Архитектура **Tesla.** Программно-аппаратный стек **CUDA.**

- Лекторы:
  - Боресков А.В. (ВМиК МГУ)
  - Харламов А.А. (Харламов А.А. (NVidiaХарламов А.А. (NVidia)

Примеры многоядерных систем

- На первой лекции мы рассмотрели
  - Intel Core 2 Duo
  - SMP
  - Cell
  - BlueGene/L
  - G80 / Tesla

Примеры многоядерных систем

- Мы хотели обратить ваше внимание на следующие особенности:
  1) Как правило вычислительный узел – достаточно маломощный процессор
  2) Вычислительные узлы имеют свою оперативную память и свой кэш
  3) Вычислительные узлы объединяются в более крупные блоки
  4) Крупные блоки могут объединяться с целью наращивания вычислительной мощи

Tesla vs GeForce

- У кого есть вопросы в чем разница?

План

- Архитектура Tesla
- Программная модель CUDA
- Синтаксические особенности CUDA

Архитектура **Tesla:** Мультипроцессор **Tesla 8**

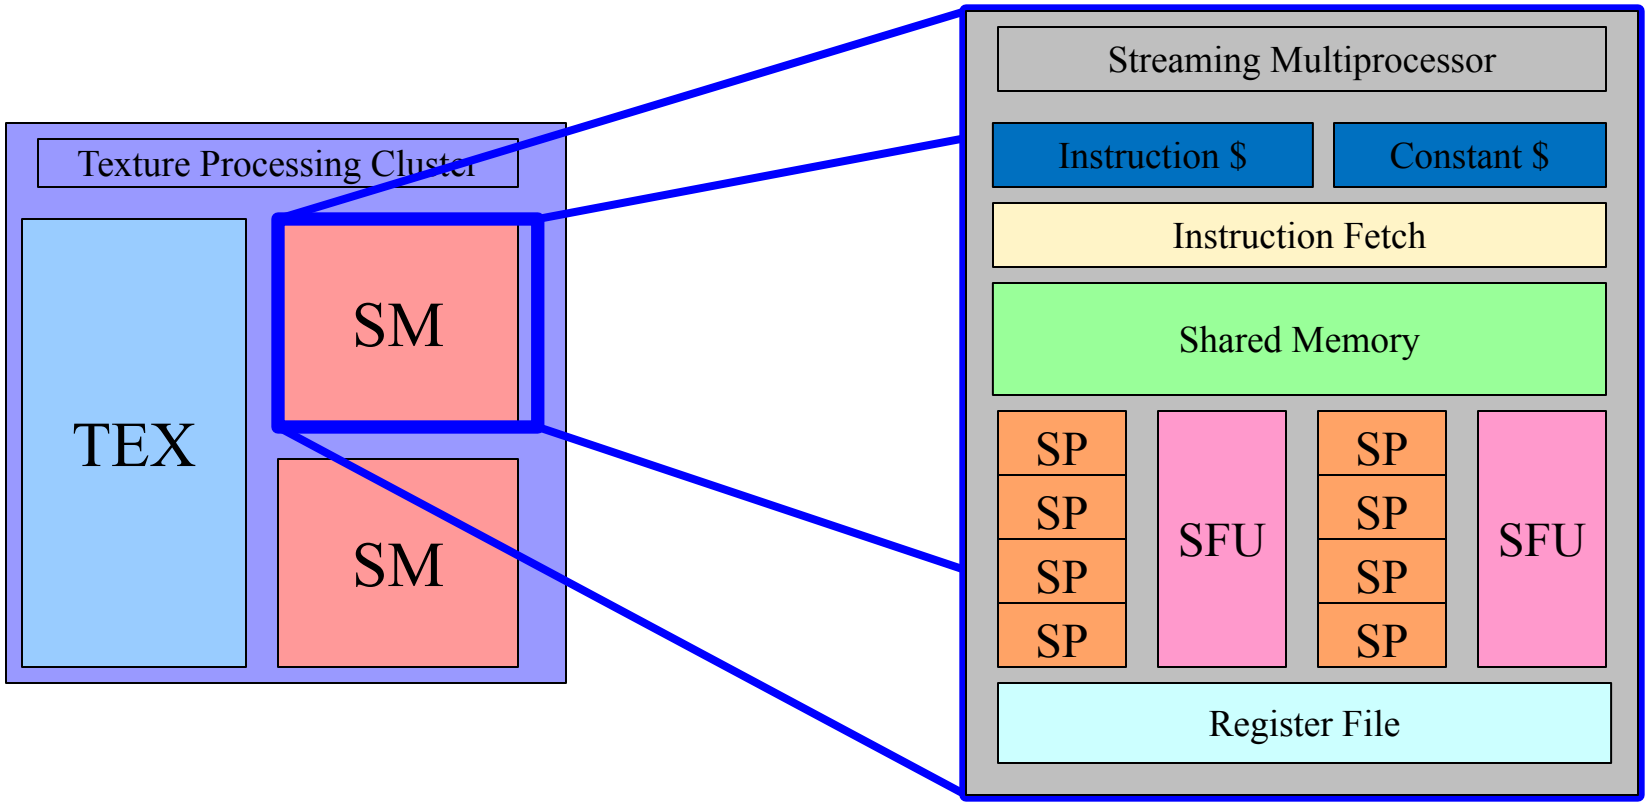

Архитектура **Tesla**
Мультипроцессор **Tesla 10**

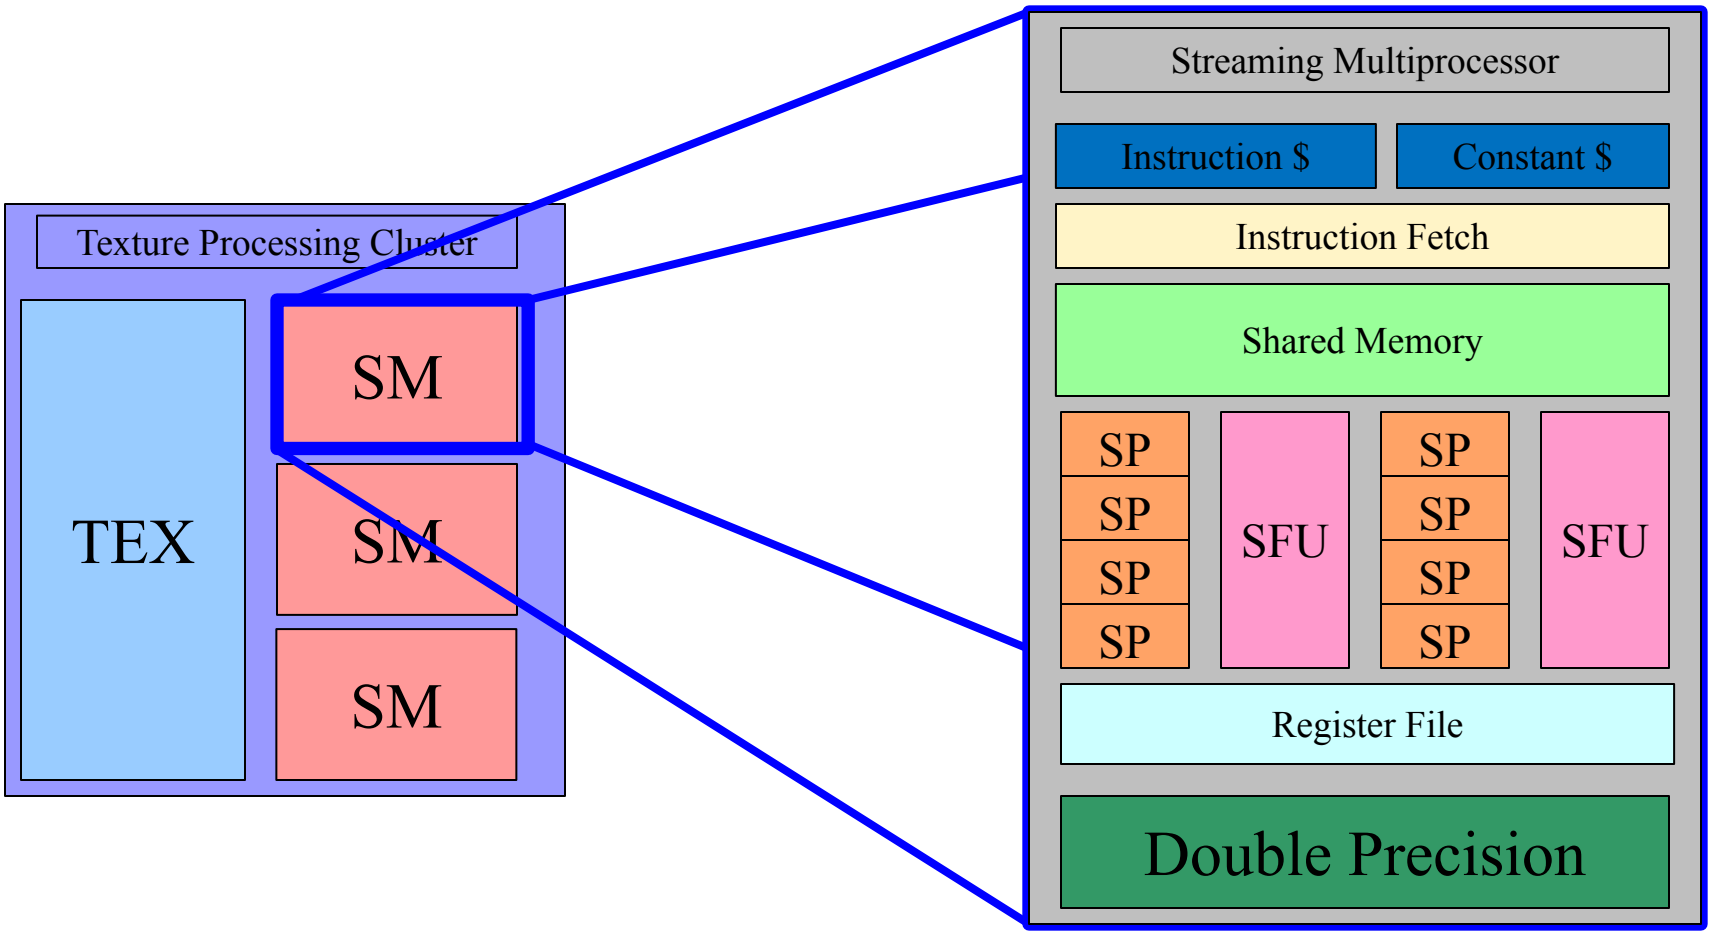

Архитектура **Tesla 10**

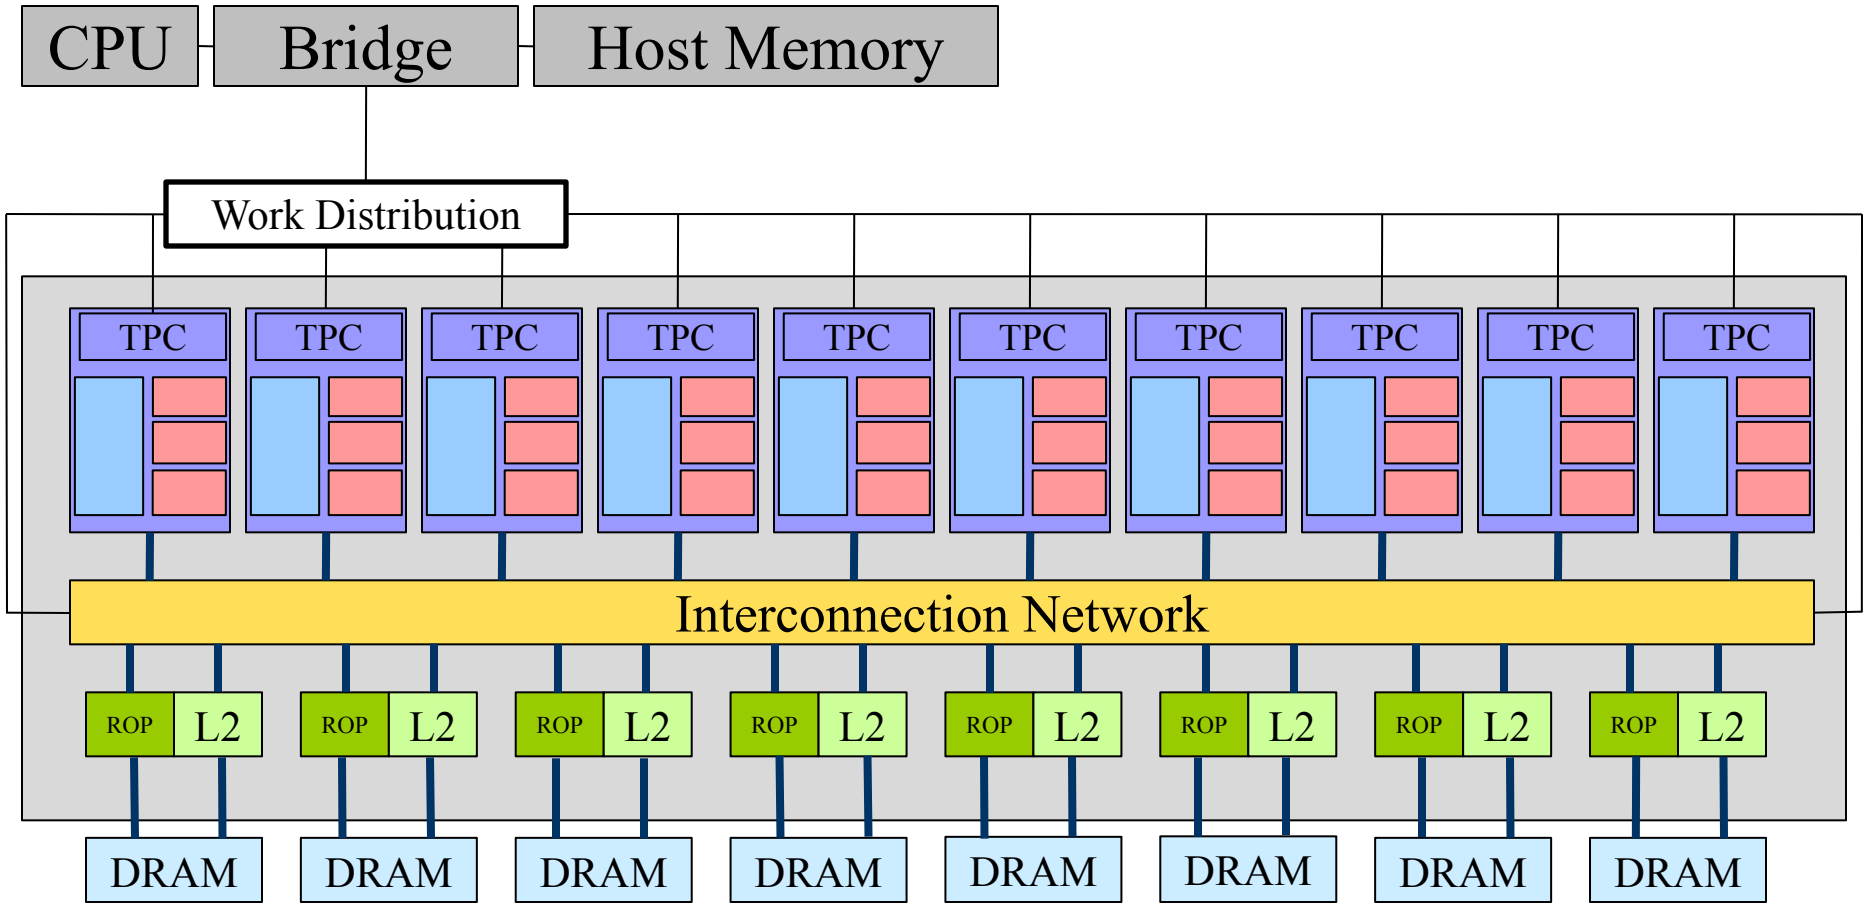

Архитектура

- Маштабируемость:
  - [+][-] SM внутри TPC
  - [+][-] TPC
  - [+][-] DRAM партиции
- Схожие архитектуры:
  - Tesla 8: 8800 GTX
