CUDA
ВВЕДЕНИЕ

Романенко А.А.
arom@ccfit.nsu.ru
Новосибирский государственный университет

Мощность вычислительных систем

«K computer» **2011**
68 544 x 8-core SPARC64 VIIIfx.
8,162 Pflops

280 Tflops
212,992 CPUs

Производительность

Время

Рост производительности

- За счет увеличения частоты процессоров
- За счет увеличения количества ядер/процессоров
- За счет усложнения архитектуры самих процессоров
  - Увеличение количества регистров
  - Изменение длинны конвейера
  - Увеличение разрядности
  - пр.

Компьютерная графика

Обработка графики

* Работа с векторами
* Работа с маленькими матрицами
* Фильтры/post-processing
* Вычисление проекций
* пр.

* Однотипные операции над большим количеством данных

Производительность видеокарт

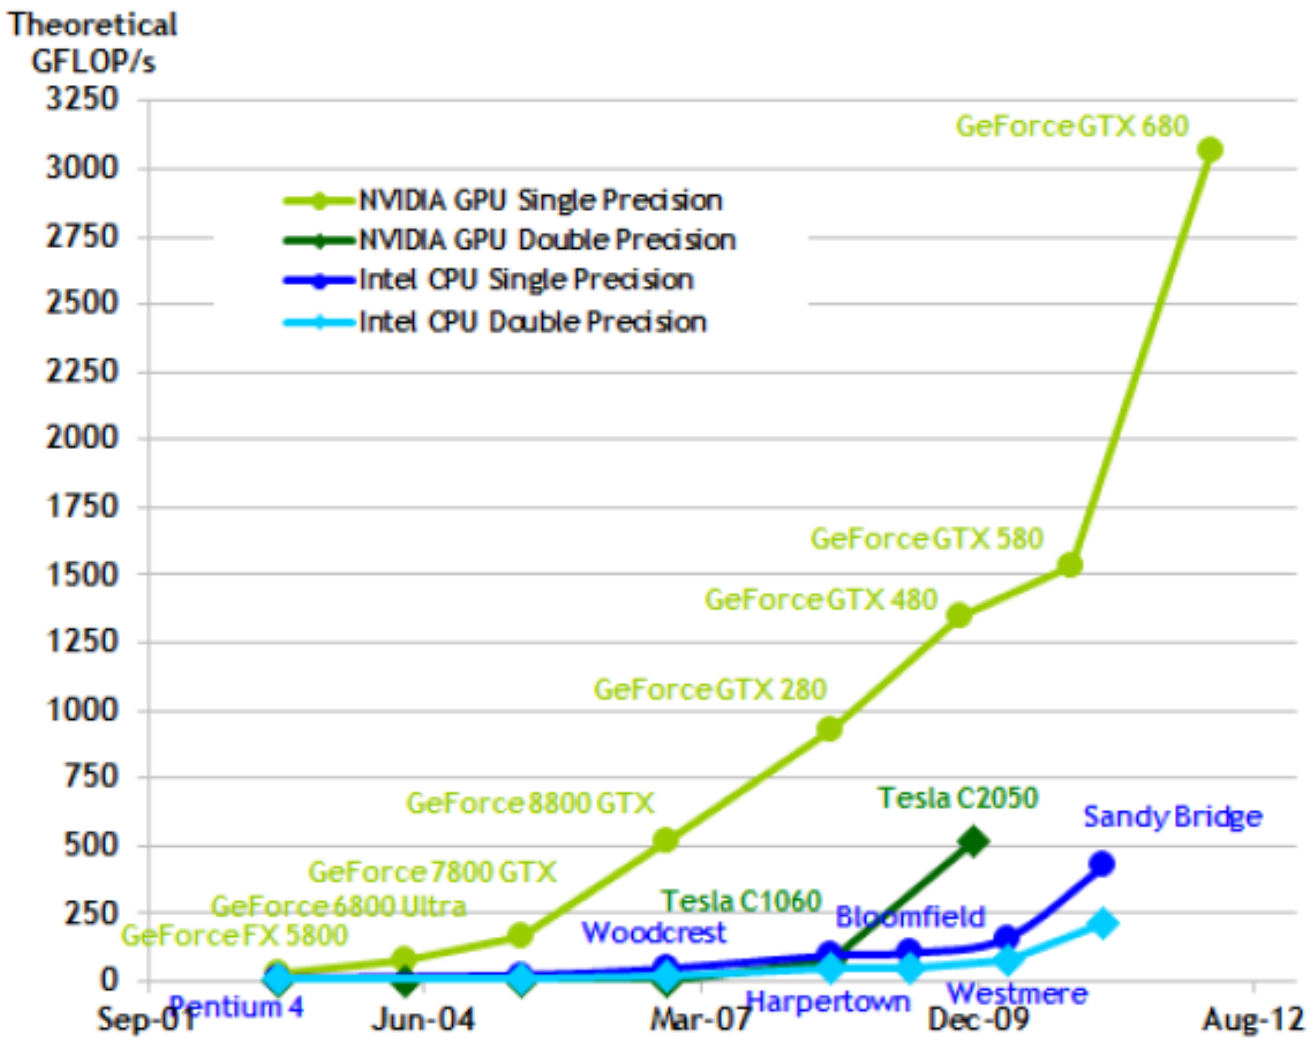

Дорожная карта

Данные на сентябрь 2010

