Анатолий Свириденков
(codedgers.com)

Блог: http://bit.ly/cuda_blog

Проблематика

Где нужна вычислительная мощность:

- Ускорение вычислений

- Переход в реальное время

- Разгрузка **CPU**

- Улучшение качества

Чего ожидать от параллелизма

Закон Амдала (ускорение от параллелизма):

$$Sp = 1 / (a + (1 – a) / p)$$

p – количество потоков

a – доля последовательных вычислений

	p = 2	p = 8	p = 1000
a = 0,9	1,05	1,1	1,11
a = 0,5	1,33	1,77	2,0
a = 0,1	1,81	4,71	9,91

Примеры параллелизма

- Параллелизм данных, DPL: MMX, SSE, и т. д.

- Параллелизм кода, IPL: спекулятивные вычисления и конвейер, VLIW

- Квази многопоточность, многоядерность, hyper threading

- Кластеры

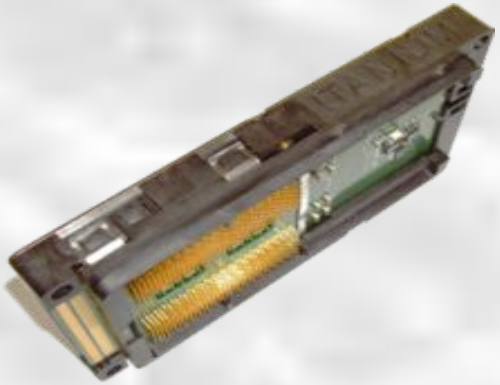

Предыстория к GPGPU

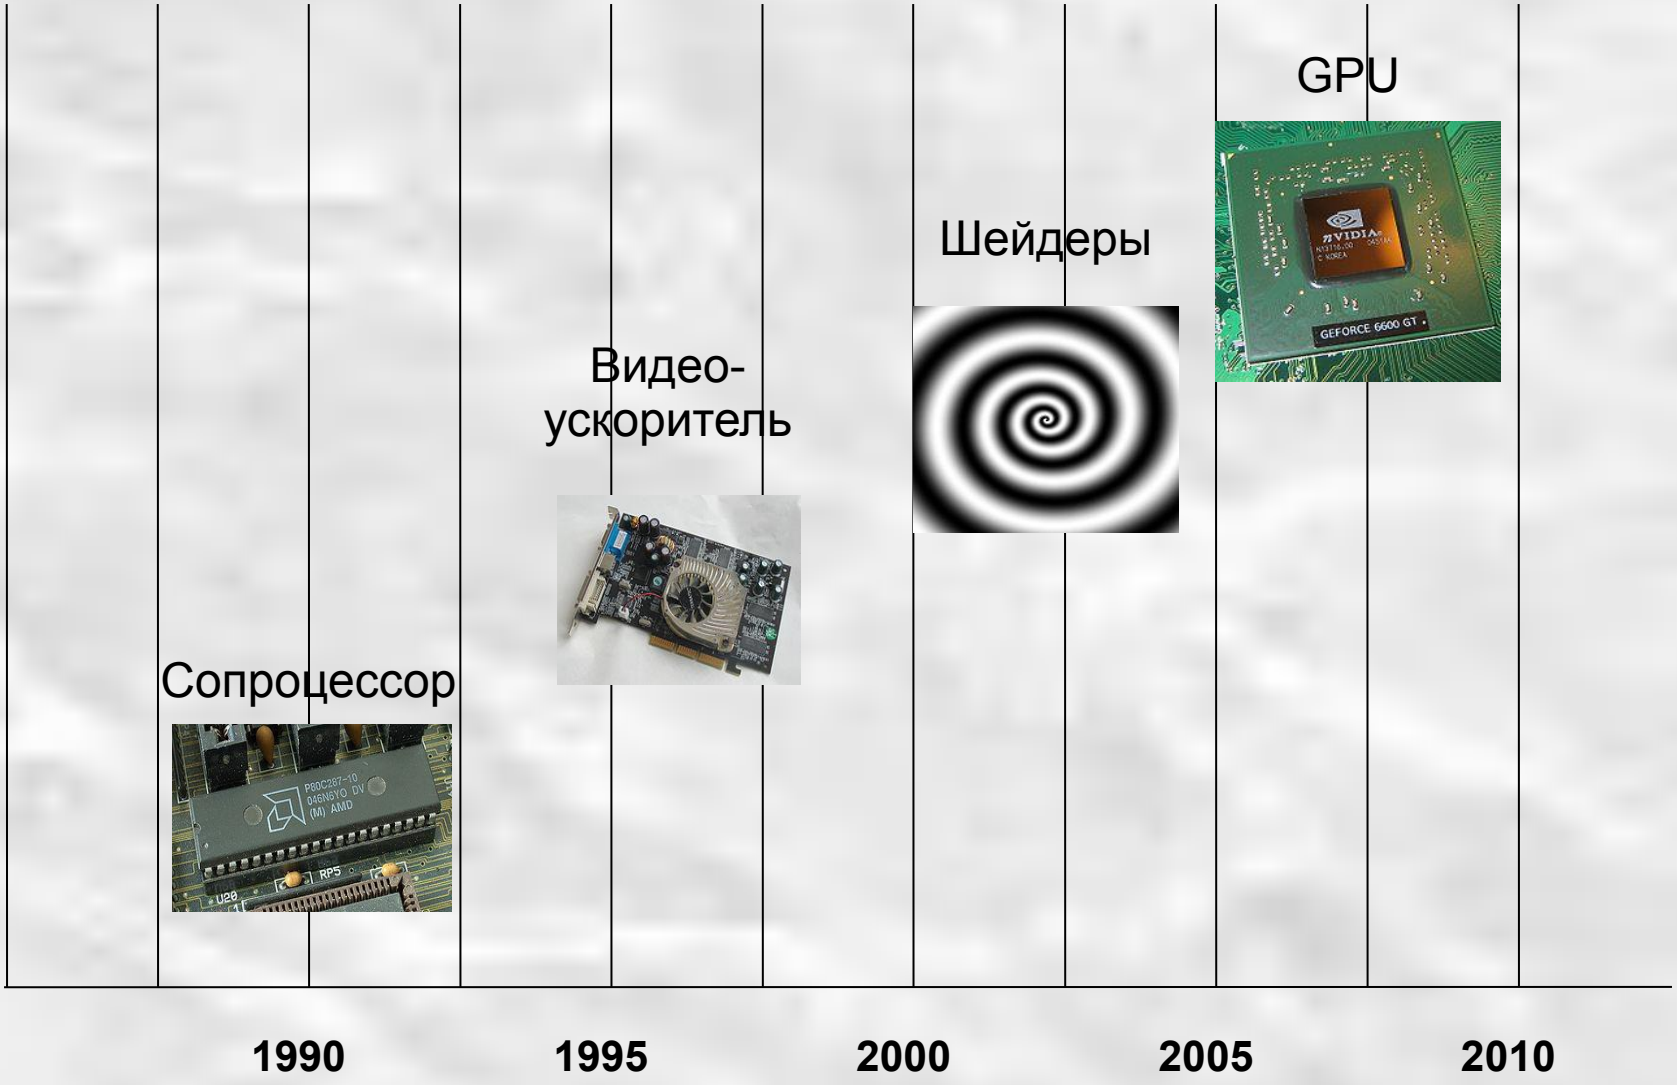

Рост производительности

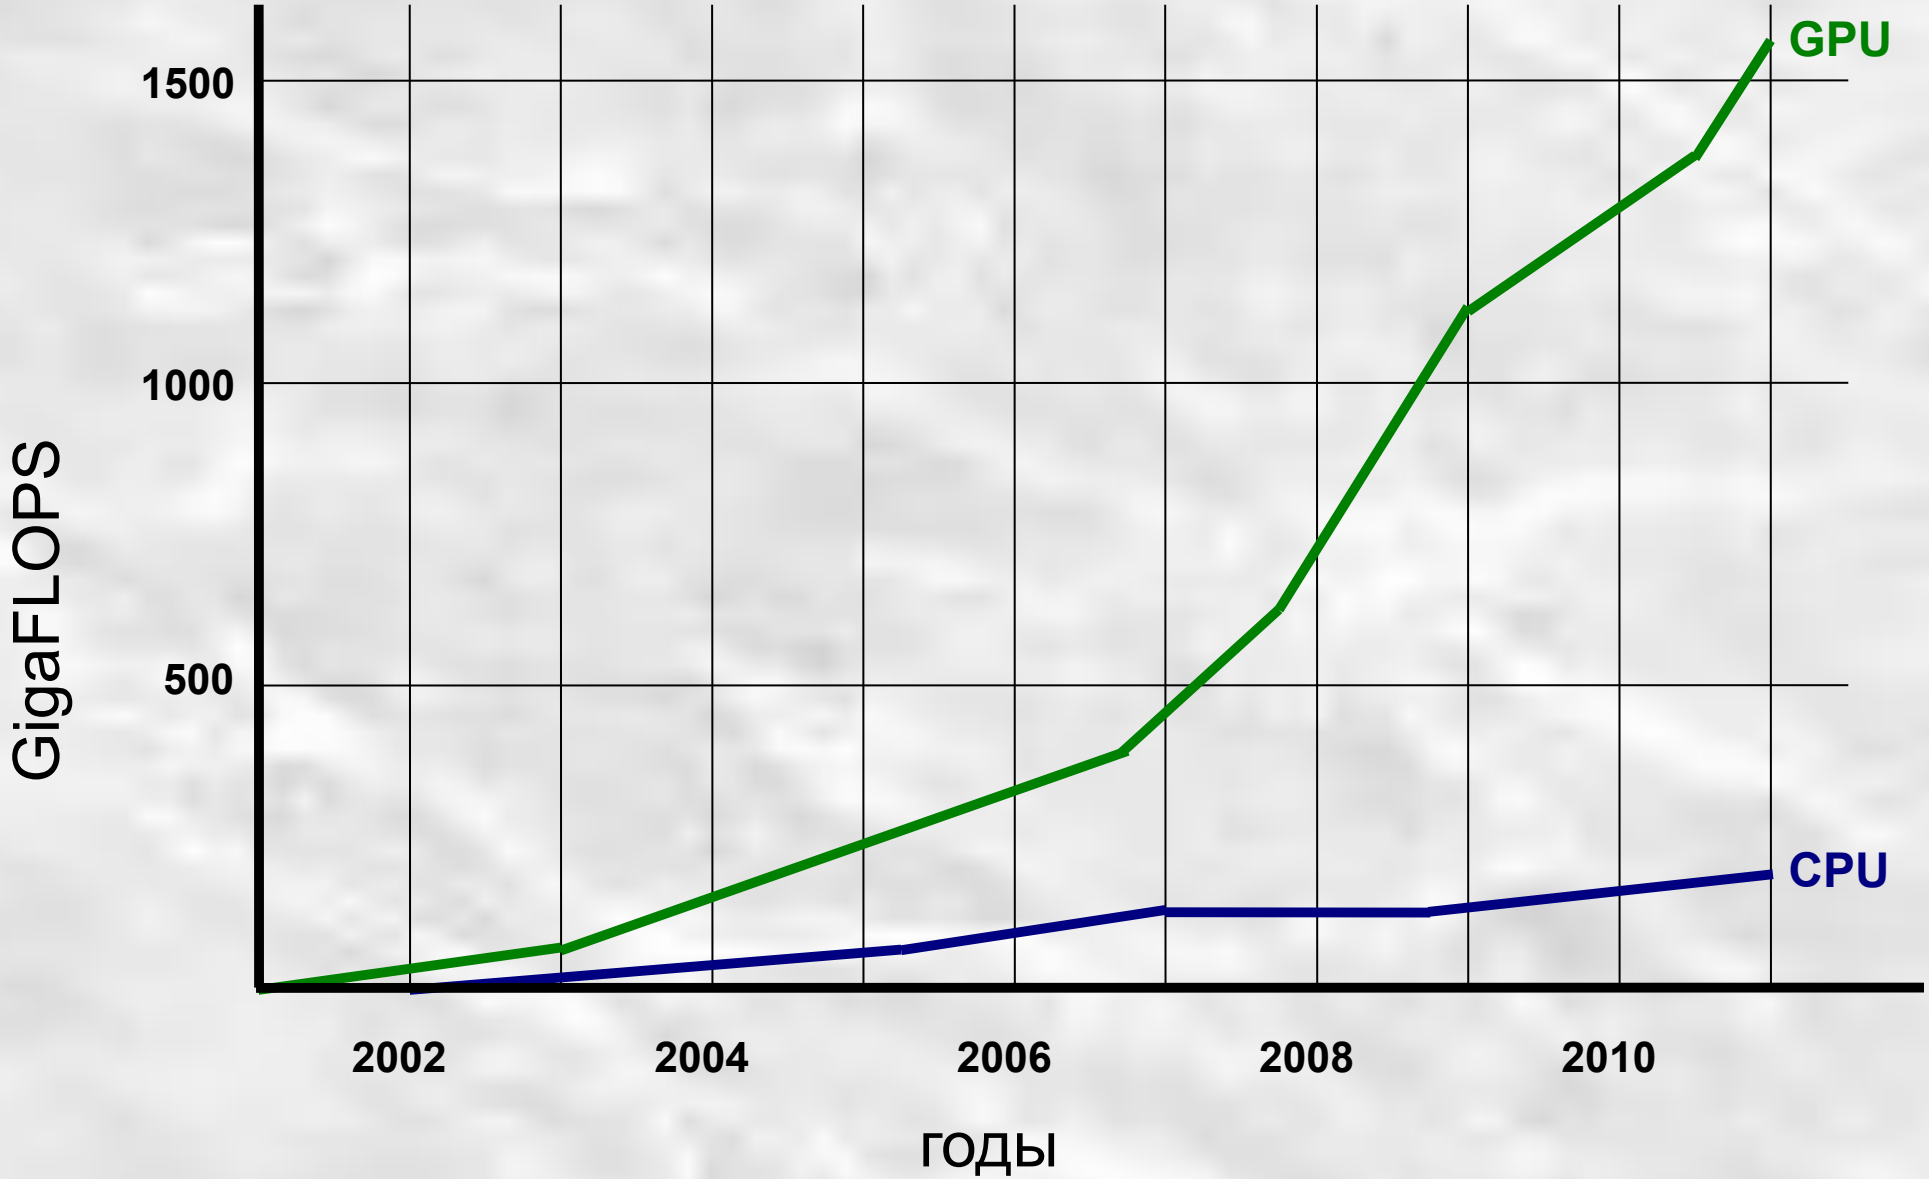

Терминология

- **host** - **CPU**

- **device** - **GPU**

- **ядро** — код запускаемого на GPU из основного приложения

