

Примеры оптимизаций с local memory.

Вычисления на видеокартах. Лекция 3

Немного уточнений по архитектуре

N-body simulation

Brute force matching

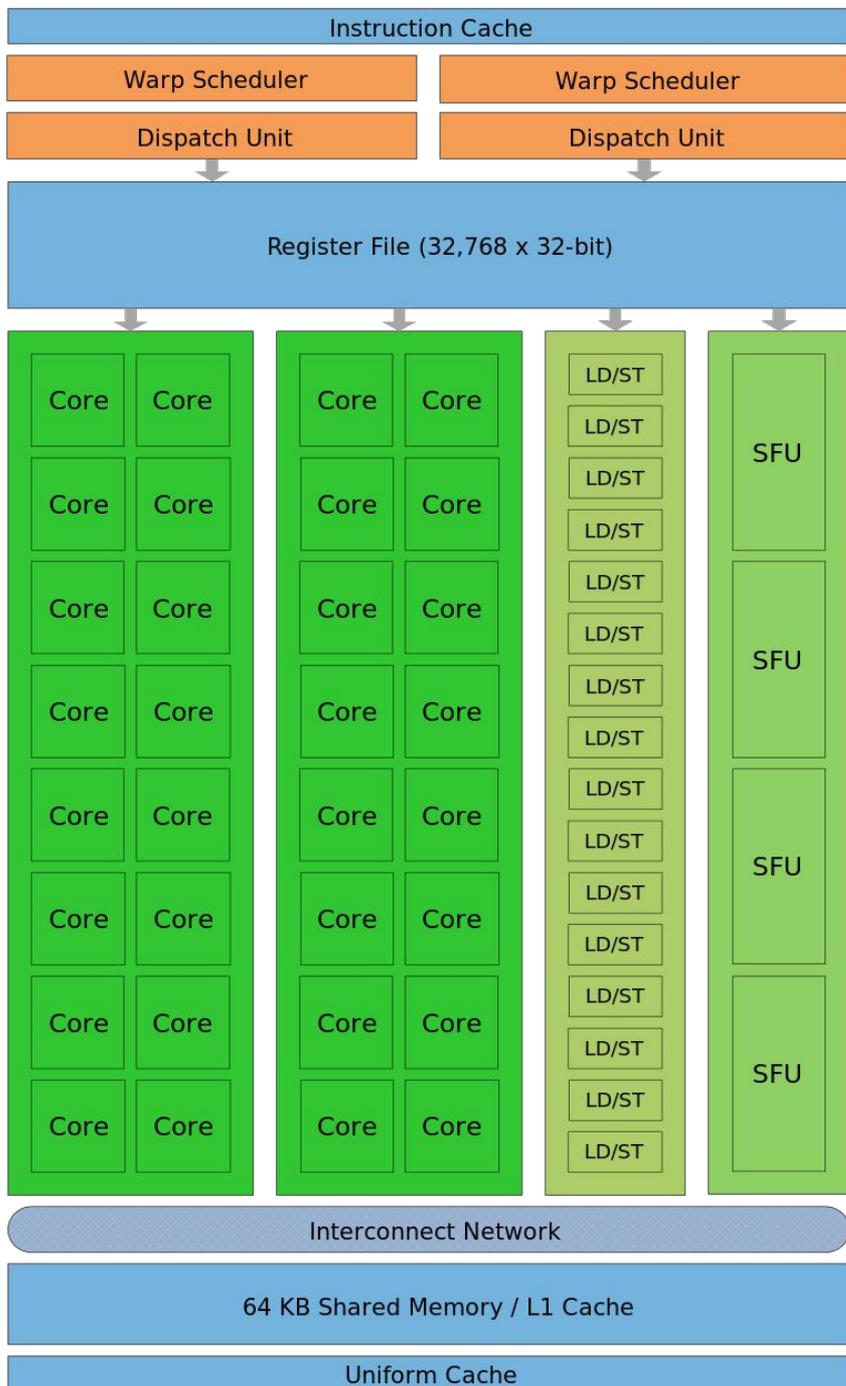
Key points detection

Matrix transpose

Matrix multiplication

Полярный Николай

polarnick239@gmail.com



NVIDIA: 32 threads in warp (32xCore слева)

AMD: 64 threads in wavefront

Каждая WorkGroup состоит из одного или более warp/wavefront-ов.

