

# Архитектура и программирование массивно- параллельных вычислительных систем

Лектор:

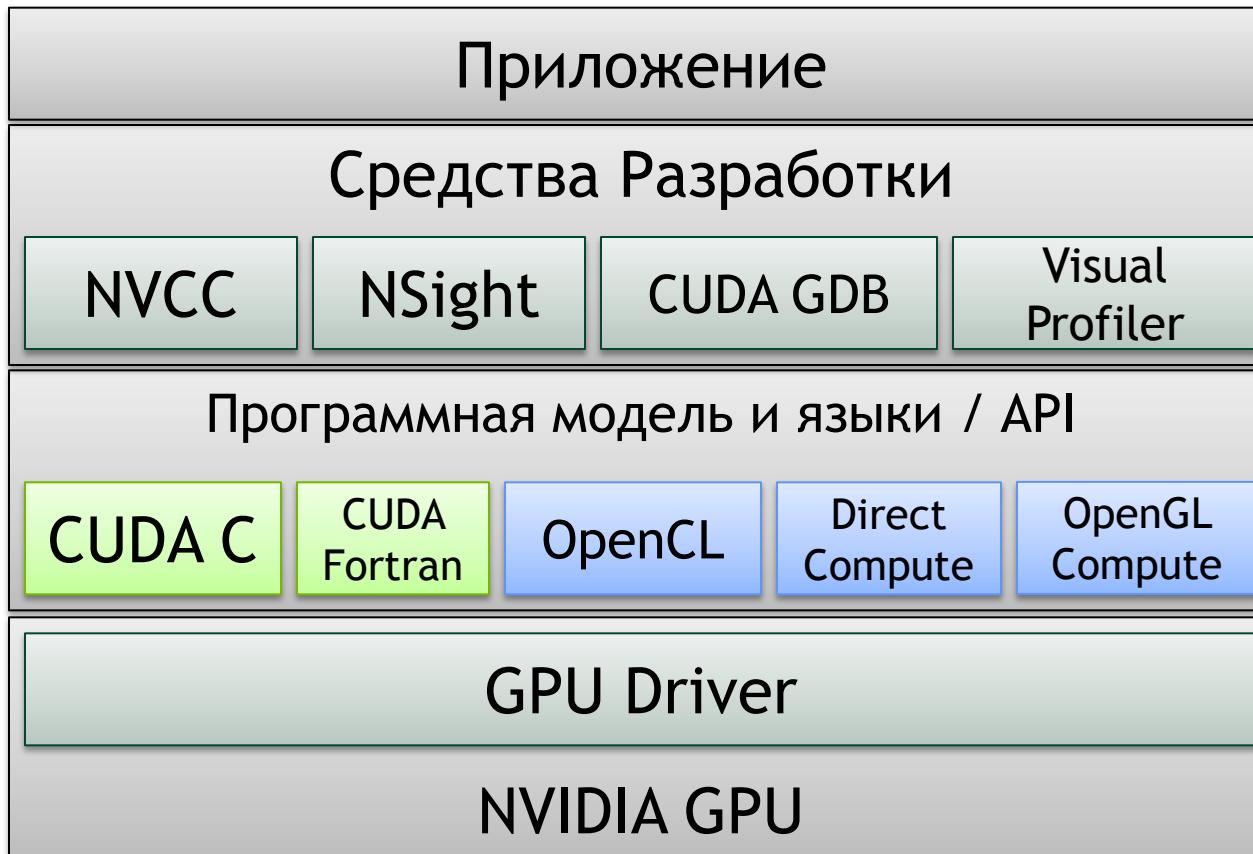
Боресков А.В. (ВМиК МГУ)

# План

- CUDA
- Архитектура
- Hello, World
- Несколько слов о курсе
- Дополнительные слайды

# Compute Unified Device Architecture (CUDA)

- CUDA - программно-аппаратный стек для программирования GPU



# Программная модель CUDA

- Код состоит из последовательных и параллельных частей
- Последовательные части кода выполняются на CPU (*host*)
- Массивно-параллельные части кода выполняются на GPU (*device*)
- GPU
  - Является сопроцессором к CPU (*host*)
  - Имеет собственную память (DRAM)
  - Выполняет одновременно **очень много** нитей

# Программная модель CUDA

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

# Программная модель CUDA

- Компромисс между желанием дать возможность каждой нити взаимодействовать с каждой из аппаратными возможностями
- Исходная задача разбивается на набор независимо решаемых подзадач
- Каждая подзадача решается параллельно блоков взаимодействующих нитей

