Использование графических ускорителей при решении задач обработки текстов

Афонин С.А.
Сыроватский Д.А.

1.11.2011
МГУ им.М.В.Ломоносова

План

- Что такое GPU и CUDA
- Алгоритмы анализа данных
- Задачи обработки текстов

GPU и CUDA

- GPU = Graphic Processing Unit
- CUDA = Computing Unified Device Architecture

Почему графические ускорители (GPU)?

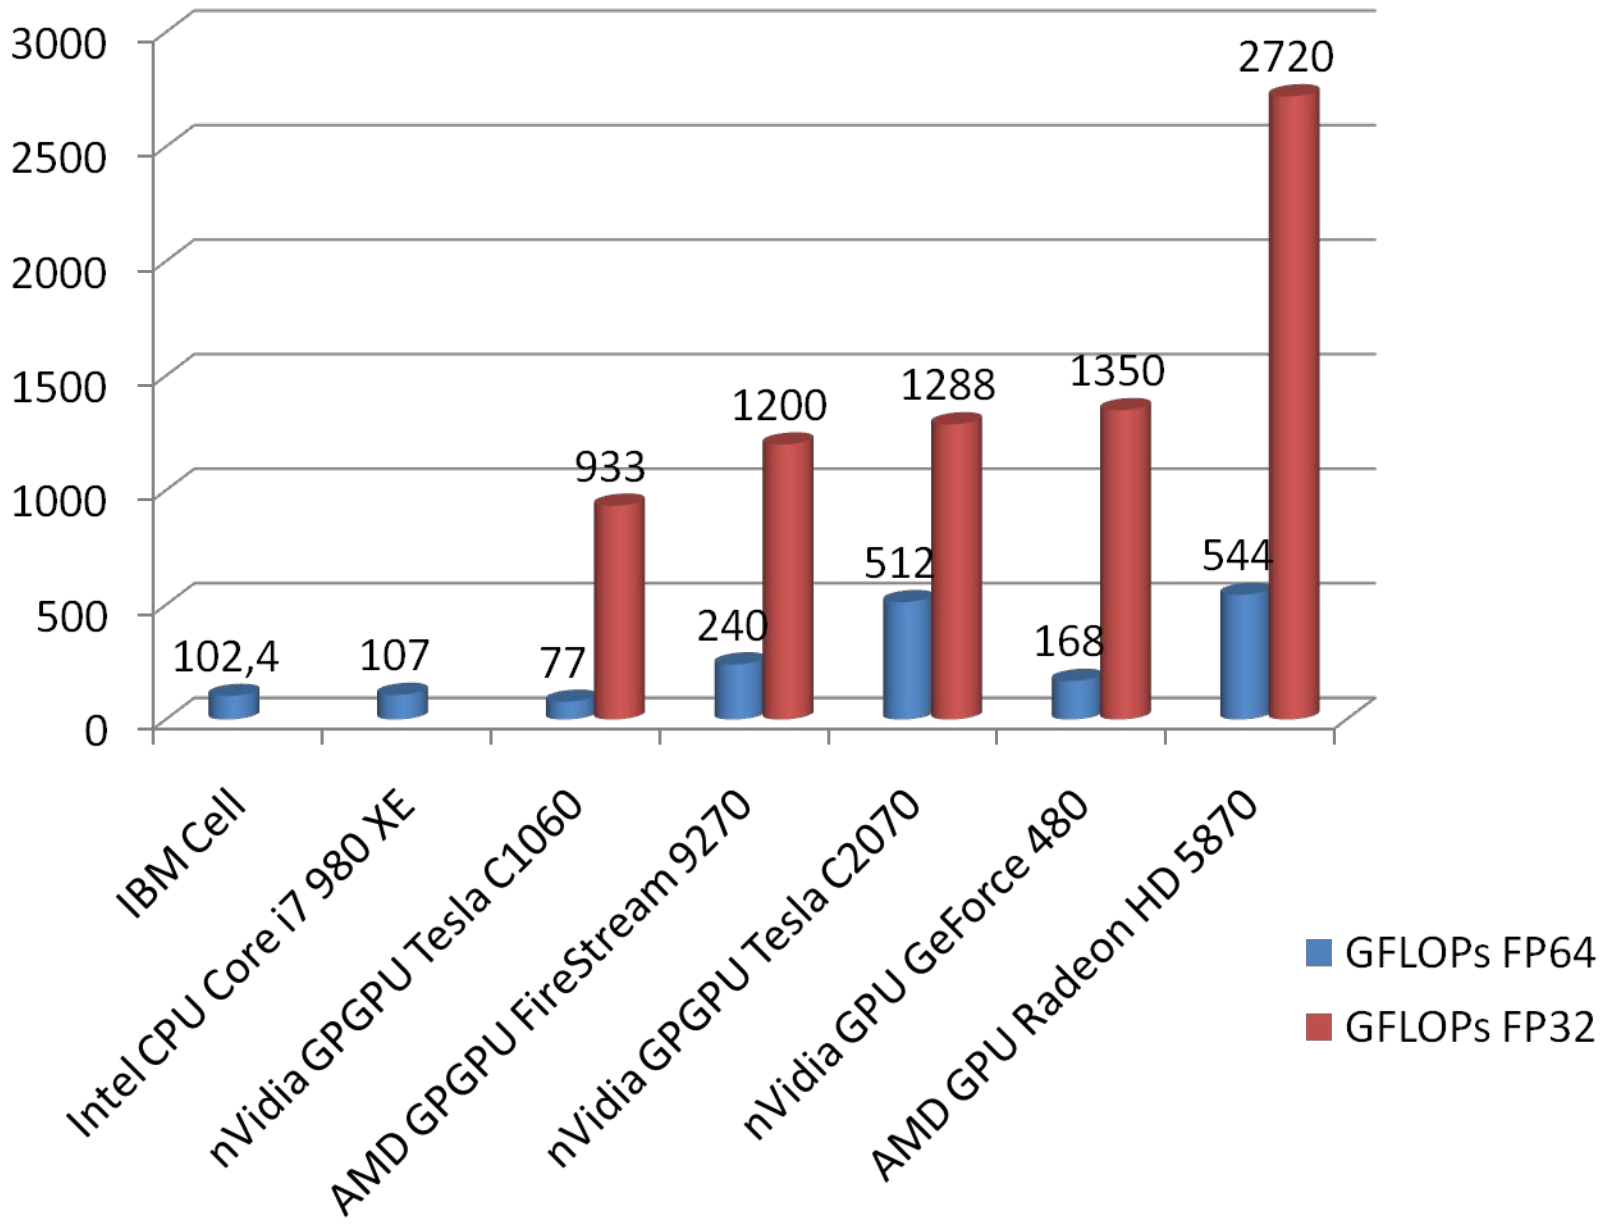
3000
2500
2000
1500
1000
500
0
102,4
107
77
933
240
1200
512
1288
168
1350
544
2720
IBM Cell
Intel CPU Core i7 980 XE
nVidia GPGPU Tesla C1060
AMD GPGPU FireStream 9270
nVidia GPGPU Tesla C2070
nVidia GPU GeForce 480
AMD GPU Radeon HD 5870
GFLOPs FP64
GFLOPs FP32

