

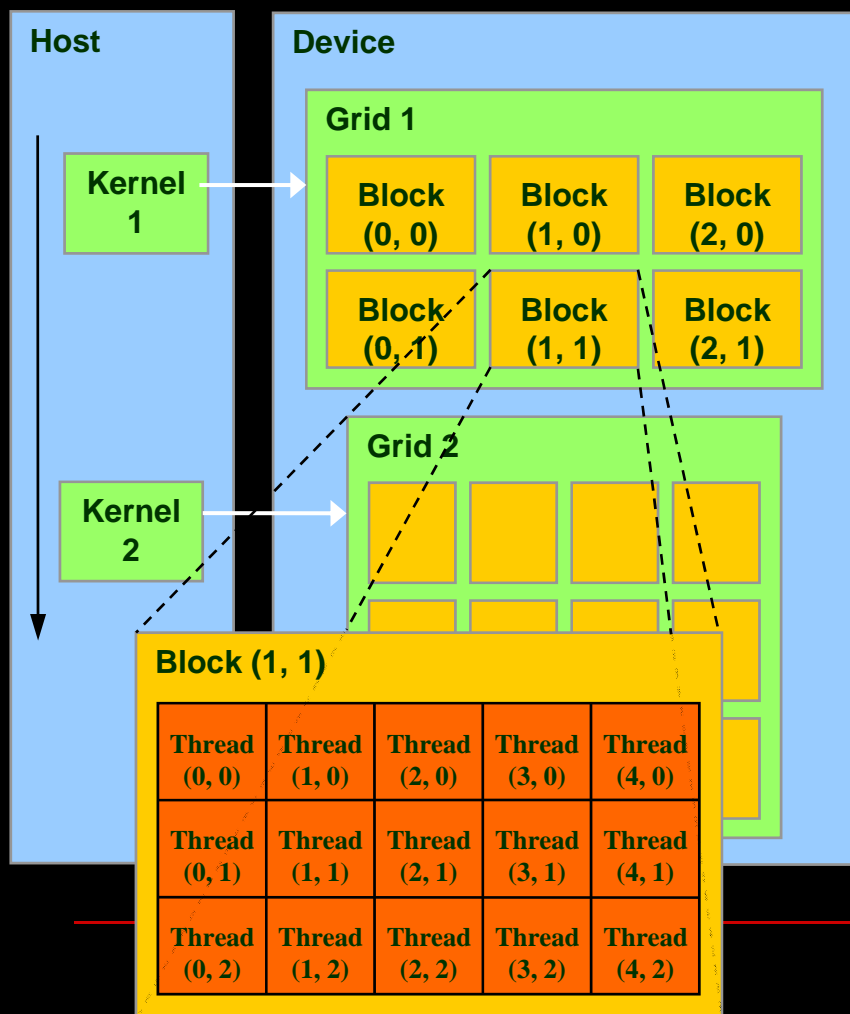
Архитектура и программирование поточковых многоядерных процессоров для научных расчётов

Лекция 5. Пример вычислительного ядра
– задача умножения матриц. Текстуры.
Атомарные функции. Библиотека CUTIL

Процедура разработки программы

- Общий подход к программированию
 - Разбить задачу на элементарные блоки данных, над которыми выполняется стандартный алгоритм обработки (**единый для всех блоков**)
 - Разбить за-/вы-гружаемые данные на элементарные **непересекающиеся** блоки, которые каждый из процессов прочтёт/запишет
 - Определить **конфигурацию грида/блока**, позволяющее
 - Оптимальное **размещение промежуточных данных** в регистрах и общей памяти
 - Оптимальную **вычислительную загрузку** потоковых процессоров
 - Определить график **когерентного** обращения к памяти процессами при загрузке данных

