
$ ./inc_seq
```

- **-arch sm\_21** は、最新のCUDA機能を使うためのオプション  
(普段つけておいてください)



# サンプルプログラム: inc\_seq.cu

int型配列の全要素を1加算

GPUであまり意味がない(速くない)例ですが

```
#include <stdio.h>
#include <stdlib.h>
#include <cuda.h>
#include <cuda_runtime.h>

#define N (32)
__global__ void inc(int *array, int len)
{
    int i;
    for (i = 0; i < len; i++)
        array[i]++;
    return;
}

int main(int argc, char *argv[])
{
    int i;
    int arrayH[N];
    int *arrayD;
    size_t array_size;
```

```
for (i=0; i<N; i++) arrayH[i] = i;
printf("input: ");
for (i=0; i<N; i++)
    printf("%d ", arrayH[i]);
printf("\n");

array_size = sizeof(int) * N;
cudaMalloc((void **)&arrayD, array_size);
cudaMemcpy(arrayD, arrayH, array_size,
           cudaMemcpyHostToDevice);
inc<<<1, 1>>>(arrayD, N);
cudaMemcpy(arrayH, arrayD, array_size,
           cudaMemcpyDeviceToHost);
printf("output: ");
for (i=0; i<N; i++)
    printf("%d ", arrayH[i]);
printf("\n");
return 0;
}
```

# CUDAプログラム構成



ホストプログラム + GPUカーネル関数

- ホストプログラム
  - CPU上で実行されるプログラム
  - ほぼ通常のC言語。main関数から処理がはじまる
  - GPUに対してデータ転送、GPUカーネル関数呼び出しを実行
- GPUカーネル関数
  - GPU上で実行される関数 (サンプルではinc関数)
  - ホストプログラムから呼び出されて実行
  - (単にカーネル関数と呼ぶ場合も)

# 典型的な制御とデータの流れ

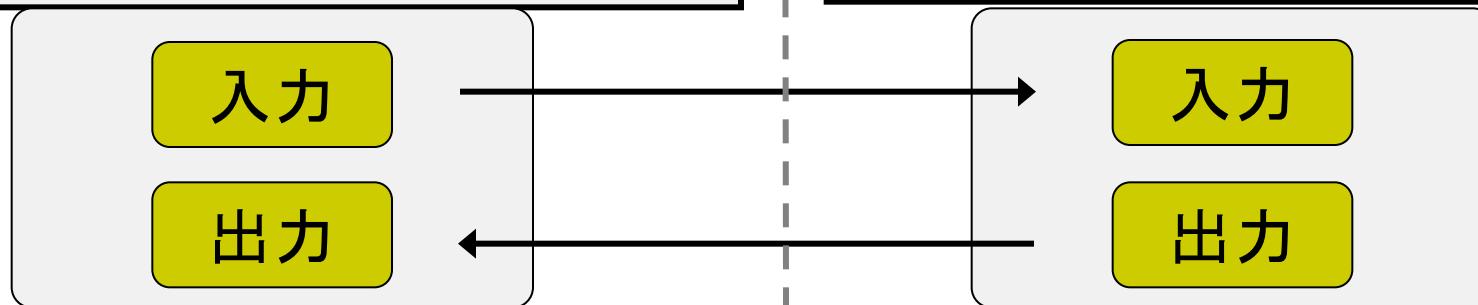


@ CPU

- (1) GPU側メモリにデータ用領域を確保
- ↓
- (2) 入力データをGPUへ転送
- ↓
- (3) GPUカーネル関数を呼び出し
- ↓
- (5) 出力をCPU側メモリへ転送

@ GPU

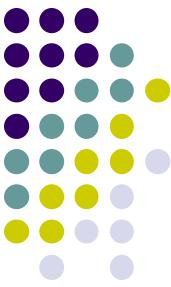
```
__global__ void kernel_func()  
{  
    ↓ (4)カーネル関数  
    return;  
}
```



CPU側メモリ(メインメモリ)

GPU側メモリ(デバイスマメモリ)

この2種類のメモリの  
区別は常におさえておく

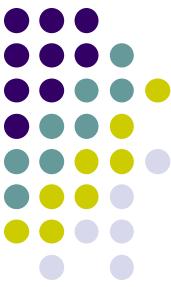


# (1) @CPU: GPU側メモリ領域確保

- `cudaMalloc(void **devpp, size_t count)`
  - GPU側メモリ(デバイスマメリ、グローバルメモリと呼ばれる)に領域を確保
  - `devpp`: デバイスマモリアドレスへのポインタ。確保したメモリのアドレスが書き込まれる
  - `count`: 領域のサイズ
- `cudaFree(void *devp)`
  - 指定領域を開放

例: 長さ1024のintの配列を確保