- **поток** — часть вычислений исполняемых параллельно

- **сетка** (grid) — все множество потоков для одного ядра

- **блок** — набор потоков исполняемых на одном SM

- **warp** — набор потоков физически исполняемых параллельно

Программная модель памяти

Тип	Доступ	Расположение	Латентность
Регистры	Поток GPU (R\W)	SM	2-4 такта
Локальная	Поток GPU (R\W)	DRAM	~500 тактов
Разделяемая	Блок потоков GPU (R\W)	SM	2-4 такта
Глобальная	CPU(R\W), GPU(R\W)	DRAM	~500 тактов
Константная	CPU(R\W), GPU(Read-only)	DRAM + КЕШ SM	~500 к DRAM 2-4 к кешу
Текстурная	CPU(R\W), GPU(Read-only)	DRAM + КЕШ SM	~500 к DRAM 2-4 к кешу

Программная модель потоков

Grid

B (0:0)	B (1:0)	B (2:0)	B (3:0)	B (4:0)
B (0:1)	B (1:1)	B (2:1)	B (3:1)	B (4:1)
B (0:2)	B (1:2)	B (2:2)	B (3:2)	B (4:2)
B (0:3)	B (1:3)	B (2:3)	B (3:3)	B (4:3)

Block

T (0:0:0)	T (1:0:0)	T (2:0:0)
T (0:1:0)	T (1:1:0)	T (2:1:0)
T (0:2:0)	T (1:2:0)	T (2:2:0)

Приведен пример сетки из 20 блоков (5x4), в каждом блоке 18 (3x3x2) потоков. Всего в сетке 360 потоков.