  - Tesla 10: GTX 280

Технические детали

- RTM **CUDA Programming Guide**
- Run CUDAHelloWorld
  - Печатает аппаратно зависимые параметры
    - Размер shared памяти
    - Кол-во SM
    - Размер warp’a
    - Кол-во регистров на SM
    - т.д.

План

- Архитектура Tesla
- Программная модель CUDA
- Синтаксические особенности CUDA

Программная модель CUDA

- GPU (*device*) это вычислительное устройство, которое:
  - Является сопроцессором к CPU (*host*)
  - Имеет собственную память (DRAM)
  - Выполняет одновременно ***очень много*** нитей

Программная модель CUDA

- Последовательные части кода выполняются на CPU
- Массивно-параллельные части кода выполняются на GPU как ядра
- Отличия нитей между CPU и GPU
  - Нити на GPU очень «легкие»
  - HW планировщик задач
  - Для полноценной загрузки GPU нужны тысячи нитей
    - Для покрытия латентностей операций чтения / записи
    - Для покрытия латентностей sfu инструкций

Программная модель CUDA

- Параллельная часть кода выполняется как большое количество нитей
- Нити группируются в блоки фиксированного размера
- Блоки объединяются в сеть блоков
- Ядро выполняется на сетке из блоков
- Каждая нить и блок имеют свой идентификатор

Программная модель CUDA

- Десятки тысяч потоков

```
for (int ix = 0; ix < nx; ix++)
{
   pData[ix] = f(ix);
}

for (int ix = 0; ix < nx; ix++)
  for (int iy = 0; iy < ny; iy++)
  {
     pData[ix + iy * nx] = f(ix) * g(iy);
  }

for (int ix = 0; ix < nx; ix++)
  for (int iy = 0; iy < ny; iy++)
    for (int iz = 0; iz < nz; iz++)
    {
       pData[ix + (iy + iz * ny) * nx] = f(ix) * g(iy) * h(iz);
    }
```

Программная модель CUDA

- Потоки в CUDA объединяются в блоки:
  - Возможна 1D, 2D, 3D топология блока
    - Общее кол-во потоков в блоке ограничено
    - В текущем HW это 512 потоков