```
#define N (1024)
int *arrayD;
cudaMalloc((void **) &arrayD, sizeof(int) * N);
// arrayD has the address of allocated device memory
```

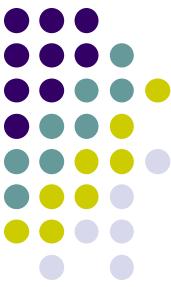


## (2) @CPU: 入力データ転送

- `cudaMemcpy(void *dst, const void *src, size_t count, enum cudaMemcpyKind kind)`
  - 先に`cudaMalloc`で確保した領域に指定したCPU側メモリのデータをコピー
  - `dst`: 転送先デバイスマモリ
  - `src`: 転送元CPUメモリ
  - `count`: 転送サイズ(バイト単位)
  - `kind`: 転送タイプを指定する定数。ここでは`cudaMemcpyHostToDevice`を与える

例: 先に確保した領域へCPU上のデータ`arrayH`を転送

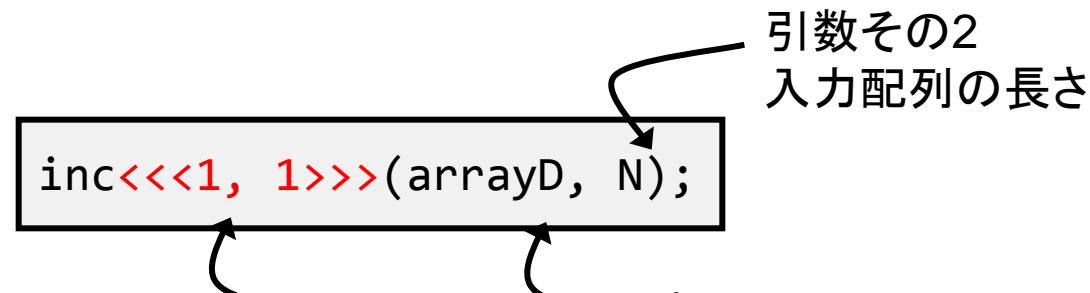
```
int arrayH[N];
cudaMemcpy(arrayD, arrayH, sizeof(int)*N,
           cudaMemcpyHostToDevice);
```



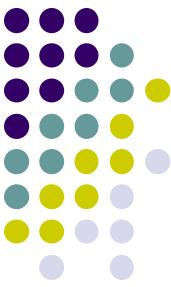
## (3) @CPU: GPUカーネルの呼び出し

- `kernel_func<<<grid_dim, block_dim>>>`  
`(kernel_param1, ...);`
  - `kernel_func`: カーネル関数名
  - `kernel_param`: カーネル関数の引数

例： カーネル関数 “inc” を呼び出し



CUDA特有な構文により、  
スレッド数を記述する。  
詳しくは後で

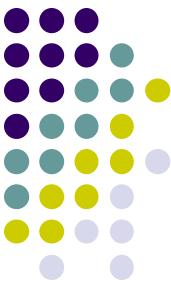


## (4) @GPU: カーネル関数

- GPU上で実行される関数
  - globalというキーワードをつける  
注:「global」の前後にはアンダーバー2つずつ
- GPU側メモリのみアクセス可、CPU側メモリはアクセス不可
- 引数利用可能
- 値の返却は不可 (voidのみ)

例: int型配列をインクリメントするカーネル関数

```
global void inc(int *array, int len)
{
    int i;
    for (i = 0; i < len; i++) array[i]++;
    return;
}
```

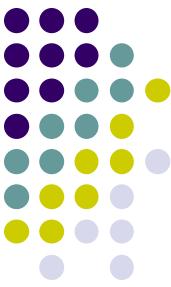


## (5) @CPU: 結果の返却

- 入力転送と同様にcudaMemcpyを用いる
- ただし、転送タイプは  
cudaMemcpyDeviceToHost を指定

例： 結果の配列をCPU側メモリへ転送