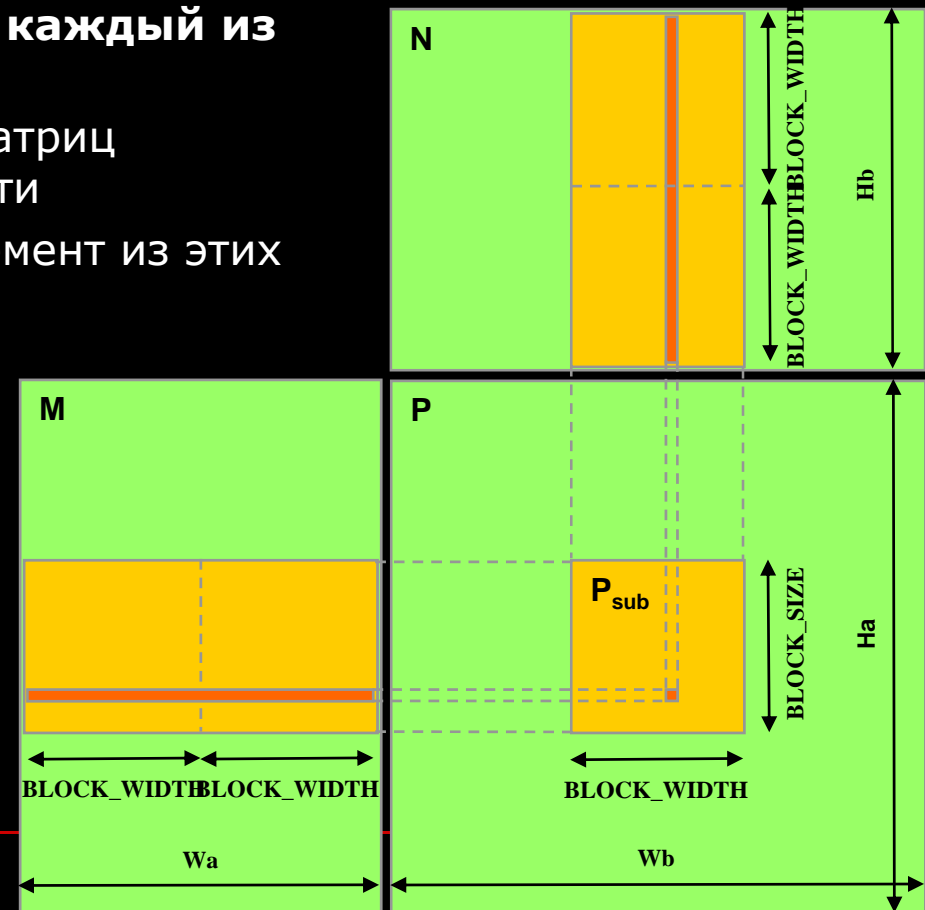
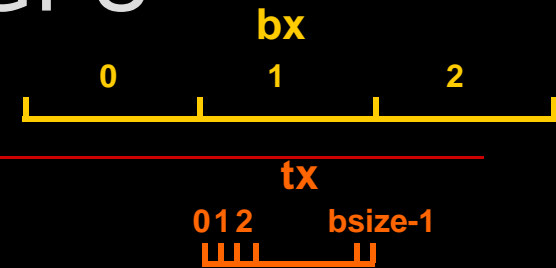
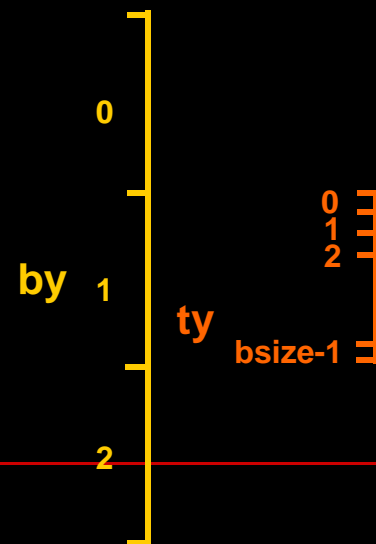
Вычислительная конфигурация GPU



