W • SENSE
INTEGRATED CABLELESS SOLUTIONS


SAPIENZA
UNIVERSITÀ DI ROMA

# Programmazione di sistemi multicore CUDA

Fabrizio Gattuso

# Avvisi

12 Dicembre **NO LEZIONE PER IT MEETING**

**Il secondo esonero sarà svolto insieme al pirmo appello**

Date esame completo e primo esonero:

- **14 Gennaio** ore 16-18, Aula 2L - Via del Castro Laurenziano 7A
- **4 Febbraio** ore 16-18, Aula 2L - Via del Castro Laurenziano 7A

È uscito il codice OPIS per la **valutazione del corso**

È importante che cominciate ad **inviare la mail con la richiesta materiale per il progetto**

# CUDA

L'architettura **CUDA** è composta da due componenti:

1. L'**hardware** CUDA (le GPU NVIDIA)
2. Le **librerie** CUDA che estendono il **C** standard.

Ovviamente per eseguire il codice è necessario avere una scheda dedicata NVIDIA. In queste lezioni parleremo in modo molto generale del paradigma e del framework.

# CUDA (2)

Per chi è munito di scheda video NVIDIA:

https://developer.nvidia.com/cuda-downloads

- Online esistono diversi **emulatori** ma non sono molto semplici da utilizzare o installare.
- Se siete in possesso di buoni **Amazon Cloud** allora potete utilizzare una macchina dotata di scheda video.
- Per possessori di schede video di altri brand **Open CL** è un framework alternativo ma molto simile sia nella sintassi che nel paradigma CUDA.

# Calcolo eterogeneo

Il codice sviluppato per la piattaforma CUDA è definito eterogeneo in quanto:

- Alcune parti del codice sono eseguite sulla **CPU**
- Altre parti vengono eseguite direttamente sulla **GPU**

La CPU è chiamata ***Host*** mentre la GPU ***Device***

# Calcolo eterogeneo (2)

```
#include <iostream>
#include <algorithm>

using namespace std;

#define N          1024
#define RADIUS     3
#define BLOCK_SIZE 16

__global__ void stencil_1d(int *in, int *out) {
        __shared__ int temp[BLOCK_SIZE + 2 * RADIUS];
        int gindex = threadIdx.x + blockIdx.x * blockDim.x;
        int lindex = threadIdx.x + RADIUS;

        // Read input elements into shared memory
        temp[lindex] = in[gindex];
        if (threadIdx.x < RADIUS) {
                temp[lindex - RADIUS] = in[gindex - RADIUS];
                temp[lindex + BLOCK_SIZE] = in[gindex + BLOCK_SIZE];
        }

        // Synchronize (ensure all the data is available)
        __syncthreads();

        // Apply the stencil
        int result = 0;
        for (int offset = -RADIUS ; offset <= RADIUS ; offset++)
                result += temp[lindex + offset];

        // Store the result
        out[gindex] = result;
}

void fill_ints(int *x, int n) {
        fill_n(x, n, 1);
}

int main(void) {
        int *in, *out;          // host copies of a, b, c
        int *d_in, *d_out;      // device copies of a, b, c
        int size = (N + 2*RADIUS) * sizeof(int);

        // Alloc space for host copies and setup values
        in  = (int *)malloc(size); fill_ints(in,  N + 2*RADIUS);
        out = (int *)malloc(size); fill_ints(out, N + 2*RADIUS);

        // Alloc space for device copies
        cudaMalloc((void **)&d_in,  size);
        cudaMalloc((void **)&d_out, size);

        // Copy to device
        cudaMemcpy(d_in,  in,  size, cudaMemcpyHostToDevice);
        cudaMemcpy(d_out, out, size, cudaMemcpyHostToDevice);

        // Launch stencil_1d() kernel on GPU
        stencil_1d<<<N/BLOCK_SIZE,BLOCK_SIZE>>>(d_in + RADIUS,
d_out + RADIUS);

        // Copy result back to host
        cudaMemcpy(out, d_out, size, cudaMemcpyDeviceToHost);

        // Cleanup
        free(in); free(out);
        cudaFree(d_in); cudaFree(d_out);
        return 0;
}
```