Например если рабочая группа размера 128, а размер wavefront=64, то **рабочая группа выполняется двумя wavefront-ами в рамках одного compute unit**. Но эти два wavefront не обязаны выполняться действительно параллельно, да и не всегда могут - ведь в compute unit может быть всего один warp/wavefront.

Но они могут выполняться чередуясь на одном и том же множестве **Cores (т.н. ALUs = Arithmetic Logic Units)**.

Т.о. из всех потоков одной WorkGroup доступна одна и та же local memory.

NVIDIA GTX 1080ti

28 compute units (i.e. Streaming Multiprocessor) * 128 cores (i.e. 4 warps with 32 ALUs in each)
= 3584 ALUs (CUDA cores)

GTX 1080 TI OVERVIEW



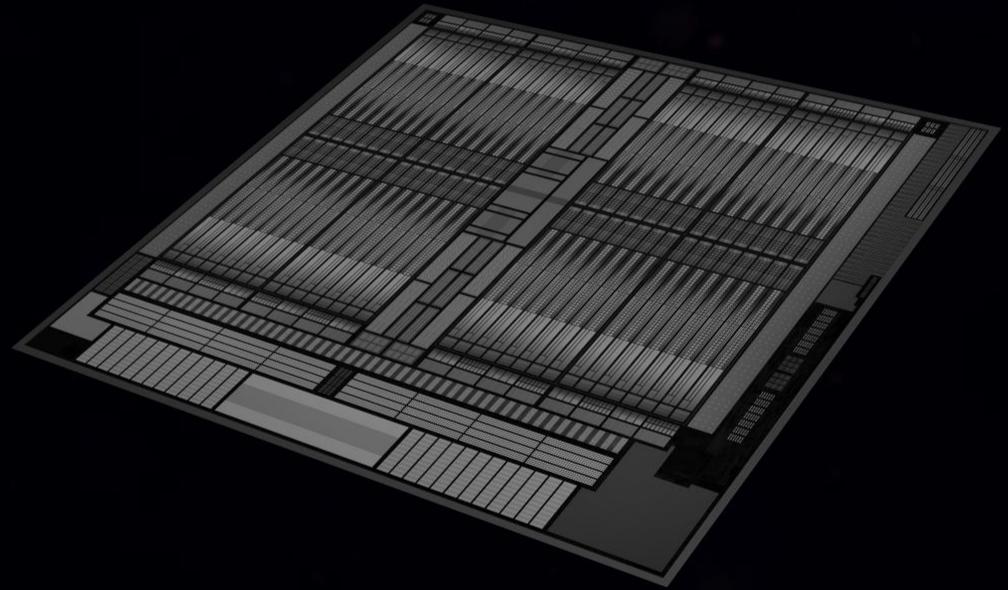
- 12B Transistors
- 1.6 GHz Boost, 2 GHz OC
- 28 SMs, 128 cores each
- 3584 CUDA cores
- 28 Geometry units
- 224 Texture units
- 6 GPCs
- 88 ROP units
- 352 bit GDDR5x

AMD Vega 64

64 compute units * 64 cores (i.e. 1 wavefront - 64 ALUs)
= 4096 ALUs (stream processors)

"Vega 10" by the numbers

- 1** Graphics Engine
- 4** Asynchronous Compute Engines
- 4** Next-Gen Geometry Engines
- 64** Next-Gen Compute Units
- 4096** Stream Processors
- 256** Texture Units
- 64** Render Back-Ends
- 4 MB** L2 Cache
- 2048-bit** HBM2



N-body simulation

Есть N частиц с массой, нужно промоделировать взаимное притяжение каждой пары частиц.

Асимптотика - $O(N^2)$.

Как не упереться в **memory bandwidth**? (как при суммировании чисел)

Использовать **local memory**!

Brute Force feature matching

Есть N ключевых точек на одной картинке, и M ключевых точек на второй картинке. Нужно найти для каждой парную (самую похожую).

Асимптотика - $O(N*M)$.

Как не упереться в **memory bandwidth**?

Использовать **local memory**!

Key points detection

Есть картинка, хочется в каждом пикселе проверить “не угол ли это на границе” и если да - добавить этот пиксель в результат.

