

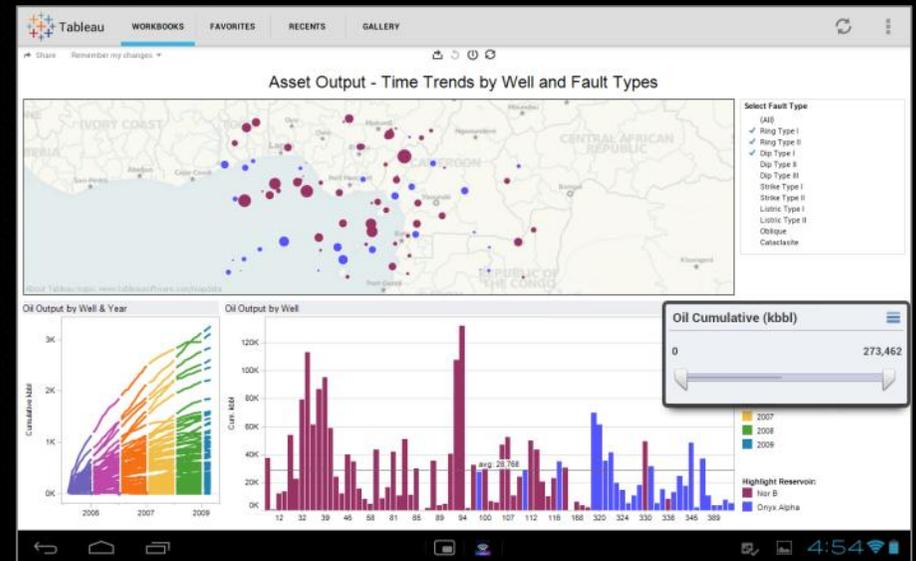
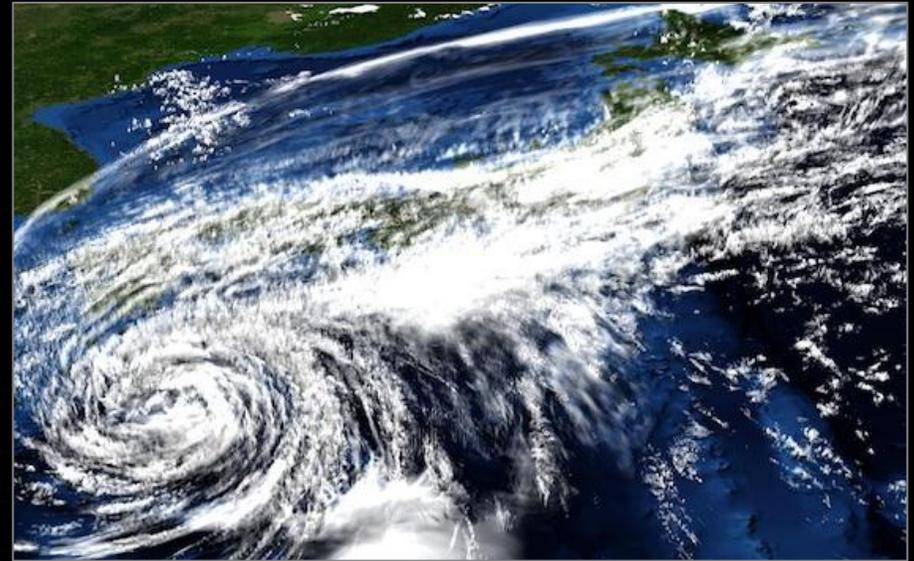


**NVIDIA**®

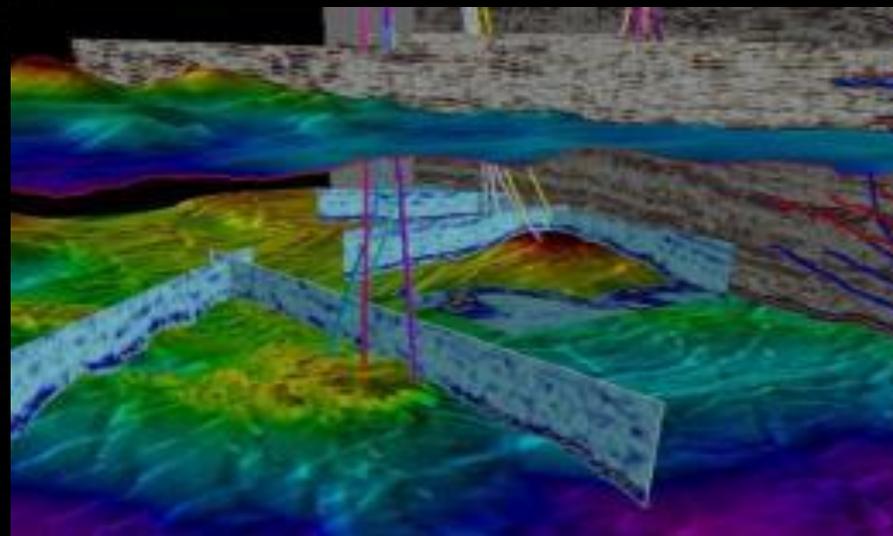
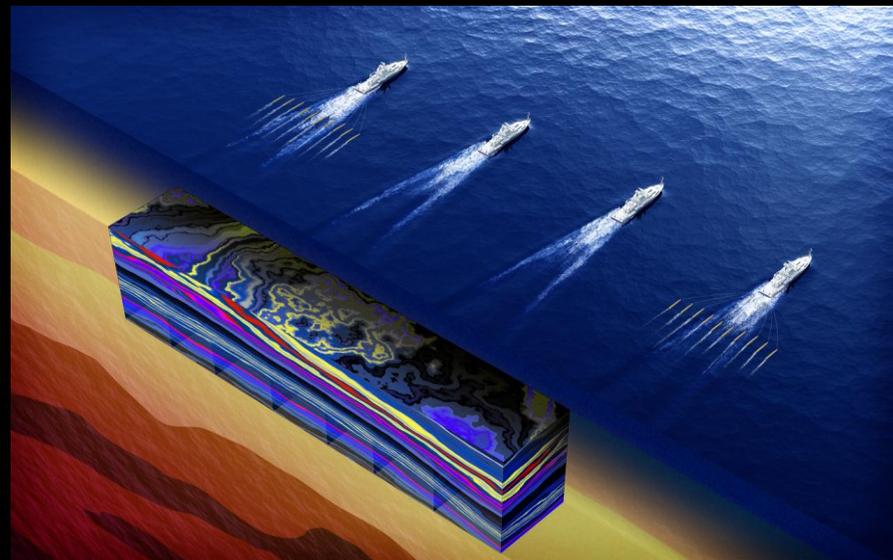
**GPU - БУДУЩЕЕ ГИБРИДНЫХ ВС**