parallel fn

serial code

parallel code

serial code

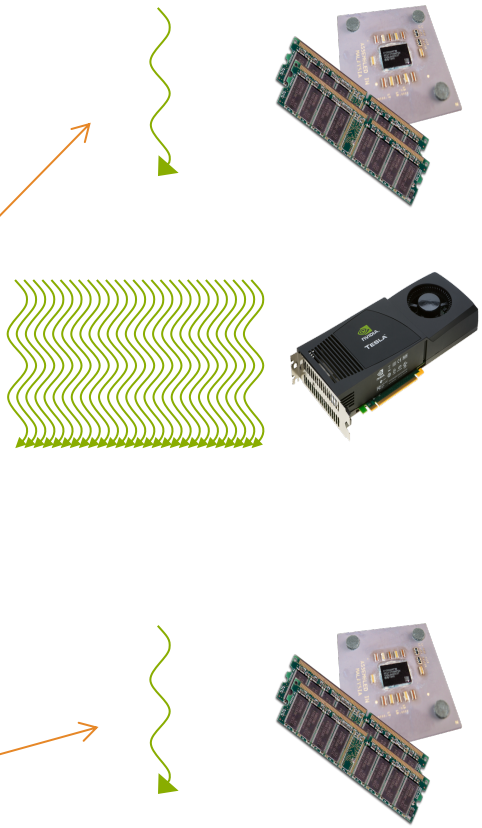

# Flusso di computazione

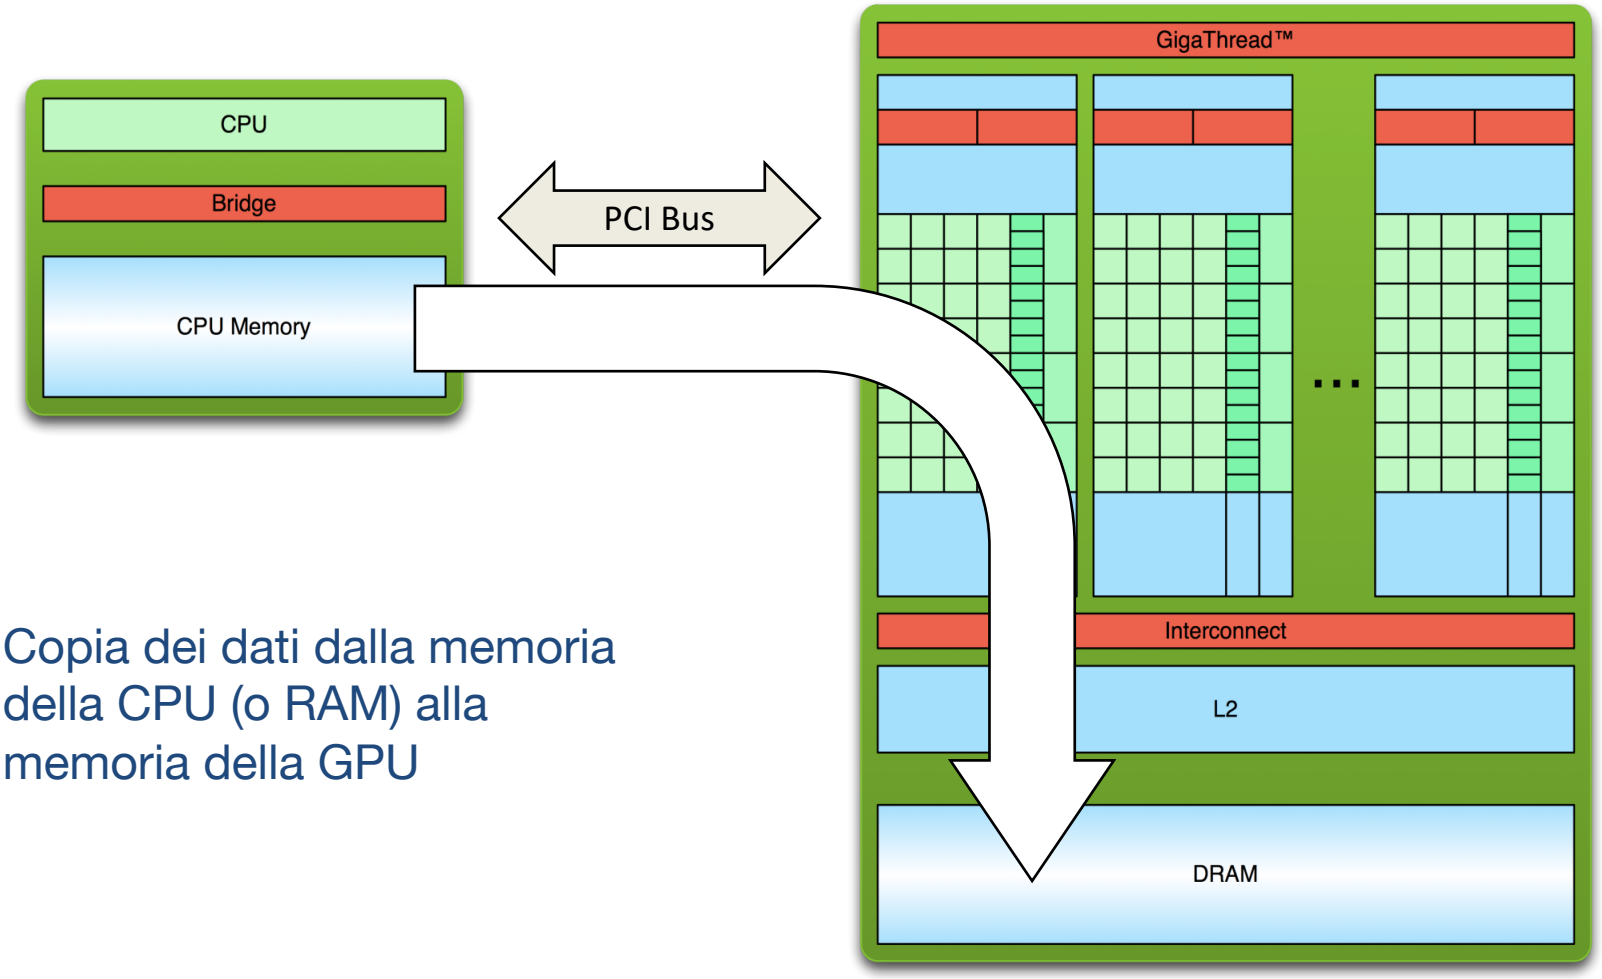


1. Copia dei dati dalla memoria della CPU (o RAM) alla memoria della GPU

# Flusso di computazione (2)

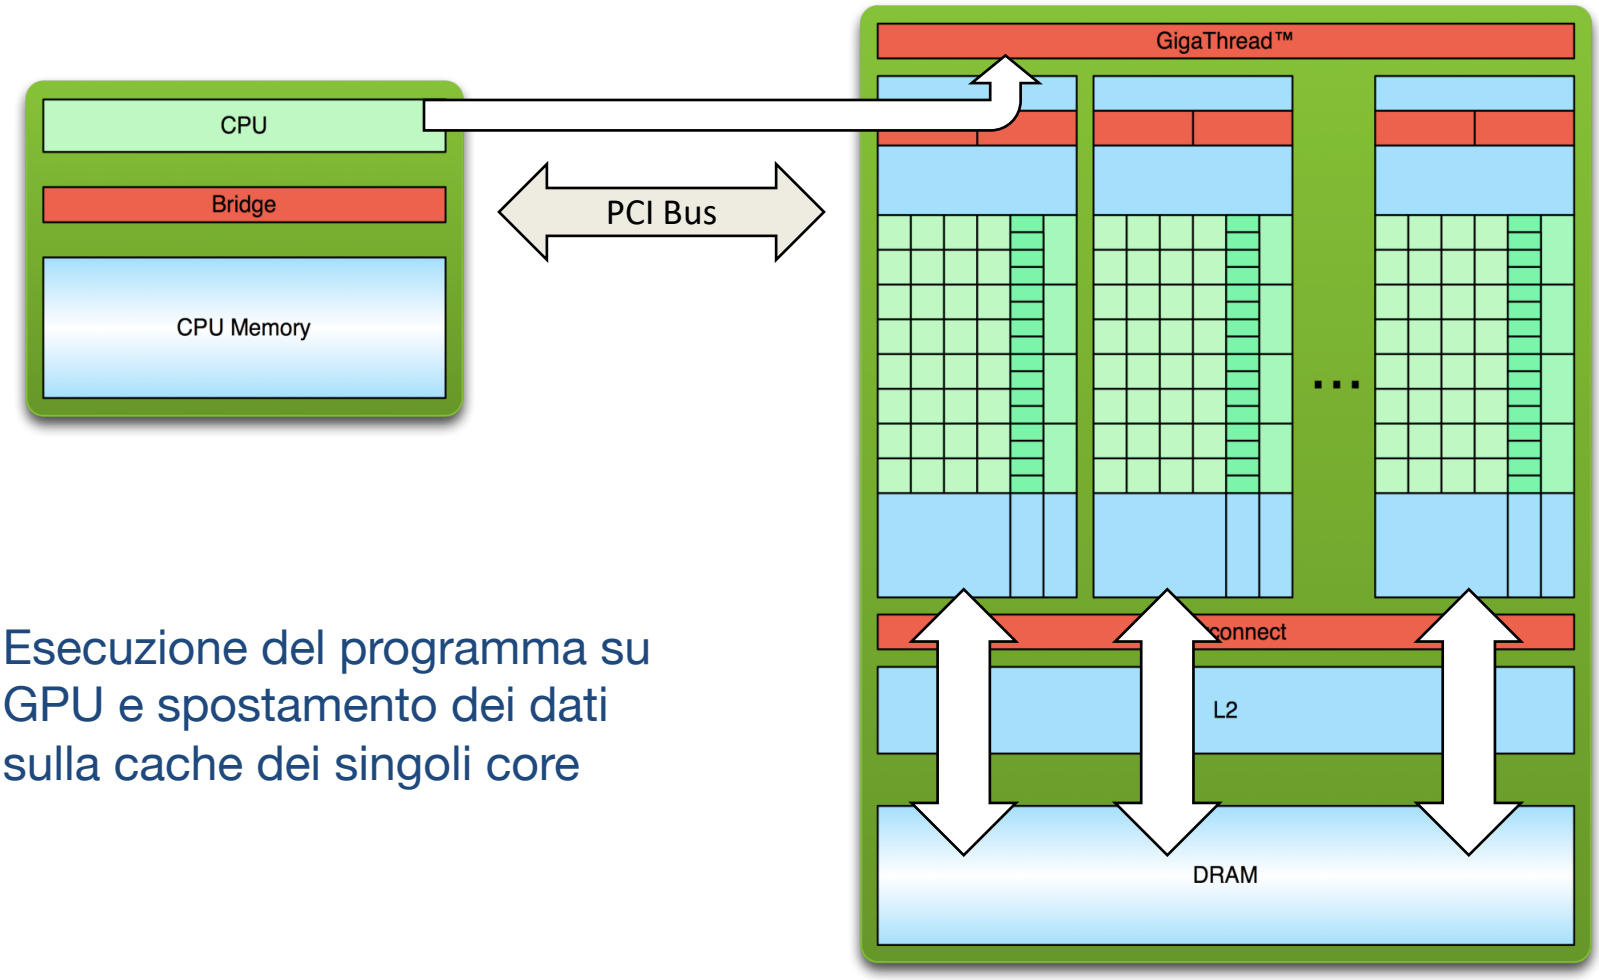


2. Esecuzione del programma su GPU e spostamento dei dati sulla cache dei singoli core