# Программная модель CUDA

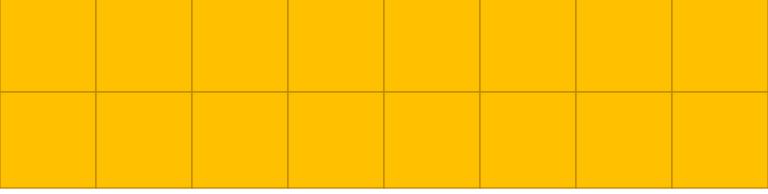
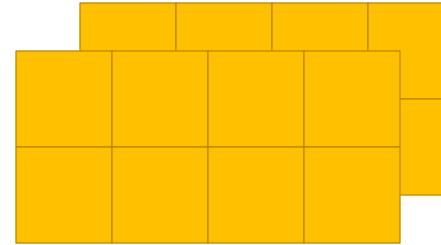
- Десятки тысяч нитей

```
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

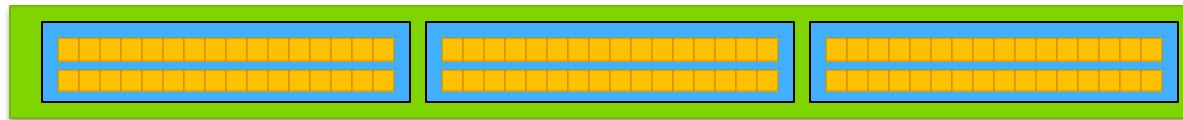
- Нити в CUDA объединяются в блоки:
  - 1D топология блока
  - 2D топология блока
  - 3D топология блока
- Общее кол-во нитей в блоке ограничено
- В текущем HW это 1024 нитей

# Программная модель CUDA

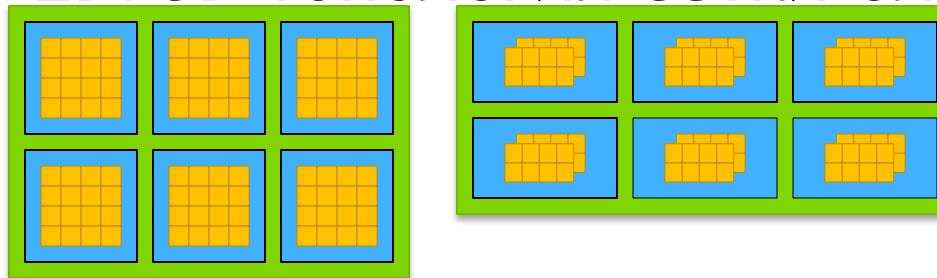
- Блоки могут использовать *shared* память
  - Нити могут обмениваться общими данными
- Внутри блока потоки могут синхронизоваться
  - Барьерная синхронизация

# Программная модель CUDA

- Блоки потоков объединяются в сеть (*grid*) блоков потоков
  - 1D топология сетки блоков



- 2D/3D топология сетки блоков



- Блоки в сети выполняются независимо друг от друга

Легенда:  
-нить  
-блок  
-сеть



# Связь программной модели с HW

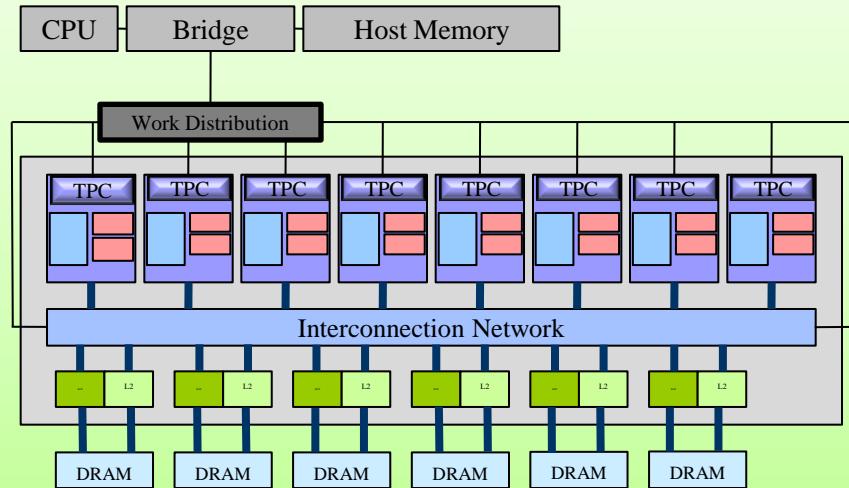
- Блоки могут использовать *shared* память
  - Т.к. блок целиком выполняется на одном SM
  - Объем *shared* памяти ограничен и зависит от HW
- Внутри блока нити могут синхронизоваться
  - Т.к. блок целиком выполняется на одном SM
- Масштабирование архитектуры и производительности

# Связь программной модели с HW

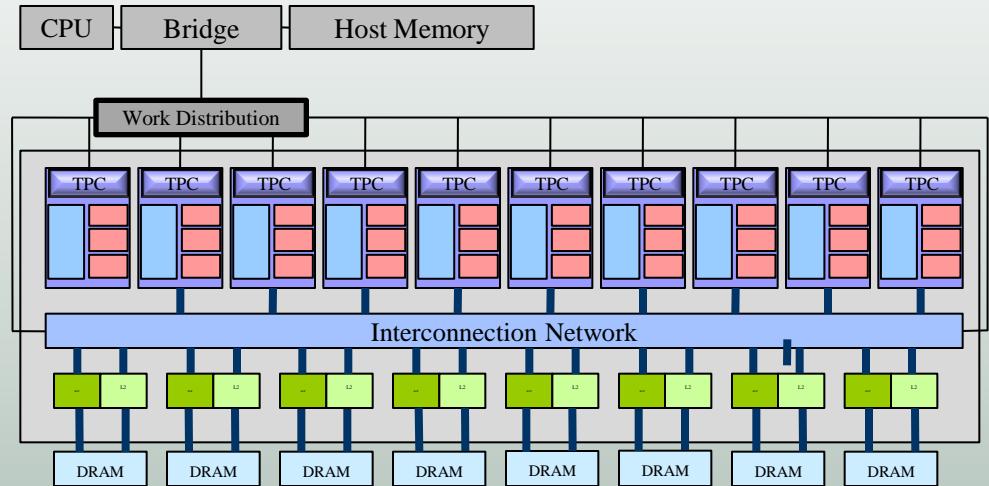
- Очень высокая степень параллелизма
  - Десятки тысяч нитей на кристалле
  - Потоки на GPU очень «легкие» - переключение между нитями очень дешевое
    - Фактически переключение выполняется на каждую команду
  - Аппаратный планировщик
- Основная часть кристалла занята не кэшем, а логикой
- Для полноценной загрузки GPU (получение пиковой мощности) нужны многие тысячи потоков
  - Для покрытия латентности доступа к памяти