Performance Development

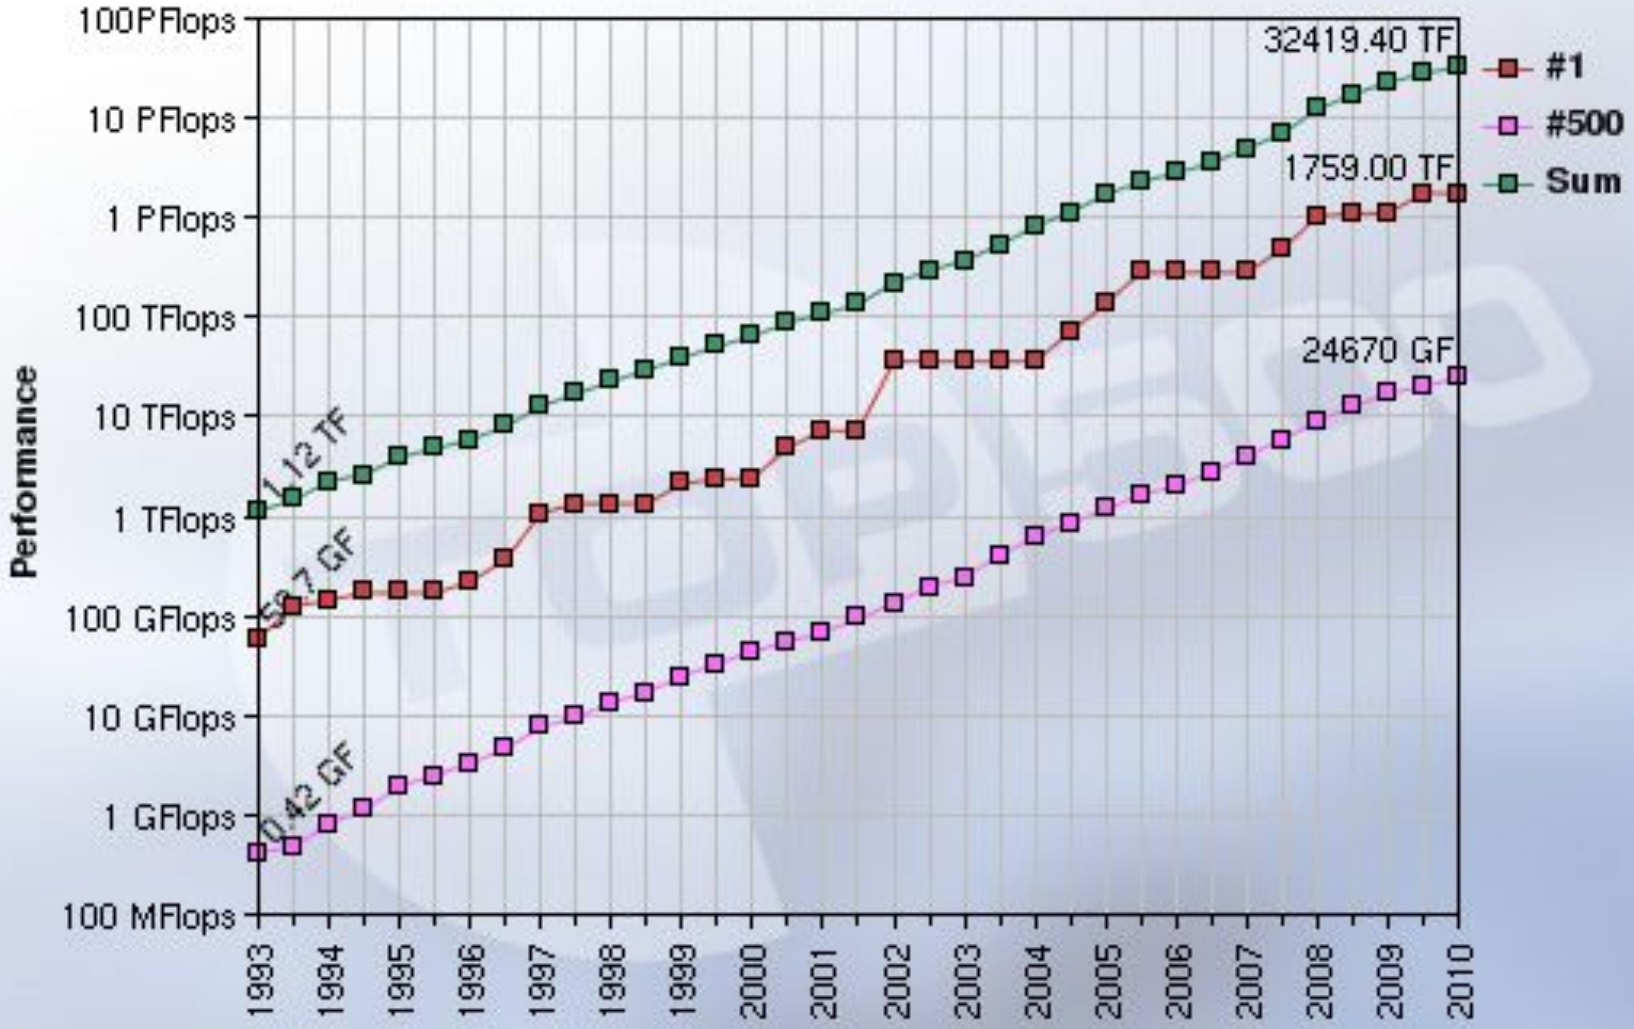

Performance Development

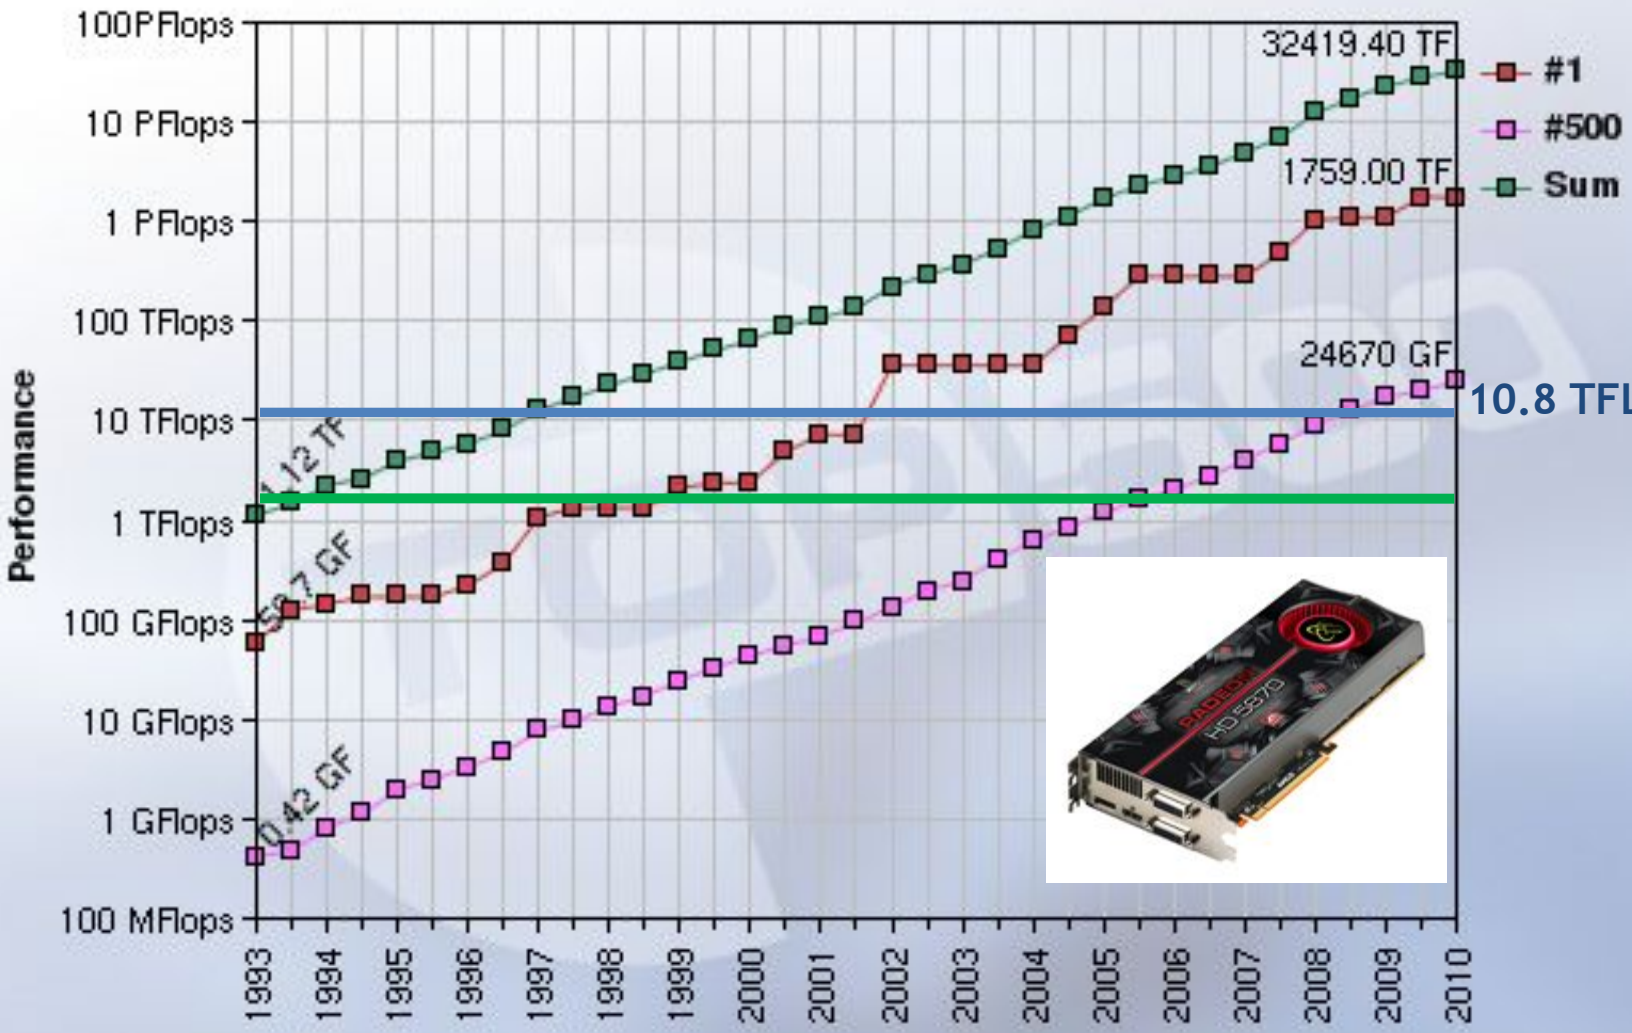

Внешний вид


INTEL©©'09