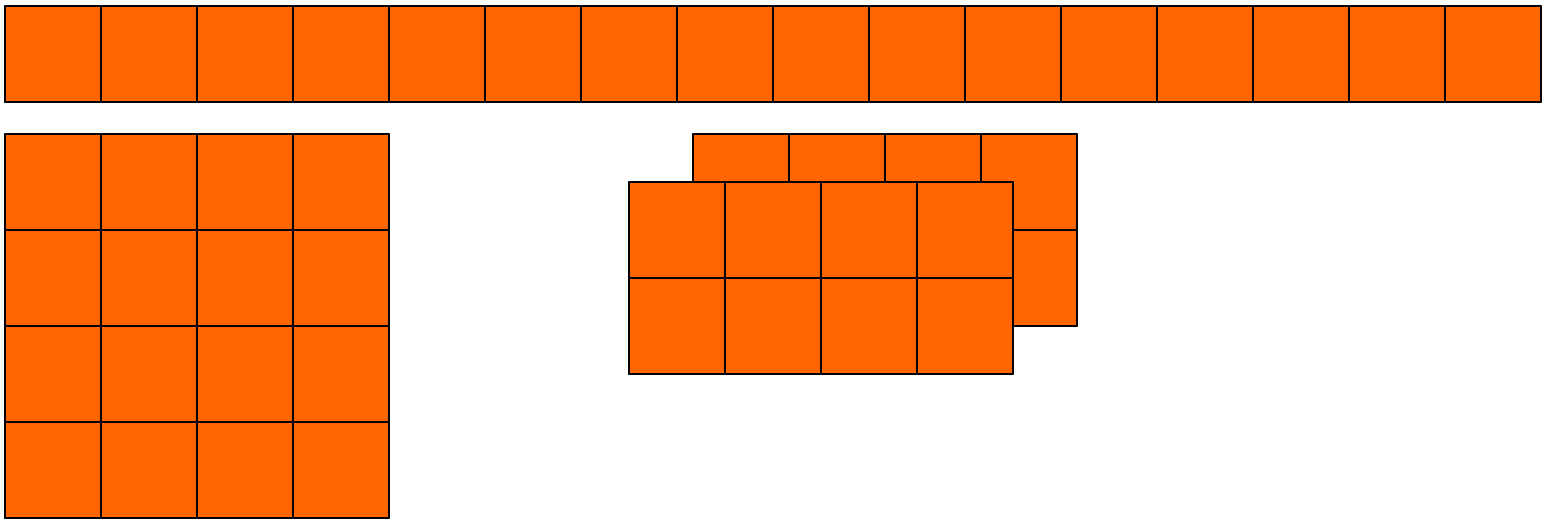

Программная модель CUDA

- Потоки в блоке могут разделять ресурсы со своими соседями

```
float g_Data[gN];
for (int ix = 0; ix < nx; ix++)
{
   pData[ix] = f(ix, g_Data[ix / n]);
}
```

Программная модель CUDA

- Блоки могут использовать shared память
  - Т.к. блок целиком выполняется на одном SM
  - Объем shared памяти ограничен и зависит от HW
- Внутри Блока потоки могут синхронизоваться
  - Т.к. блок целиком выполняется на одном SM

Программная модель CUDA

- Блоки потоков объединяются в сетку (grid) потоков
  - Возможна 1D, 2D топология сетки блоков потоков