  - Для покрытия латентности SFU операций

# Масштабирование архитектуры Tesla

Tesla 8

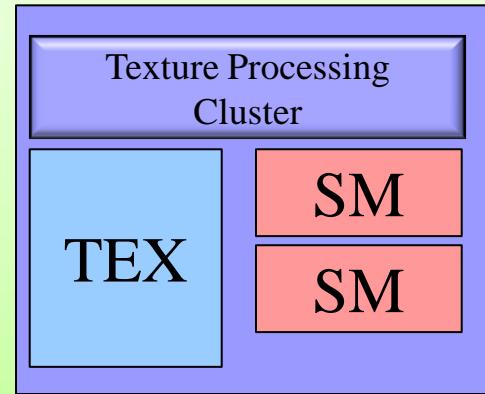


Tesla  
10

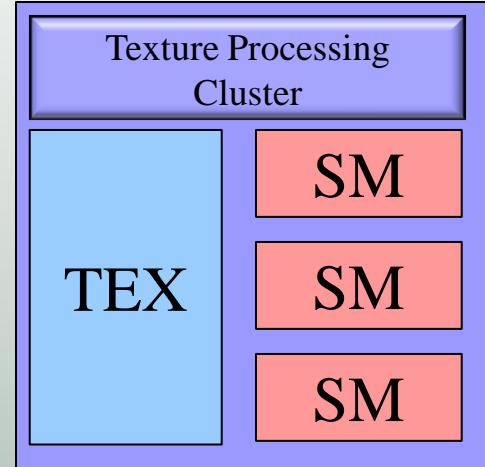


# Масштабирование мультипроцессора Tesla 10

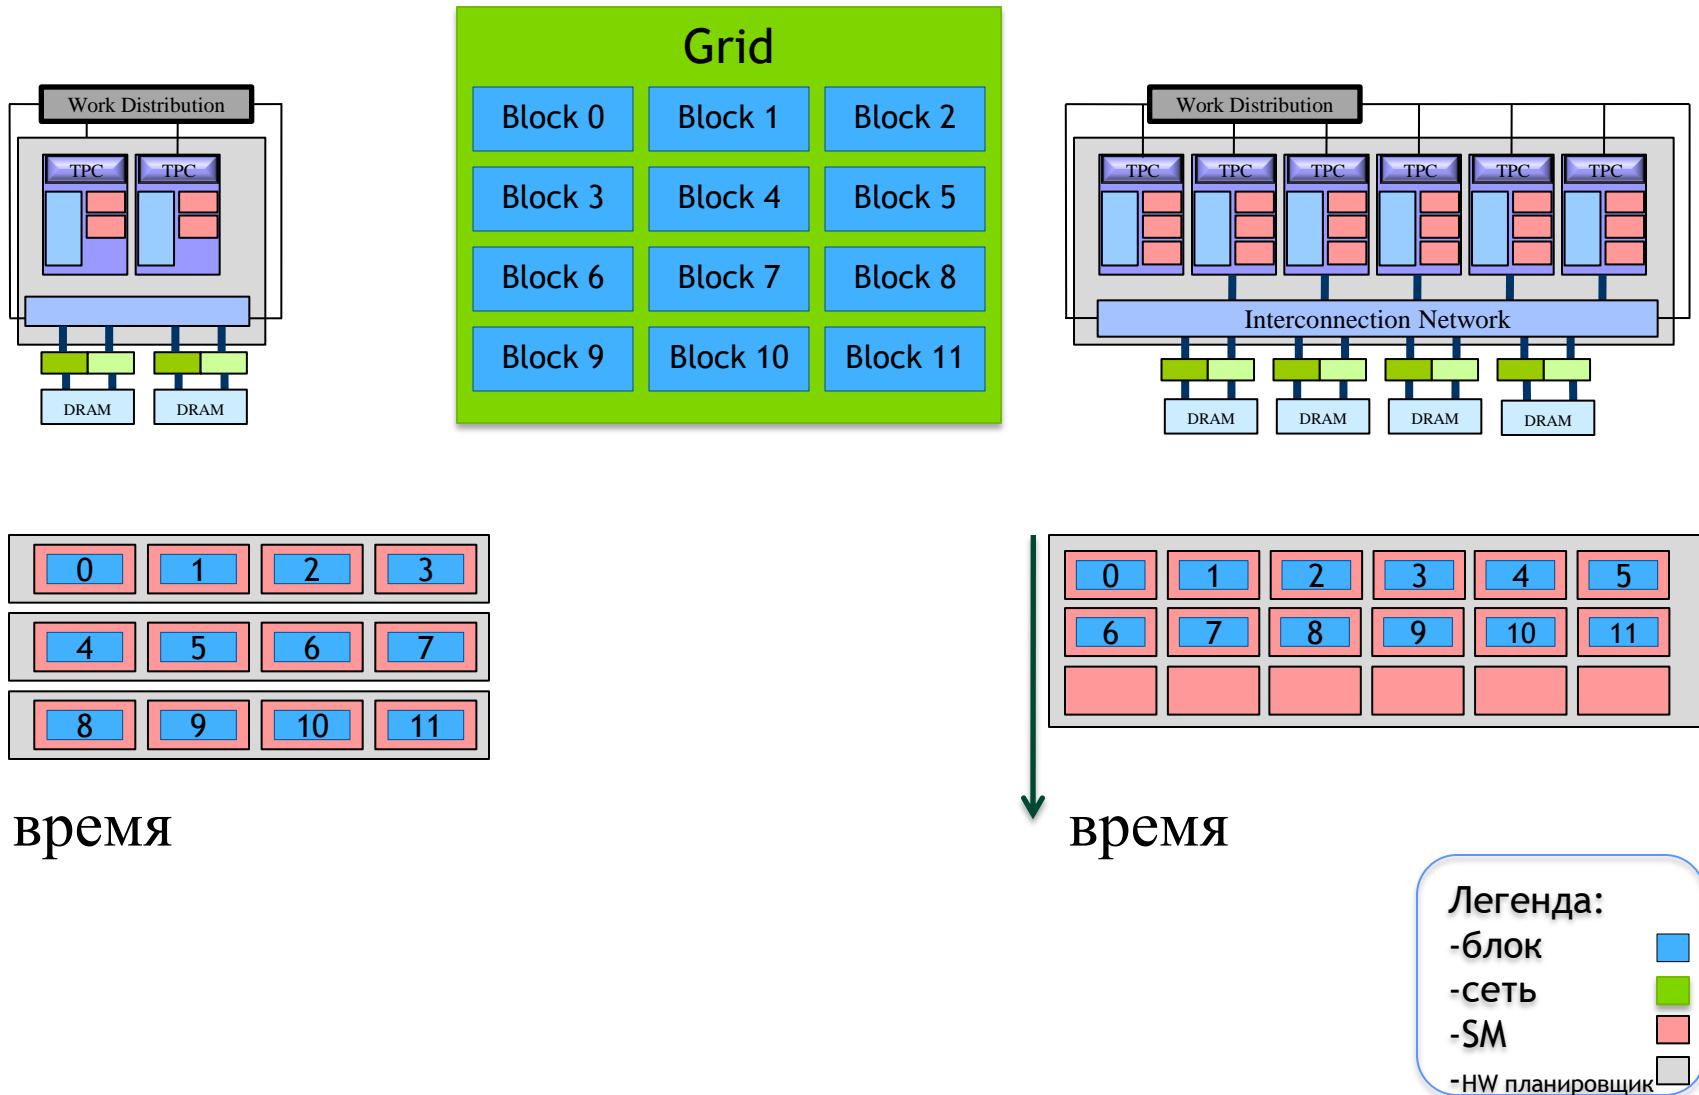
Tesla 8



Tesla  
10



# Масштабирование производительности

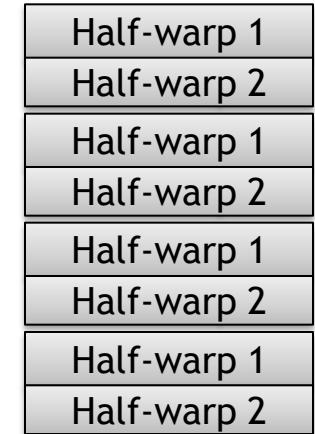
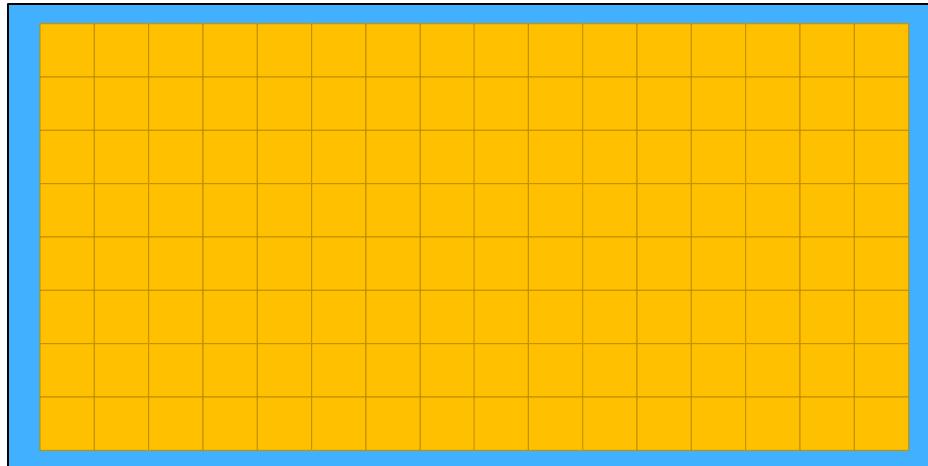


# Warp

- Все нити, выполняемые на GPU, перенумеровываются и разбиваются на группы по 32 подряд идущих нити - *варпы*
- Нити внутри варпа фактически выполняются одновременно и всегда выполняют одну и ту же команду
  - При этом для поддержки ветвления отдельные нити могут временно «выключаться»
- Сам SM содержит приоритизированную очередь варпов и по очереди выполняет по одной команде для каждого варпа
  - В современных GPU одновременно выполняются сразу несколько варпов на одном SM
- Переключение между варпами происходит на каждую команду

# Блоки и warp'ы?

- Блоки - абстракция программной модели
- Warp - реальная единица исполнения HW



Легенда:

-нить



-блок



-сеть



# Single Instruction Multiple Threads (SIMT)

- Параллельно на каждом SM выполняется большое число отдельных нитей (*threads*)
- Нити в пределах одного *warp'a* выполняются физически параллельно (SIMD)
- Разные *warp'ы* могут исполнять разные команды
- Большое число *warp'ов* покрывает латентность

# Язык CUDA C

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

# Язык CUDA C Спецификаторы

## Спецификатор функций

Спецификатор	Выполняется на	Может вызываться из
<code>__device__</code>	device	device
<code>__global__</code>	device	host
<code>__host__</code>	host	host

