

## Решения для высокопроизводительных вычислений от NVIDIA

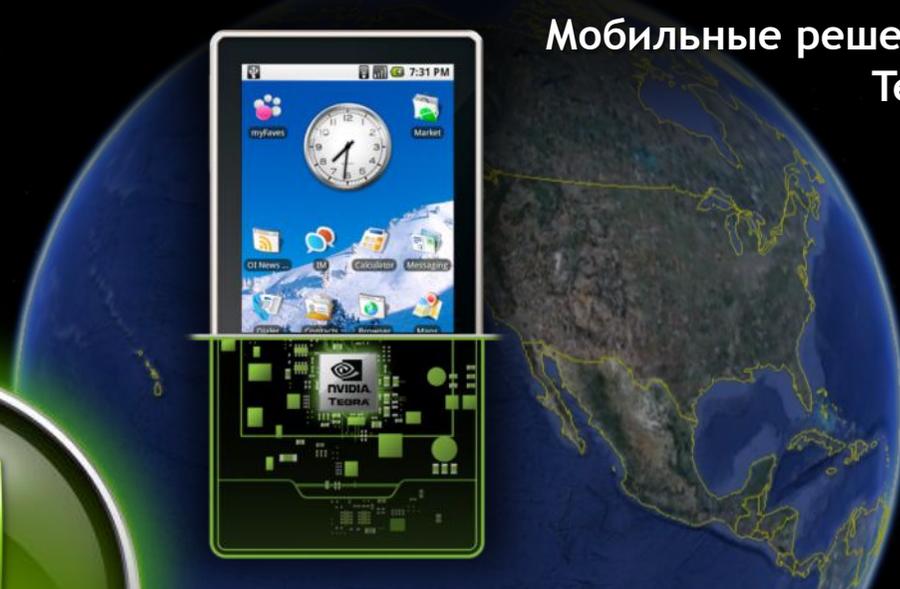
Февраль 2010



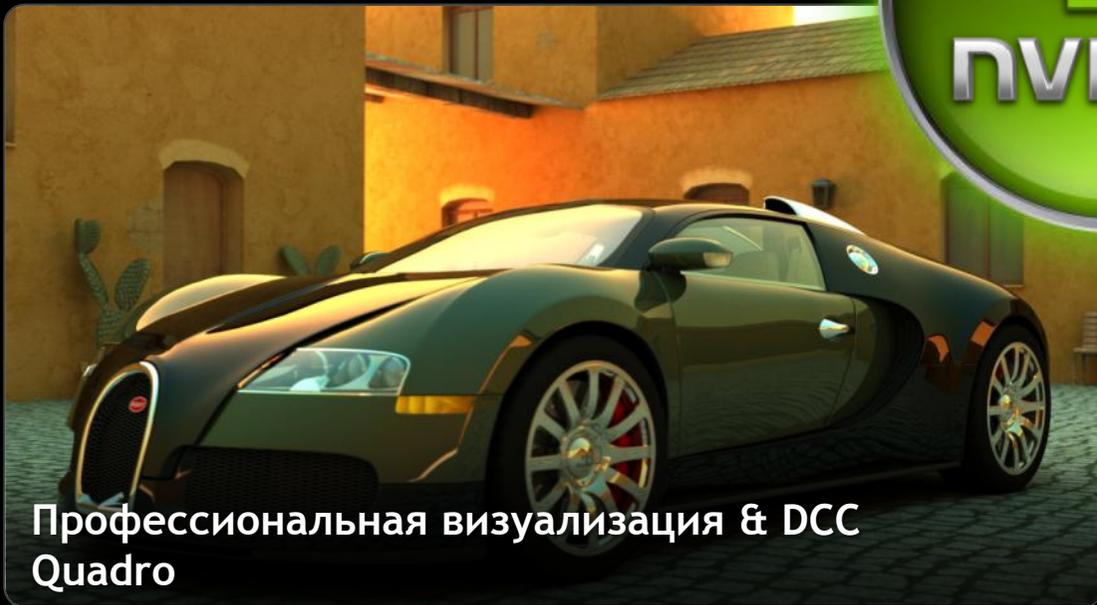
Игры  
GeForce



Мобильные решения  
Tegra



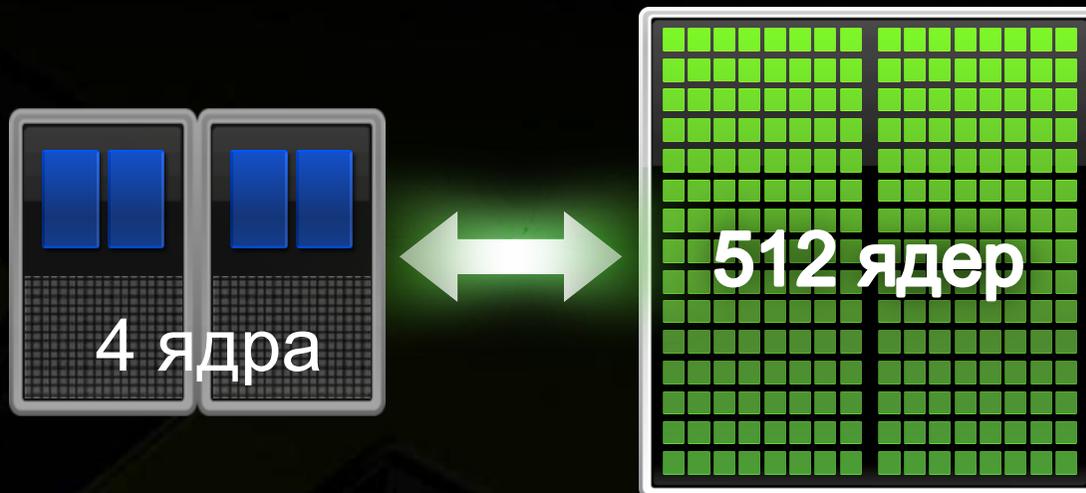
Профессиональная визуализация & DCC  
Quadro