Как осуществить добавление пикселя в конец результата?

atomic_add + локальный аккумулятор “аллокаций”

Как аллоцировать буфер в видеопамяти под результат чей размер заранее мы не знаем?

Транспонирование матрицы

Как довести наивную версию до идеального `coalesced memory access`?

Использовать **local memory**!

Умножение матриц

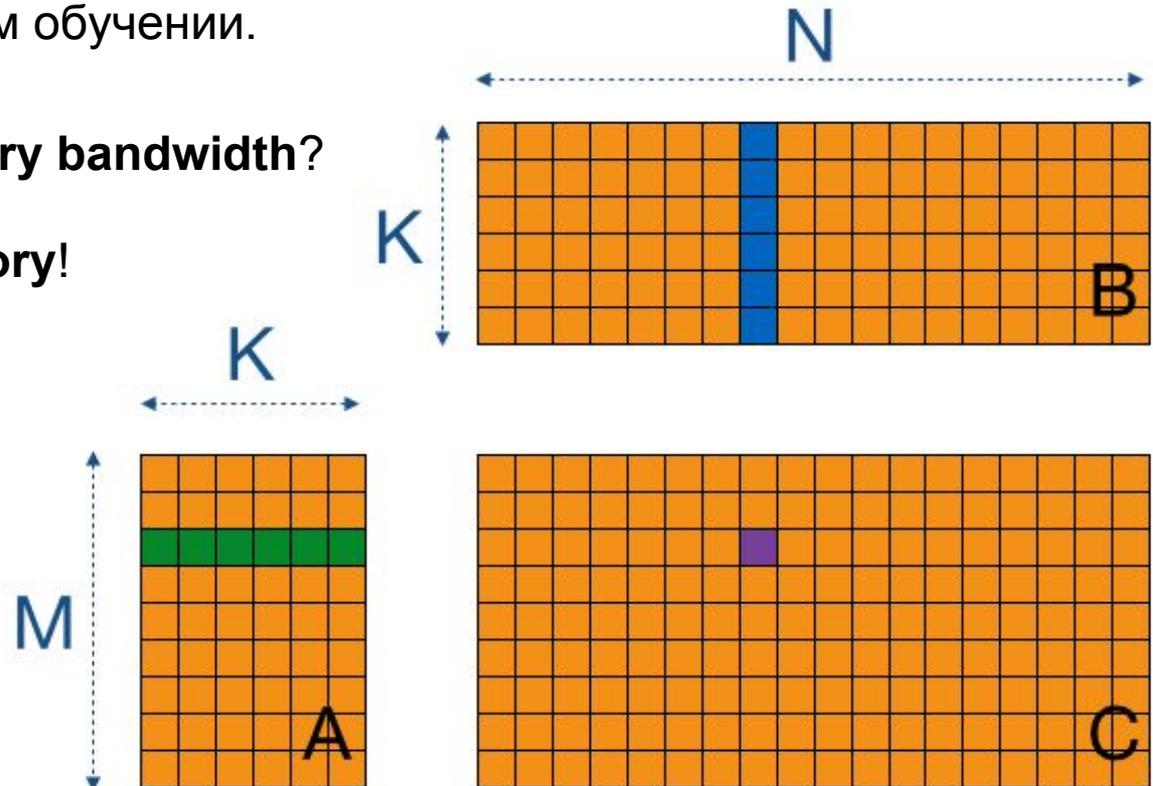
Размер **A** - $M \times K$, размер **B** - $K \times N$, размер **C** - $M \times N$.

Асимптотика - $O(M \times N \times K)$.

Используется в машинном обучении.

Как не упереться в **memory bandwidth**?