## Спецификатор переменных

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

# Язык CUDA C

## Спецификаторы

- Спецификатор `_global_` соответствует ядру
  - Может возвращать только `void`
- Спецификаторы `_host_` и `_device_` могут использоваться одновременно
  - Компилятор сам создаст версии для CPU и GPU
- Спецификаторы `_global_` и `_host_` не могут быть использованы одновременно

# Язык CUDA C Ограничения на GPU-код

- Не поддерживаются static-переменные для GPU-кода
- Не поддерживается переменное число входных аргументов
- Не поддерживается RTTI
- Не поддерживаются исключения
- Нельзя применять спецификаторы к полям struct/union
- Не могут быть extern
- \_\_shared\_\_ не могут инициализироваться при объявлении
- Запись в \_\_constant\_\_ переменные только через специальные функции
- Старые модели GPU могут накладывать дополнительные ограничения

# Язык CUDA C Возможности GPU-кода

- Полноценная поддержка template
- Поддержка рекурсии (кроме \_\_global\_\_)
- Поддержка лямбд (есть определенные ограничения)
  - Для явного задания цели (\_\_host\_\_ \_\_device\_\_) нужно включить расширение через опцию **--expt-extended-lambda**
    - [] \_\_host\_\_ \_\_device\_\_ () { . . . }
- R-value
- Variadic templates
- auto
- Классы, включая операторы
- Виртуальные функции

# Язык CUDA C

## Типы данных

- Новые типы данных:
  - 1/2/3/4-мерные вектора из базовых типов
    - (u)char, (u)int, (u)short, (u)long, longlong
    - float, double
  - dim3 – uint3 с нормальным конструктором, позволяющим задавать не все компоненты
    - Не заданные инициализируются единицей
  - Через дополнительный заголовочный файл подключается поддержка fp16 (half)
    - half и half2

# Язык CUDA C

## Встроенные переменные

Сравним CPU vs CUDA C код:

```
float * data;
for ( int i = 0; i < n; i++ )
{
    data [i] = data[i] + 1.0f;
}

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

Пусть  $n = 2048$   
Пусть в блоке 256 потоков  
 $\rightarrow$  кол-во блоков =  $2048 / 256 = 8$

# Язык CUDA C

## 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'a. По сути – это **uint3**.

# Язык CUDA C

## Директивы запуска ядра

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

```
float * data;  
dim3 threads ( 256 );  
dim3 blocks ( nx / 256 );  
incKernel<<<blocks, threads>>> ( data );
```

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

Можно для одномерного случая запустить и так

```
incKernel<<<nx/256, 256>>> ( data );
```

# Язык CUDA C

## Директивы запуска ядра

- Общий вид команды для запуска ядра  
`incKernel<<<b1, th, ns, st>>>` ( *data* ) ;
- *b1* – число блоков в сетке
- *th* – число нитей в блоке
- *ns* – количество дополнительной shared-памяти, выделяемое блоку
- *st* – поток, в котором нужно запустить ядро

# Как скомпилировать CUDA код

- NVCC - компилятор для CUDA
  - Основными опциями команды nvcc являются:
  - `--use_fast_math` - заменить все вызовы стандартных математических функций на их быстрые (но менее точные) аналоги
  - `-o <outputFileName>` - задать имя выходного файла
  - `-l` - дополнительные библиотеки
  - Можно линковать с нормальным C/C++ кодом
- CUDA файлы обычно носят расширение .cu

# Как скомпилировать CUDA код

Через опции nvcc можно задать во что компилируется код - в бинарный код или PTX и для какой именно архитектуры.

Можно откомпилировать код для нескольких архитектур сразу

```
nvcc test.cu --machine 64 -arch=compute_30 -o  
test.exe
```

```
nvcc x.cu  
-gencode arch=compute_35,code=sm_35  
-gencode arch=compute_50,code=sm_50  
-gencode arch=compute_60,code=\`compute_60,sm_60\`
```

# Некоторые опции nvcc

- `--ptx` - компилировать все в PTX
- `-c` - только компилировать (в o/obj)
- `--cudart none|shared|static` - cudart library
- `--debug`
- `--device-debug`
- `--optimize level`
- `--machine 32|64`
- `--gpu-architecture <arch>` - virtual architecture, (`-arch`)
- `--gpu-code <code>` - GPU to optimize PTX (`-code`)
- `--maxrregcount <count>`
- `--use_fast_math`
- `--help`

# GPU-совместимость

- Бинарная совместимость
  - -code sm35
  - Генерирует бинарный модуль (cubin) для данной архитектуры
  - Будет работать только на 3.x, x>=5
- Совместимость на уровне PTX
  - -arch compute\_30
- Можно задавать сразу несколько
  - -code='compute\_60,sm\_60'
- При выполнение сперва пытается выбрать подходящий бинарный формат, потом PTX
- Определен макрос \_\_CUDA\_ARCH\_\_
  - Для 3.5 он будет равен 350

# CUDA “Hello World”

```
#define N (1024*1024)

__global__ void kernel ( float * data )

{
    int idx = blockIdx.x * blockDim.x + threadIdx.x;
    float x = 2.0f * 3.1415926f * (float) idx / (float) N;
    data [idx] = sinf ( sqrtf ( x ) );
}

int main ( int argc, char * argv [] )

{
    float * a = new float [N];
    float * dev = NULL;
    cudaMalloc ( (void**)&dev, N * sizeof ( float ) );
    kernel<<<dim3((N/512),1), dim3(512,1)>>> ( dev );
    cudaMemcpy ( a, dev, N * sizeof ( float ), cudaMemcpyDeviceToHost );
    cudaFree ( dev );
    for (int idx = 0; idx < N; idx++) printf("a[%d] = %.5f\n", idx, a[idx]);
    return 0;
}
```

# CUDA “Hello World”

```
__global__ void kernel ( float * data )
{
    int idx = blockIdx.x * blockDim.x + threadIdx.x; // номер текущей нити
    float x = 2.0f * 3.1415926f * idx / N;           // значение аргумента
    data [idx] = sinf ( sqrtf ( x ) );                // найти значение и
                                                       // записать в массив
}
```

- Для каждого элемента массива (всего N) запускается отдельная нить, вычисляющая требуемое значение.
- Каждая нить обладает уникальным id