HPC  
Tesla



# Гетерогенные вычисления



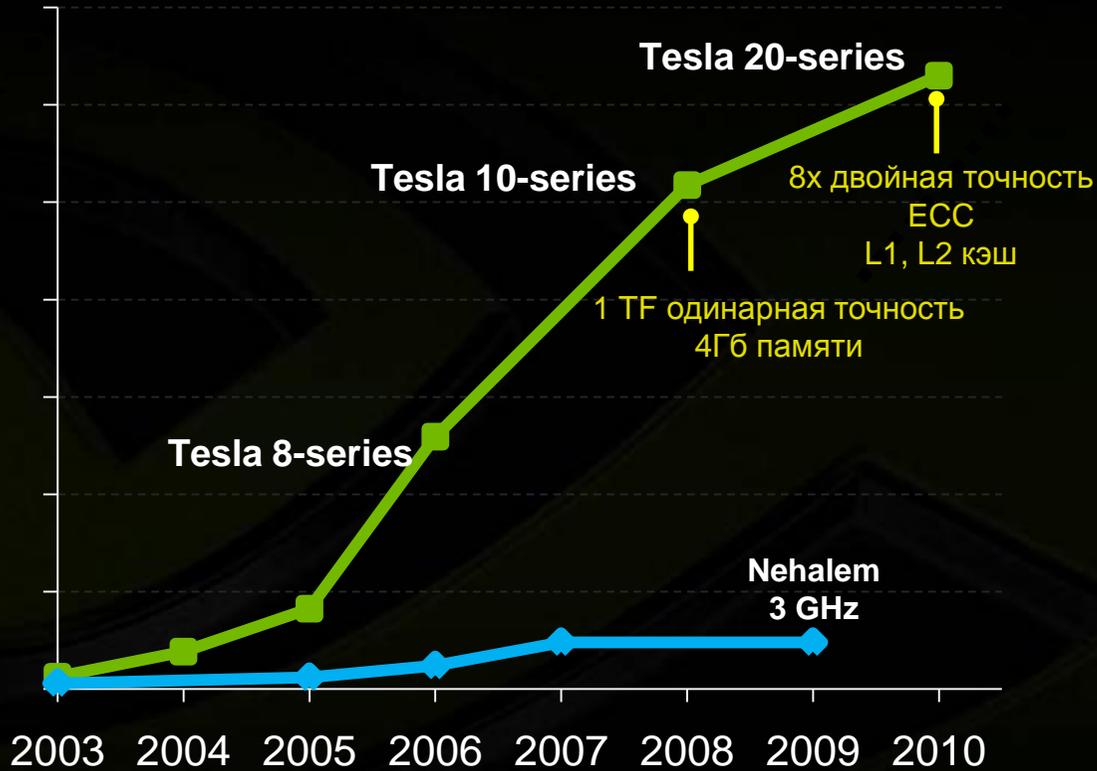
**Вычисления CPU + GPU**

*Гибридные вычислительные системы*

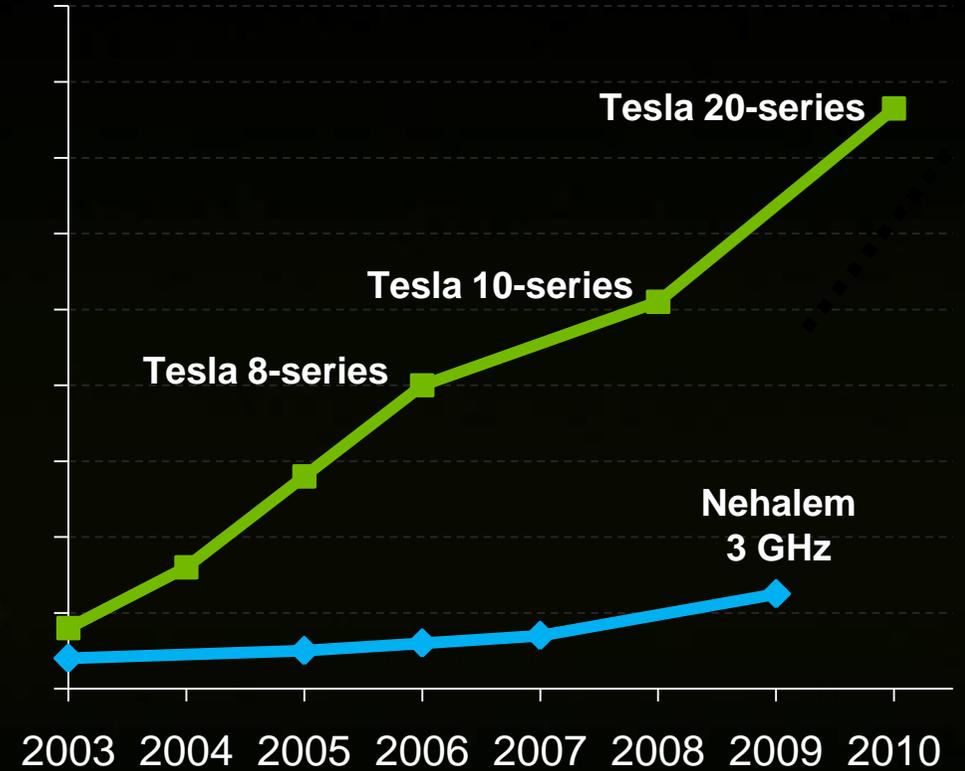
# Постоянный прирост производительности



## Пиковая производительность SP GFlops/sec



## Пиковая пропускная способность GB/sec

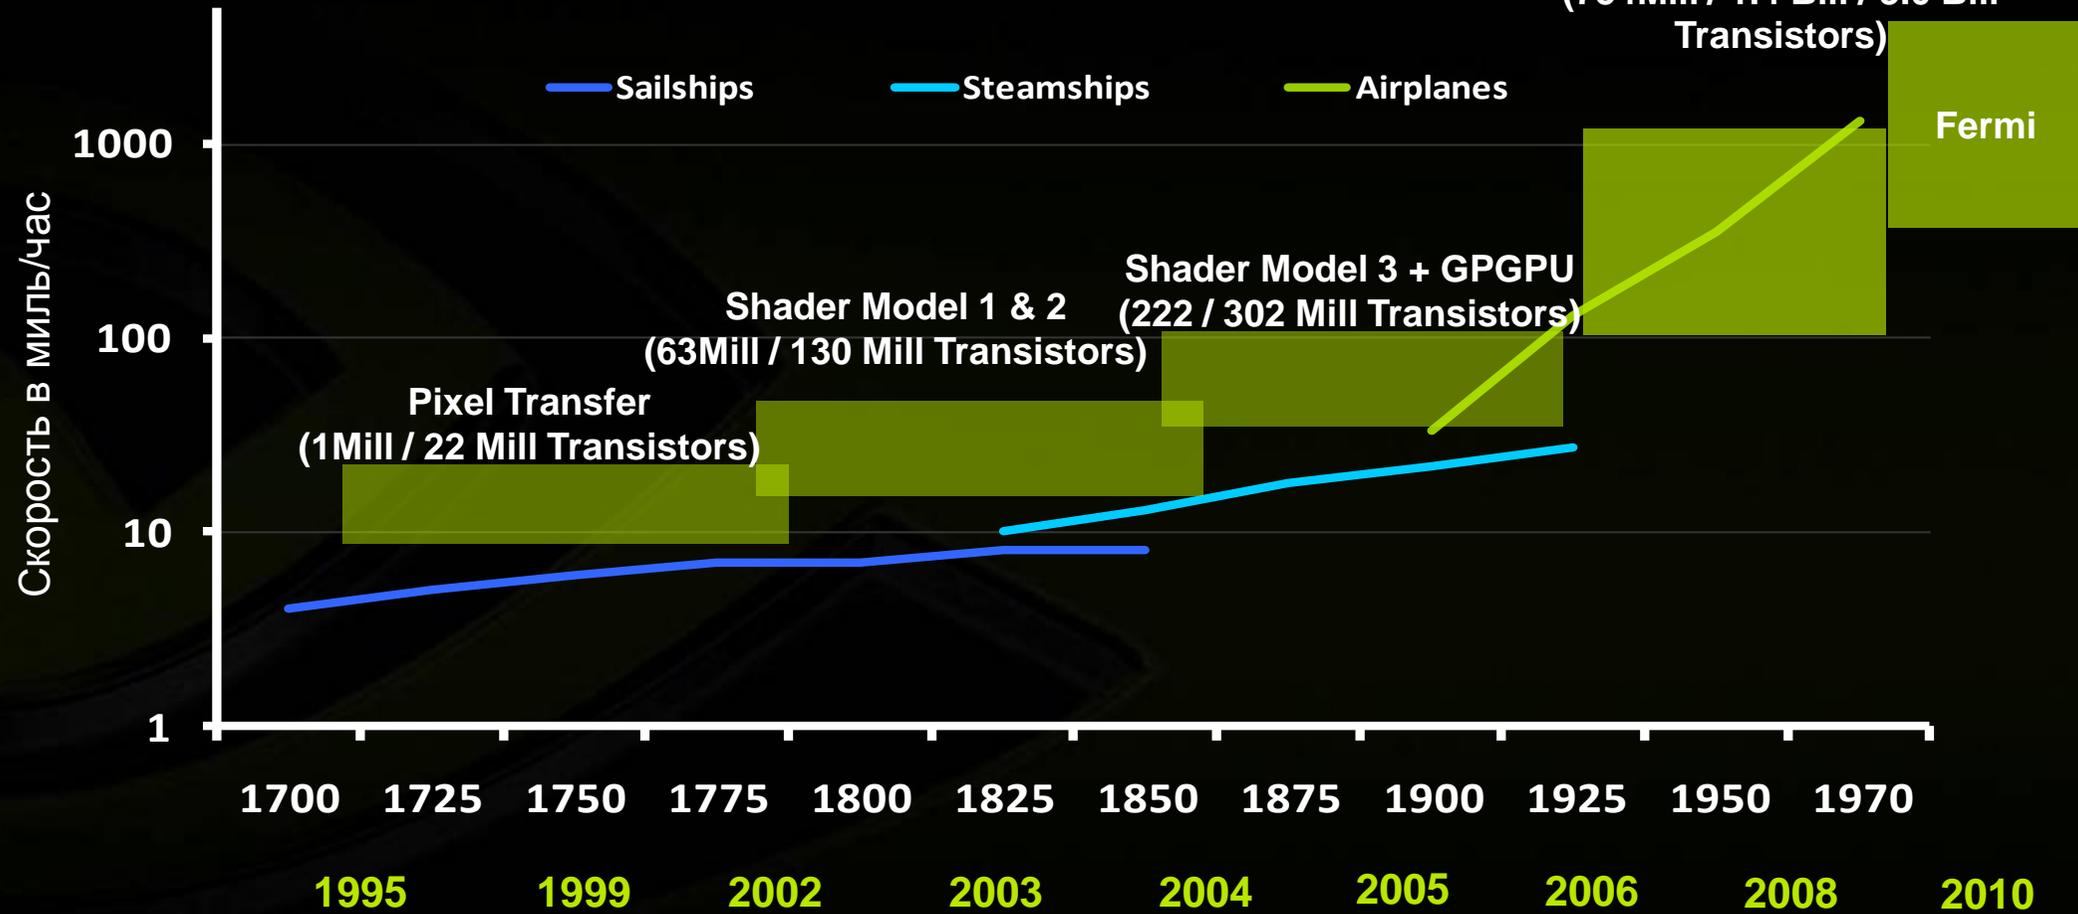


■ NVIDIA GPU  
◆ X86 CPU

# Когда прирост производительности имеет значение?



Производительность в GFlops



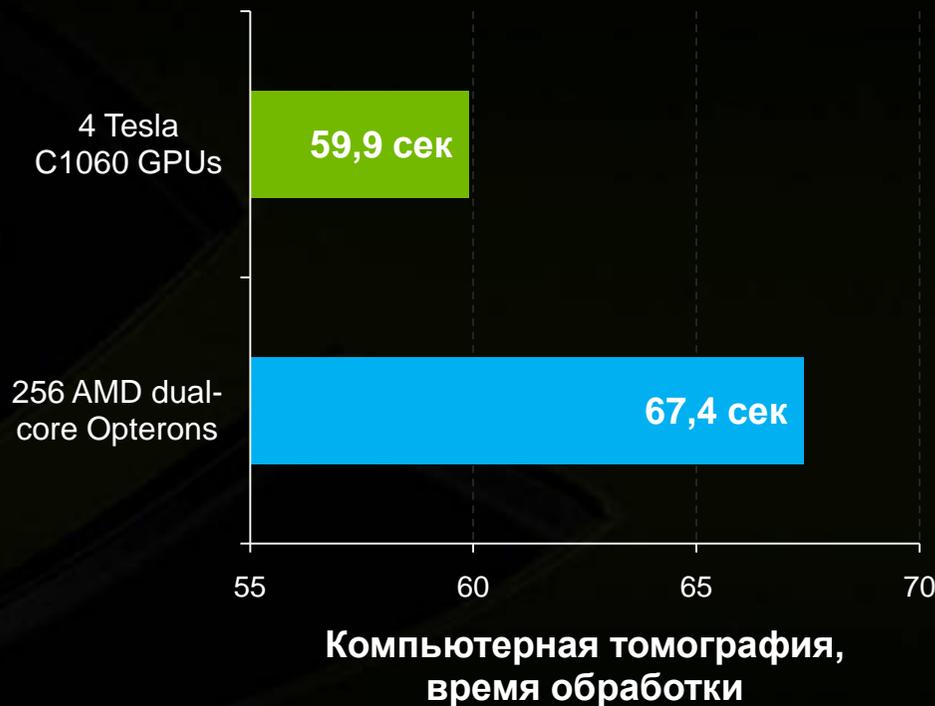
# GPU : переломный момент в отрасли суперкомпьютеров



*Десктоп эффективнее кластера*