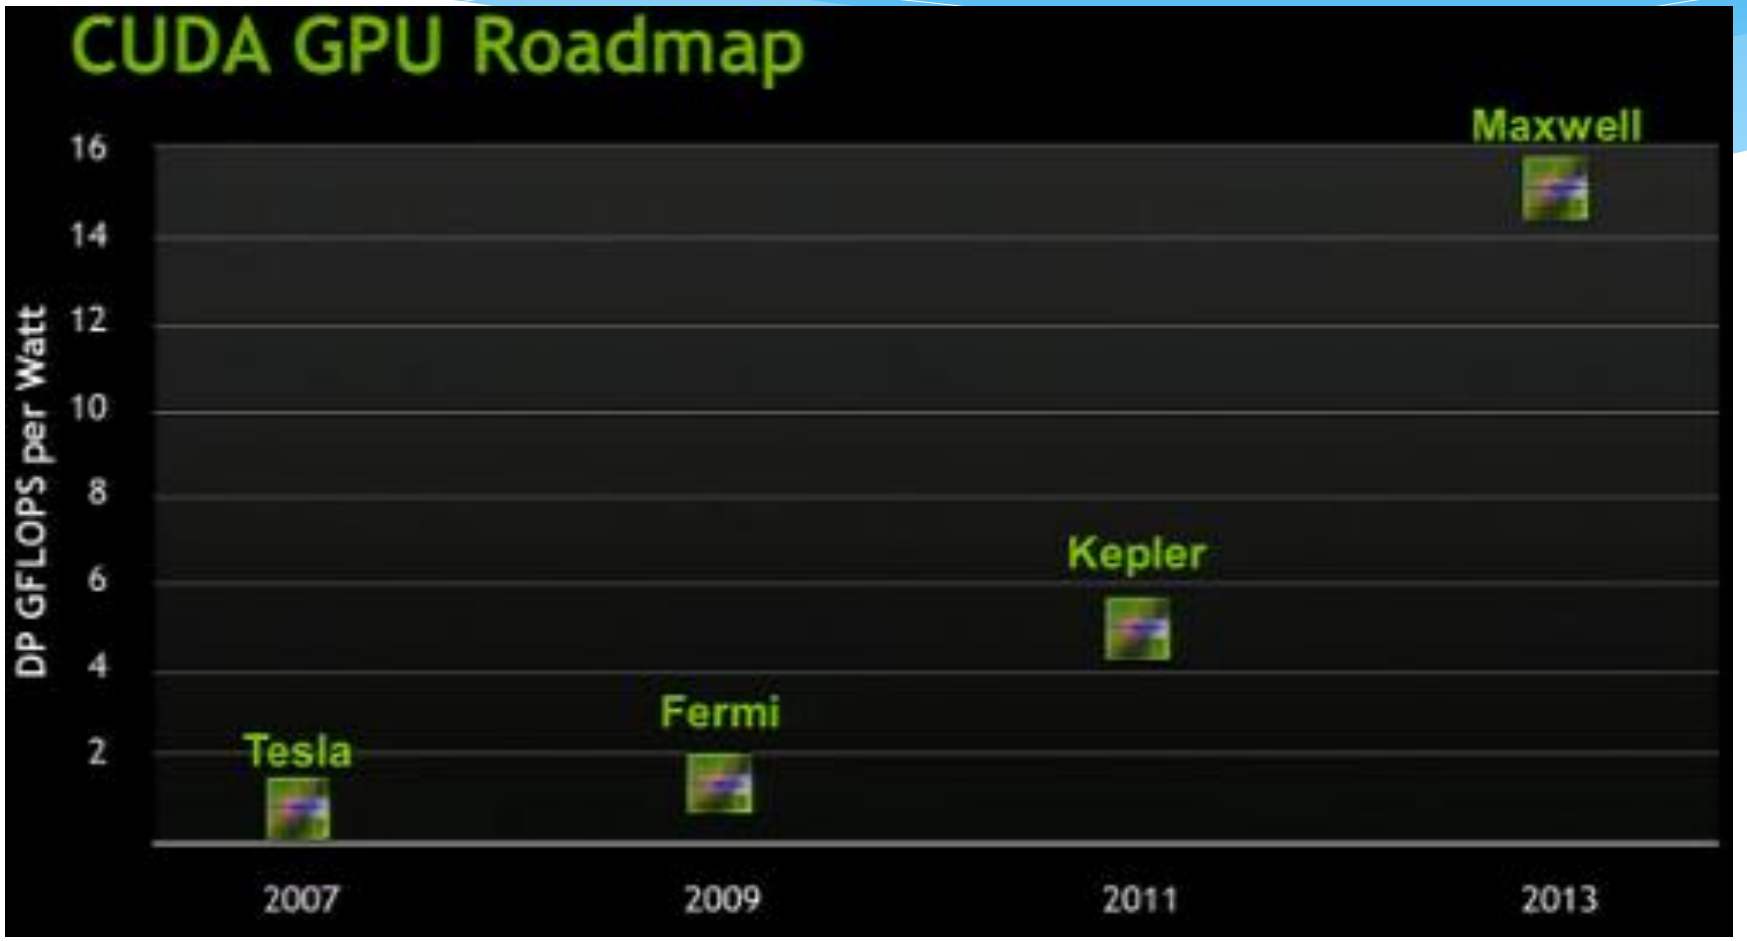

* Kepler: 28nm, 1.4 Tflops DP
* Maxwell: 22nm, 4 Tflops DP

Пропускная способность шины

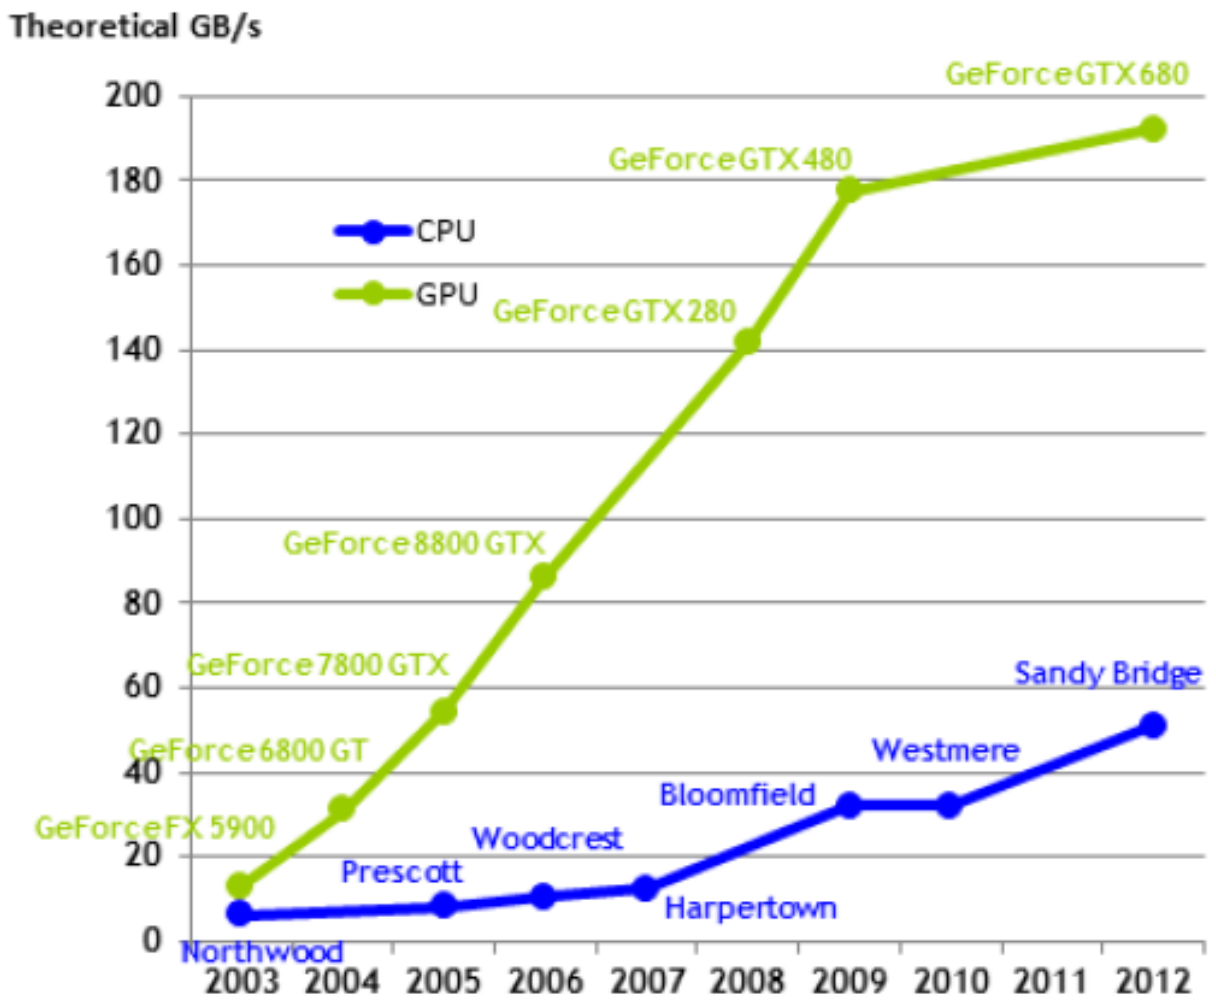

Гетерогенные системы

+

3 из 5 в лидерах списка top500 !

Гетерогенные vs. традиционные вычислительные системы

* **Tianhe-1A** (2 место)
  * Xeon X5670 6C 2.93 GHz, NVIDIA 2050

  * 4,7 Pflops (peak)
  * 4040 kW

* **Jaguar** (3 место)
  * Opteron 6-core 2.6 GHz

  * 2,3 Pflops (peak)
  * 6950 kW

GPU — Graphical Processing Unit

* GPU — процессор на видеокарте. Имеет свою архитектуру
* Программа на GPU не может общаться с хостом
* Программа на GPU не может писать в память хоста
* Загрузка и выгрузка данных на видеокарту производятся через шину PCI Express 1 (2). Передача данных инициируется на стороне хоста
* Видеокарта - сопроцессор