# CUDA “Hello World”

```
float * a    = new float [N];
float * dev = NULL;

        // выделить память на GPU под N элементов
cudaMalloc ( (void**)&dev, N * sizeof ( float ) );

        // запустить N нитей блоками по 512 нитей
        // выполняемая на нити функция - kernel
        // массив данных - dev
kernel<<<dim3(N/512), dim3(512)>>> ( dev );

        // скопировать результаты из памяти GPU (DRAM) в
        // память CPU (N элементов)
cudaMemcpy ( a, dev, N * sizeof ( float ), cudaMemcpyDeviceToHost );

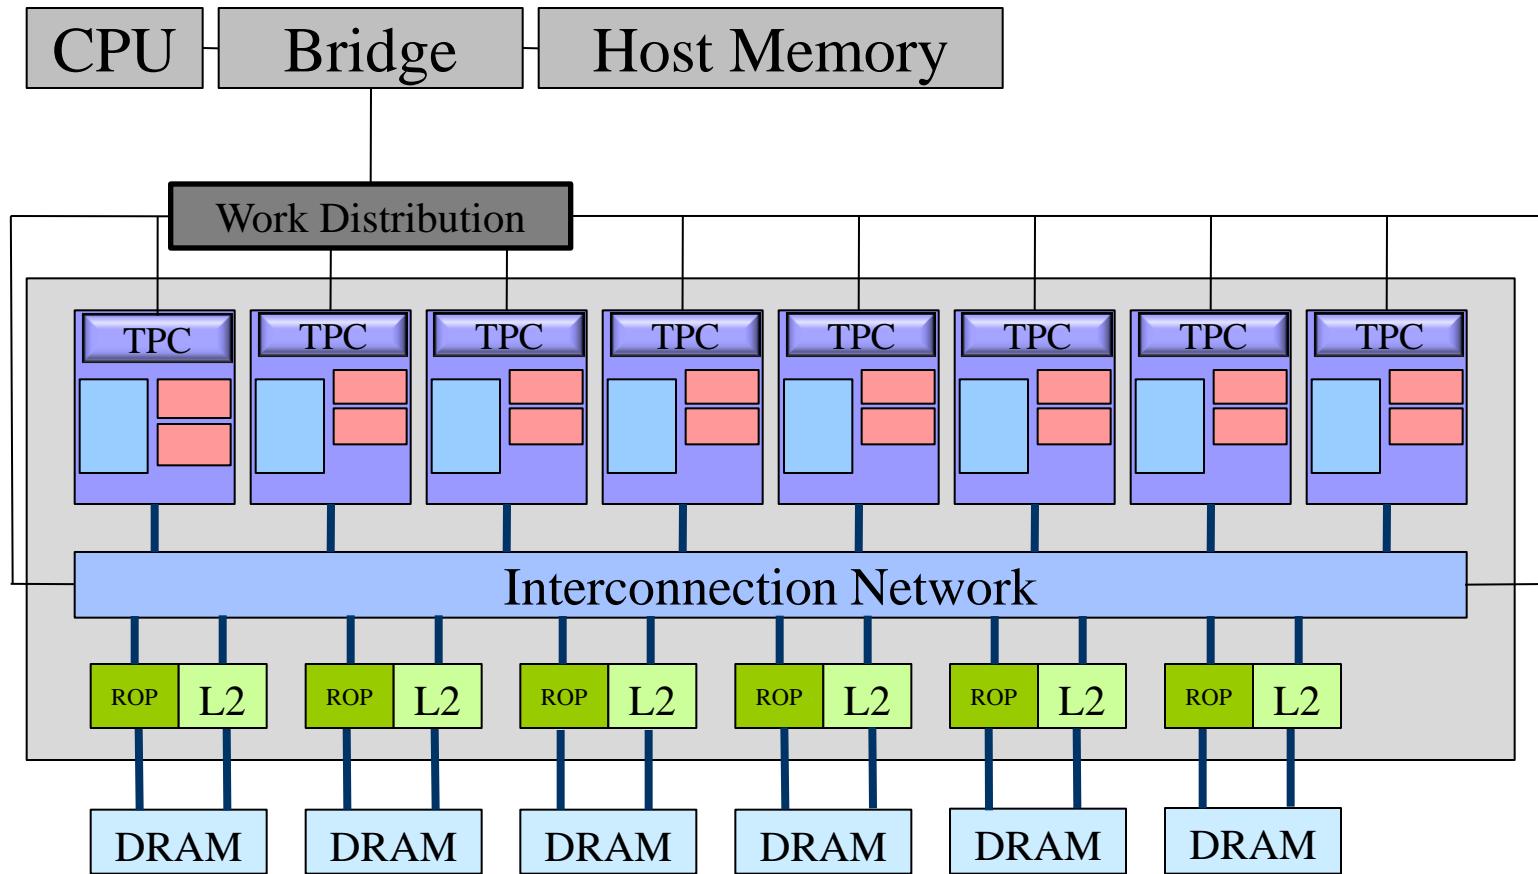
        // освободить память GPU
cudaFree   ( dev   );
```