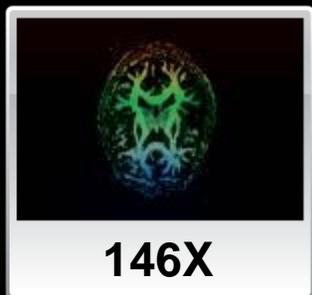
**CalcUA**  
**\$5 млн.**



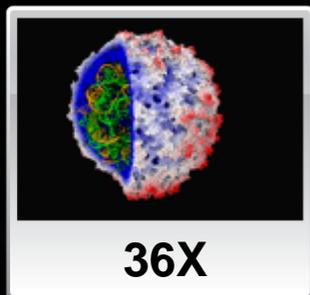
**Tesla Personal Supercomputer**  
**\$10,000**

Источник: University of Antwerp, Belgium

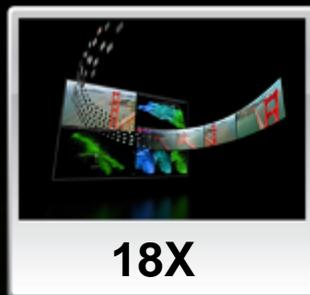
# Прирост производительности до 150 раз



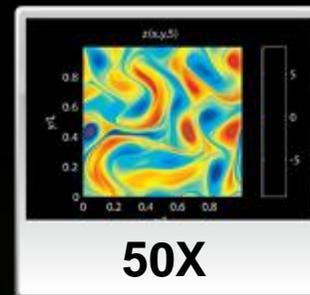
Рентгенография,  
томография  
U of Utah



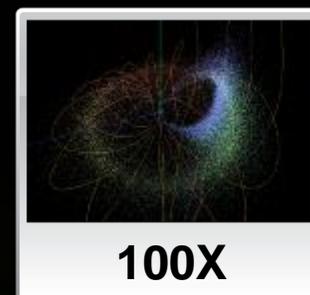
Молекулярная  
динамика  
U of Illinois, Urbana



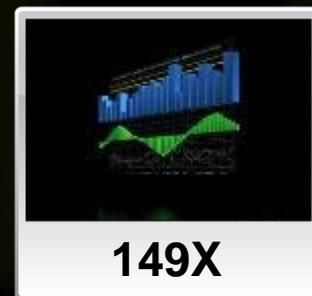
Транскодирование  
видео  
Elemental Tech