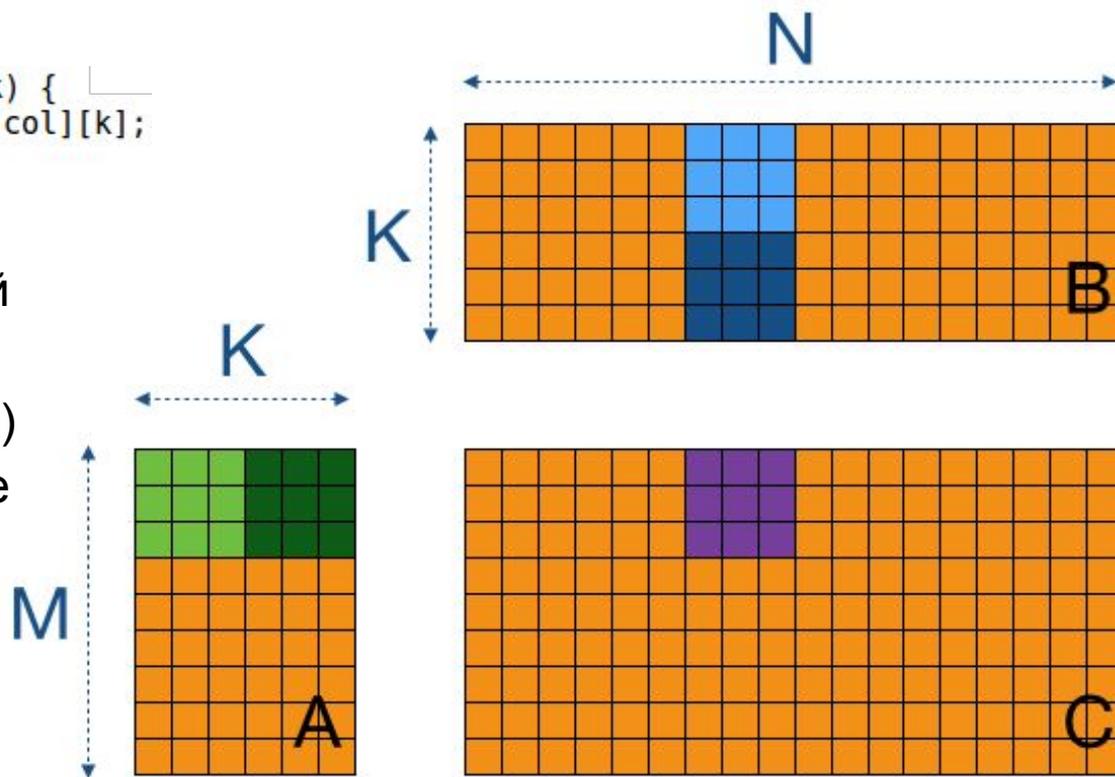
Использовать **local memory**!



Умножение матриц 1: локальная память

```
for (int k = 0; k < TileSize; ++k) {  
    acc += Atile[k][row] * Btile[col][k];  
}
```

Т.е. подгружать очередной блок из A и из B в local memory (Atile и Btile) и добавлять произведение в аккумулятор потока.



$$\begin{matrix} \text{purple} \\ \text{tile} \end{matrix} = \begin{matrix} \text{green} \\ \text{tile} \end{matrix} \times \begin{matrix} \text{blue} \\ \text{tile} \end{matrix} + \begin{matrix} \text{dark green} \\ \text{tile} \end{matrix} \times \begin{matrix} \text{dark blue} \\ \text{tile} \end{matrix}$$

Умножение матриц 2: больше FMA-операций

На каждой итерации внутреннего цикла:

- 1) подгрузить значение из Atile
- 2) подгрузить значение из Btile
- 3) умножить и добавить (FMA инструкция)

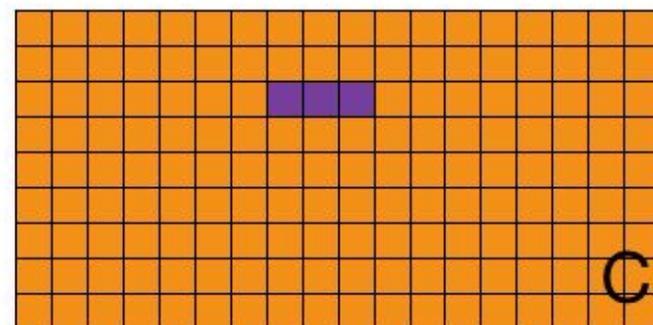
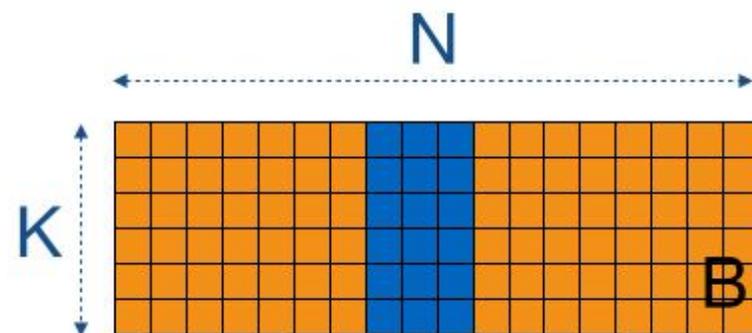
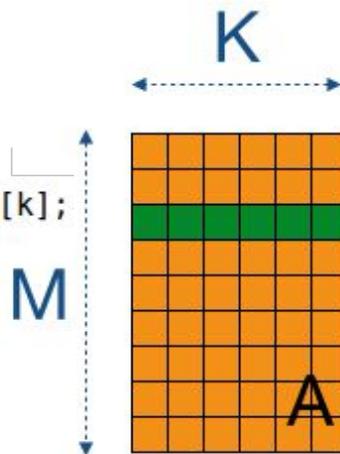
Можно заменить две подгрузки на одну.