# Flusso di computazione (3)

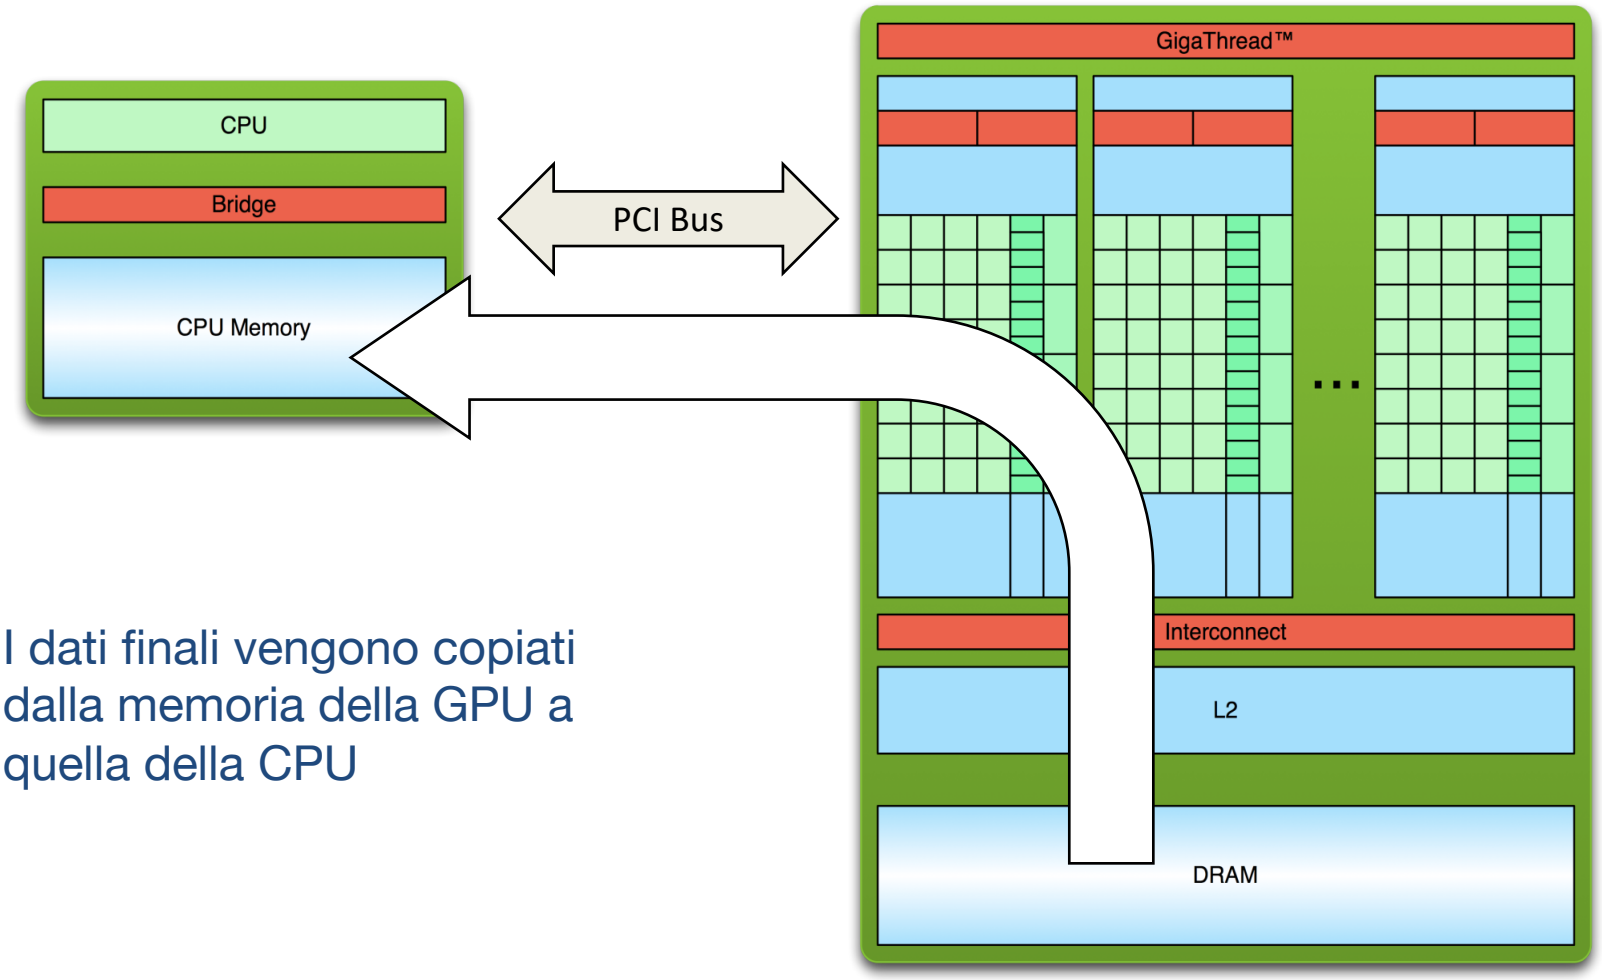


3. I dati finali vengono copiati dalla memoria della GPU a quella della CPU

# Hello World in CUDA

```
__global__ void mykernel(void) { }

int main(void) {
        mykernel<<<1,1>>>();
        printf("Hello World!\n");
        return 0;
}
```

Codice **Device**

Codice **Host**

Il codice host viene compilato con **GCC** mentre il codice device con **NVCC**