INTEL CONFIDENTIAL
Q4EG ES COSTA RICA
AT80613003543AE
3952A844

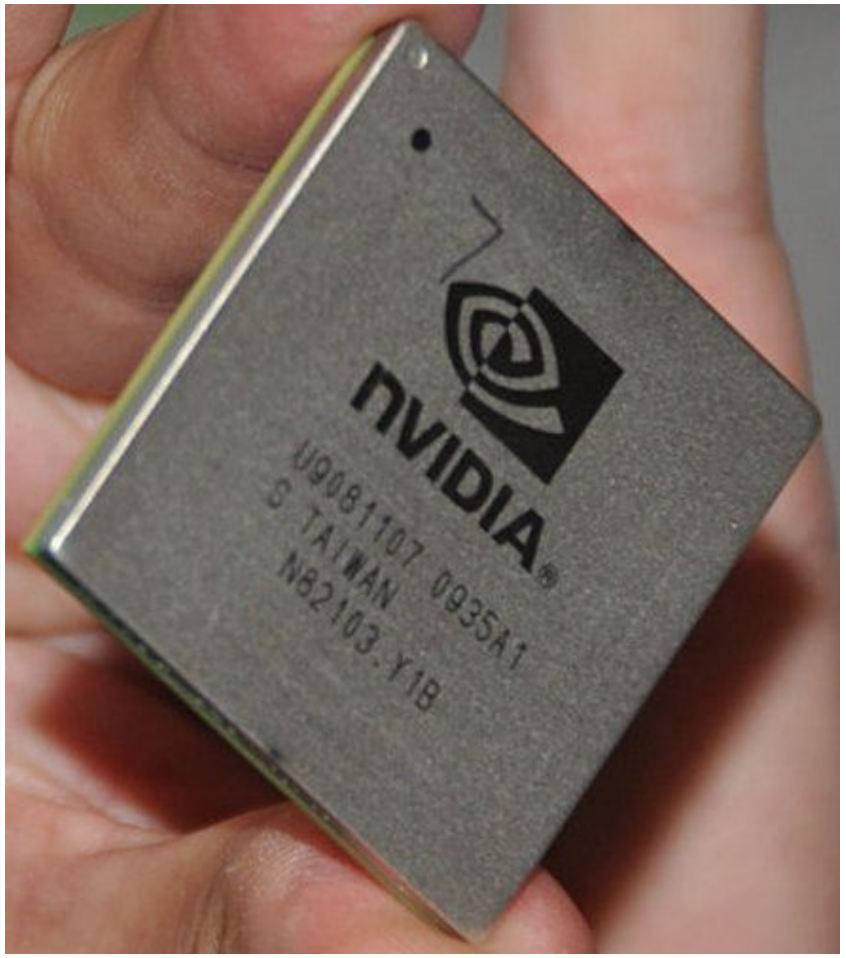
NVIDIA
U9081107 0935A1
S TAIWAN
N82103.Y1B