- Процессы объединяются в блоки (**blocks**), внутри которых они имеют общую память (**shared memory**) и синхронное исполнение
- Блоки объединяются в сетки (**grids**)
 - Нет возможности предсказать очередность запуска блоков в сетки
 - Между блоками нет и не может быть (см. выше) общей памяти

Пример программы для GPU умножение матриц -2

- Разбить данные на элементарные блоки (непересекающиеся), которые каждый из процессов прочтёт/запишет
- Необходимые области исходных матриц разбиваются на квадратные области
- Каждый из тредов читает один элемент из этих областей в разделяемую память



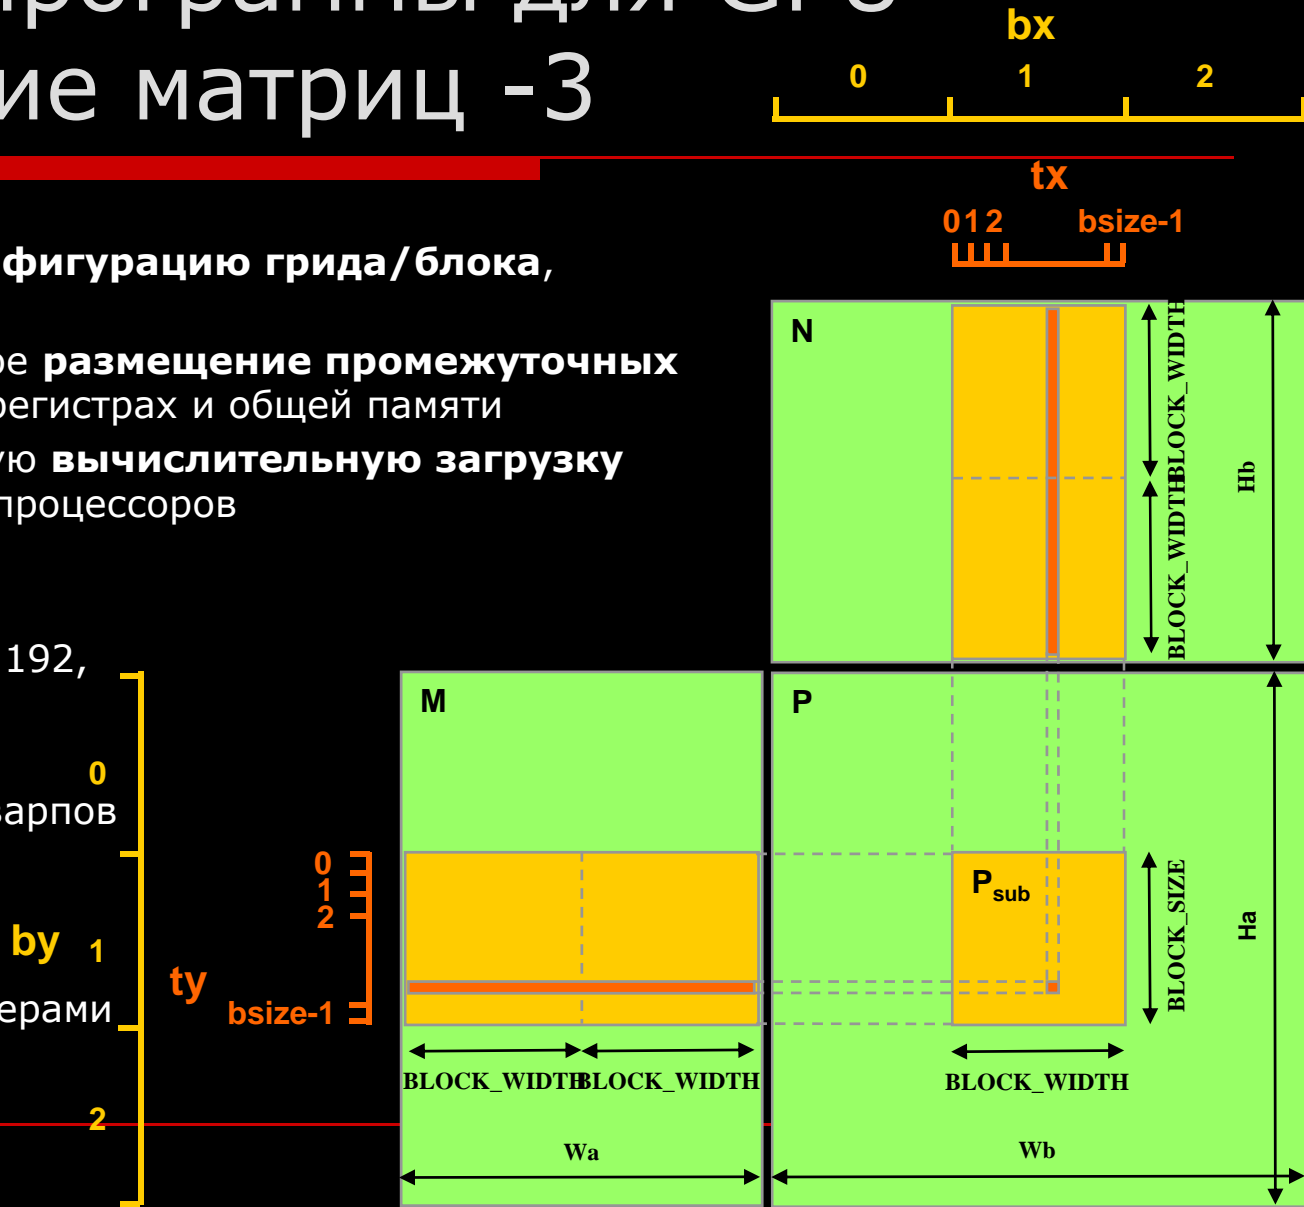
Пример программы для GPU умножение матриц -3