# Hello World in CUDA (2)

La compilazione viene eseguita una sola volta con NVCC. Sarà lui ad occuparsi della compilazione tramite GCC delle componenti host.

**Compilazione**: **nvcc** –o mycode mycode.cu

**Esecuzione**: ./mycode

La compilazione può essere eseguita anche senza la necessità di avere l'hardware.

# Somma di due vettori

**Partiamo con la somma di due interi**

```
__global__ void add(int *a, int
*b, int *c) {
        c = a + b;
}

int main(void) {
    int a, b, c;
    add<<<1,1>>>(&a, &b, &c);
    }
```

**Qualche problema?**

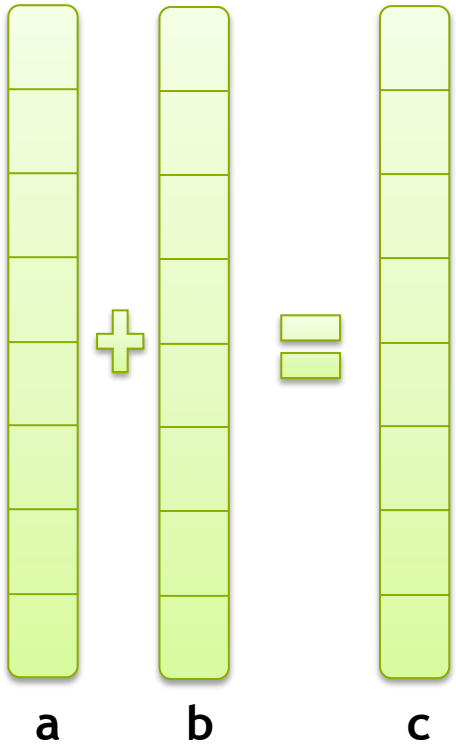

# Gestione della memoria

La **memoria** dell'**host** (CPU) e del **device** (GPU) sono sempre **separate**. È sconsigliata la condivisione con i puntatori.

È sempre consigliata:

- L'allocazione sulla CPU
- e la successiva copia sulla GPU

A questo scopo esistono delle funzioni CUDA simili a quelle standard C:

**cudaMalloc() cudaFree() cudaMemcpy()**

# Gestione della memoria (3)

**cudaError_t cudaMalloc** ( **void**** devPtr, **size_t** size )

**cudaError_t cudaFree** ( **void*** devPtr )

**cudaError_t cudaMemcpy** ( **void*** dst, **const void*** src, **size_t** count, **cudaMemcpyKind** kind )

cudaMemcpyKind:

cudaMemcpyHostToHost = 0

**cudaMemcpyHostToDevice** = 1

**cudaMemcpyDeviceToHost** = 2

cudaMemcpyDeviceToDevice = 3

cudaMemcpyDefault = 4

# Gestione della memoria (4)

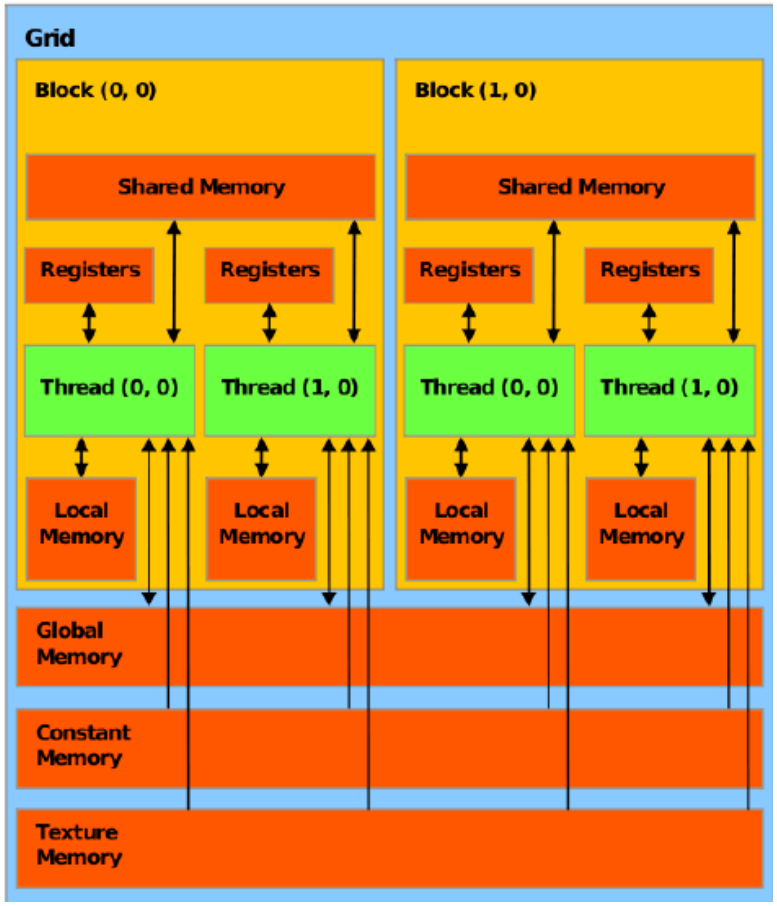


| Variabile | Memoria | Scope |
|---|---|---|
| int var | register | thread |
| int array[10] | local | thread |
| __shared__ | shared | block |
| __device__ | global | grid |
| __constant__ | constant | grid |

# Il parallelismo

Fino ad adesso abbiamo eseguito del codice sulla GPU ma in modalità sequenziale

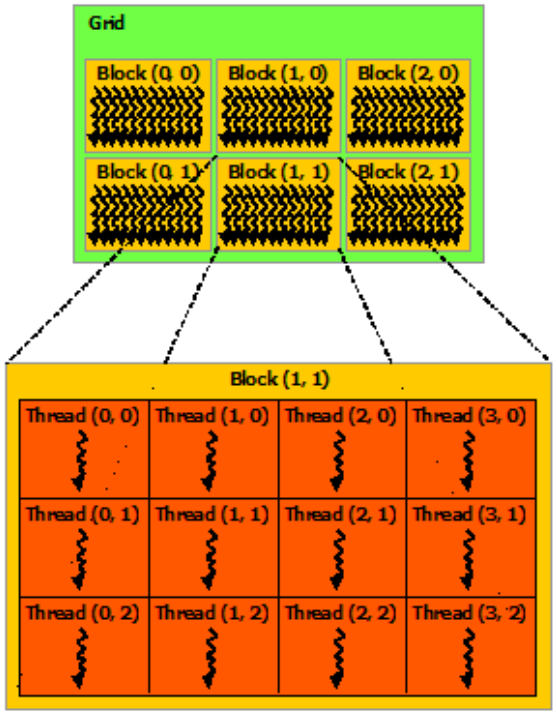


**add<<<1,1>>>**

**add<<<dimGrid, dimBlock>>>**

**add<<<N, 1>>>**

Esegui il codice su N block e 1 thread

# Concentriamoci sui blocchi

Una **GRID** è un insieme di **BLOCK**.

```
__global__ void add(int *a, int *b, int *c) {
            c[blockIdx.x] = a[blockIdx.x] + b[blockIdx.x];
      }
```

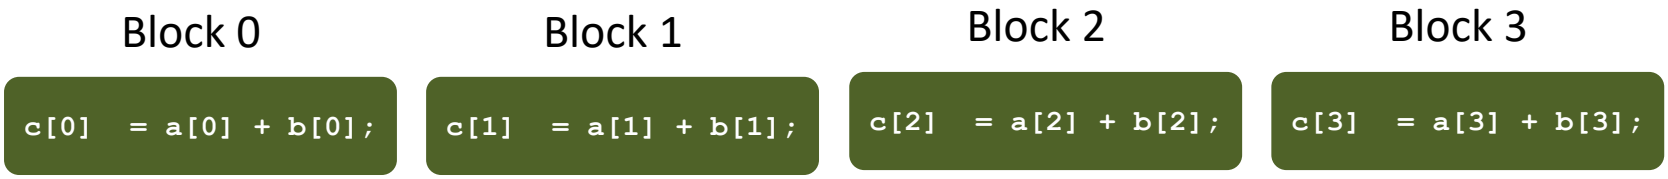

# Thread

Un **BLOCK** può essere diviso in più **THREAD**.