CPU vs. GPU

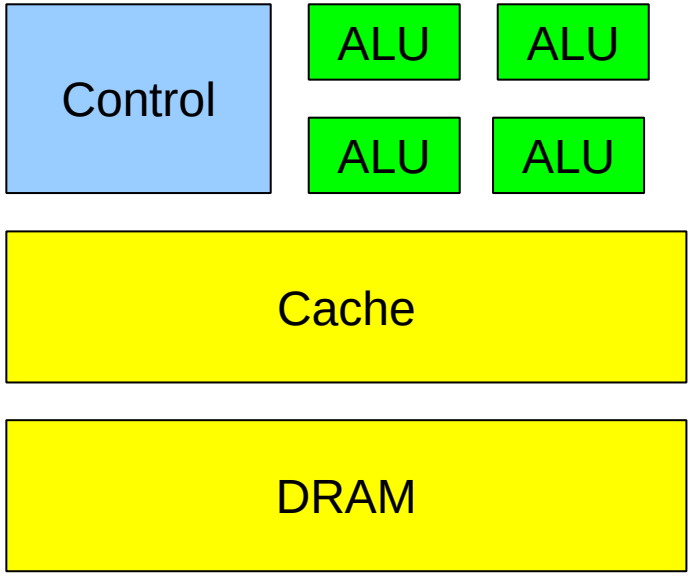

CPU

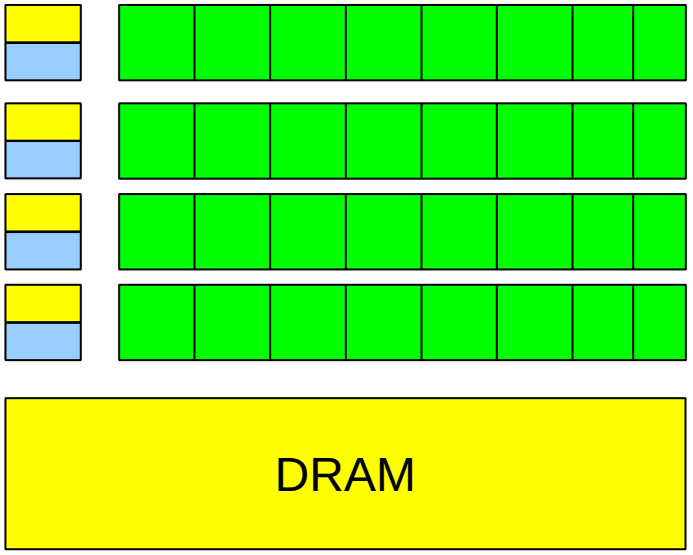

GPU

* Меньше транзисторов на управление и кэш
* Больше на АЛУ

Доступ к памяти

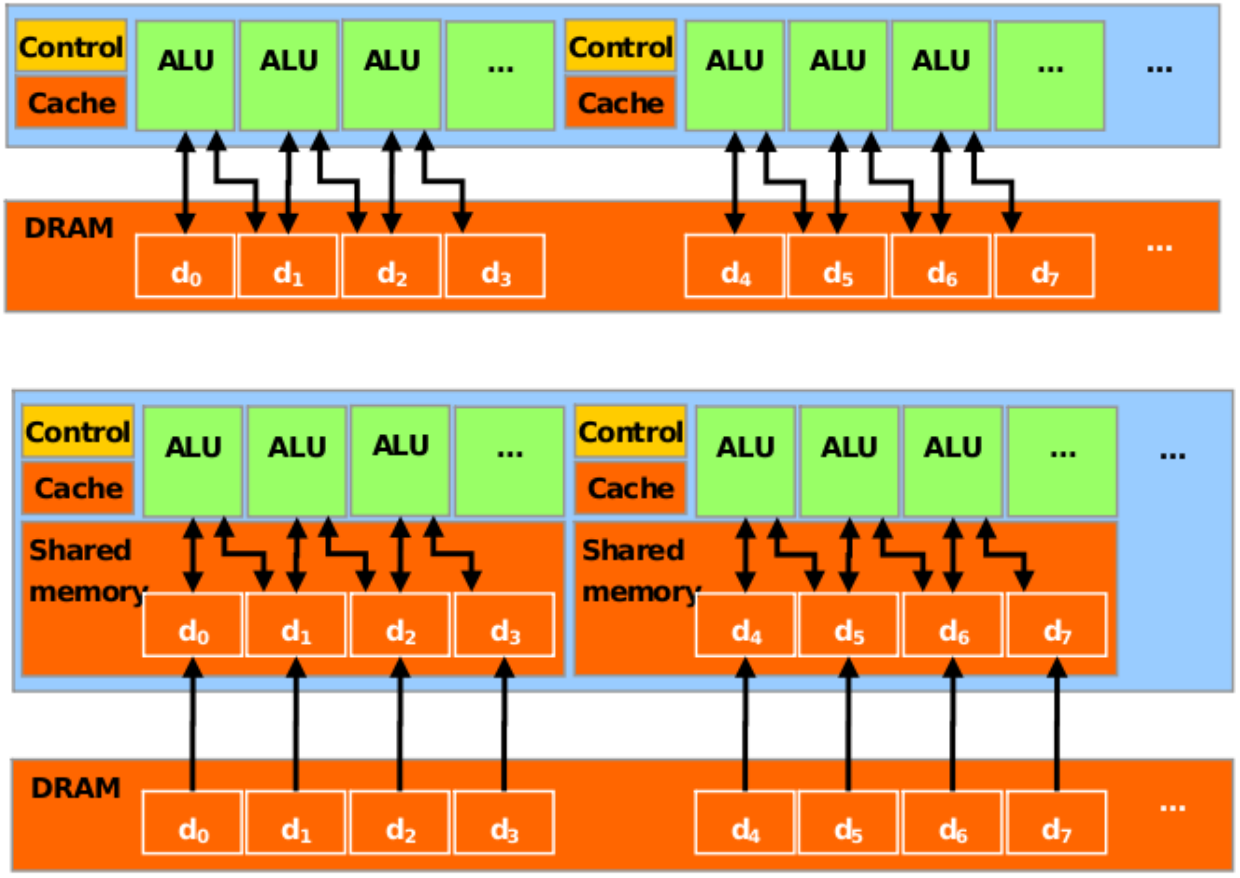

Аппаратная архитектура GPU (GT200)

Streaming Processor Array

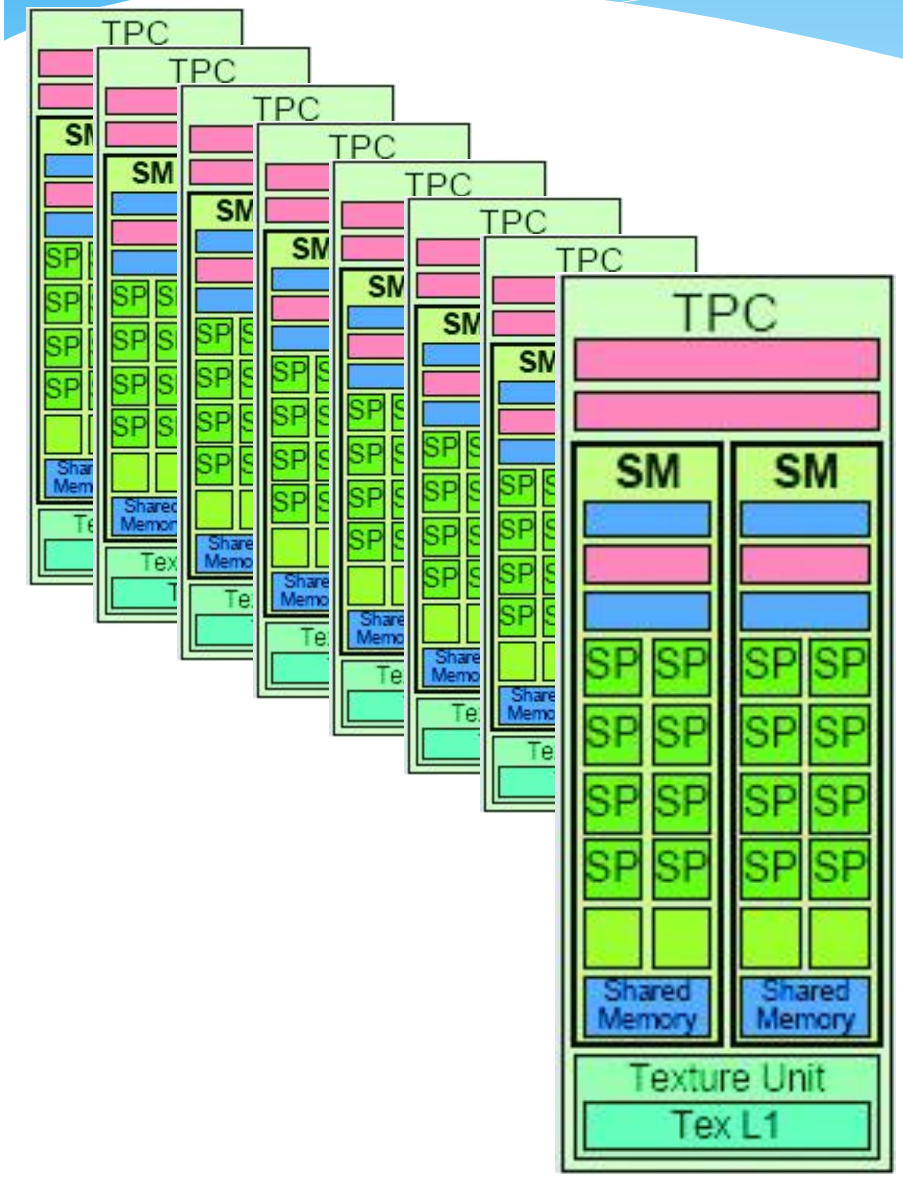

* TPC - Texture Processor Cluster
* SM — Streaming Multiprocessor
  * Multi-threaded processor core
  * Fundamental processing unit for CUDA thread block
* SP — Streaming Processor
  * Scalar ALU for a single CUDA thread

	Количество SM
GeForce 8800 GTX	16
GeForce 8800 GTS	12
Tesla D870	2x16
Tesla S870	4x16
Tesla C1060, GT200, Tesla T10	30
Tesla S1070	4x30

Вычислительная совместимость
Compute capatibility

* Compute Capability 1.0+
  * Асинхронный запуск ядер
* Compute Capability 1.1+
  * Добавлена поддержка асинхронного копирования (одно устройство). Свойство asyncEngineCount
  * Атомарные операции
* Compute Capability 1.3+ (например, C1060)
  * Операции над числами с двойной точностью
* Compute Capability 2.0+ (например, C2050)
  * Добавлена возможность параллельного исполнения ядер на GPU (свойство concurrentKernels)
  * Добавлено второе устройство для двунаправленного асинхронного копирования (свойство asyncEngineCount)

Tesla C1060

1 TFlops

Tesla S1070

4 TFlops

Fermi

* Анонс в сентябре 2009г.
* В мае 2010 года начала продаж видеокарт серии GT300 с новым чипом с кодовым названием Fermi