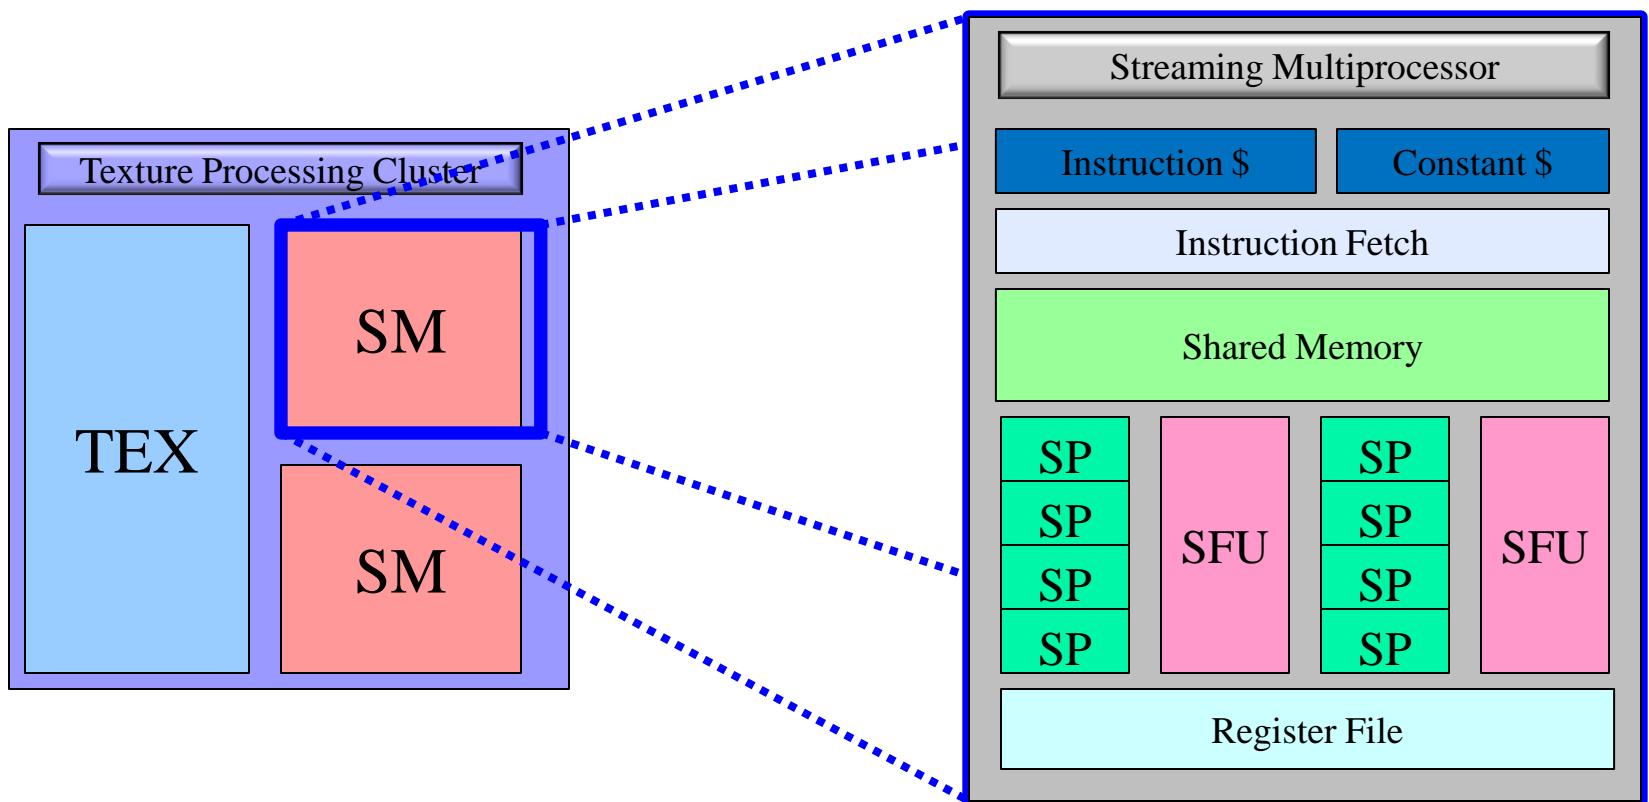
# План

- CUDA
- Архитектура
- Hello, World
- Дополнительные слайды
  - Архитектура Tesla 8
  - Архитектура Tesla 20
  - Архитектура Kepler
  - Архитектура Maxwell
  - Архитектура Pascal
  - Архитектура Volta