Математические  
вычисления  
AccelerEyes



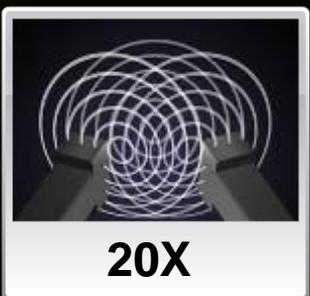
Астрофизика  
RIKEN



Финансовые  
задачи  
Oxford



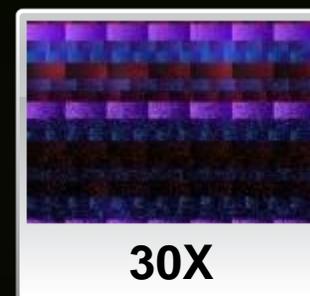
Линейная  
алгебра  
Universidad Jaime



3D ультразвук  
Techniscan



Квантовая химия  
U of Illinois, Urbana



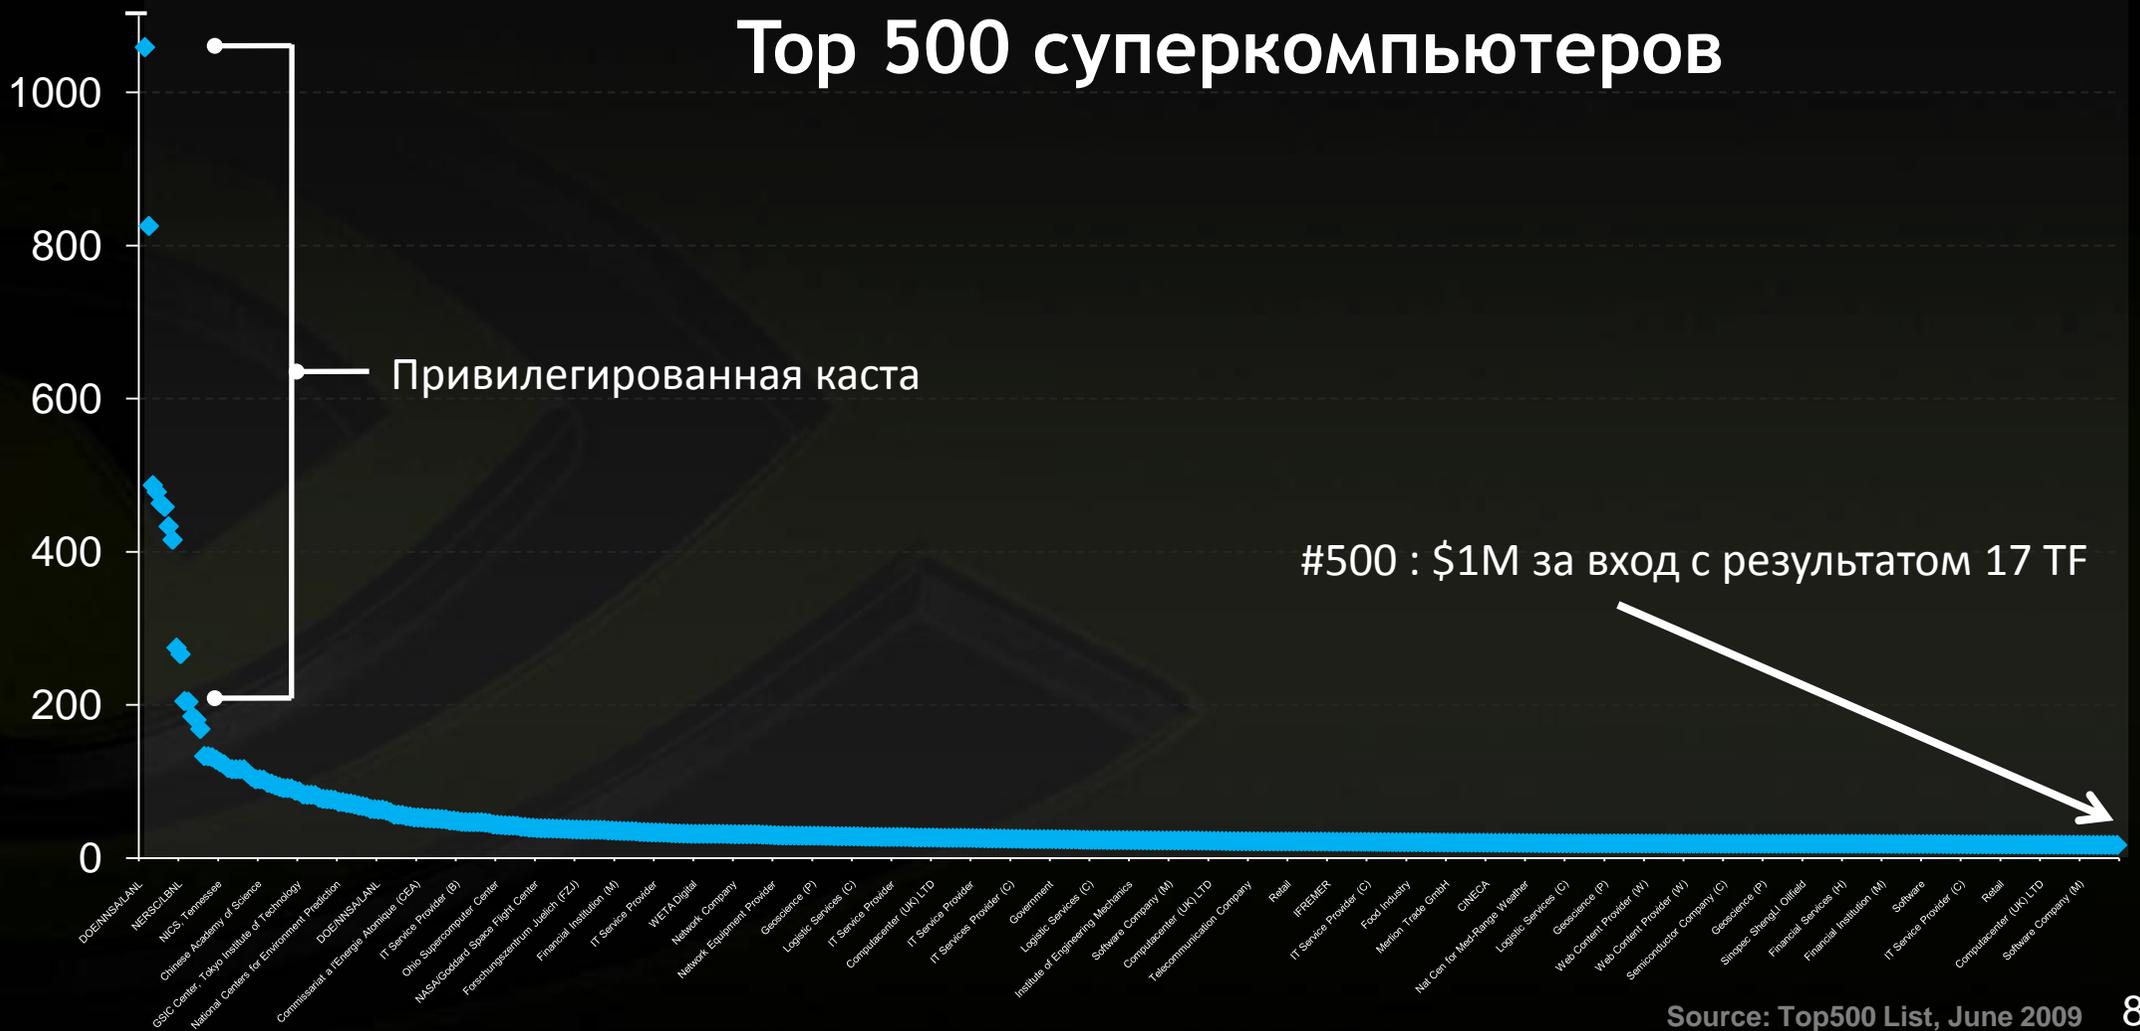
Генная  
инженерия  
U of Maryland

# Сегодня: супервычисления дороги



Linpack  
Gigaflops

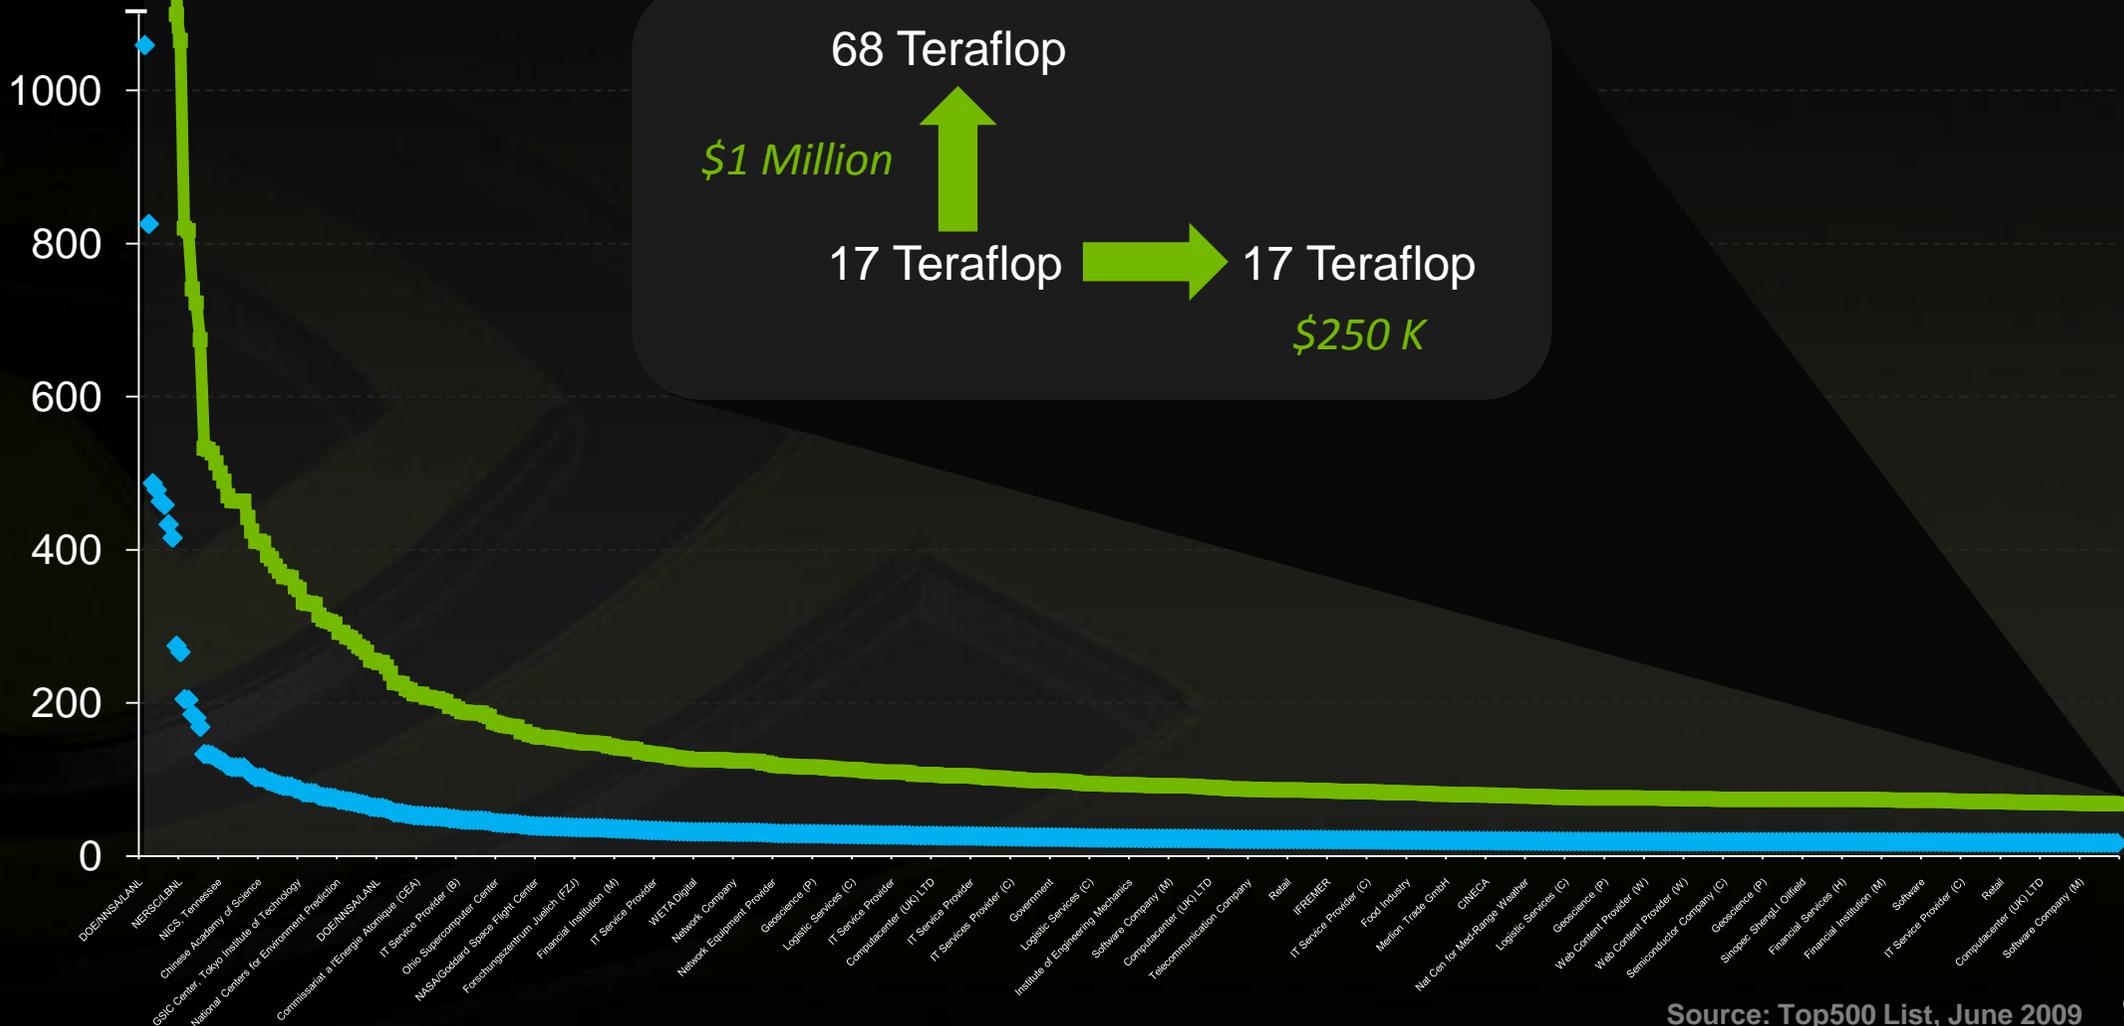
## Топ 500 суперкомпьютеров



# Что, если бы все из Top 500 использовали GPU



Linpack  
Gigaflops



# Решения для нефтегазового сектора



## GPU vs CPU преимущества



Производительность / Ватт	18x - 27x	12x - 17x
Производительность / м <sup>2</sup>	20x - 31x	15x - 20x
Производительность / \$	15x - 20x	10x - 12x

# Bloomberg: прогнозирование рынка облигаций



48 GPUs

\$144K



**42x экономия места**

**28x меньше стоимость**



2000 CPUs

\$4 млн

# Финансы: оценка котировок



1

**Одинаковая производительность**

1

2 Tesla S1070

**16x экономия места**

500 CPU серверов

\$24 К

**10x меньше стоимость**

\$250 К

2.8 кВт

**13x меньше потребление**

37.5 кВт

# CUDA

Compute Unified Device Architecture

Программно-аппаратная архитектура для  
параллельных вычислений

# Параллельная архитектура CUDA



Приложение, использующее GPU

C++

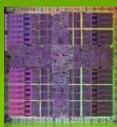
C

OpenCL™

Direct  
Compute

Fortran

Java and  
Python



GPU NVIDIA

с параллельной архитектурой CUDA

# CUDA – самая массово преподаваемая модель параллельного программирования

## 269 университетов преподают параллельную модель программирования CUDA



# Более 250 заказчиков / разработчиков ПО



## Life Sciences & Medical Equipment

## Productivity / Misc

## Oil and Gas

## EDA

## Manufacturing

## Finance

## CAE / Numerics

## Communication

Max Planck  
FDA  
Robarts  
Research  