Графические процессоры


NVIDIA
TESLA

#2 in Top500: NEBULAE

1.27 PFlops Linpack 2.9 PFlops peak

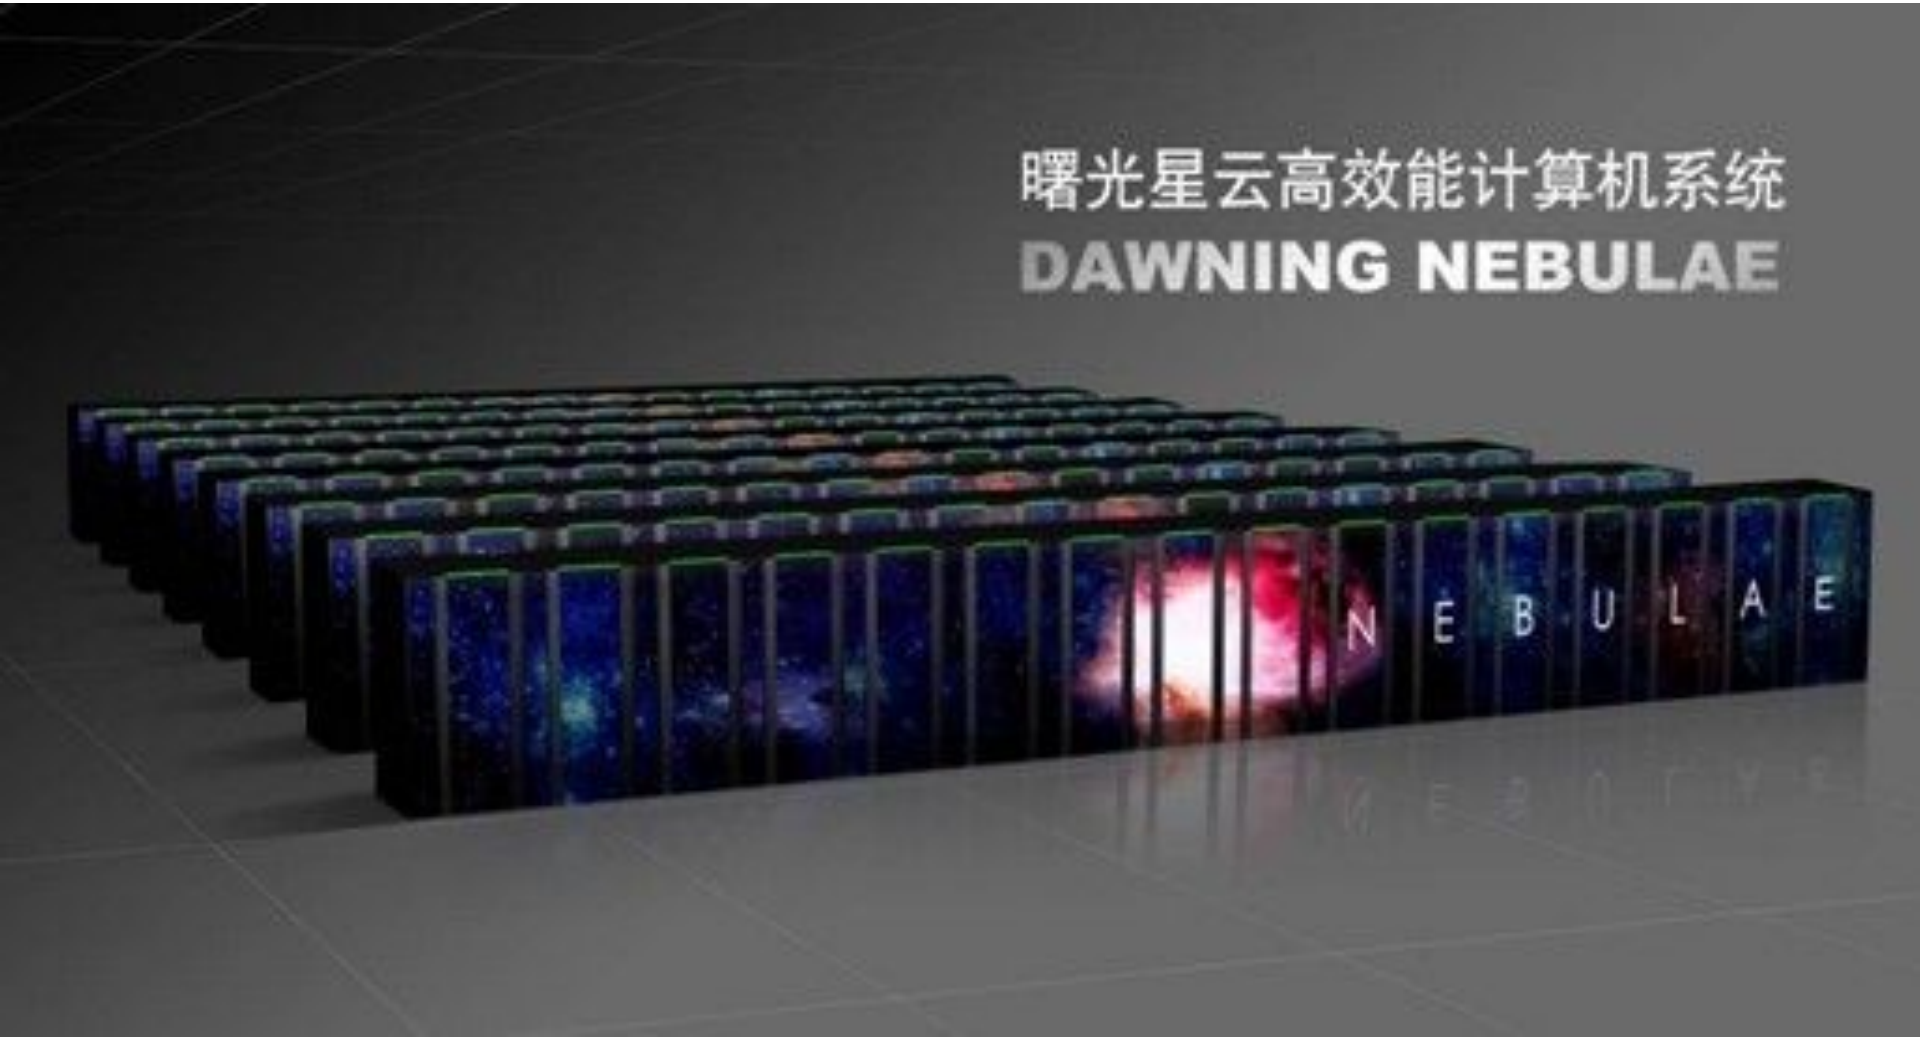

CUDA – почти C

- Единственное отличие – добавления для работы с потоками

Архитектура CUDA

- SIMD мультипроцессоры (8 или 16 ядер)
- Мультипроцессор имеет регистры и разделяемую (локальную) память
- Задача разбивается на блоки, блоки — на потоки
- Блоки назначаются на процессоры; выполненный блок невозможно запустить повторно

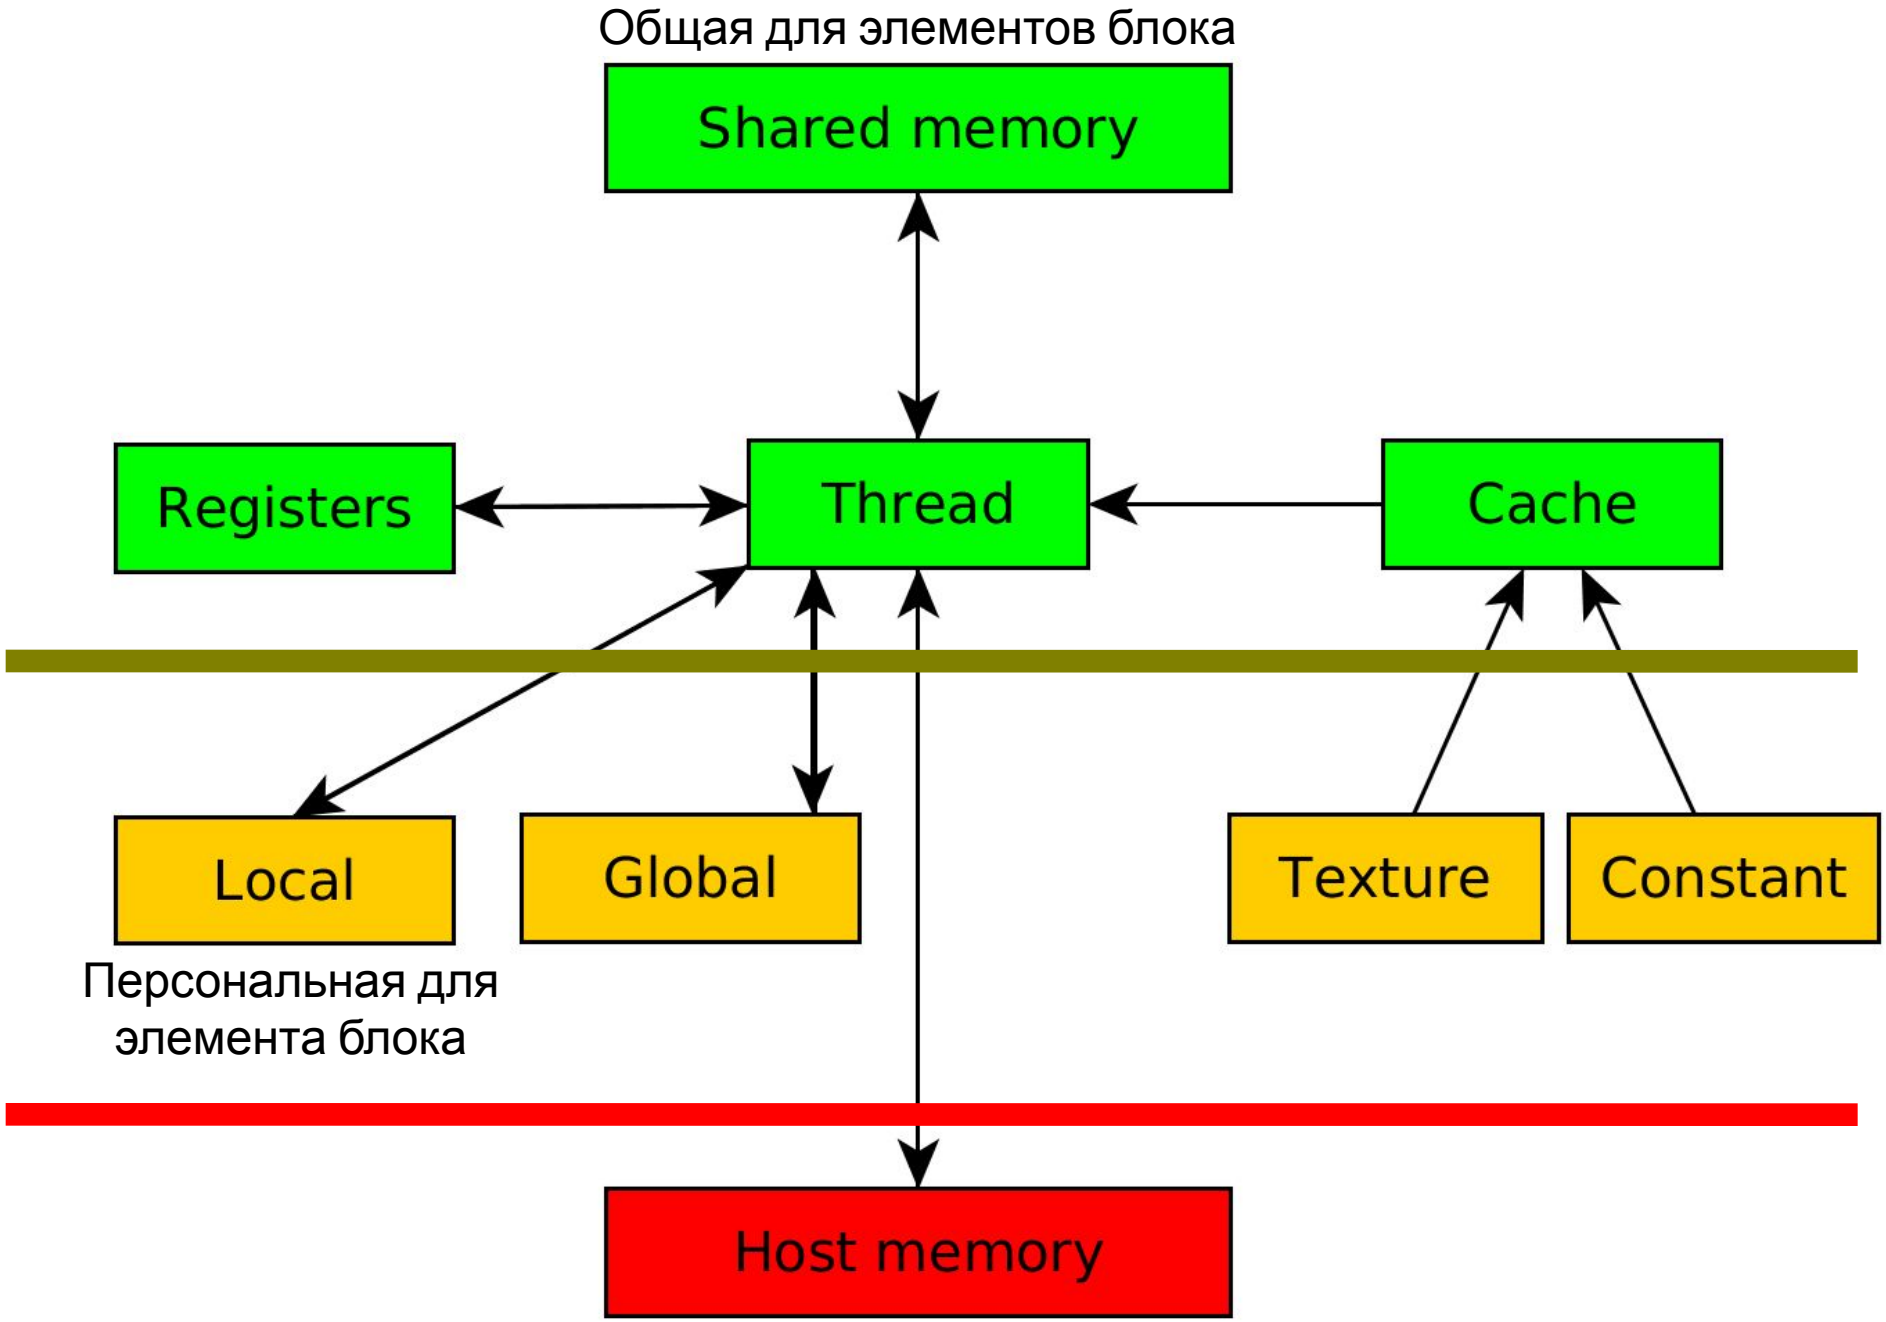
Общая для элементов блока
Shared memory
Registers
Thread
Cache
Local
Global
Texture
Constant
Персональная для элемента блока
Host memory

```
[talis@tesla ~]$ NVIDIA_GPU_Computing_SDK/C/bin/linux/release/deviceQuery
CUDA Device Query (Runtime API) version (CUDART static linking)
There is 1 device supporting CUDA

Device 0: "Tesla C1060"
  CUDA Driver Version:                           3.10
  CUDA Runtime Version:                          3.10
  CUDA Capability Major revision number:         1
  CUDA Capability Minor revision number:         3
  Total amount of global memory:                 4294770688 bytes
  Number of multiprocessors:                     30
  Number of cores:                               240
  Total amount of constant memory:               65536 bytes
  Total amount of shared memory per block:       16384 bytes
  Total number of registers available per block: 16384
  Warp size:                                     32
  Maximum number of threads per block:           512
  Maximum sizes of each dimension of a block:    512 x 512 x 64
  Maximum sizes of each dimension of a grid:     65535 x 65535 x 1
  Maximum memory pitch:                          2147483647 bytes
  Texture alignment:                             256 bytes
  Clock rate:                                    1.30 GHz
  Concurrent copy and execution:                 Yes
  Run time limit on kernels:                     No
  Integrated:                                    No
  Support host page-locked memory mapping:       Yes
  Compute mode:                                  Default (multiple host threads
can use this device simultaneously)

Test PASSED

Press ENTER to exit...

[talis@tesla ~]$
```