Антон Джораев

Современный мир  
требует все больших  
вычислительных  
ресурсов



Современный мир  
требует все больших  
вычислительных  
ресурсов



Современный мир  
требует все больших  
вычислительных  
ресурсов

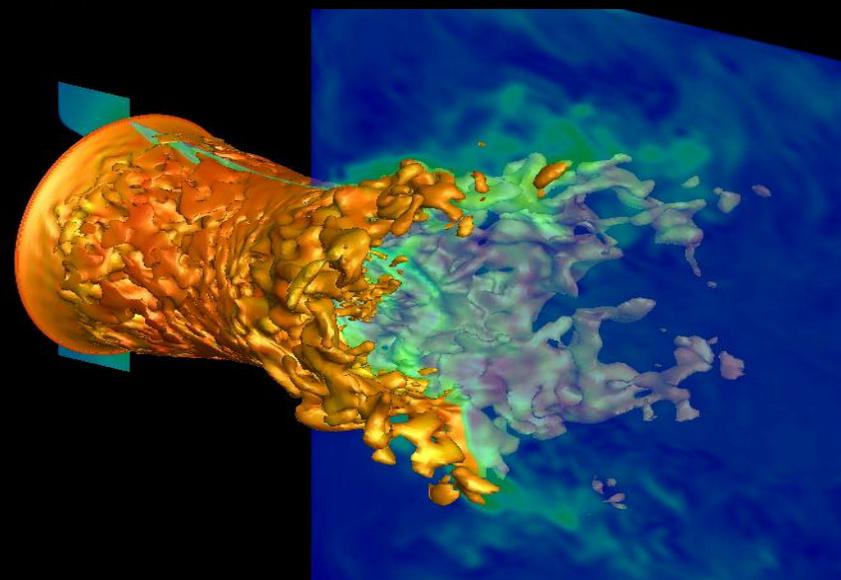
Google

Яндекс

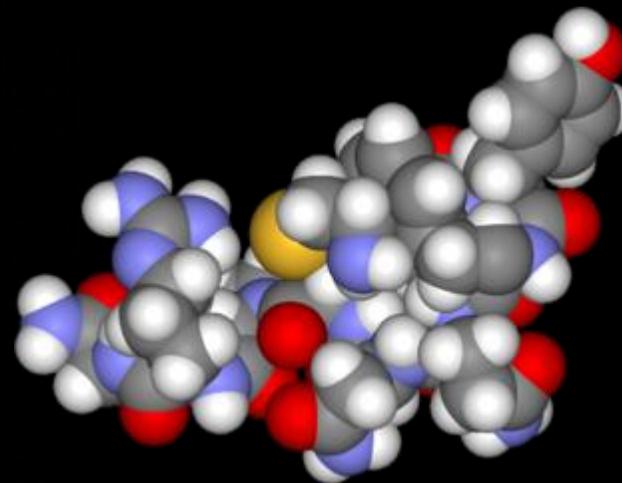
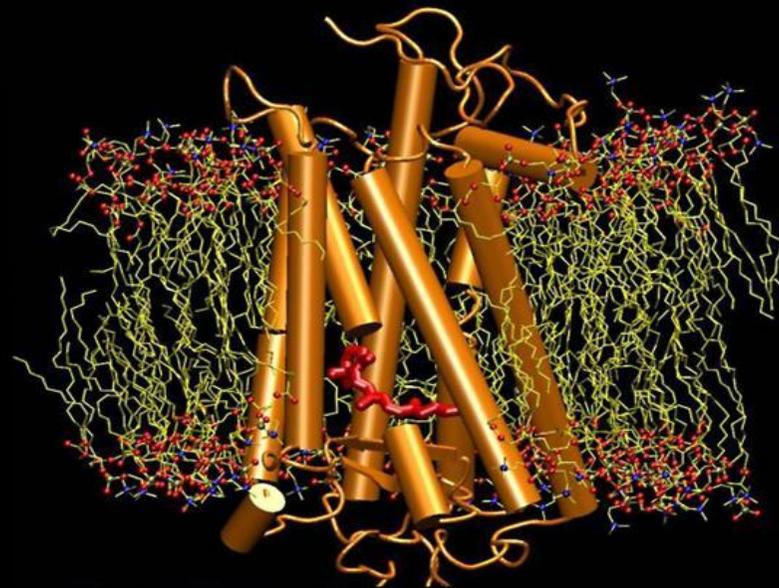
Современный мир  
требует все больших  
вычислительных  
ресурсов