Особенности программирования

- **функция ядро** возвращает только **void**

- **память** — узкое место в вычисленях и требует особого внимания

- **шина PCI-Express** — узкое место в вычислениях

- **ветвления** внутри warp **снижают** быстродействие

Программный стек CUDA

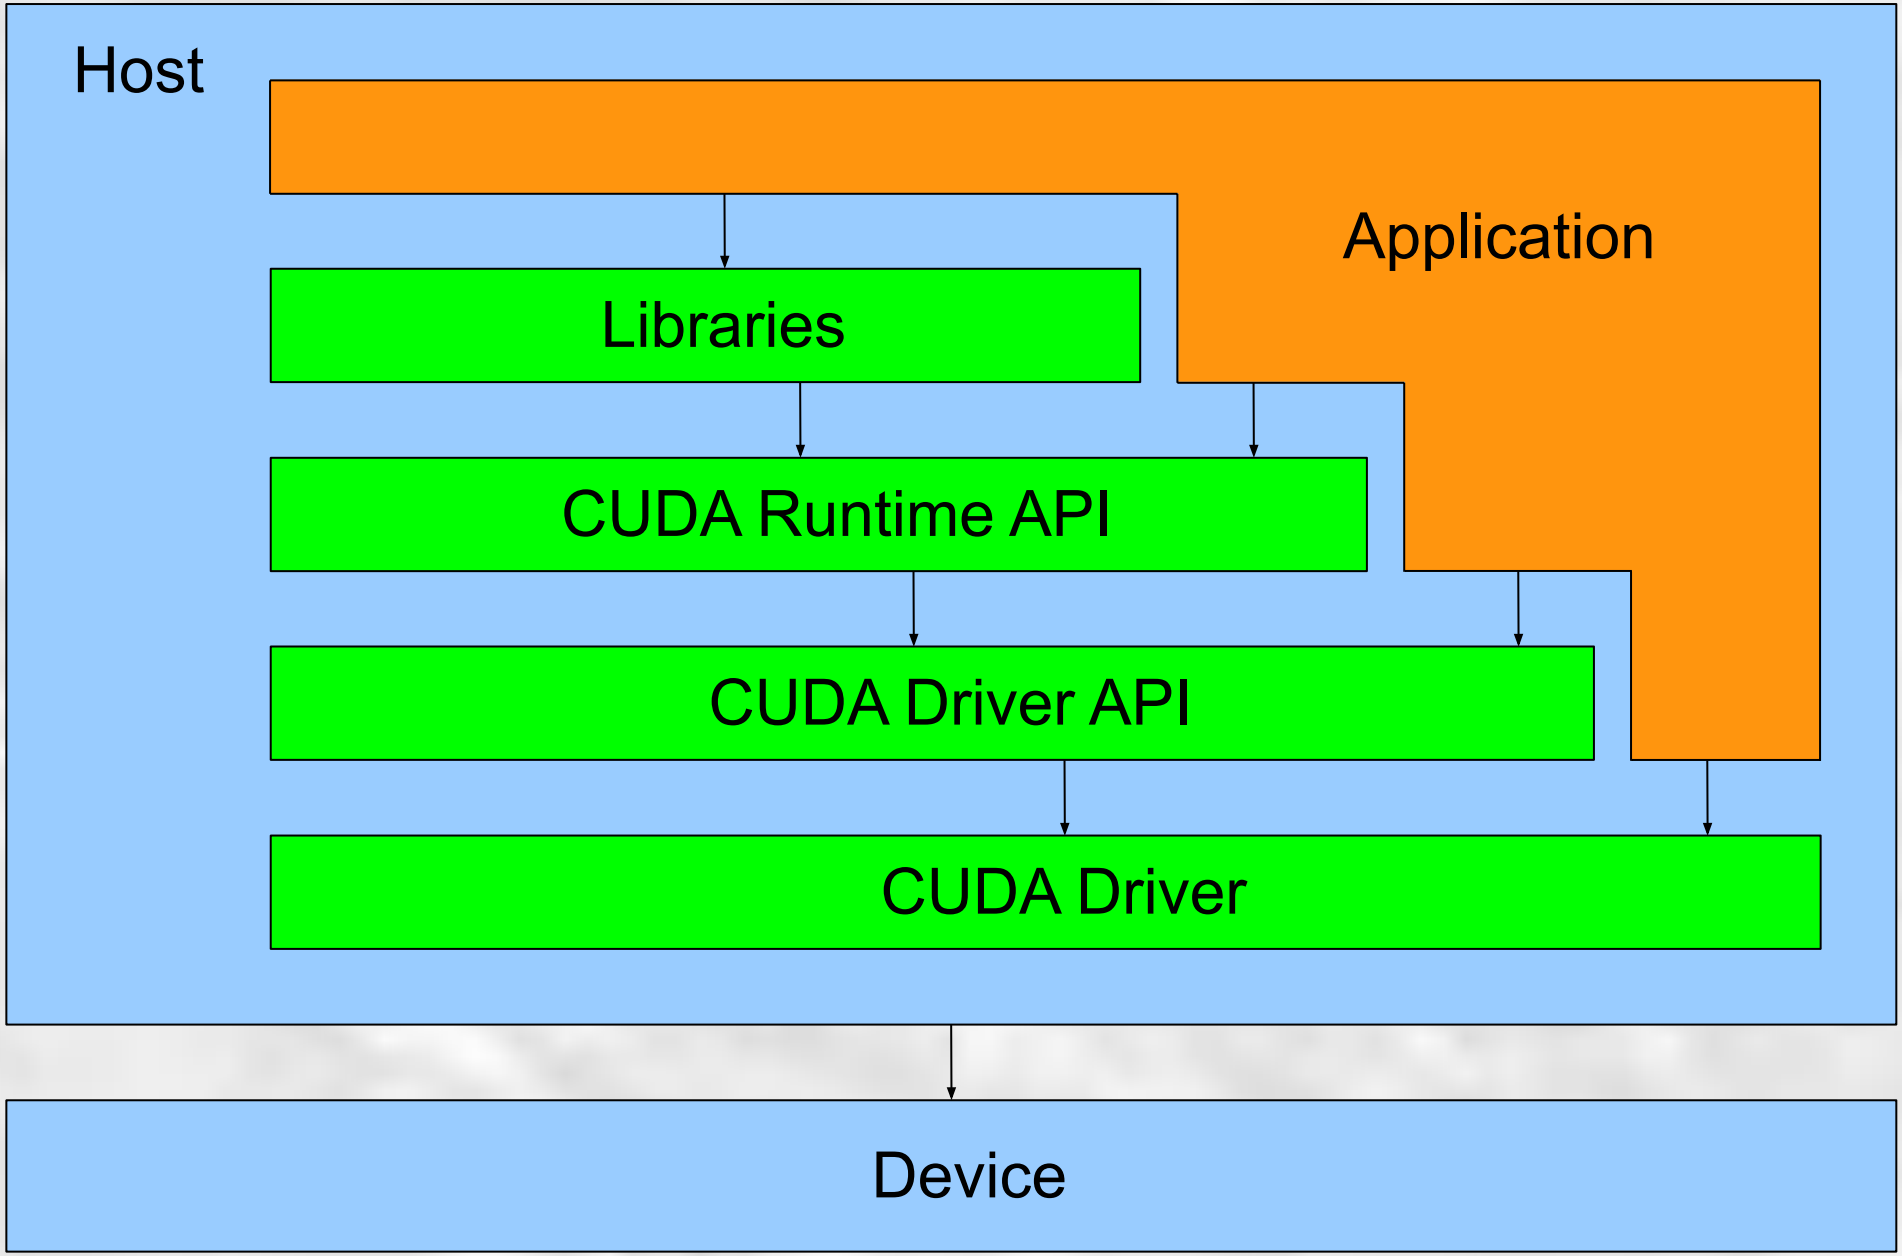

CUDA Toolkit

Последняя версия CUDA Toolkit 4.0 RC2
- https://nvdeveloper.nvidia.com

Состав:
- Драйвер для разработчиков
- GPU Computing SDK

GPU Computing SDK:
- Компилятор
- Набор утилит
- Документация
- Библиотеки (CUBLAS, CUSPARSE)
- Примеры

Компилятор NVCC

Самый важный параметр:

--help (**-help**) — печатает справку

Основные выходные форматы (и ключи компиляции):

--cubin (**-cubin**) — компилирует в виртуальный формат cubin

--ptx (**-ptx**) — компиляция в ассемблер для gpu

--gpu (**-gpu**) — компиляция в бинарный формат

NVIDIA Parallel nSight специально разработан для работы в Visual Studio

Типы функций

Обозначение	Где расположена	Кто может вызывать
__global__	GPU	CPU
__device__	GPU	GPU
__host__	CPU	CPU

- **по умолчанию** все функции **__host__**
- **__host__** и **__device__ совместимы,** компилятор создаст две версии: для **CPU** и **GPU**

```
__global__ void sum(float *c, float *a, float b);

__host__ __device__ float add(float a, float b);
```

Hello World! Сложение массивов.

```
#define      N        1024

// GPU
__global__ void sum(float *c, float *a, float *b)
{
    int index = blockIdx.x * blockDim.x + threadIdx.x;
    c[index] = a[index] + b[index];
}

// CPU
void sum(float *c, float *a, float b)
{
    for(int i = 0; i < N; i++)
    {
        c[i] = a[i] + b[i];
    }
}
```

Встроеные константы:

blockIdx — номер блока у текущего потока;

blockDim — количество блоков;

threadIdx — номер потока в блоке.