```
cudaMemcpy(arrayH, arrayD, sizeof(int)*N,  
cudaMemcpyDeviceToHost);
```

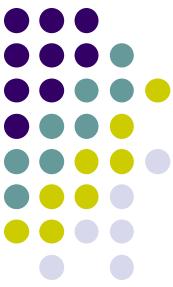


# カーネル関数内でできること・できないこと

- if, for, whileなどの制御構文はok
- GPU側メモリのアクセスはok、CPU側メモリのアクセスは不可
  - inc\_seqサンプルで、arrayDと間違ってarrayHをカーネル関数に渡してしまったとバグ!! (何が起こるか分からない)
- ファイルアクセスなどは不可
  - printfは例外的にokなので、デバッグに役立つ
- 関数呼び出しは、「\_\_device\_\_つき関数」に対してならok



- 上図の矢印の方向にのみ呼び出しできる
  - GPU内からCPU関数は呼べない
- \_\_device\_\_つき関数は、返り値を返せるので便利



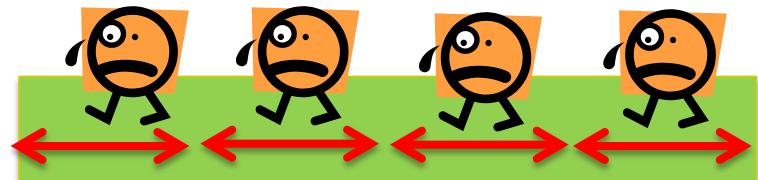
# CUDAにおける並列化

- たくさんのスレッドがGPU上で並列に動作することにより、初めてGPUを有効活用できる
  - inc\_seqプログラムは1スレッドしか使っていない
- データ並列性を基にした並列化が一般的
  - 例：巨大な配列があるとき、各スレッドが一部づつを分担して処理 → 高速化が期待できる

一人の小人が大きな畠  
を耕す場合



複数の小人が分担して  
耕すと早く終わる





# CUDAにおけるスレッド(1)

- CUDAでのスレッドは階層構造になっている
  - グリッドは、複数のスレッドブロックから成る
  - スレッドブロックは、複数のスレッドから成る
- カーネル関数呼び出し時にスレッド数を二段階で指定