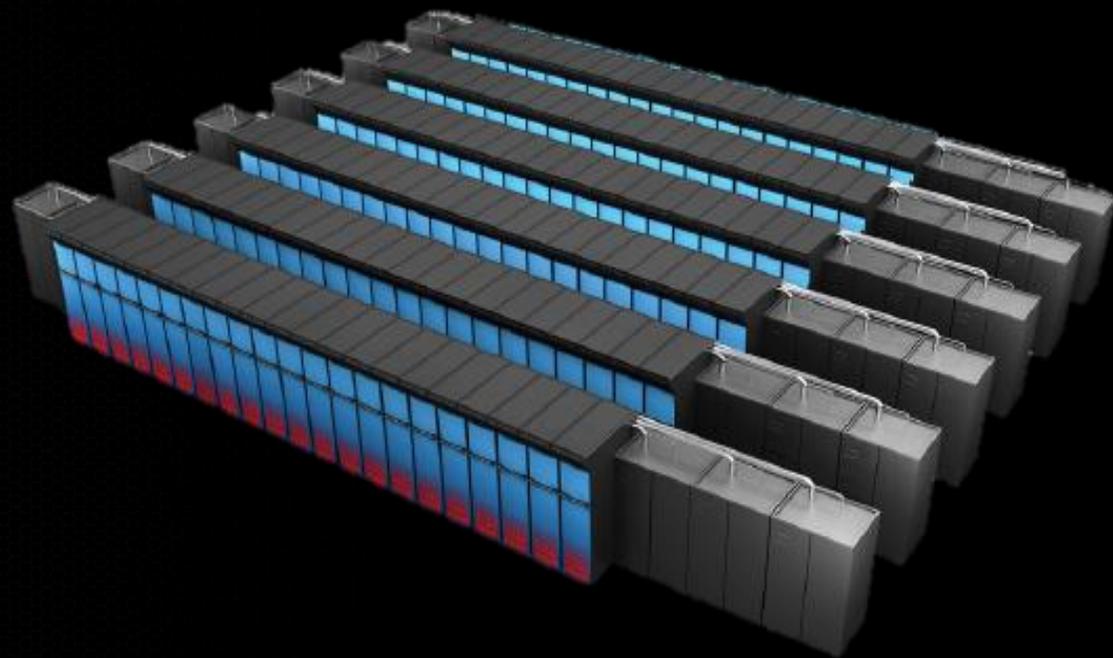
Современный мир  
требует все больших  
вычислительных  
ресурсов



Современный мир  
требует все больших  
вычислительных  
ресурсов



Современный мир  
требует все больших  
вычислительных  
ресурсов



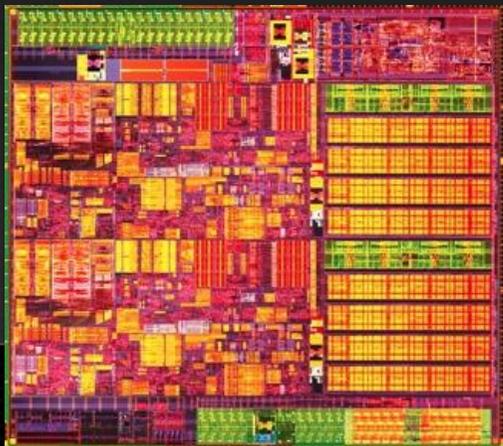
# Проблемы архитектуры x86

- Оптимизация под последовательный код, низкая произв. SIMD
- Низкая эффективность - стоимость, энергетика, охлаждение
- Огромное количество ПО написанного давно и неэффективно

# CPU

1690 pJ/flop

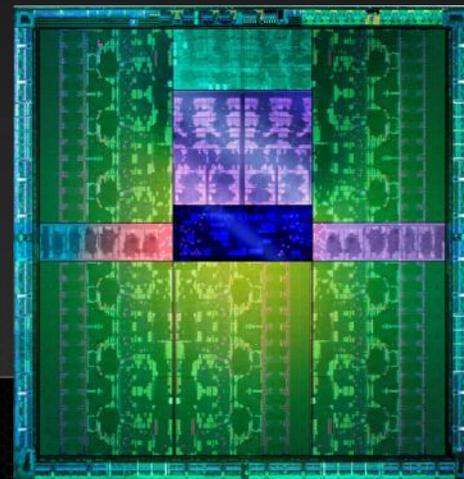
Оптимизирован для исполнения  
последовательного кода  
Неконтролируемый кэш



# GPU

140 pJ/flop

Оптимизирован для работы с  
большим количеством данных  
Явное управление памятью GPU

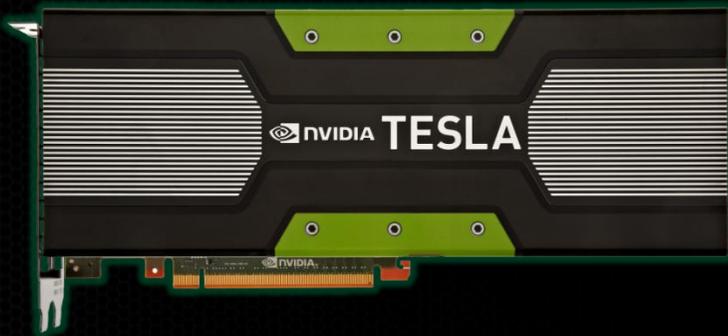


# GPU - будущее HPC

- GPU - самая производительная архитектура
- GPU - наиболее энергоэффективная архитектура
- GPU - незаменимы для визуализации