# Архитектура Tesla 8



# Архитектура Tesla: Мультипроцессор Tesla 8

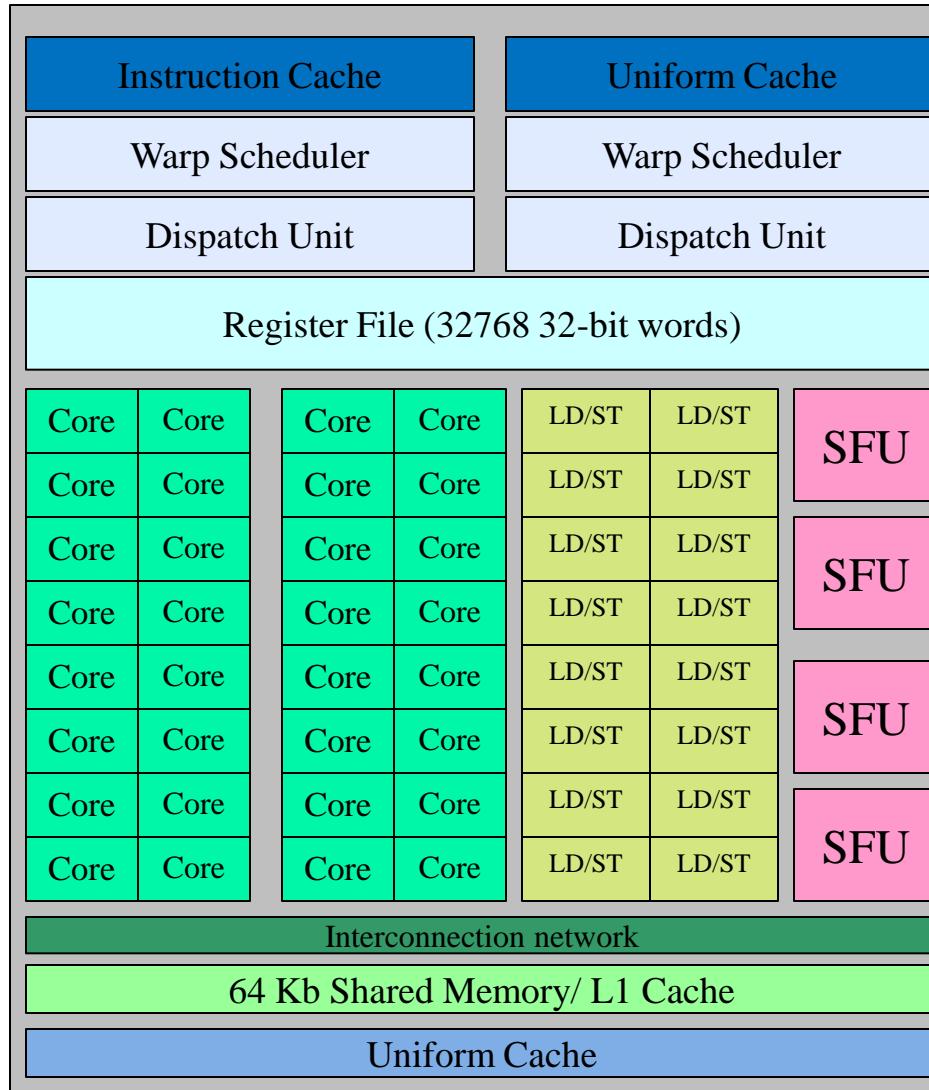


# Архитектура Tesla 20

- Объединенный L2 кэш (768 Kb)
- До 1 Tb памяти (64-битная адресация)
- Общее адресное пространство памяти
- ККО (DRAM, регистры, разделяемая память, кэш)
- Одновременное исполнение ядер, копирования памяти (CPU->GPU, GPU->CPU)
- Быстрая смена контекста (10x)
- Одновременное исполнение ядер (до 16)

# Архитектура Tesla 20

## Потоковый мультипроцессор



# Архитектура Tesla 20 (Fermi)

- 32 ядра на SM
- Одновременное исполнение 2x варпов.
- 48 Kb разделяемой памяти
- 16 Kb кэш
  - или 16 Kb разделяемой + 48 Kb кэш
- Дешевые атомарные операции

# Архитектура 3.0 (Kepler)

- 192 ядра на SM
- Одновременное исполнение 4x варпов.
- 48 Kb разделяемой памяти
- 32 SFU
- 16 Kb кэш
  - или 16 Kb разделяемый + 48 Kb кэш
- Регистры 2X

# Архитектура 5.0 (Maxwell)

- 128 ядра на SM
- Одновременное исполнение 4x варпов.
- 48 Kb разделяемой памяти
- 32 SFU
- 16 Kb кэш
  - или 16 Kb разделяемый + 48 Kb кэш
- Read-only constant cache

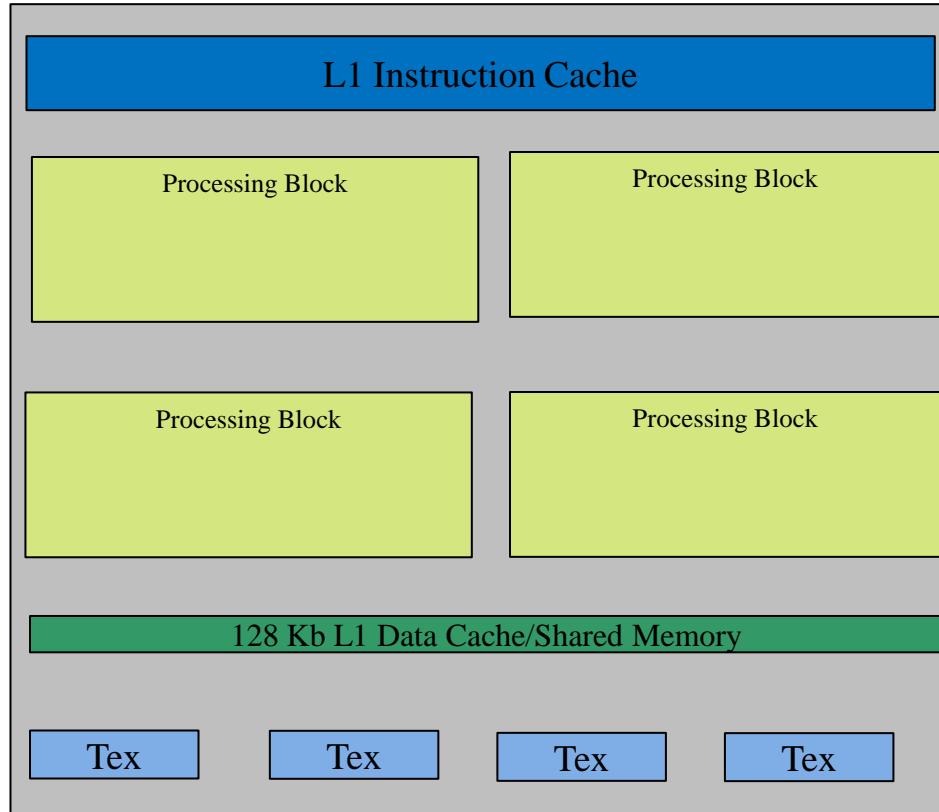
# Архитектура 6.0 (Pascal)

- 64/128 ядра на SM
- Одновременное исполнение 2/4x варпов.
- 16/32 SFU
- Shared/cache 64/128 Kb
- Read-only constant cache

# Архитектура 7.0 (Volta)

- 64 FP32 ядра на SM
- 64 INT32 ядра на SM
- 32 FP64 ядра на SM
- 8 tensor cores
- 4 texture units
- Shared/L1 Cache – 128 Kb
- 16 SFU
- 4 warp scheduler/dispatch units

# Volta. Streaming Multiprocessor



# Volta Processing Block