Было:

```
for (int k = 0; k < TileSize; ++k) {  
    acc += Atile[k][row] * Btile[col][k];  
}
```

Стало:

```
for (int k = 0; k < TileSize; ++k) {  
    for (int w = 0; w < TileSize; ++w) {  
        acc[w] += Atile[k][row] * Btile[col + w * TileSize][k];  
    }  
}
```



Умножение матриц 3: local memory -> registers

На каждой итерации внутреннего цикла:

- 1) подгрузить значение из Btile
- 2) умножить и добавить (FMA инструкция)

Оптимзация:

Хочется подгружать значение из Btile не из **local memory**, а из регистров.

Т.е. сначала прогрузить из **local memory** в **регистры**, а потом быстро забирать оттуда. Но это бессмысленно пока поток обрабатывает всего лишь ряд внутри **C**. Поэтому нужно обрабатывать микро-блок внутри **C**.

Тут уже надо аккуратно балансировать между высоким числом используемых регистров и удельным количеством обращений к локальной памяти. Т.к. при большом числе используемых регистров будет низкая occupancy и начнет стучать global memory access (т.к. низкий процент occupancy - плохое сокрытие latency).

Умножение матриц

Но можно ли быстрее?

- loop-unrolling
- минимизация числа барьеров/CUDA shuffle instruction
- считать в half-precision
- на ассемблере ради минимального числа регистров и ради интринсик

Но можно ли быстрее?