# GPU - самый производительный процессор

Tesla K20X

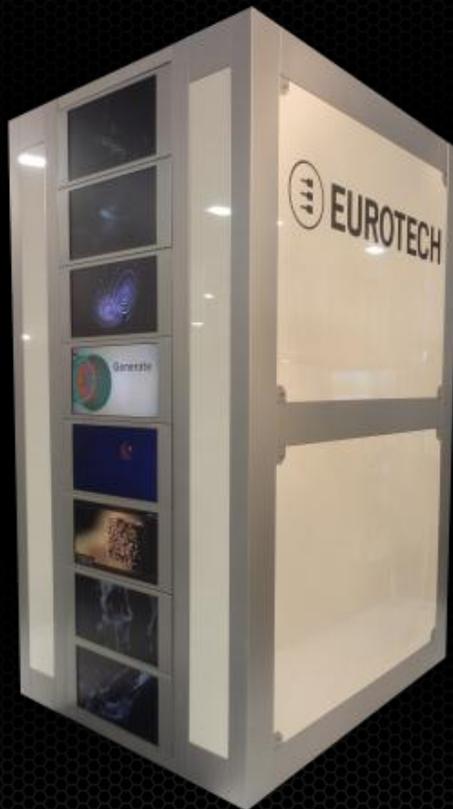


Кол-во CUDA ядер	2688
Пиковая произв-ть DP DGEMM	1.32 TF 1.22 TF
Пиковая произв-ть SP SGEMM	3.95 TF 2.90 TF
Пропускная способность памяти	250 GB/s
Объем памяти	6 GB
Потребление	235W