Medtronic  
AGC  
Evolved  
machines  
Smith-Waterman  
DNA sequencing  
AutoDock  
NAMD/VMD  
Folding@Home  
Howard Huges  
Medical  
CRIBI Genomics

GE Healthcare  
Siemens  
Techniscan  
Boston Scientific  
Eli Lilly  
Silicon  
Informatics  
Stockholm  
Research  
Harvard  
Delaware  
Pittsburg  
ETH Zurich  
Institute Atomic  
Physics

CEA  
WRF Weather  
Modeling  
OptiTex  
Tech-X  
Elemental  
Technologies  
Dimensional  
Imaging  
Manifold  
Digisens  
General Mills  
Rapidmind  
MS Visual  
Studio  
Rhythm & Hues  
xNormal  
Elcomsoft  
LINZIK

Hess  
TOTAL  
CGG/Veritas  
Chevron  
Headwave  
Acceleware  
Seismic City  
P-Wave  
Seismic  
Imaging  
Mercury  
Computer  
ffA

Synopsys  
Nascentric  
Gauda  
CST  
Agilent

Renault  
Boeing

Symcor  
Level 3  
SciComp  
Hanweck  
Quant  
Catalyst  
RogueWave  
BNP Paribas

The  
Mathworks  
Wolfram  
National  
Instruments  
Access  
Analytics  
Tech-x  
RIKEN  
SOFA

Nokia  
RIM  
Philips  
Samsung  
LG  
Sony  
Ericsson  
NTT  
DoCoMo  
Mitsubishi  
Hitachi  
Radio  
Research  
Laboratory  
US Air Force

# CUDA

# Параллельные вычисления на GPU

200+ млн. GPU в мире поддерживают CUDA



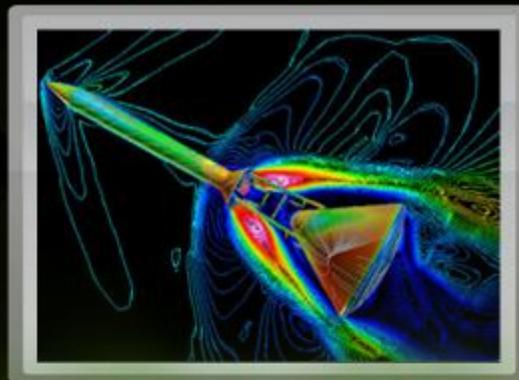
**GeForce®**

Развлечения



**Tesla™**

Высокопроизводительные вычисления



**Quadro®**

Дизайн, разработка



**GPU**

# Выбор CUDA платформы



	Tesla	Quadro	GeForce
Стресс-тест с проверкой точности вычислений	X		
Произведено NVIDIA из высококачественных комплектующих	X	X	
3-х летняя гарантия, корпоративная поддержка	X	X	
4 Гб оперативной памяти для работы с большими объемами данных	X	X	
Единое профессиональное решение для вычислений и графики		X	
Пользовательские приложения: PhysX, Video, Imaging			X
Короткий жизненный цикл пользовательского продукта			X
Производится и сопровождается партнерами NVIDIA			X
Поддержка осуществляется через партнеров NVIDIA			X