- Определить **конфигурацию грида/блока**, позволяющее
 - Оптимальное **размещение промежуточных данных** в регистрах и общей памяти
 - Оптимальную **вычислительную загрузку** потоковых процессоров

- Блок = $16 \times 16 = 256$ тредов больше чем 192, меньше чем 512

- Целое количество варпов в блоке

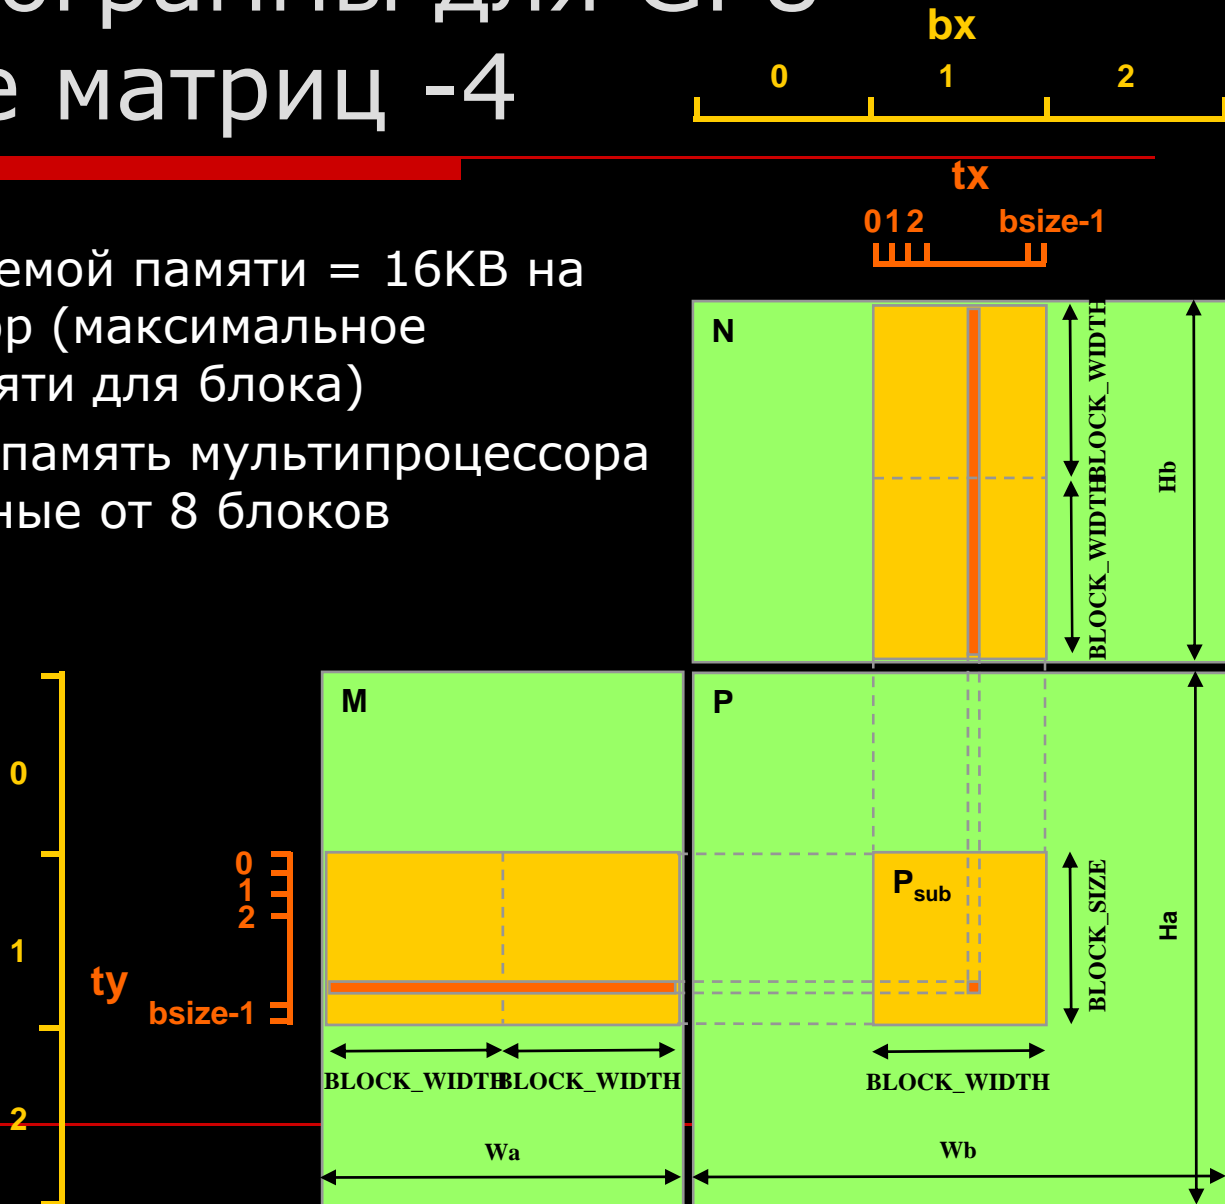
- Размеры грида определяются размерами исходных матриц



Пример программы для GPU умножение матриц -4

- Размер разделяемой памяти = 16KB на мультипроцессор (максимальное количество памяти для блока)
- В разделяемую память мультипроцессора поместятся данные от 8 блоков

- Регистровая память расходуется незначительно
- Для определения количества регистров, приходящееся на один тред нужно смотреть PTX код