I thread di una GPU sono molti di più e molto più leggeri.

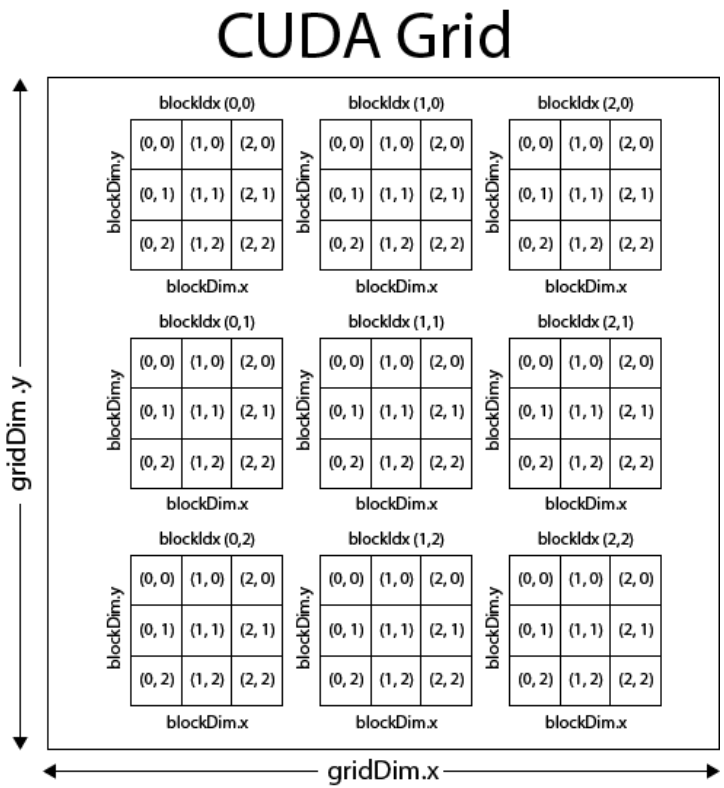

# Thread (2)

```
__global__ void add(int *a, int *b, int *c) {
        c[threadIdx.x] = a[threadIdx.x] + b[theadIdx.x];
}
```

add<<<1, N>>>

**Esegui questo codice su 1 block e N threads**

| Thread 0 | Thread 1 | Thread 2 | Thread 3 |
|---|---|---|---|
| `c[0] = a[0] + b[0];` | `c[1] = a[1] + b[1];` | `c[2] = a[2] + b[2];` | `c[3] = a[3] + b[3];` |

# Combiniamo blocchi e thread

La potenza computazionale di una GPU deriva dalla possibilità di utilizzare **blocchi**, **thread** e **grid** modellati in base al problema da risolvere.

Questo fornisce una potenza di calcolo molto superiore rispetto a una CPU.

Il problema principale è la **CAPACITA DI INDEXING**.