# Вычислительные решения Tesla

*Созданы для профессионалов.*

# Персональный суперкомпьютер Tesla



Производительность



Tesla C1060  
933 Гфлопс SP  
78 Гфлопс DP  
4 Гб памяти

Tesla C2050  
520-630 Гфлопс DP  
3 Гб памяти  
ECC

Tesla C2070  
520-630 Гфлопс DP  
6 Гб памяти  
ECC

ЦОД

8x производительность в DP

Решения среднего уровня

Q4	Q1	Q2	Q3	Q4
2009		2010		

# Tesla для ЦОД



Производительность

Tesla S1070-500  
4.14 Тфлопс SP  
345 Гфлопс DP  
4 Гб памяти/ GPU



Tesla S2050  
2.1-2.5 Тфлопс DP  
3 Гб памяти/ GPU  
ECC



Tesla S2070  
2.1-2.5 Т Тфлопс DP  
6 Гб памяти/ GPU  
ECC



ЦОД

8x производительность в DP

Решения среднего уровня

Q4	Q1	Q2	Q3	Q4
2009			2010	

# Tesla: созданы для вычислений



## Системные решения



## Поддержка NVIDIA

- 3-х летняя гарантия
- Длинный жизненный цикл
- Корпоративная поддержка



## Профессиональный уровень

- Высококачественная память
- Надежность вычислений
- 24-часовой стресс-тест

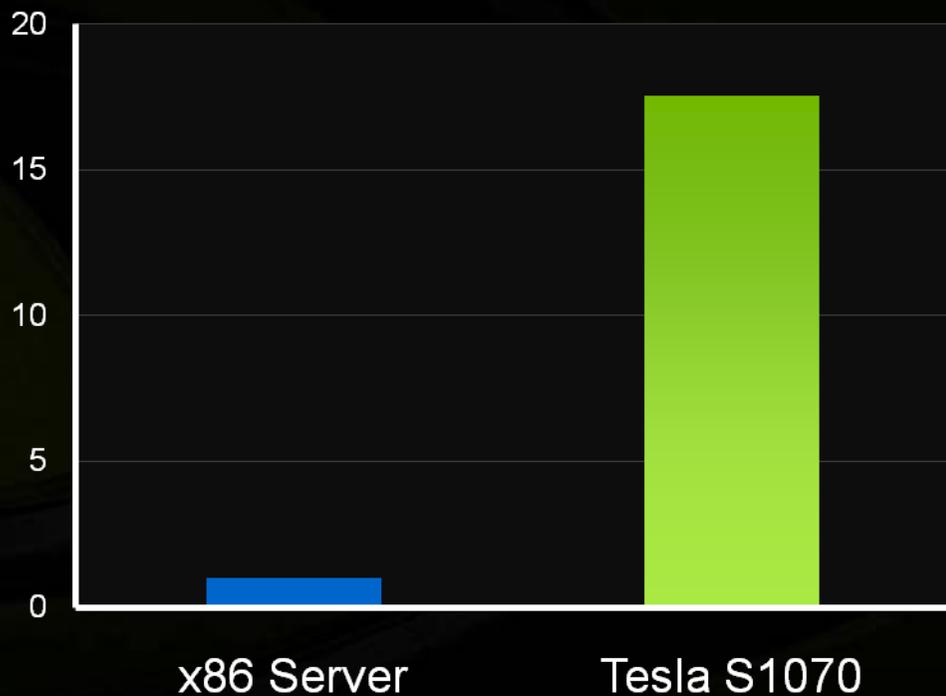
## Вычислительные ресурсы

- Архитектура вычислений CUDA
- 4 ГБ ОЗУ
- двойная точность IEEE-754

# Tesla S1070: эффективное решение



До 20 раз лучше показатель  
производительность/Ватт



- Hess
- Chevron
- Petrobras
- NCSA
- CEA
- TiTech
- JFCOM
- SAIC
- Federal
- Motorola
- Kodak
- University of Heidelberg
- University of Illinois
- University of North Carolina
- Max Planck Institute
- Rice University
- University of Maryland
- GusGus
- Eotvas University
- University of Wuppertal
- Chinese Academy of Sciences
- National Taiwan University

# Пример: ЦОД стоимостью \$5 млн.



## CPU 1U Server



2 Quad-core Xeon  
CPUs: 8 cores

0.17 Teraflop (single)  
0.08 Teraflop (double)

\$ 3,000

700 W

8 CPU Cores +  
960 GPU Cores

4.14 Teraflops (single)  
0.346 Teraflop (double)

\$ 11,000

1500 W

## CPU 1U Server Tesla 1U System



1819 CPU servers

310 Teraflops (single)

155 Teraflops (double)

Total area 16K sq feet

Total 1273 KW

455 CPU servers  
455 Tesla systems

1961 Teraflops (single)

196 Teraflops (double)

Total area 9K sq feet

Total 682 KW

6x more perf

60% smaller

1/2 the power

# Персональный суперкомпьютер Tesla



## Производительность

- Массивно параллельная CUDA архитектура
- 960 ядер. 4 Терафлоп/с
- В 250 раз мощнее ПК

## Удобство

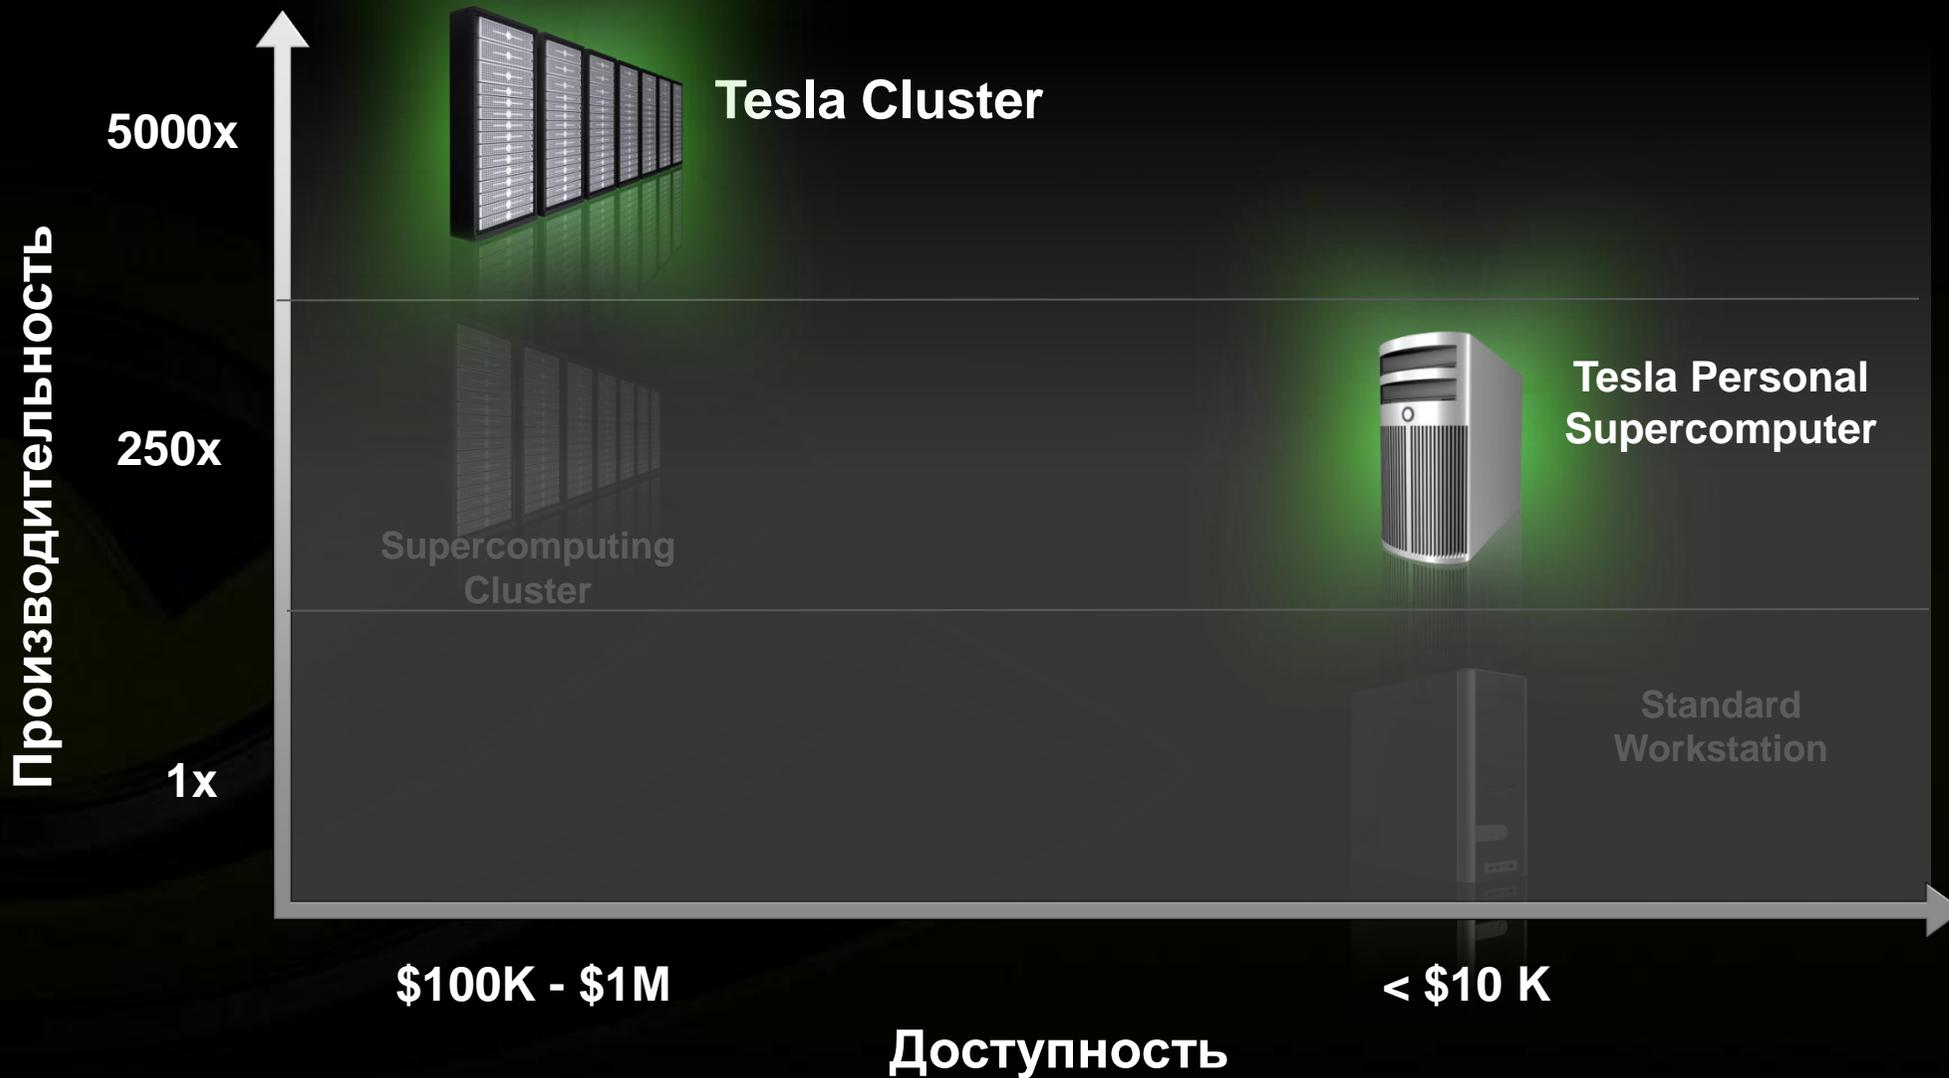
- Суперкомпьютер на рабочем столе
- Включается в обычную розетку