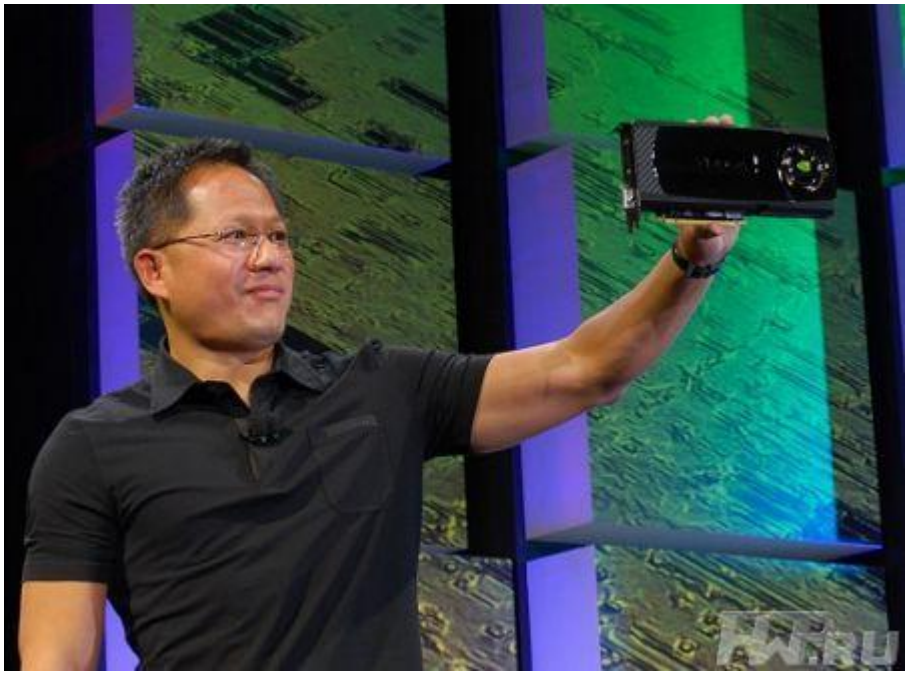

Fermi. Характеристики

* 3 млдр. транзисторов, 40-нм техпроцесс TSMC
* 512 ядер CUDA с поддержкой IEEE 754-2008, объединенные в 16 потоковых мультипроцессоров
* Тактовая частота ядер CUDA - около 1,5 Ггц
* 128 блоков выборки текстур
* 384-битный контроллер памяти GDDR5 (6x64 бит)
* Пропускная способность шины памяти - около 192 Гбайт/с
* 1,5 Тфлопс SP, 750 Гфлопс DP
* Интерфейс - PCI Express x16 2.0
* C++, в дополнение к поддержке C, Fortran, Java, Python, OpenCL и DirectCompute.
* ECC