# Самый энергоэффективный компьютер мира

3150 MFLOPS/Watt

128 Tesla K20

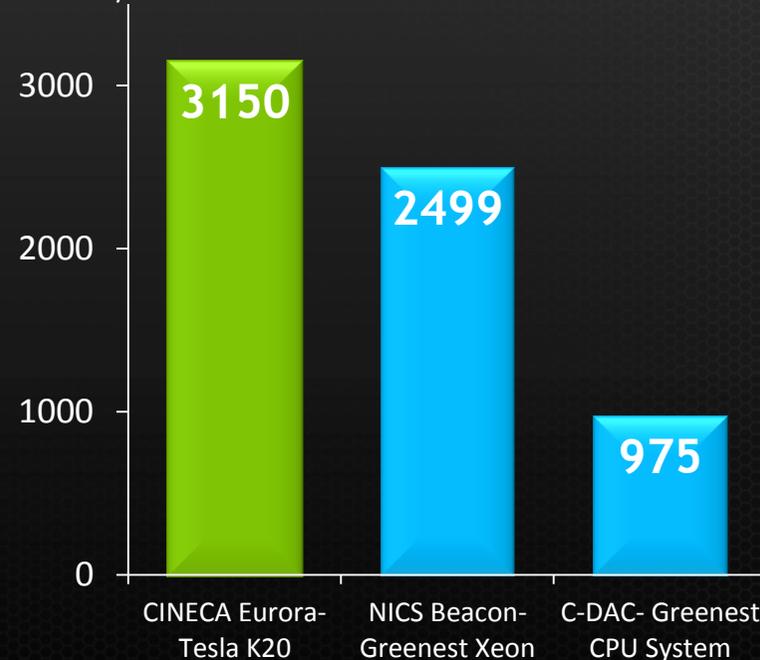


CINECA Eurora

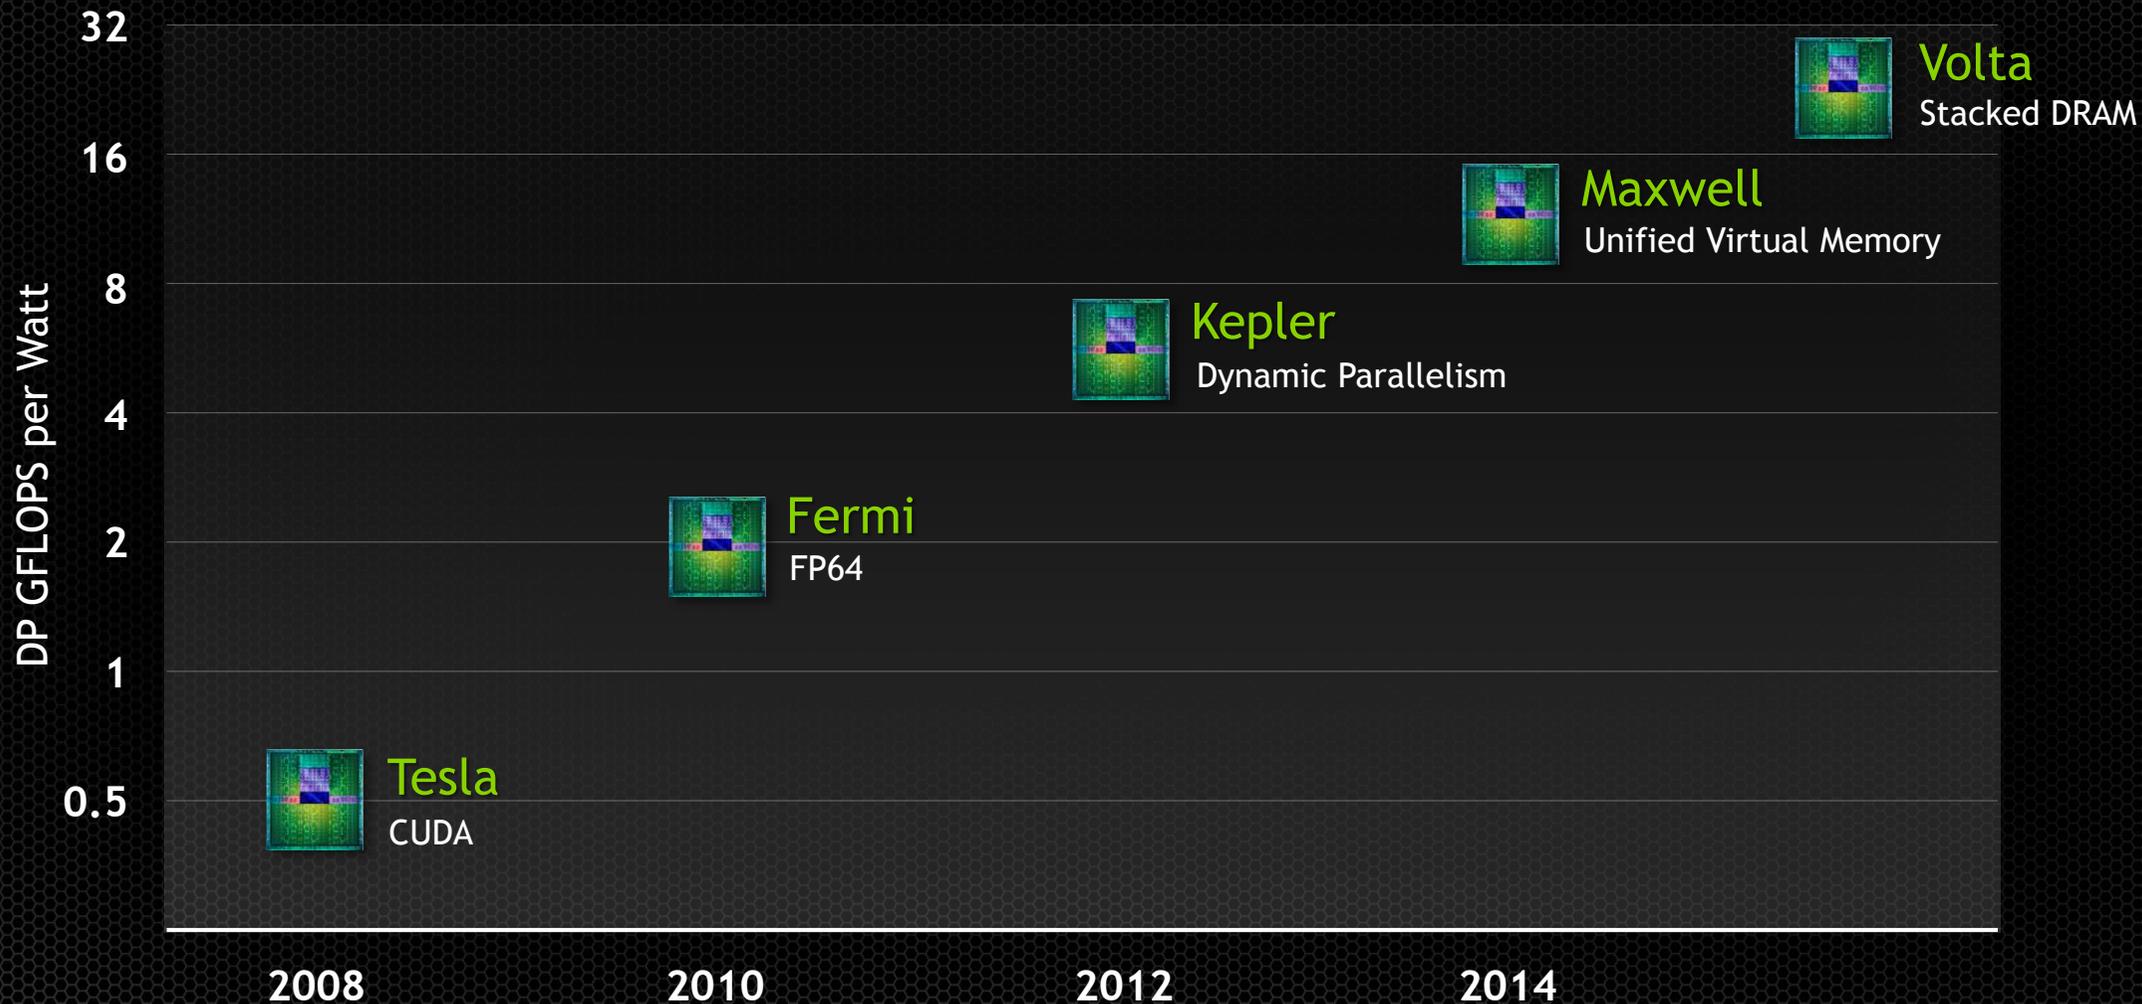
“Liquid-Cooled” Eurotech Aurora Tigon

## Эффективнее Xeon Phi и Xeon

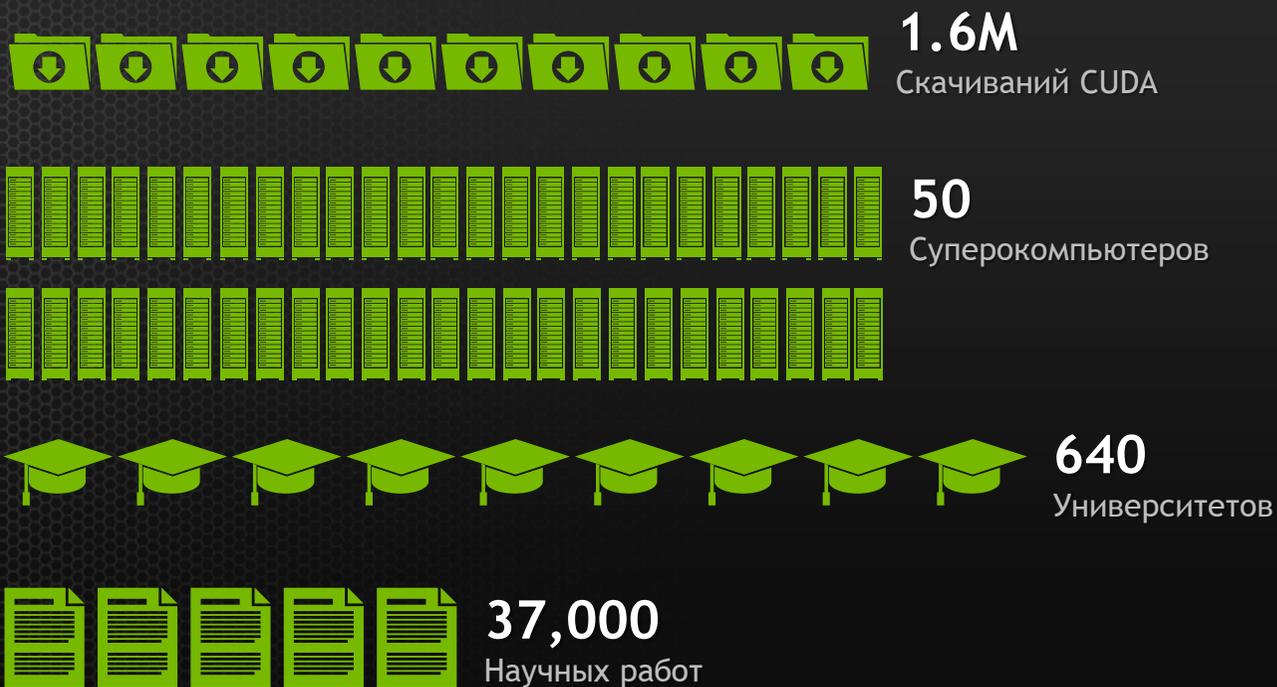
MFLOPS/Watt



# GPU Roadmap



# Распространенность вычислений на GPU



2013

# Вычисления на GPU в России и СНГ

 **20M+**  
GPU с CUDA

 **16**  
Суперкомпьютеров



 **25+**  
Университетов

 **500+**  
Научных работ

2013

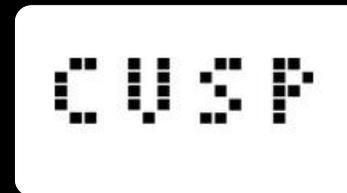
# GPU доступны каждому исследователю

- 30% (120 из 400) институтов РАН решают вычислительные задачи
- 65% (78) из них применяют вычисления на GPU

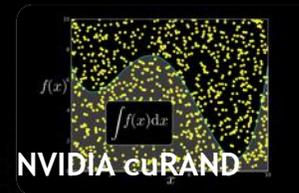
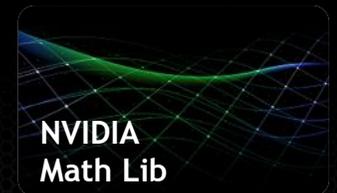
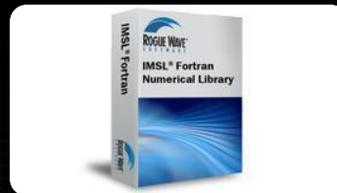
# GPU Accelerated Libraries

## “Drop-in” Acceleration for your Applications

Linear Algebra  
FFT, BLAS,  
SPARSE, Matrix



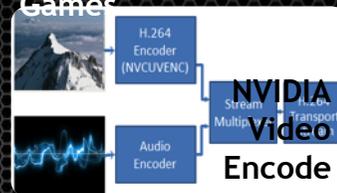
Numerical & Math  
RAND, Statistics



Data Struct. & AI  
Sort, Scan, Zero Sum



Visual Processing  
Image & Video





## POPULAR GPU-ACCELERATED APPLICATIONS

### CONTENTS

- 02 Research: Higher Education and Supercomputing
  - COMPUTATIONAL CHEMISTRY AND BIOLOGY
  - NUMERICAL ANALYTICS
  - PHYSICS
  - WEATHER AND CLIMATE FORECASTING
- 06 Defense and Intelligence
- 07 Computational Finance
- 08 Manufacturing: CAD and CAE
  - COMPUTER AIDED DESIGN
  - COMPUTATIONAL FLUID DYNAMICS
  - COMPUTATIONAL STRUCTURAL MECHANICS
  - ELECTRONIC DESIGN AUTOMATION
- 10 Media and Entertainment
  - ANIMATION, MODELING AND RENDERING
  - COLOR CORRECTION AND GRAIN MANAGEMENT
  - COMPOSITING, FINISHING AND EFFECTS
  - EDITING
  - ENCODING AND DIGITAL DISTRIBUTION
  - ON-AIR GRAPHICS
  - ON-SET, REVIEW AND STEREO TOOLS
  - SIMULATION
  - WEATHER GRAPHICS
- 14 Oil and Gas