```
kernel_func<<<100, 30>>>(a, b, c);
```

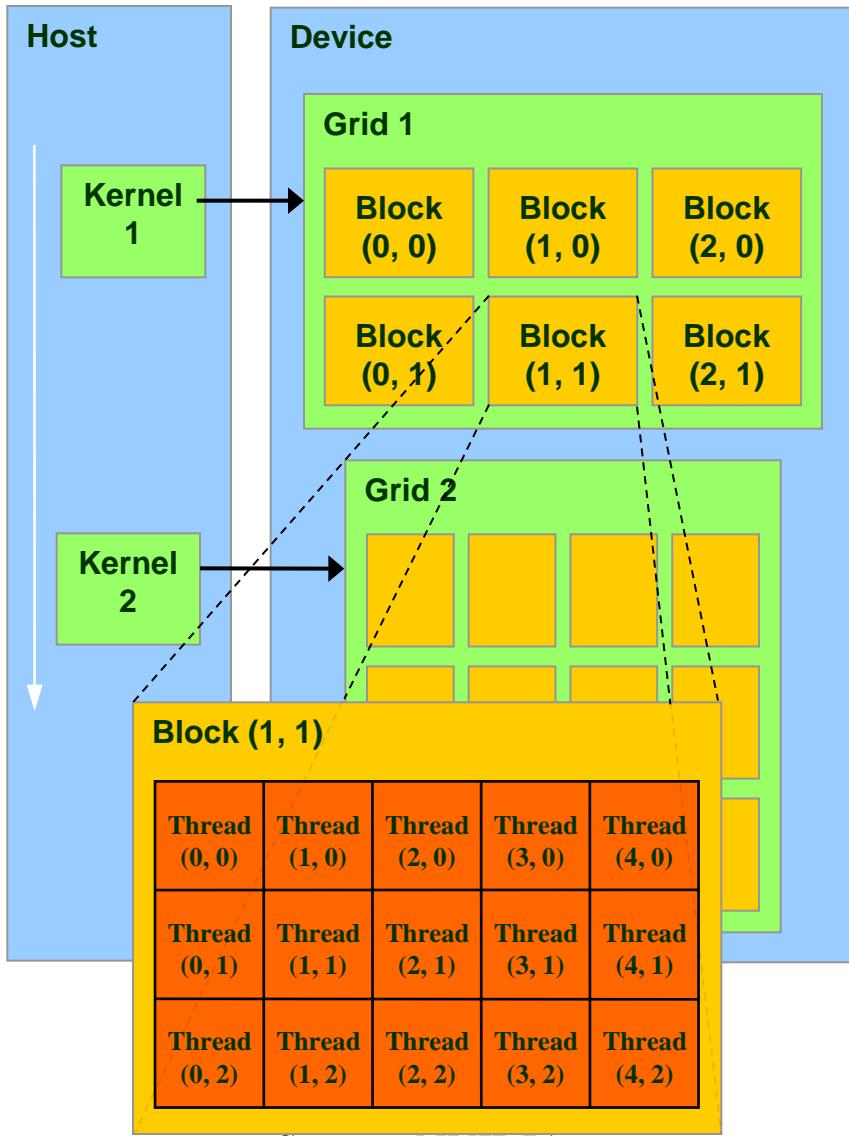
スレッドブロックの数

(スレッドブロックあたりの)  
スレッドの数

- この例では、 $100 \times 30 = 3000$ 個のスレッドが kernel\_func を並列に実行する



# CUDAでのスレッド(2)

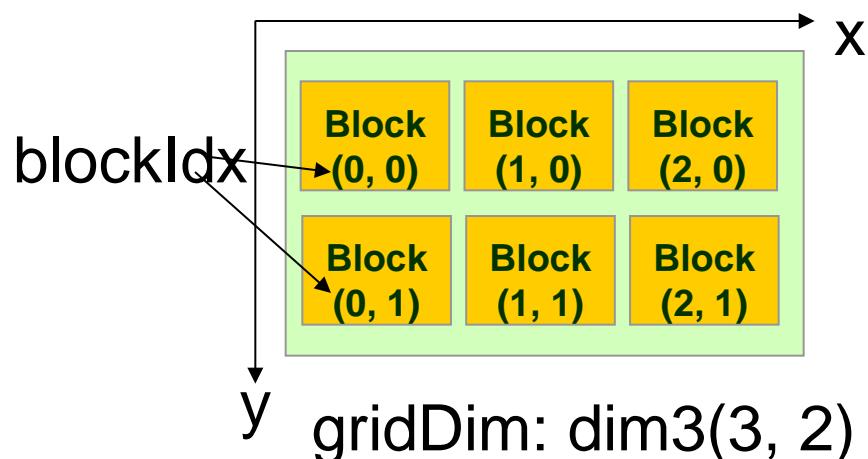


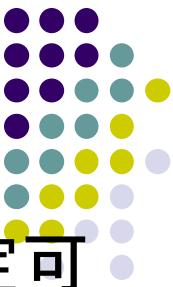
- スレッドブロック数およびスレッド数はそれぞれが
    - int型整数
    - 三次元のdim3型 (CUDA特有) のどちらか
  - 指定例
    - <<<100, 30>>>
    - <<<dim3(100,20,5), dim3(4, 8, 4)>>>
    - <<<4, dim3(20, 9)>>>
- なお、dim3(100,1,1)と100は同じ意味となる



# グリッドとスレッドブロック

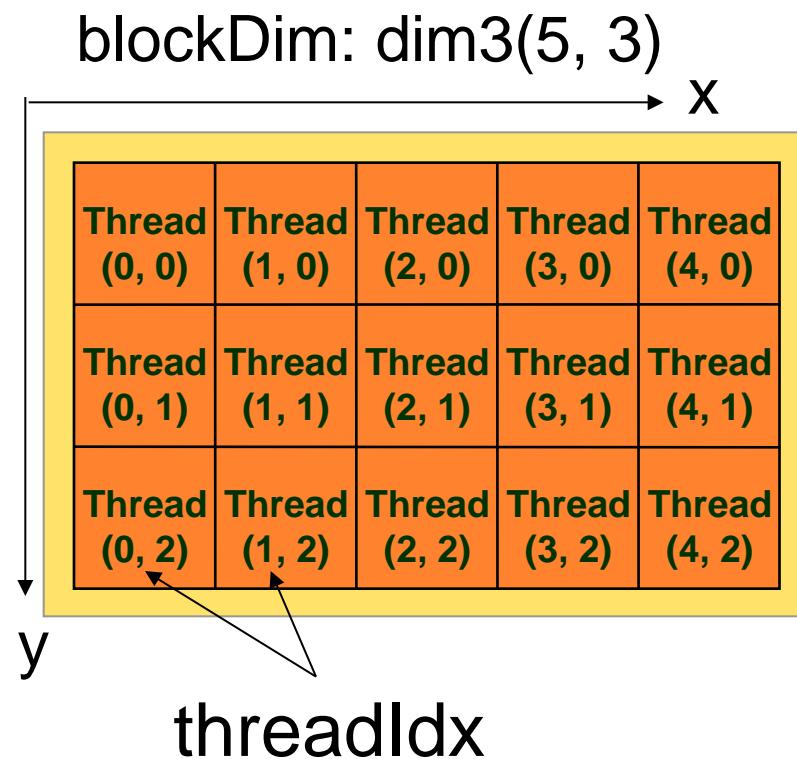
- 1次元、2次元、3次元でグリッドのサイズを指定可
- 各スレッドが「自分は誰か？」を知るために、以下を利用可能
  - dim3 **gridDim**