Hello World! CPU инициализация

```
int main(int argc, char **argv)
{
    float *a, *b, *c;
    float *A, *B, *C;
    a = (float*) malloc(N * sizeof(float));
    b = (float*) malloc(N * sizeof(float));
    c = (float*) malloc(N * sizeof(float));

    cudaMalloc((void **)&A, N * sizeof(float));
    cudaMalloc((void **)&B, N * sizeof(float));
    cudaMalloc((void **)&C, N * sizeof(float));

    for(int i = 0; i < N; i++)
    {
        a[i] = RandFloat(0.0f, 1.0f);
        b[i] = RandFloat(0.0f, 1.0f);
    }
```

Hello World! CPU вызов ядра

```
cudaMemcpy(A, a, N * sizeof(float), cudaMemcpyHostToDevice);
cudaMemcpy(B, b, N * sizeof(float), cudaMemcpyHostToDevice);

sum<<<N/256, 256>>>(C, A, B);

cudaMemcpy(c, C, N * sizeof(float), cudaMemcpyDeviceToHost);

cudaFree(A);
cudaFree(B);
cudaFree(C);

free(a);
free(b);
free(c);
}
```

Hello World! CPU вызов ядра

```
cudaMemcpy(A, a, N * sizeof(float), cudaMemcpyHostToDevice);
cudaMemcpy(B, b, N * sizeof(float), cudaMemcpyHostToDevice);

sum<<<N/256, 256>>>(C, A, B);

cudaMemcpy(c, C, N * sizeof(float), cudaMemcpyDeviceToHost);

cudaFree(A);
cudaFree(B);
cudaFree(C);

free(a);
free(b);
free(c);
}
```

Hello World! CPU вызов ядра

```
cudaMemcpy(A, a, N * sizeof(float), cudaMemcpyHostToDevice);
cudaMemcpy(B, b, N * sizeof(float), cudaMemcpyHostToDevice);

sum<<<N/256, 256>>>(C, A, B);

cudaMemcpy(c, C, N * sizeof(float), cudaMemcpyDeviceToHost);

cudaFree(A);
cudaFree(B);
cudaFree(C);

free(a);
free(b);
free(c);
}
```

Hello World! CPU вызов ядра

```
cudaMemcpy(A, a, N * sizeof(float), cudaMemcpyHostToDevice);
cudaMemcpy(B, b, N * sizeof(float), cudaMemcpyHostToDevice);

sum<<<N/256, 256>>>(C, A, B);

cudaMemcpy(c, C, N * sizeof(float), cudaMemcpyDeviceToHost);

cudaFree(A);
cudaFree(B);
cudaFree(C);

free(a);
free(b);
free(c);
}
```

GPGPU прочее

DirectCompute — библиотека от Microsoft. Часть DirectX;

OpenCL — кроссплатформенная библиотека;

Готовые библиотеки с поддержкой GPGPU:

- **OpenCV** — обработка изображения и компьютерное зрение
- **CUBLAS** — математические вычисления
- **CUFFT** — быстрые преобразования фурье
- **CUSPARSE** — библиотека линейной алгебры

Пакеты ПО со встроенной поддержкой **GPU**, например **Matlab**

OpenCV

```
#include <iostream>
#include "opencv2/opencv.hpp"
#include "opencv2/gpu/gpu.hpp"

int main (int argc, char* argv[])
{
    cv::gpu::GpuMat dst, src = cv::imread("file.png",
                                          CV_LOAD_IMAGE_GRAYSCALE);

    cv::gpu::threshold(src, dst, 128.0, 255.0, CV_THRESH_BINARY);

    cv::imshow("Result", dst);
    cv::waitKey();

    return 0;
}
```

Ссылки:

- http://www.nvidia.ru/object/cuda_home_new_ru.html - о CUDA
- http://www.nvidia.ru/object/cuda_opencl_new_ru.html - OpenCL
- http://www.nvidia.ru/object/directcompute_ru.html - DirectCompute
- http://gpgpu.org/ - подборка информации по GPGPU
- http://www.gpgpu.ru - GPGPU по-русски

Контакты:

- skype: sviridenkov.anatoliy
- e-mail: Anatoliy.Sviridenkov@gmail.com
- **блог http://bit.ly/cuda_blog**