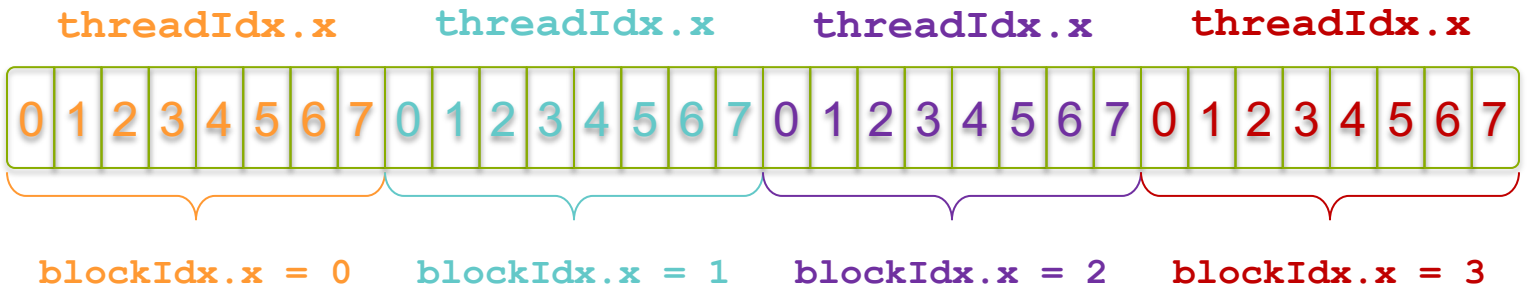

# Indexing

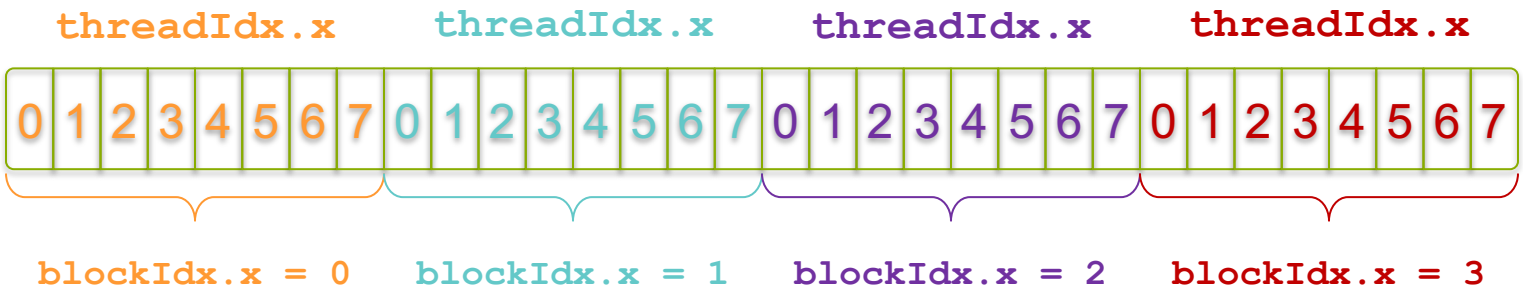


```
int index = threadIdx.x + blockIdx.x * M;
```

**M = blockDim.x (in questo caso)**

# Indexing (2)

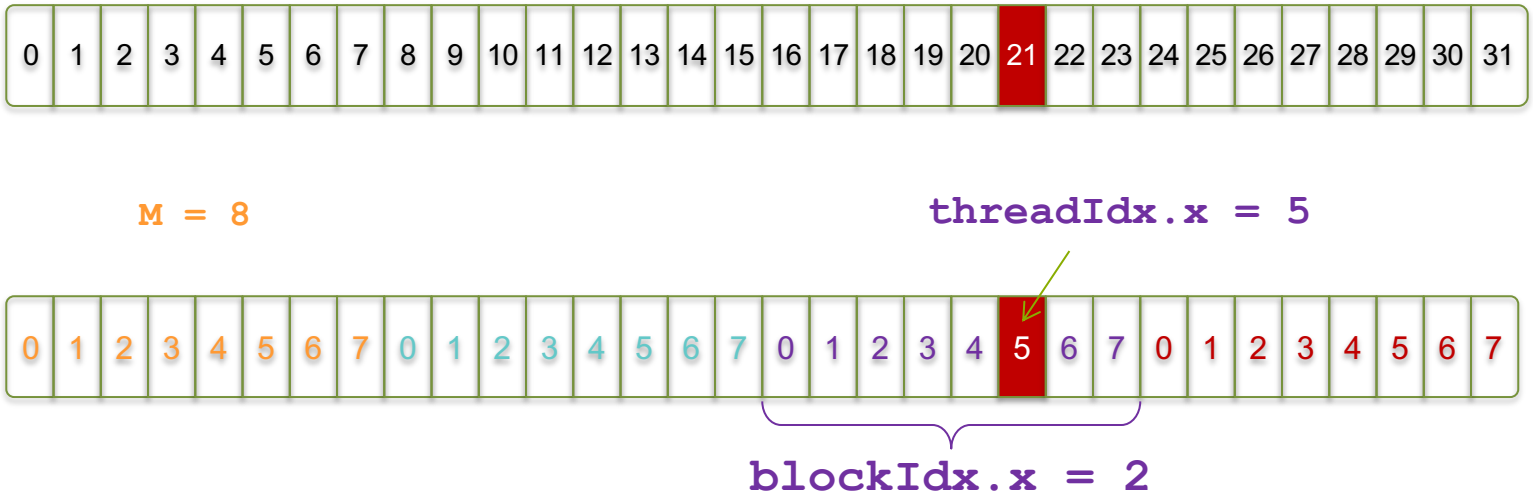


```
int index = threadIdx.x + blockIdx.x * M;
          =      5      +     2      * 8;
          = 21;
```

# Thread (3)

Come avete visto i thread introducono un livello di complessità in più. Perché non è possibile calcolare tutto con i soli blocchi?

**Perché tra threads è molto più facile:**

- **Comunicare**
- **Sincronizzare**

# Compute Capability

È una tabella che mostra le capacità tecniche di ogni singola GPU. Interrogabile tramite l'utility **deviceQuery**.