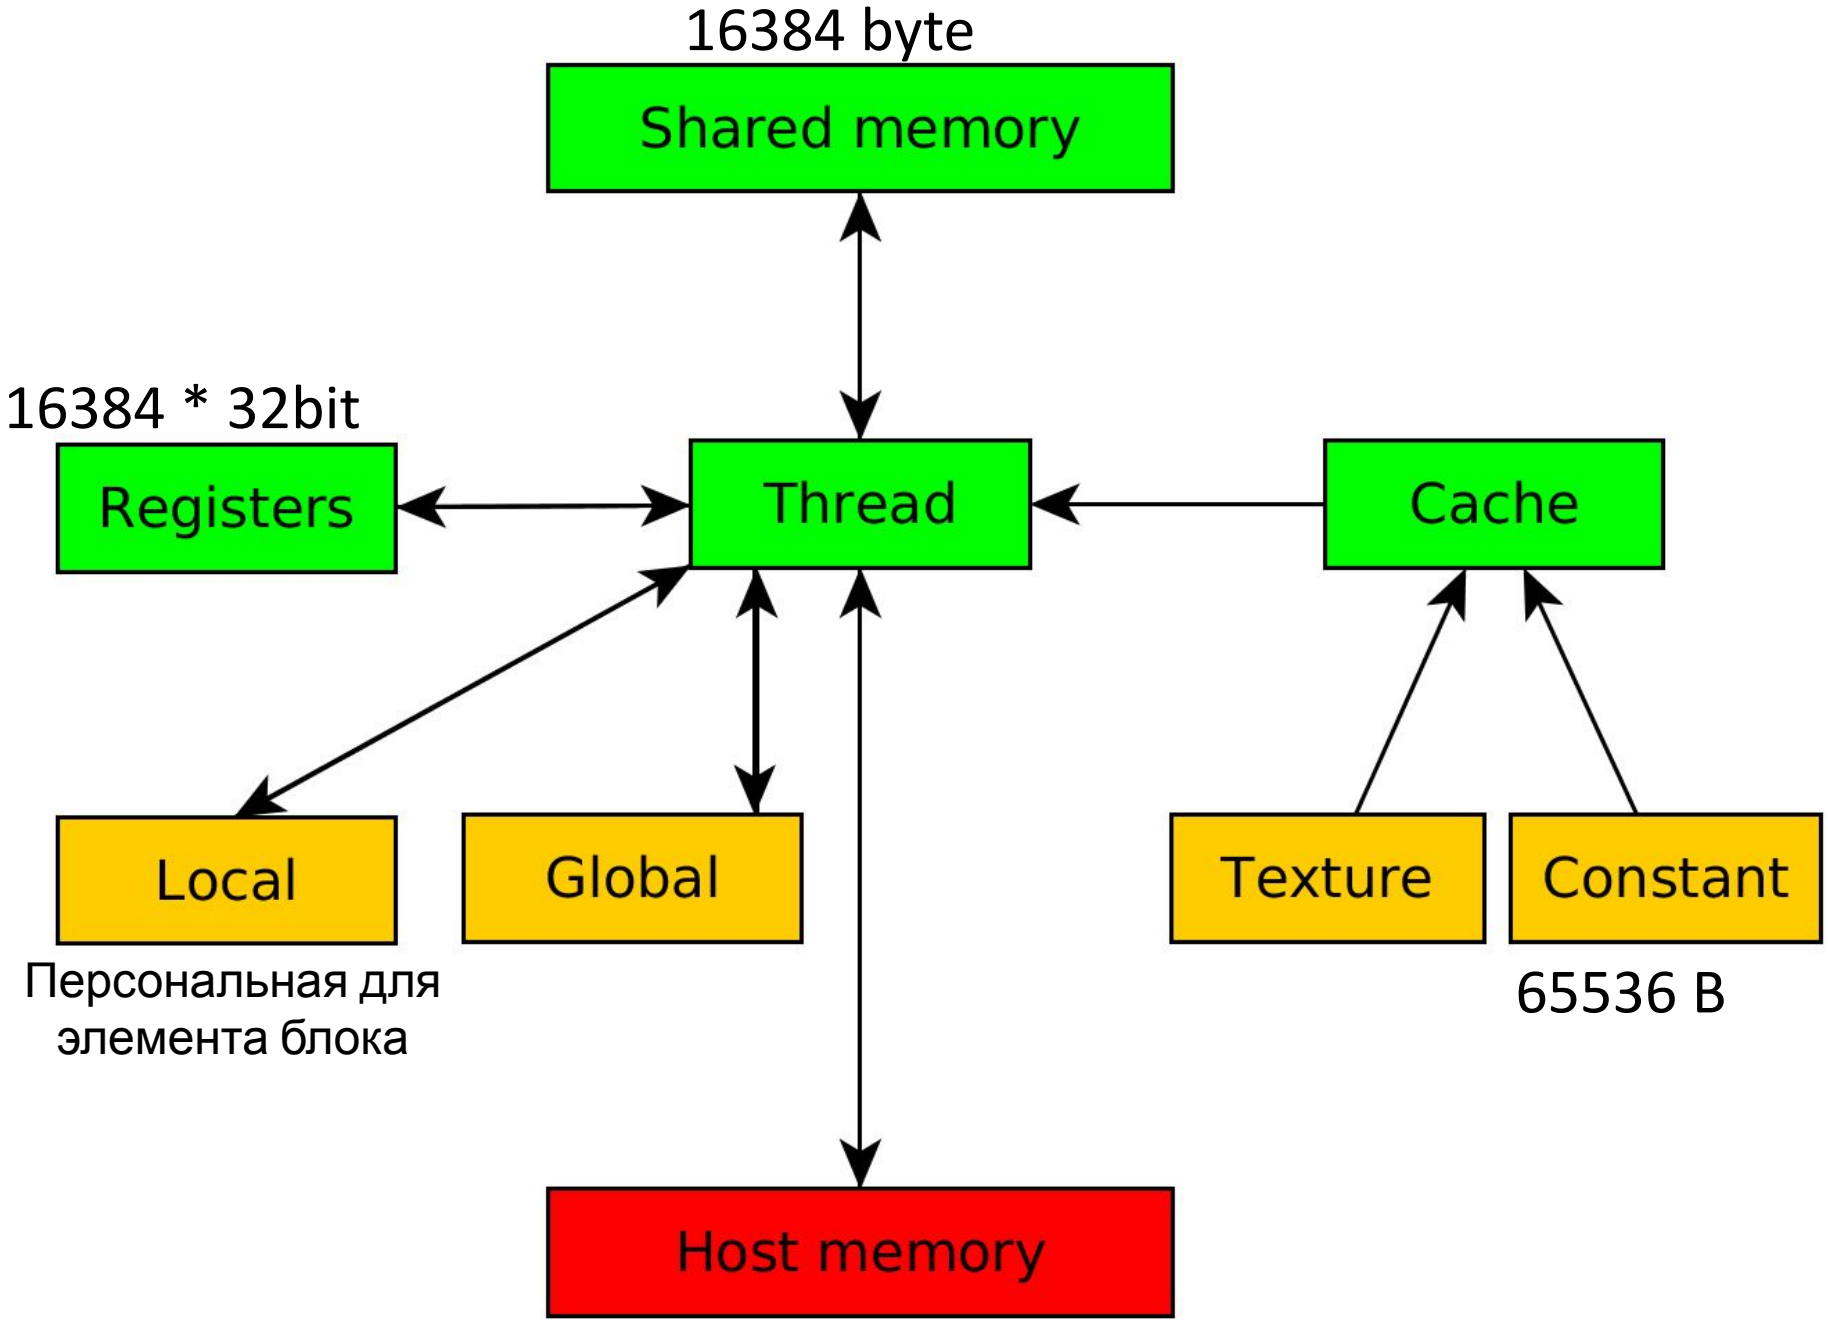
16384 byte
Shared memory
16384 * 32bit
Registers
Thread
Cache
Local
Global
Texture
Constant
Персональная для элемента блока
65536 B
Host memory