    - グリッドサイズ
  - dim3 **blockIdx**
    - グリッド内のブロックのインデックス、つまり自分が何番目のブロックに属するか。  
(0からはじまる)
- 1次元目は  
**gridDim.x**, **blockIdx.x**として利用
- 同様に、2次元目は～**.y**, 3次元目は～**.z**
- 最大サイズ(M2050 GPUでは)
  - 65535 × 65535 × 65535

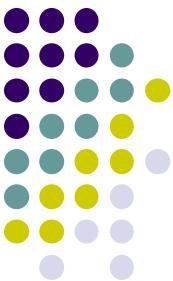




# スレッドブロックとスレッド

- 1次元、2次元、3次元でスレッドブロックのサイズを指定可能
- 各スレッドが「自分は誰か？」を知るために、以下を利用可能
  - dim3 **blockDim**
    - スレッドブロックサイズ
  - dim3 **threadIdx**
    - ブロック内のスレッドインデックス、つまりブロック内で自分が何番目のスレッドか。  
(0からはじまる)
- 最大サイズの制限有り
  - M2050 GPU ではxは1024まで、yは1024まで、zは64まで
  - 全体で1024まで





# サンプルプログラムの改良

inc\_parは、inc\_seqと同じ計算を行うが、  
N要素の計算のためにNスレッドを利用する点が違う