## Доступность

- Программируется на Си под Windows и Linux
- Стоимость порядка \$10,000



# Высокопроизводительные вычисления на базе GPU

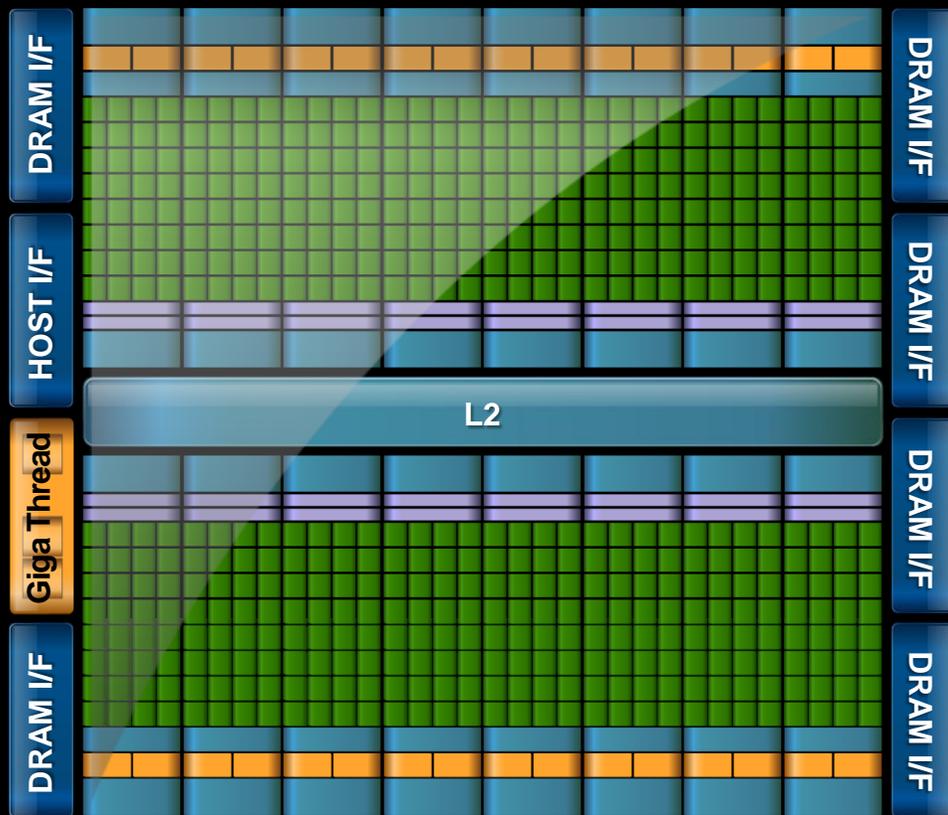




## Новое поколение архитектуры GPU CUDA “Fermi”

# Обзор Fermi

## Суперкомпьютер в формате GPU



- 3 млрд транзисторов
- Вдвое больше ядер (512 ядер)
- 8-кратный прирост DP производительности
- ECC
- L1 и L2 кэш
- Вдвое большая пропускная способность памяти (GDDR5)
- До 1Тб памяти на GPU
- Конкурирующее исполнение кода, C++

**“Oak Ridge National Lab (ORNL) has already announced it will be using Fermi technology in an upcoming super that is “expected to be 10-times more powerful than today's fastest supercomputer.”**

**Since ORNL's Jaguar supercomputer, for all intents and purposes, holds that title, and is in the process of being upgraded to 2.3 PFlops....**

**...we can surmise that the upcoming Fermi-equipped super is going to be in the 20 Petaflops range.”**

# Tesla C – GPU для рабочих станций



	<b>C2050</b>	<b>C2070</b>
Процессоры	<b>1 GPU 20-й серии Tesla 20</b>	
Производительность DP	<b>520-630 Гфлопс</b>	
Память GPU	<b>3 Гб</b>	<b>6 Гб</b>
Интерфейс памяти	<b>GDDR5</b>	
Интерфес	<b>PCIe x16 Gen2</b>	
Энергопотребление	<b>190 Вт (типичное) 225 Вт (максимальное)</b>	

# Tesla S – GPU для 1U систем



	<b>S2050</b>	<b>S2070</b>
Процессоры	<b>4 GPU 20-й серии Tesla 20</b>	
Производительность DP	<b>2.1 – 2.5 Тфлопс</b>	
Память GPU	<b>3 Гб / GPU</b>	<b>6 Гб / GPU</b>
Интерфейс памяти	<b>GDDR5</b>	
Интерфес	<b>2x PCIe x16 Gen2 (опционально x8)</b>	
Энергопотребление	<b>900 Вт (типичное) 1200 Вт (максимальное)</b>	