## Research: Higher Education and Supercomputing

### COMPUTATIONAL CHEMISTRY AND BIOLOGY

#### Bioinformatics

Application	Description	Supported Platforms	Expected Speed Up	Downloaded GPUs**	Multi-GPU Support	Release Status
BarraCUDA	Sequence mapping software	Alignment of short sequencing reads	6-10x	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 0.6.2
CUDASW++	Open source software for Smith-Waterman protein database searches on GPUs	Parallel search of Smith-Waterman database	10-50x	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 2.0.8
CUSHAW	Parallelized short read aligner	Parallel, accurate long read aligner - gapped alignments for large genomes	10x	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 1.0.40
GPU-BLAST	Local search with fast k-tuple heuristic	Protein alignment according to blastp, multi cpu threads	3-4x	T 2075, 2090, K10, K20, K20X	Single only	Available now Version 2.2.26
GPU-HMMER	Parallelized local and global search with profile Hidden Markov models	Parallel local and global search of Hidden Markov Models	60-100x	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 2.3.2
mCUDA-MEME	Ultrafast scalable motif discovery algorithm based on MEME	Scalable motif discovery algorithm based on MEME	4-10x	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 3.0.12
SeqFind	A GPU Accelerated Sequence Analysis Toolset	Reference assembly, blast, smith-waterman, hmm, de novo assembly	400x	T 2075, 2090, K10, K20, K20X	Yes	Available now
UGENE	Opensource Smith-Waterman for SSE/CUDA, Suffix array based repeats finder and dotplot	Fast short read alignment	6-8x	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 1.11
WideLM	Fits numerous linear models to a fixed design and response	Parallel linear regression on multiple similarly-shaped models	150x	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 0.1-1