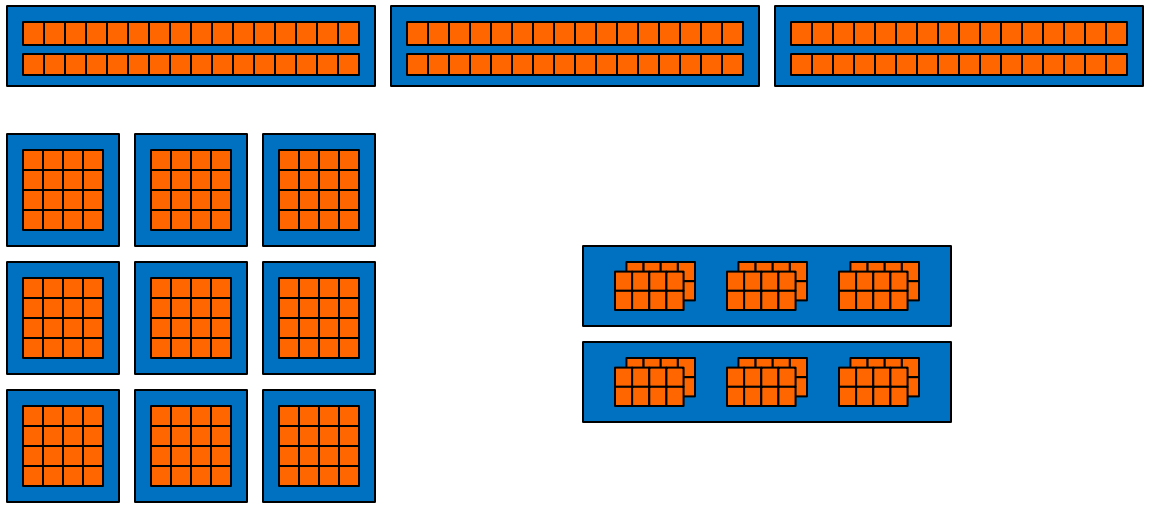

План

- Архитектура Tesla
- Программная модель CUDA
- Синтаксические особенности CUDA

Синтаксис **CUDA**

- CUDA – это расширение языка C
  - [+] спецификаторы для функций и переменных
  - [+] новые встроенные типы
  - [+] встроенные переменные (внутри ядра)
  - [+] директива для запуска ядра из C кода
- Как скомпилировать CUDA код
  - [+] nvcc компилятор
  - [+] .cu расширение файла

Синтаксис **CUDA**
Спецификаторы

- Спецификатор функций

Спецификатор	Выполняется на	Может вызываться из
__device__	device	device
__global__	device	host
__host__	host	host

- Спецификатор переменных

Спецификатор	Находится	Доступна	Вид доступа
__device__	device	device	R
__constant__	device	device / host	R / W
__shared__	device	block	RW / **__syncthreads()**

Синтаксис CUDA

Встроенные переменные

- Сравним CPU код vs CUDA kernel:

```
float * pData;
for (int ix = 0; ix < nx; ix++)
{
    pData[ix] = pData[ix] + 1.0f;
}
```

Пусть nx = 2048
Пусть в блоке 256 потоков

кол-во блоков = 2048 / 256 = 8

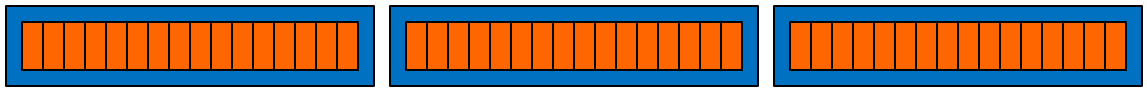

```
__global__ void incKernel ( float * pData )
{                    [ 0 .. 7 ]          [ == 256]          [ 0 .. 255 ]
  int idx = blockIdx.x * blockDim.x + threadIdx.x;
  pData [idx] = pData [idx] + 1.0f;
}
```

Синтаксис **CUDA**
Встроенные переменные

- В любом CUDA kernel'е доступны:
  - `dim3  gridDim;`
  - `uint3 blockIdx;`
  - `dim3  blockDim;`
  - `uint3 threadIdx;`
  - `int   warpSize;`

`dim3` – встроенный тип, который используется для задания размеров kernel'а
По сути – это `uint3`.

Синтаксис **CUDA**

Директивы запуска ядра

- Как запустить ядро с общим кол-во тредов равным nx?

```
float * pData;

dim3 threads(256, 1, 1);
dim3 blocks(nx / 256, 1);

incKernel<<<blocks, threads>>> ( pData );
```

Неявно предполагаем, что nx кратно 256

<<< , >>> угловые скобки, внутри которых задаются параметры запуска ядра:

- Кол-во блоке в сетке
- Кол-во потоков в блоке
- …

Как скомпилировать **CUDA** код

- NVCC – компилятор для CUDA
  - Основными опциями команды **nvcc** являются:
  - **-deviceemu** - компиляция в режиме эмуляции, весь код будет выполняться в многонитевом режиме на CPU и можно использовать обычный отладчик (хотя не все ошибки могут проявится в таком режиме)
  - **--use_fast_math** - заменить все вызовы стандартных математических функций на их быстрые (но менее точные) аналоги
  - **-o <outputFileName>** - задать имя выходного файла
- CUDA файлы обычно носят расширение .cu

Ресуры нашего курса

- CUDA.CS.MSU.SU
  - Место для вопросов и дискуссий
  - Место для материалов нашего курса
  - Место для ваших статей!
    - Если вы нашли какой-то интересный подход!
    - Или исследовали производительность разных подходов и знаете, какой из них самый быстрый!
    - Или знаете способы сделать работу с CUDA проще!
- Steps3d
- www.nvidia.ru