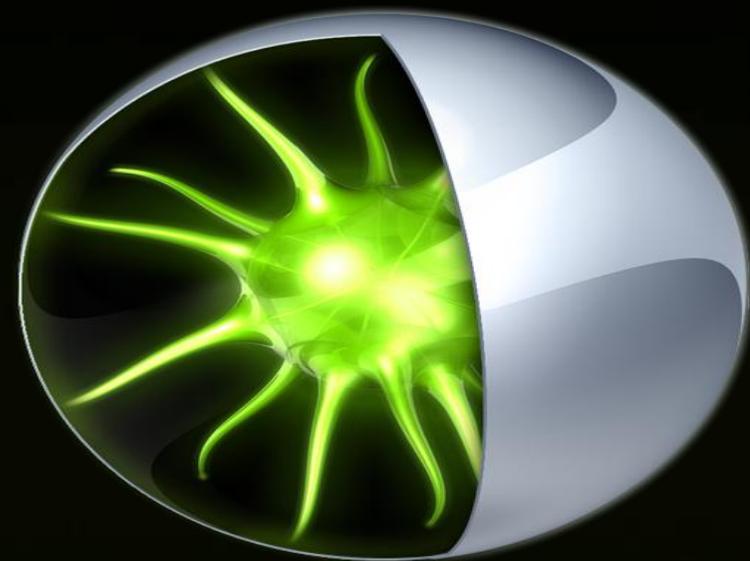
# NVIDIA Nexus IDE



1-й в индустрии IDE (Integrated Development Environment) для  
**массивно-параллельных** приложений

Ускорение разработки  
**гетерогенных** (CPU + GPU) приложений

Полная интеграция со средствами  
разработки **Visual Studio**



Solution Explorer - matrixMul

Solution 'Nexus CUDA Samples.90' (3 projects)

- matrixMul
  - inc
  - src
    - matrixMul.cu

NVIDIA Nexus - CUDA Focus Picker

Dimensions

Block:  8, 5, 1

Thread:  16, 16, 1

Examples

- #129 for block index 129
- 10 for coordinates 10, 0
- 10, 5 for coordinates 10, 5

OK Cancel

```

// Loop over all the sub-matrices of A and B
// required to compute the block sub-matrix
for (int a = aBegin, b = bBegin;
     a <= aEnd;
     a += aStep, b += bStep) {

// Declaration of the shared memory array As used to
// store the sub-matrix of A
__shared__ float As[BLOCK_SIZE][BLOCK_SIZE];

// Declaration of the shared memory array Bs used to
// store the sub-matrix of B
__shared__ float Bs[BLOCK_SIZE][BLOCK_SIZE];

// Load the matrices from device memory
// to shared memory; each thread loads
// one element of each matrix
AS(ty, tx) = A[a + wA * ty + tx];
BS(ty, tx) = B[b + wB * ty + tx];

// Synchronize to make sure the matrices are loaded
__syncthreads();
    
```

Nexus CUDA Device Summary

Name	Details
Devices	
Device 0	
Device 1	
Context 2772376	Device 0
Module 60956632	c:/ProgramData/NVIDIA Nexus 1.0/Samples/CUDA/Debug
Grid	_Z9matrixMulPfs_S_ii<<<(8,5),(16,16,1), 0>>>
Block 0	Warp Mask: 0x000000FF
Warp 0	Active Mask: 0xFFFFFFFF, PC: 0x000703E8, matrixMul_k
Warp 1	Active Mask: 0xFFFFFFFF, PC: 0x000703E8,
Warp 2	Active Mask: 0xFFFFFFFF, PC: 0x000703E8,
Warp 3	Active Mask: 0xFFFFFFFF, PC: 0x000703E8,
Warp 4	Active Mask: 0xFFFFFFFF, PC: 0x000703E8,
Warp 5	Active Mask: 0xFFFFFFFF, PC: 0x000703E8,
Warp 6	Active Mask: 0xFFFFFFFF, PC: 0x000703E8,
Warp 7	Active Mask: 0xFFFFFFFF, PC: 0x000703E8,

Locals

Name	Value	Type
blockDim	{x = 16, y = 16, z = 1}	const dim3
gridDim	{x = 8, y = 5, z = 1}	const dim3
As	0x00000024 {{0.20108646, 0.23432112, 0.2616657, 0.18860439, ...}, {0.88125247, ...}}	float[16][16] __shared__
[0]	0x00000024 {0.20108646, 0.23432112, 0.2616657, 0.18860439, ...}	float[16] __shared__
[1]	0x00000064 {0.88125247, 0.21982482, 0.15710929, 0.15753655, ...}	float[16] __shared__
[2]	0x000000a4 {0.55427718, 0.1802118, 0.76696068, 0.56581318, ...}	float[16] __shared__
[3]	0x000000e4 {0.60716575, 0.673513, 0.26108584, 0.37244788, ...}	float[16] __shared__
Bs	0x00000424 {{0.80645162, 0.41080967, 0.12955107, 0.26792198, ...}, {0.1797546, ...}}	float[16][16] __shared__
a	0	int
b	0	int
bx	0	int
by	0	int
tx	0	int

Memory 1

Address: 0x00000024

Address	Hex	ASCII
0x00000024	9c e9 4d 3e e0 f1 6f 3e 0c f9 85 3e 82 21 41 3e 6c e7 35 3f 7f	œM>ãño>.ù.>.!A>lç5?.
0x00000028	63 3f 3f 97 4d 4b 3f 91 59 48 3f 0a e1 04 3e 1f 69 0f 3f fc 11	c??-MK?'YH?.á.>.i.?ü.
0x0000002c	fe 3d 1c d5 0d 3f 5a 3d ad 3e e4 27 72 3f 8a f9 44 3e ca c7 64	p=.õ.?Z=->ã'x?ŠùD>ÊÇd
0x00000030	3f c3 99 61 3f c2 19 61 3e 42 e1 20 3e 43 51 21 3e a4 11 52 3e	?Ã=ã?Ã.a>Bá >CQ!>x.R>
0x00000034	eb 43 75 3f 8a ed c4 3e ba dd dc 3e 54 2f 2a 3f 23 b5 91 3e 49	âCu?Šiã>*YÜ>T/*?#µ'>I
0x00000038	75 24 3f c5 b1 62 3f 9a 3b 4d 3f a9 b5 f4 3f 88 33 44 3f 47 65	u\$?Ã±b?š;M?@;T'^3D?Ge
0x0000003c	a3 3e 1c e5 0d 3f 71 89 38 3e 89 57 44 3f 22 d9 10 3f 13 71 09	E>.&.?q.8>.WD?'Ü.?q.
0x00000040	3e ba c1 dc 3d dc e3 6d 3f 9c c1 cd 3e 76 c1 3a 3e 70 c9 37 3f	>*ÃÜ=Üãm?œÃÍ>vÃ.:>pË?7
0x00000044	21 4d 10 3f d6 37 6b 3f db 7d 6d 3f d9 85 6c 3f 42 3d 21 3f 47	!M.?Ö7k?Ü?m?Ü.1?B=!?G
0x00000048	7d 23 3f 37 6f 1b 3f 59 6b 2c 3f 0b ad 85 3e 7d b1 be 3e b7 69	]#?7o.?Yk,?.->]±.->+i
0x0000004c	5b 3e 10 35 88 3e 21 6f 10 3f 04 2d 82 3e 89 51 c4 3d 5b 99 ad	[>.5">!o.?.->.QÃ=[M-
0x00000050	3e 2e 15 97 3f cd ab 66 3f 23 91 11 3f c6 f1 62 3f 20 e9 0f 3e	>..->í«f?#'.?EÃb? é.>
0x00000054	7f 49 3f 3f cd 11 ee 3d 84 c9 41 3f da 01 6d 3c d8 dd 6b 3f ee	.I??'Ü.i=.ÉA>Ü.m<@Yk?i
0x00000058	01 f7 3b ee fb 76 3f 2f 81 17 3d 6e f3 36 3f 48 1d e4 3e ef b1	+.;iúv?/..nó6?H.x>i±

# Экосистема параллельных вычислений на GPU



## Научные пакеты

MATLAB  
Mathematica  
NI LabView  
pyCUDA

## Дебаггеры & профилировщики

cuda-gdb  
NV Visual Profiler  
"Nexus" VS 2008  
Allinea  
TotalView

## GPU компиляторы

C  
C++  
Fortran  
OpenCL  
DirectCompute  
Java  
Python

## Параллелизующие компиляторы

PGI Accelerator  
CAPS HMPP  
mCUDA  
OpenMP

## Библиотеки

BLAS  
FFT  
LAPACK  
NPP  
Video  
Imaging

## Консалтинг CUDA



## Интеграторы

# Ссылки

- **Fermi**

- <http://www.nvidia.ru/fermi>

- **CUDA Zone**

- <http://www.nvidia.ru/cuda>
- Приложения, документы, видео

- **Tesla**

- <http://www.nvidia.ru/tesla>
- Спецификации, технические и маркетинговые материалы

- **Вертикальные отраслевые решения**

- [http://www.nvidia.com/object/vertical\\_solutions.html](http://www.nvidia.com/object/vertical_solutions.html)

- **YouTube Videos**

- <http://www.youtube.com/nvidiatesla>