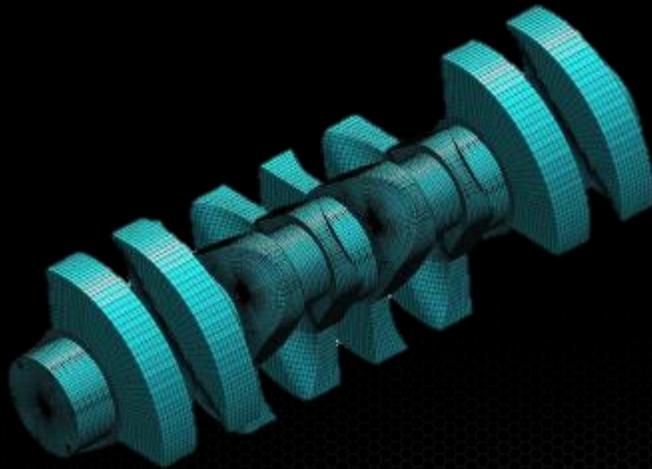
#### Molecular Dynamics

Application	Description	Supported Platforms	Expected Speed Up	Downloaded GPUs**	Multi-GPU Support	Release Status
Abalone	Models molecular dynamics of biopolymers for simulations of proteins, DNA and ligands	Simulations (on 1060 GPU)	4-29x	T 2075, 2090, K10, K20, K20X	Single Only	Available now Version 1.8.48
ACEMD	GPU simulation of molecular mechanics force fields, implicit and explicit solvent	Written for use on GPUs	160 ns/day GPU version only	T 2075, 2090, K10, K20, K20X	Yes	Available now
AMBER	Suite of programs to simulate molecular dynamics on biomolecule	PMEMD: explicit and implicit solvent	89.44 ns/day JAC NVE	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 12 + bugfix9
DL-POLY	Simulate macromolecules, polymers, ionic systems, etc on a distributed memory parallel computer	Two-body forces, Link-cell pairs, Ewald SPME forces, Shake W	4x	T 2075, 2090, K10, K20, K20X	Yes	Available now, Version 4.0 Source only
CHARMM	MD package to simulate molecular dynamics on biomolecule.	Implicit (Sx), Explicit (2x) Solvent via DpexMM	TBD	T 2075, 2090, K10, K20, K20X	Yes	In Development Q4/12
GRMOMACS	Simulation of biochemical molecules with complicated bond interactions	Implicit (Sx), Explicit(2x) solvent	165 ns/Day DHFR	T 2075, 2090, K10, K20, K20X	Single only	Available now Version 4.6 in Q4/12
HOOMD-Blue	Particle dynamics package written grounds up for GPUs	Written for GPUs	2x	T 2075, 2090, K10, K20, K20X	Yes	Available now
LAMMPS	Classical molecular dynamics package	Lennard-Jones, Morse, Buckingham, CHARMM, Tabulated, Course grain SDK, Anisotropic Gay-Bern, RE-squared, "Hybrid" combinations	3-18x	T 2075, 2090, K10, K20, K20X	Yes	Available now
AMD	Designed for high-performance simulation of large molecular systems	100M atom capable	6.44 ns/days STMV SRS 2050s	T 2075, 2090, K10, K20, K20X	Yes	Available now, Version 2.9
OpenMM	Library and application for molecular dynamics for HPC with GPUs	Implicit and explicit solvent, custom forces	Implicit: 127-213 ns/day, Explicit: 18-35 ns/day DHFR	T 2075, 2090, K10, K20, K20X	Yes	Available now Version 4.1.1

POPULAR GPU-ACCELERATED APPLICATIONS (CONT.) | 2012

242 GPU-Accelerated Applications  
[www.nvidia.com/appscatalog](http://www.nvidia.com/appscatalog)

# Инженерные расчеты на GPU



- ANSYS Mechanical
- Ansys Fluent
- Abaqus/Standard (Silmulia)
- MSC Nastran, MSC Marc
- Matlab
- CST Microwave Studio

Ускорение моделирования = больше итераций = выше качество и надежность  
Меньше отказов у клиентов / меньше отзывов

# NVIDIA GRID

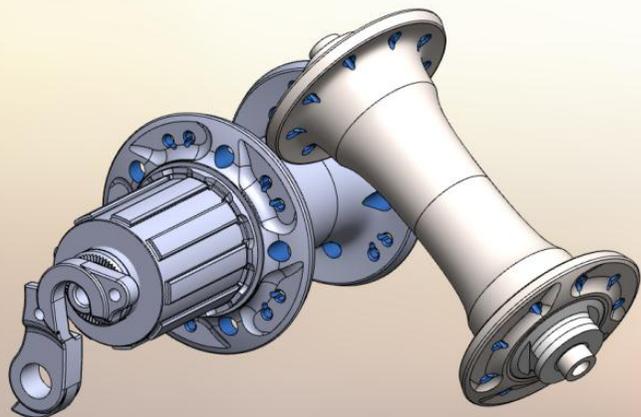
**Производительность  
полноценного ПК**

на любом персональном  
устройстве, с которого  
пользователь может  
подключиться к  
системе.