Расширения C для CUDA

Стандартный C код

```
void saxpy_serial(int i,
float a, float *x, float *y)
{
    y[i] = a*x[i] + y[i];
}

// Вызов последовательного
// ядра SAXPY

for (int i = 0; i < n; ++i)
  saxpy_serial(i, 2.0, x, y);
```

Код на CUDA C

```
__global__
void saxpy_parallel(int n, float a, float *x, float *y)
{
    int i = blockIdx.x*blockDim.x + threadIdx.x;
    if (i < n)  y[i] = a*x[i] + y[i];
}

// Вызов параллельного ядра SAXPY с размером
// блока в 256 потоков
int nblocks = (n + 255) / 256;

saxpy_parallel<<<nblocks, 256>>>(n, 2.0f, x, y);
```

Алгоритмы анализа данных

- Выявление ассоциативных зависимостей (Association rule mining, Apriori)
- Классификация (KNN)
- Кластеризация (K-means)
- Уменьшение размерности данных

•Выявление зависимостей

- I={i1,...,im} — множество атрибутов
- База данных — набор записей вида (TID, i1, ..., ip)
- Частотный k-набор — k-подмножество I, элементы которого встречаются более чем в N записях
- Задача: найти все частотные k-наборы
- Зависимости: если набор содержит X, то от содержит и x' с вероятностью p

Алгоритм выявления

- Найти все частотные 1-наборы
- Для k=2,... и пока есть новые наборы
  - Построение k-кандидатов: объединение двух частотных (k-1)-наборов с общим (k-2)-префиксом
  - Фильтрация: к-кандидат удаляется, если он содержит не частотное (k-1) подмножество
  - Определение частотности кандидатов

Классификация

- Метод ближайших соседей
  - Задана выборка объектов с приписанными метками
  - Для нового объекта вычисляется расстояние до всех объектов выборки
  - Метка нового объекта — самая частотная метка его K ближайших соседей из выборки

Понижение размерности

- На вход алгоритма поступает матрица расстояний, принцип действия следующий:
- На плоскости случайным образом фиксируются точки, попарно соединенные пружинами, длины ненапряженных состояний которых берутся из матрицы расстояний. Затем точки отпускаются, и действующие на них силы приводят потенциальную энергию систему к минимуму. Находятся варианты расположения точек, приводящие к минимуму потенциальной энергии и (или) лучше других удовлетворяющие другим формулам оценки качества распределения.
- Например, если матрица расстояний строилась по точкам, лежащим на плоскости, то в двумерное пространство точки восстановятся с точностью до поворота и смены знаков осей

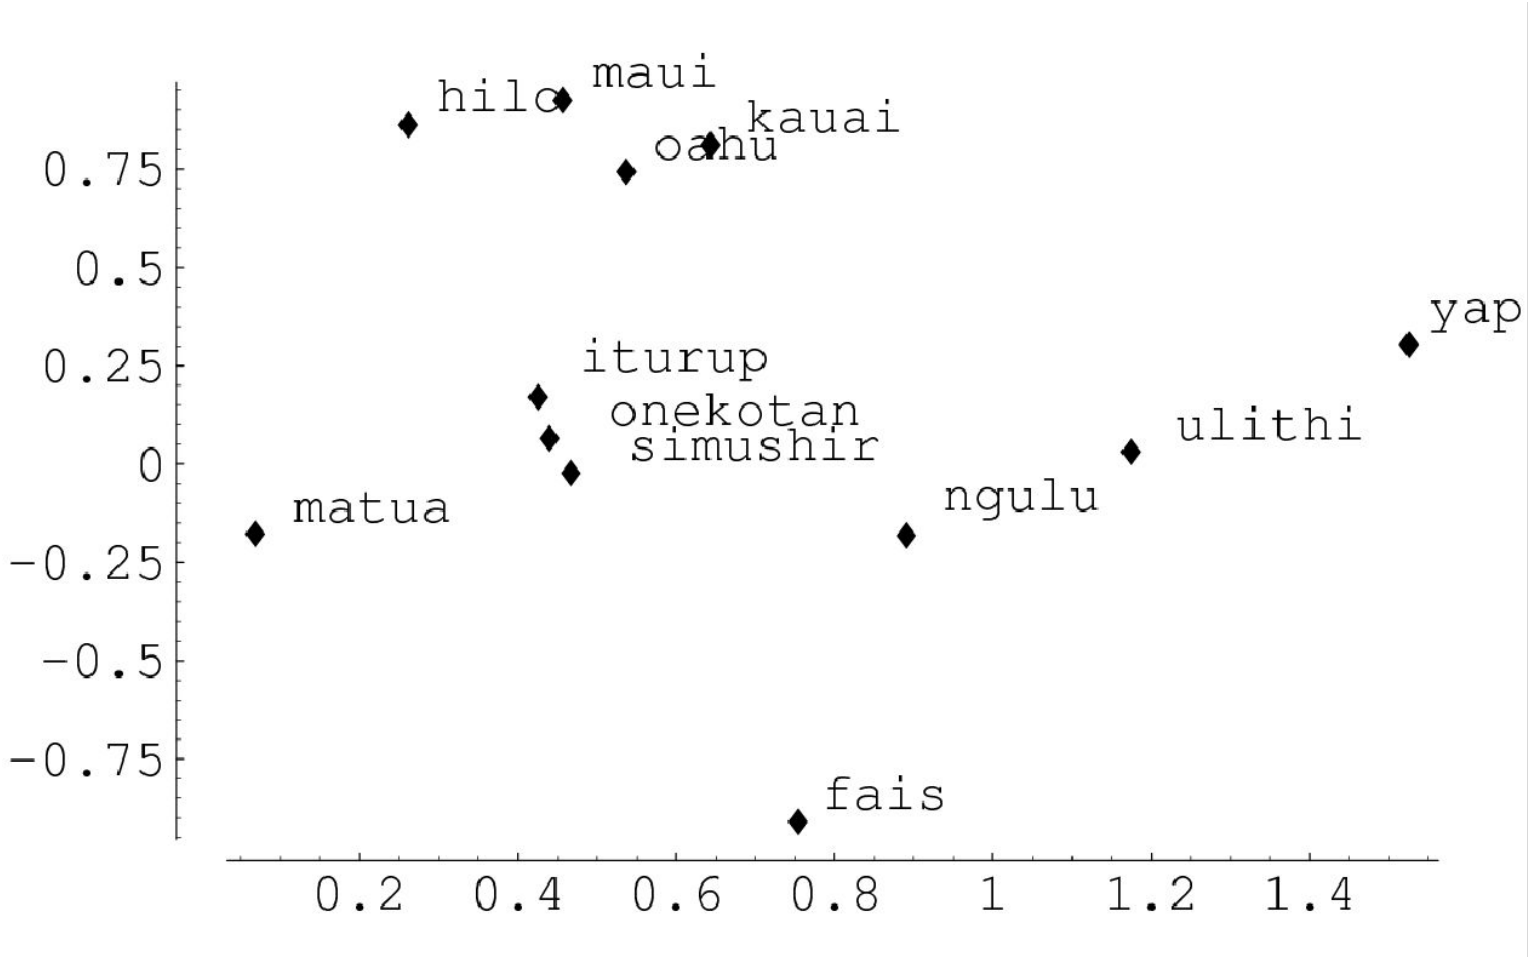

Производительность на GPU: тысячи точек за секунды