Fermi. Особенности

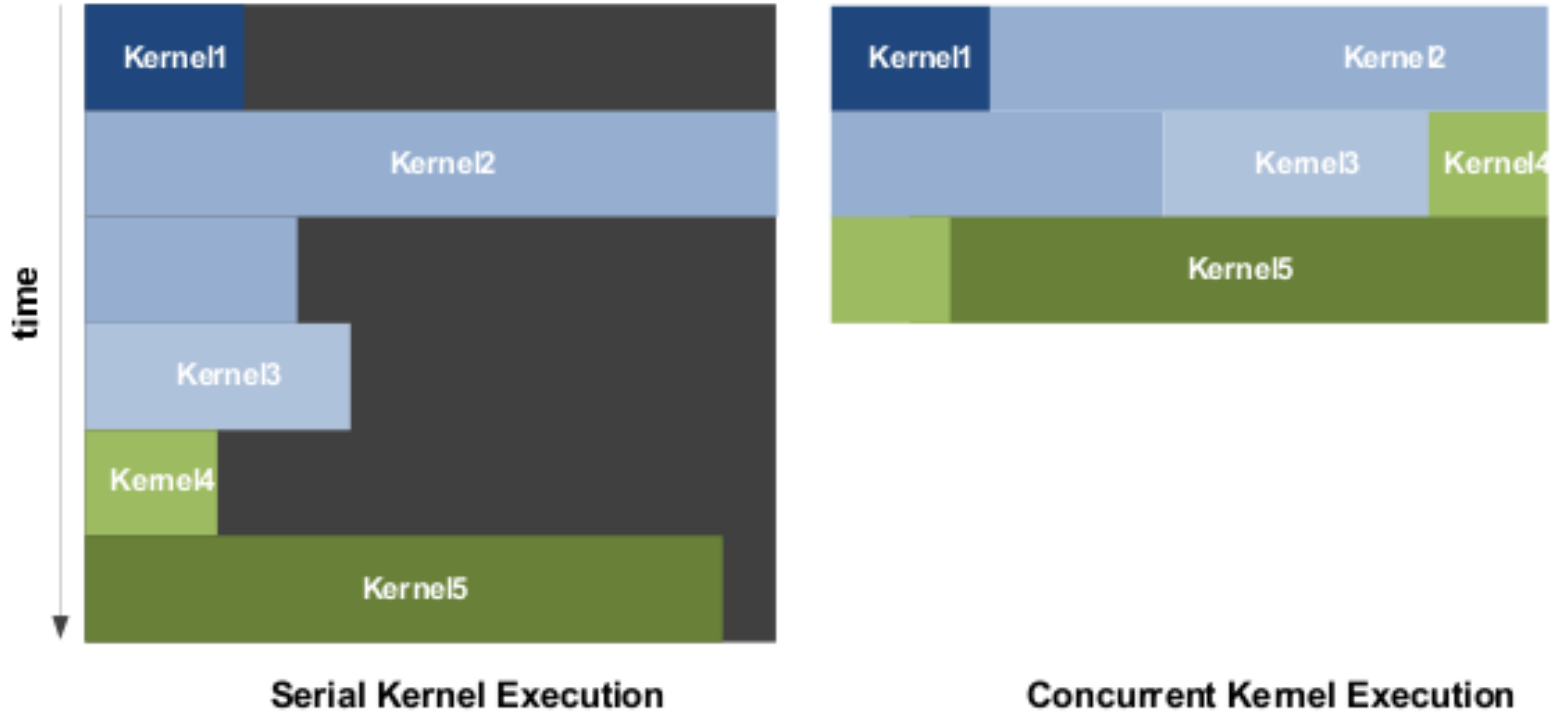

Serial Kernel Execution

Concurrent Kernel Execution

Fermi. Особенности

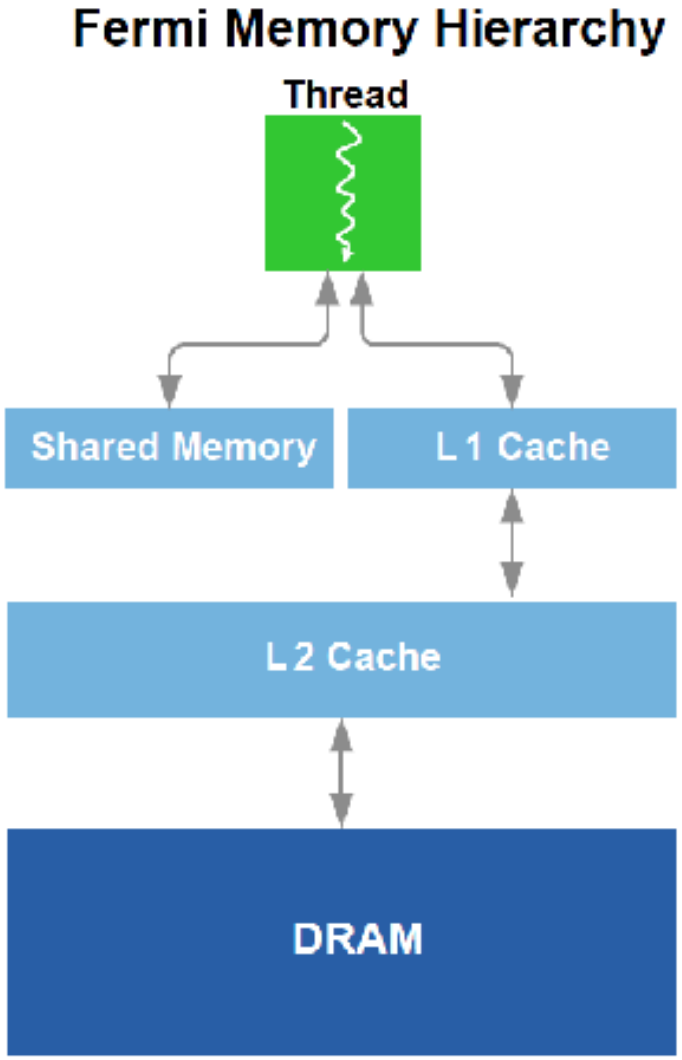

* NVIDIA Parallel DataCache™ - первый иерархический кэш на GPU

Kepler. Май 2012

* Tesla K10
  * 2 Kepler GK104s
  * 190 Gigaflops (95 Gflops на GPU) - двойная точность
  * 4577 Gigaflops (2288 Gflops на GPU) - одинарная точность
  * 320 GB/sec (160 GB/sec на GPU) шина памяти
  * 8GB GDDR5 (4 GB на GPU)
  * 3072 CUDA ядер (1536 на GPU)
* Tesla K20
  * Поставки в четвертом квартал 2012
  * Производительность в двойная точность в 3 раза выше чем для Fermi

Ускорение для некоторых приложений

Example Applications	URL	Application Speedup
Seismic Database	http://www.headwave.com	66x to 100x
Mobile Phone Antenna Simulation	http://www.acceleware.com	45x
Molecular Dynamics	http://www.ks.uiuc.edu/Research/vmd	21x to 100x
Neuron Simulation	http://www.evolvedmachines.com	100x
MRI processing	http://bic-test.beckman.uiuc.edu	245x to 415x
Atmospheric Cloud Simulation	http://www.cs.clemson.edu/~jesteel/clouds.html	50x

3 способа написать программу для GPU

Приложение

Оптимизированные библиотеки

Директивы компилятора

Языки программирования (C/C++/Фортран)

Ускорение до нескольких десятков раз

Максимум производительности

CUDA vs OpenCL

* CUDA
  * Процессоры NVIDIA (решения Cray, HP, IBM, T-Platforms, NextIO…)
  * Производительность
  * Функциональность
  * Удобство разработки
  * Поддержка
  * Учебные материалы и библиотеки
* OpenCL
  * Архитектура не фиксирована, требуется универсальность
  * Производительность не приоритетна