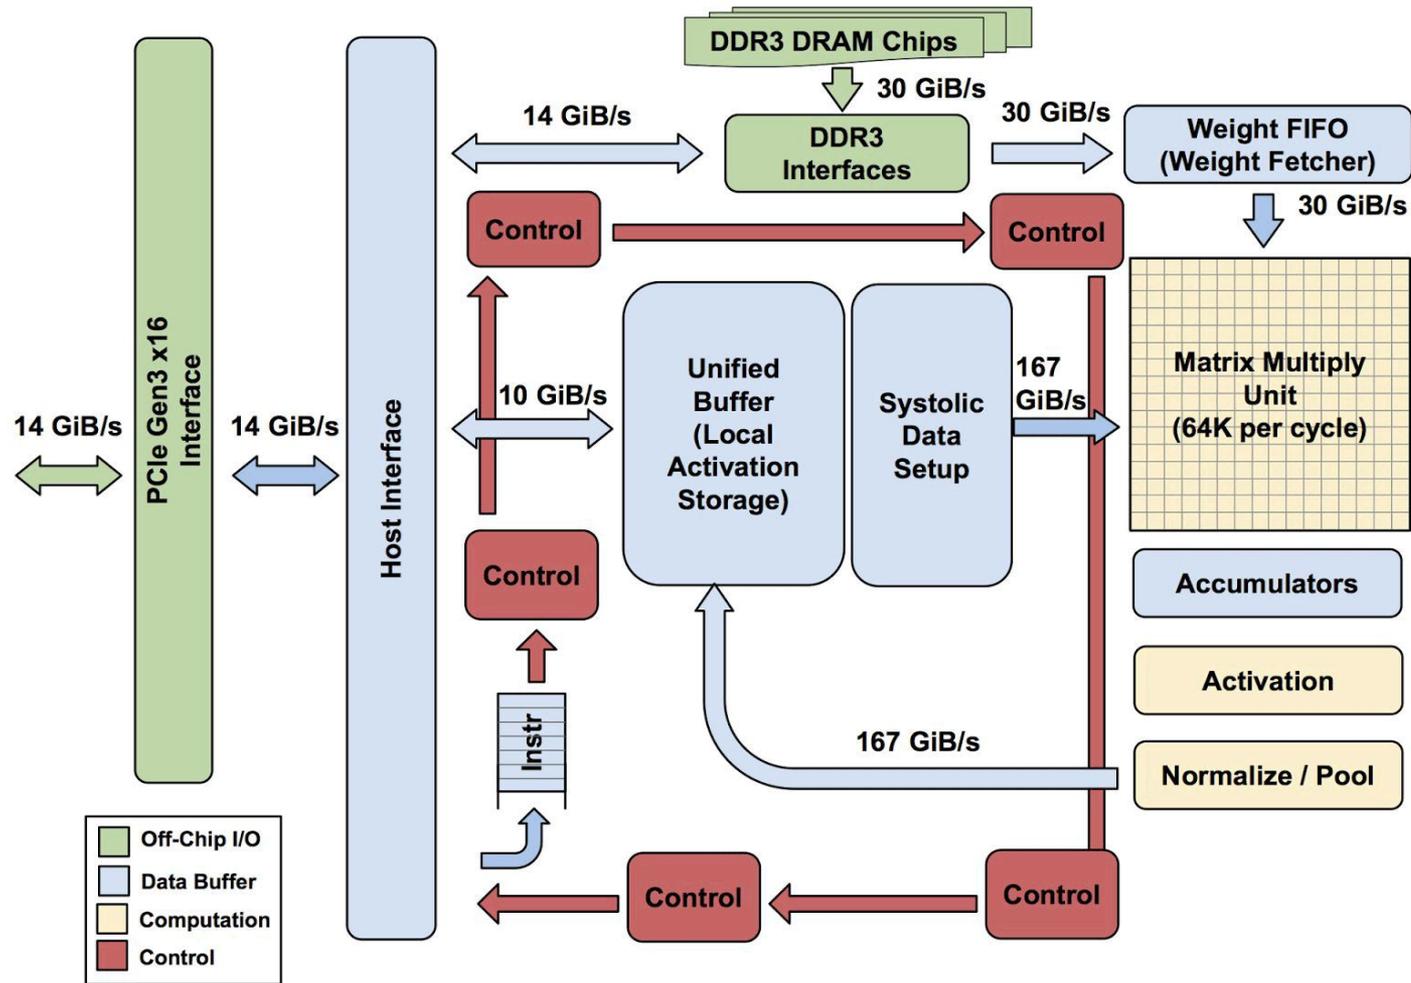
Да, но специализированное железо и/или считать в half-precision.

Tensor Cores, NVIDIA

$$\mathbf{D} = \begin{pmatrix} A_{0,0} & A_{0,1} & A_{0,2} & A_{0,3} \\ A_{1,0} & A_{1,1} & A_{1,2} & A_{1,3} \\ A_{2,0} & A_{2,1} & A_{2,2} & A_{2,3} \\ A_{3,0} & A_{3,1} & A_{3,2} & A_{3,3} \end{pmatrix} \begin{pmatrix} B_{0,0} & B_{0,1} & B_{0,2} & B_{0,3} \\ B_{1,0} & B_{1,1} & B_{1,2} & B_{1,3} \\ B_{2,0} & B_{2,1} & B_{2,2} & B_{2,3} \\ B_{3,0} & B_{3,1} & B_{3,2} & B_{3,3} \end{pmatrix} + \begin{pmatrix} C_{0,0} & C_{0,1} & C_{0,2} & C_{0,3} \\ C_{1,0} & C_{1,1} & C_{1,2} & C_{1,3} \\ C_{2,0} & C_{2,1} & C_{2,2} & C_{2,3} \\ C_{3,0} & C_{3,1} & C_{3,2} & C_{3,3} \end{pmatrix}$$

FP16 or FP32 FP16 FP16 FP16 or FP32

Tensor processing unit, Google



Not to Scale