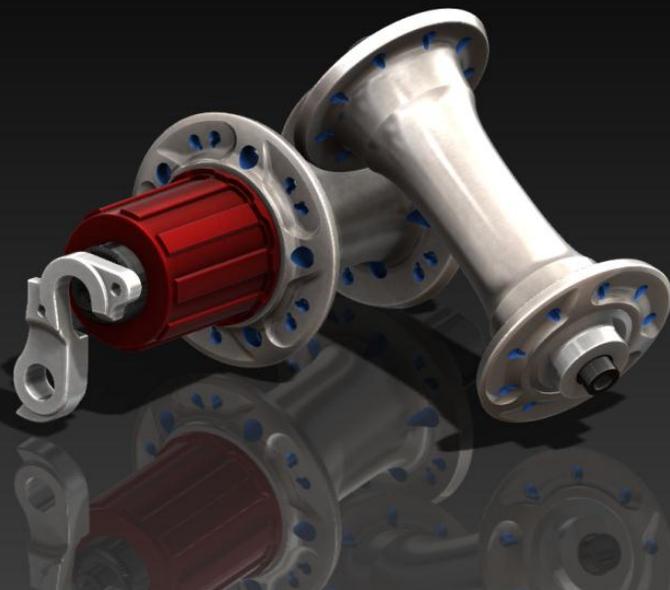


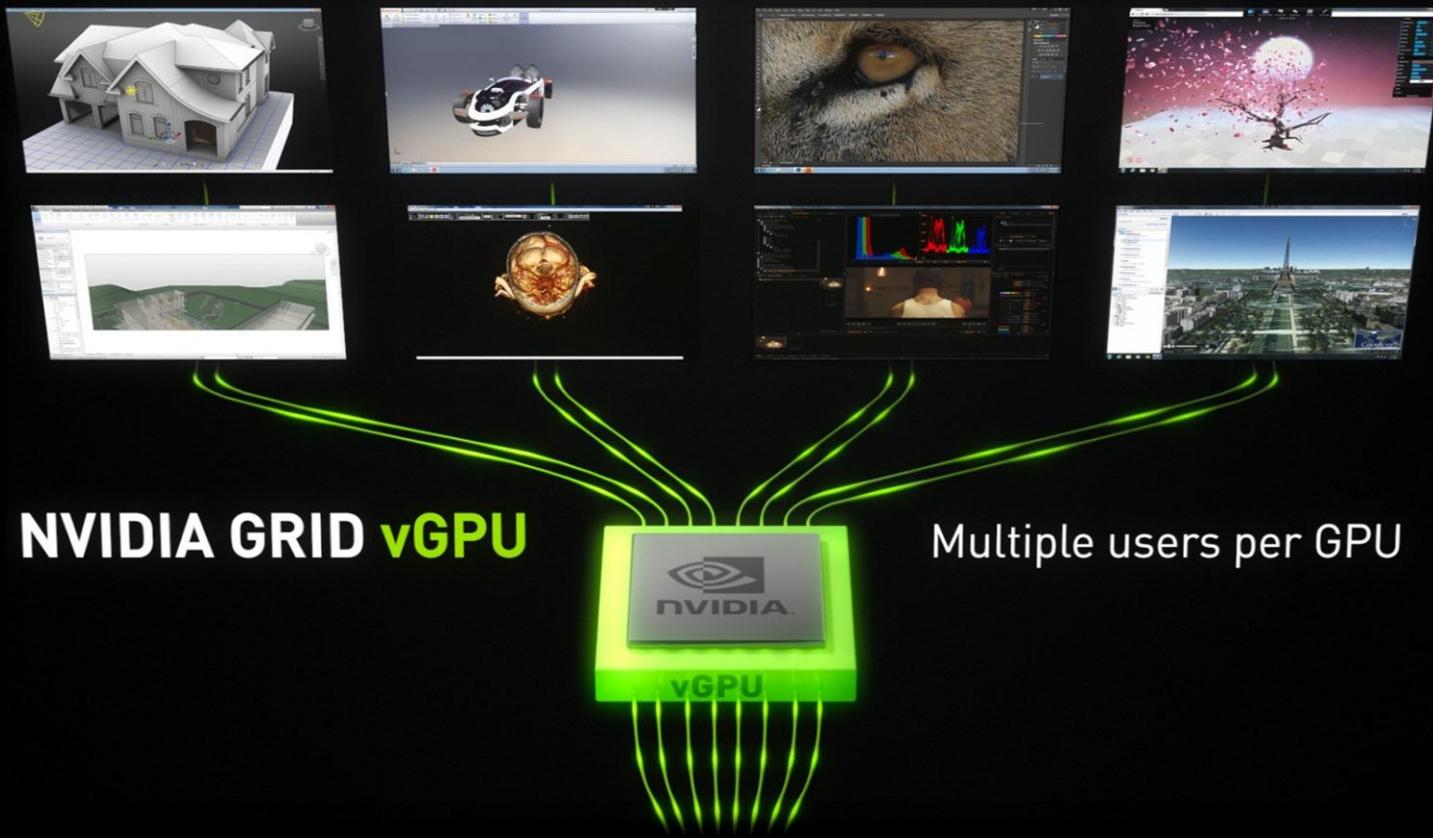
# Разница для пользователя

без GPU



с GPU





**NVIDIA GRID™ vGPU™** это технология аппаратной виртуализации графического процессора позволяющая множественным виртуальным машинам взаимодействовать с ним (с GPU) напрямую

Дизайнеры/  
Проектировщики



Опытные  
пользователи



Офисные  
сотрудники



## NVIDIA GRID K2



## NVIDIA GRID K1



<b>GPU</b>	4 Kepler GPUs	2 топовых Kepler GPUs
<b>CUDA ядра</b>	768 (192/GPU)	3072 (1536/GPU)
<b>Фреймбуфер</b>	16GB DDR3 (4GB/GPU)	8GB GDDR5 (4GB/GPU)
<b>Питание</b>	130 W	225 W
<b>Quadro аналог</b>	Quadro K600	Quadro K5000

# GPU - ответ на вызовы будущего

- Максимальная производительность и энерго-эффективность
- Большое количество ПО и библиотек
- Графический потенциал



**nVIDIA**®

АНТОН ДЖОРАЕВ  
[adzhoraev@nvidia.com](mailto:adzhoraev@nvidia.com)

# Recompile and Run..?



Если это так просто - почему до сих пор нет тысяч приложений поддерживающих Phi?