CUDA - Compute Unified Device Architecture

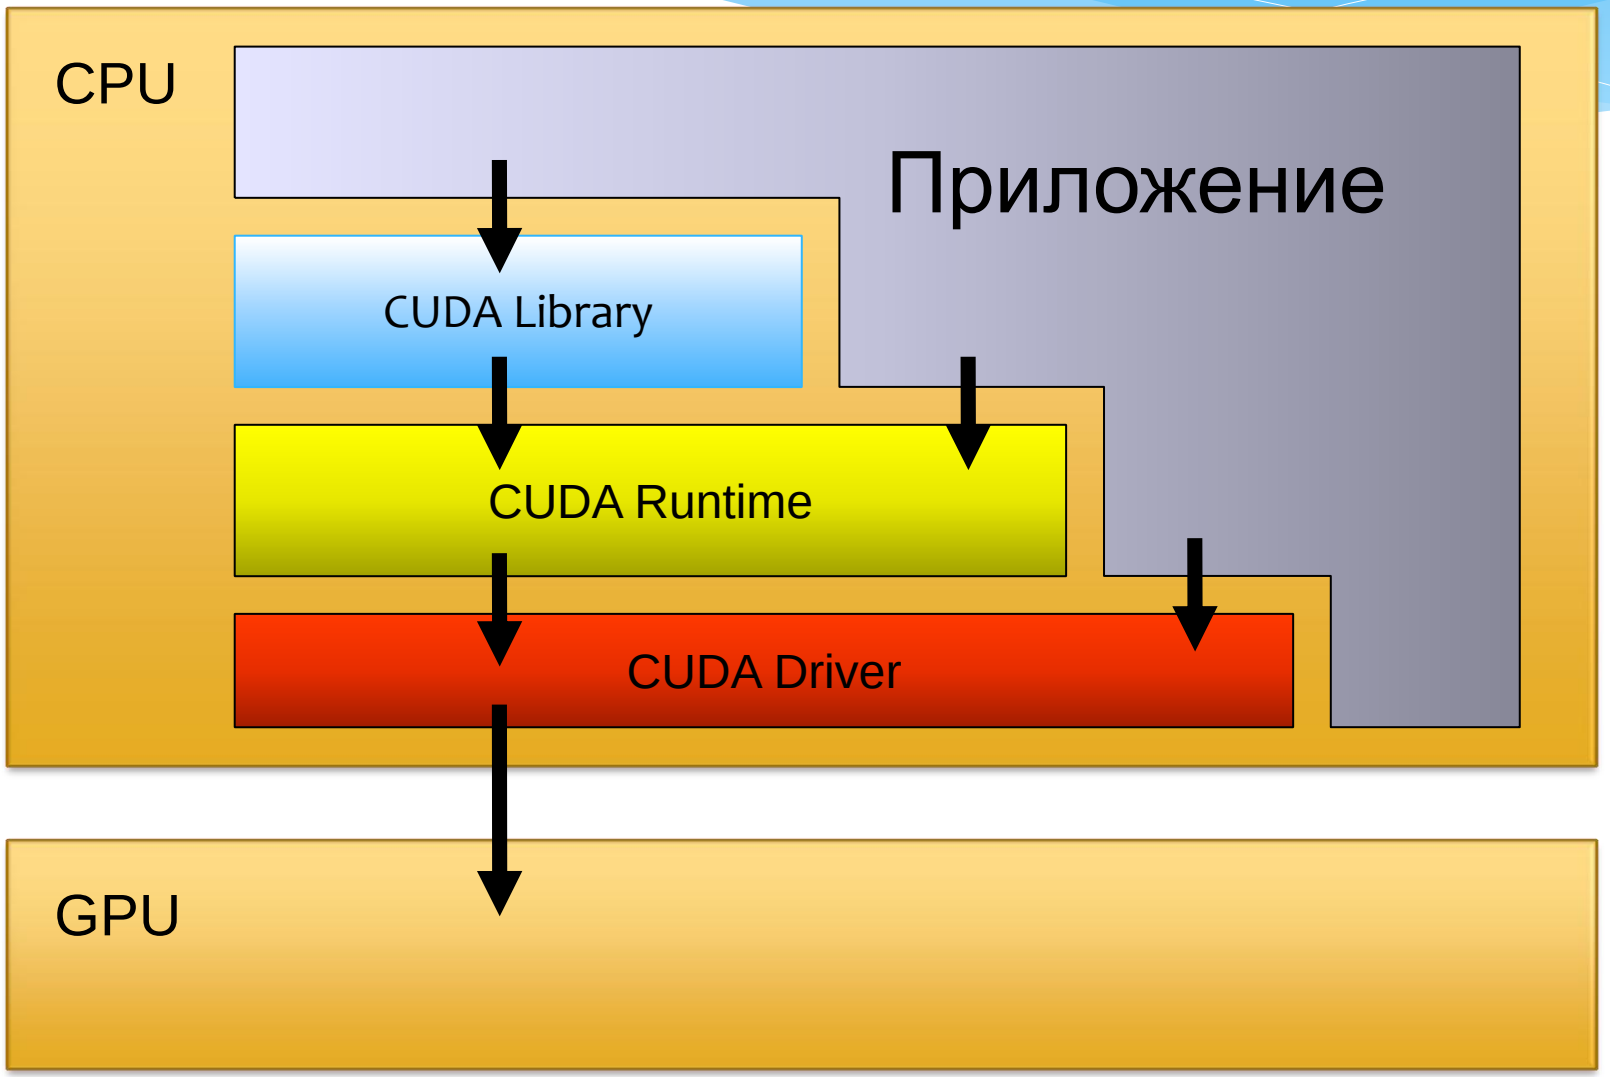

CUDA Roadmap

- CUDA 1.0 — 2007
- CUDA 2.0 — 2008
- CUDA 3.0 — 2009
- CUDA 4.0 — 2011

2012 – 5 лет!

Термины

* Поток (Thread) — единица исполнения потока команд
* Потоковый блок (Thread blok) — группа связанных между собой потоков.
* Варп (Warp)— группа потоков внутри потокового блока, которая исполняется физически одновременно (32 потока)
* Сеть (Grid) — набор блоков, который должен быть обработан прежде чем исполнение программы пойдет дальше.

Программная модель

* GPU имеет свою память
* Программа в виде потоков выполняется на SP
* SP имеет доступ только к разделяемой памяти внутри своего SM и памяти GPU
* Синхронизация потоков возможна только внутри SM
* Исполнение организовано как сеть (GRID) потоковых блоков (thread block)
* Программа выполняемая потоком — ядро (kernel)