```
#include <stdio.h>
#include <stdlib.h>
#include <cuda.h>
#include <cuda_runtime.h>

#define N  (32)
#define BS (8)
__global__ void inc(int *array, int len)
{
    int i = blockIdx.x * blockDim.x +
            threadIdx.x;
    array[i]++;
    return;
}

int main(int argc, char *argv[])
{
    int i;
    int arrayH[N];
    int *arrayD;
    size_t array_size;
```

```
for (i=0; i<N; i++) arrayH[i] = i;
printf("input: ");
for (i=0; i<N; i++)
    printf("%d ", arrayH[i]);
printf("\n");

array_size = sizeof(int) * N;
cudaMalloc((void **)&arrayD, array_size);
cudaMemcpy(arrayD, arrayH, array_size,
           cudaMemcpyHostToDevice);
inc<<<N/BS, BS>>>(arrayD, N);
cudaMemcpy(arrayH, arrayD, array_size,
           cudaMemcpyDeviceToHost);
printf("output: ");
for (i=0; i<N; i++)
    printf("%d ", arrayH[i]);
printf("\n");
return 0;
}
```



# inc\_parプログラムのポイント (1)

- N要素の計算のためにNスレッドを利用

```
inc<<<N/BS, BS>>>(.....);
```

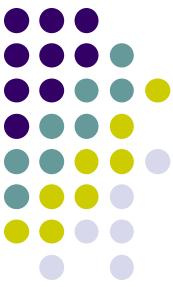
グリッドサイズ

スレッドブロックサイズ

この例では、前もってBS=8とした

ちなみに、<<<N, 1>>>や  
<<<1, N>>>でも動くのだが  
が非効率的である。

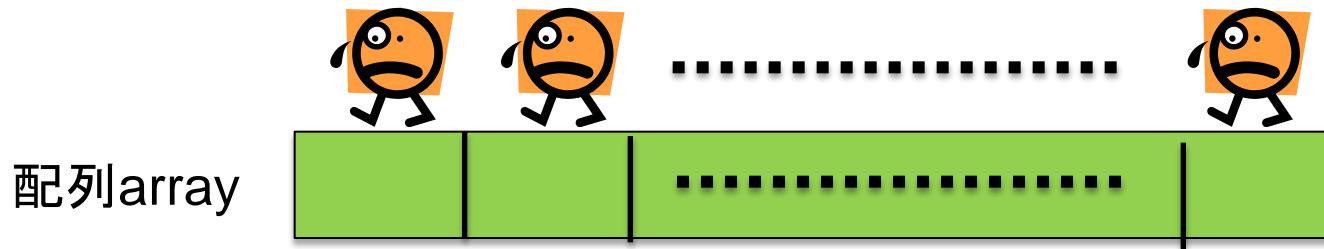
ちなみに、このままでは、NがBSで割  
り切れないときに正しく動かない。ど  
う改造すればよいか？



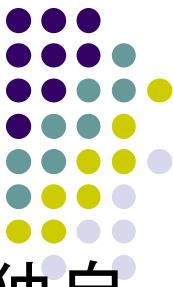
# inc\_parプログラムのポイント (2)

inc\_parの並列化の方針

- (通算で)0番目のスレッドにarray[0]の計算をさせる
- 1番目のスレッドにarray[1]の計算
- :
- N-1番目のスレッドにarray[N-1]の計算

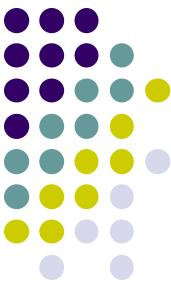


- 各スレッドは「自分は通算で何番目のスレッドか?」を知るために、下記を計算  
 $i = blockIdx.x * blockDim.x + threadIdx.x;$  いまわせる便利な式
- 1スレッドは"array[i]"の1要素だけ計算 → forループは無し



# 変数・メモリに関するルール

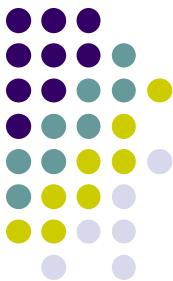
- カーネル関数内で宣言される**変数**は、各スレッド独自の値を持つ
  - あるスレッドでは $i=0$ , 別のスレッドでは $i=1 \dots$
- カーネル関数に与えられた**引数**は、全スレッド同じ値
  - inc\_parプログラムでは、arrayポインタとlen
- 全スレッドは**GPU側メモリを共有**しており、読み書きできる
  - ただし、複数スレッドが同じ場所に書き込むとぐちゃぐちゃ(race condition)になるので注意
  - 同じ場所を読み込むのはok



# 効率のよいプログラムのために

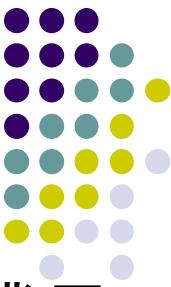
- グリッドサイズが14以上、かつスレッドブロックサイズが32以上の場合に効率的
  - M2050 GPUでは
    - GPU中のSM数=14
    - SM中のCUDA core数=32 なので
  - ぎりぎりよりも、数倍以上にしたほうが効率的な場合が多い(ベストな点はプログラム依存)

ほかにも色々効率化のポイントあり → 応用編で



# 今回のまとめ

- GPUプログラミングとTSUBAME2.0スパコンについて説明した
- CUDAプログラミング言語の基礎について説明した
  - CPU側メモリ(メインメモリ)とGPU側メモリ(デバイスマメモリ)は異なるため、cudaMemcpyでデータをコピーする
  - GPUカーネル関数を呼ぶ際には、グリッドサイズとスレッドブロックサイズ(その積がスレッド数)を指定



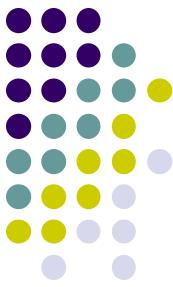
# About Account

- TSUBAME2のアカウントができたら、連絡してください。授業用のTSUBAMEグループへ登録します。

Subject: TSUBAME2 pppcomp account

To: endo@is.titech.ac.jp

- 専攻・研究室
- 学年
- 氏名
- アカウント名



# 次回/Next Lecture

- 6/17(月)は休講
- 6/24(月)
  - CUDAによるGPUプログラミング (2)
  - GPU編の課題について
- スケジュールについてはOCW pageも参照
  - <http://www.el.gsic.titech.ac.jp/~endo/>  
→ 2013年度前期情報(OCW) → 講義ノート