Запуск потоков

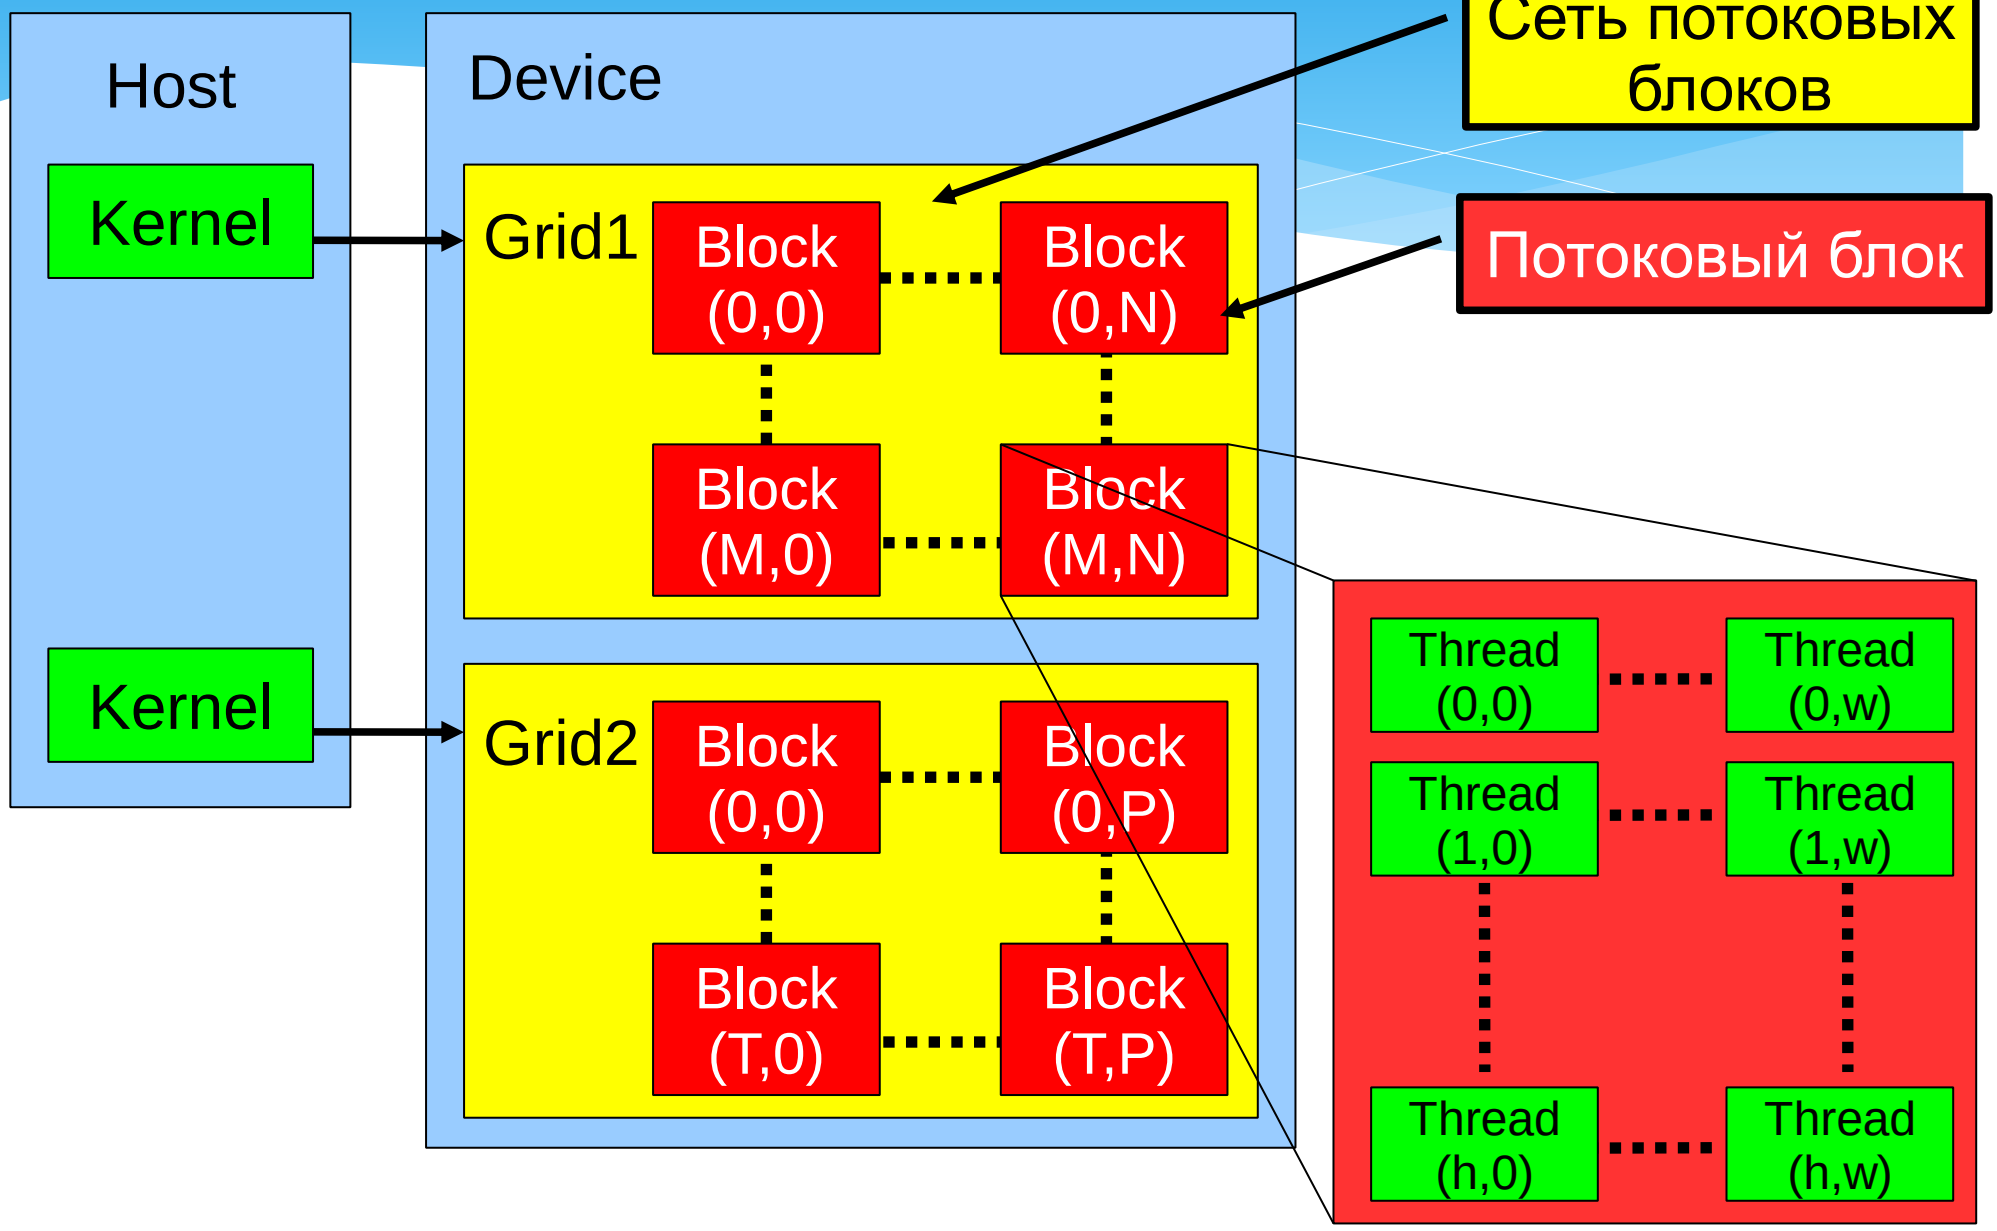

Потоковый блок

* Каждый поток в блоке имеет свой идентификатор — threadIdx
* Для удобства потоки могут отражаться на одномерную, двумерную, трехмерную сетку. При этом координаты потока задаются через (x,y,z)
* Размеры области отображения задаются при запуске ядра
* Количество потоков в блоке ≤ 512

Сеть потоковых блоков

* Каждый блок в сети имеет свой идентификатор — BlockIdx
* Для удобства блоки могут отражаться на одномерную, двумерную сетку. При этом координаты блок задаются через (x,y,z)
* Размеры области отображения задаются при запуске ядра

Пример

* Пусть при запуске задана двумерная сеть из блоков размером HxW и каждый блок содержит MxK потоков
* Таким образом область моделирования разбивается на
  * H*M потоков по вертикали
  * W*K потоков по горизонтали
* координаты потока в пространстве
  * (blockID.x*M + threadID.x, blockID.y*K + threadID.y)

Модель выполнения

* Блоки выполняются на Stream Multiprocessor
  * Один блок только на одном SM
  * Последовательность исполнения блоков не определена
* Количество блоков на SM определяется количеством регистров, требуемых потоку и количеством разделяемой памяти на блок
* Исполняемый в текущий момент блок называется активным блоком

Модель выполнения

* Каждый активный блок разбивается на SIMD группы потоков — варпы (warps). Каждый ворп содержит одинаковое количество потоков. WarpSize = 32
* Планировщик потоков периодически передает управление от одного варпа к другому
* Распределение потоков по варпам всегда одинаковое

Литература

* http://www.nvidia.com/object/cuda_home.html
* http://steps3d.narod.ru/tutorials/cuda-tutorial.html
* http://steps3d.narod.ru/tutorials/cuda-2-tutorial.html