Хост-функция умножения матриц

```
#define BLOCK_SIZE 16
__global__ void Mul(float*, float*, int, int, float*);
void Mul(const float* A, const float* B, int hA, int wA, int wB, float* C) {
    int size;
    // Load A and B to the device
    float* Ad; size = hA * wA * sizeof(float); cudaMalloc((void**)&Ad, size);
    cudaMemcpy(Ad, A, size, cudaMemcpyHostToDevice);
    float* Bd; size = wA * wB * sizeof(float); cudaMalloc((void**)&Bd, size);
    cudaMemcpy(Bd, B, size, cudaMemcpyHostToDevice);
    // Allocate C on the device
    float* Cd;
    size = hA * wB * sizeof(float);
    cudaMalloc((void**)&Cd, size);
    // Compute the execution configuration assuming the matrix dimensions are multiples of BLOCK_SIZE
    dim3 dimBlock(BLOCK_SIZE, BLOCK_SIZE);
    dim3 dimGrid(wB / dimBlock.x, hA / dimBlock.y);
    // Launch the device computation
    Mul<<<dimGrid, dimBlock>>>(Ad, Bd, wA, wB, Cd);
    // Read C from the device
    cudaMemcpy(C, Cd, size, cudaMemcpyDeviceToHost);
    // Free device memory
    cudaFree(Ad); cudaFree(Bd); cudaFree(Cd); }
```

GPU ядро умножения матриц

```
__global__ void Muld(float* A, float* B, int wA, int wB, float* C) {  
  
    int bx = blockIdx.x; // Block index  
    int by = blockIdx.y;  
    int tx = threadIdx.x; // Thread index  
    int ty = threadIdx.y;  
    int aBegin = wA * BLOCK_SIZE * by; // Index of the first sub-matrix of A processed by the block  
    int aEnd = aBegin + wA - 1; // Index of the last sub-matrix of A processed by the block  
    int aStep = BLOCK_SIZE; // Step size used to iterate through the sub-matrices of A  
    int bBegin = BLOCK_SIZE * bx; // Index of the first sub-matrix of B processed by the block  
    int bStep = BLOCK_SIZE * wB; // Step size used to iterate through the sub-matrices of B  
    float Csub = 0; // The element of the block sub-matrix that is computed by the thread  
  
    for (int a = aBegin, b = bBegin; a <= aEnd; a += aStep, b += bStep) {  
        // Shared memory for the sub-matrix of A  
        __shared__ float As[BLOCK_SIZE][BLOCK_SIZE];  
  
        // Shared memory for the sub-matrix of B  
        __shared__ float Bs[BLOCK_SIZE][BLOCK_SIZE];  
    }  
}
```

GPU ядро умножения матриц (продолжение)

```
As[ty][tx] = A[a + wA * ty + tx]; // Load the matrices from global memory to shared memory;
Bs[ty][tx] = B[b + wB * ty + tx]; // each thread loads one element of each matrix
__syncthreads(); // Synchronize to make sure the matrices are loaded

// Multiply the two matrices together;
// each thread computes one element
// of the block sub-matrix
for (int k = 0; k < BLOCK_SIZE; ++k)
    Csub += As[ty][k] * Bs[k][tx];

// Synchronize to make sure that the preceding
// computation is done before loading two new
// sub-matrices of A and B in the next iteration
__syncthreads();
}
// Write the block sub-matrix to global memory;
// each thread writes one element
int c = wB * BLOCK_SIZE * by + BLOCK_SIZE * bx;
C[c + wB * ty + tx] = Csub;
}
```

Уровень производительности

- Для матрицы 1024*1024
 - Автоматическое распределение : 3.0 сек - **45 GFLOPS**
 - 1 блок на SM : 3.6 сек. - **35 GFLOPS**
 - 2 блока на SM : 3.0 сек. - **45 GFLOPS**
 - Очевидно, ограничивающим фактором является требование запуска 2 блоков на SM, а не ограничение по разделяемой памяти (8 блоков на SM)

- Развёртывание циклов помогает (развёрнуто 16 раз)
 - Развернутая программа (автомат) : 1.6 сек. - **80 GFLOPS**
 - 1 блок на SM : 2.1 сек. - **61 GFLOPS**
 - 2 блока на SM : 1.6 сек. - **80 GFLOPS**

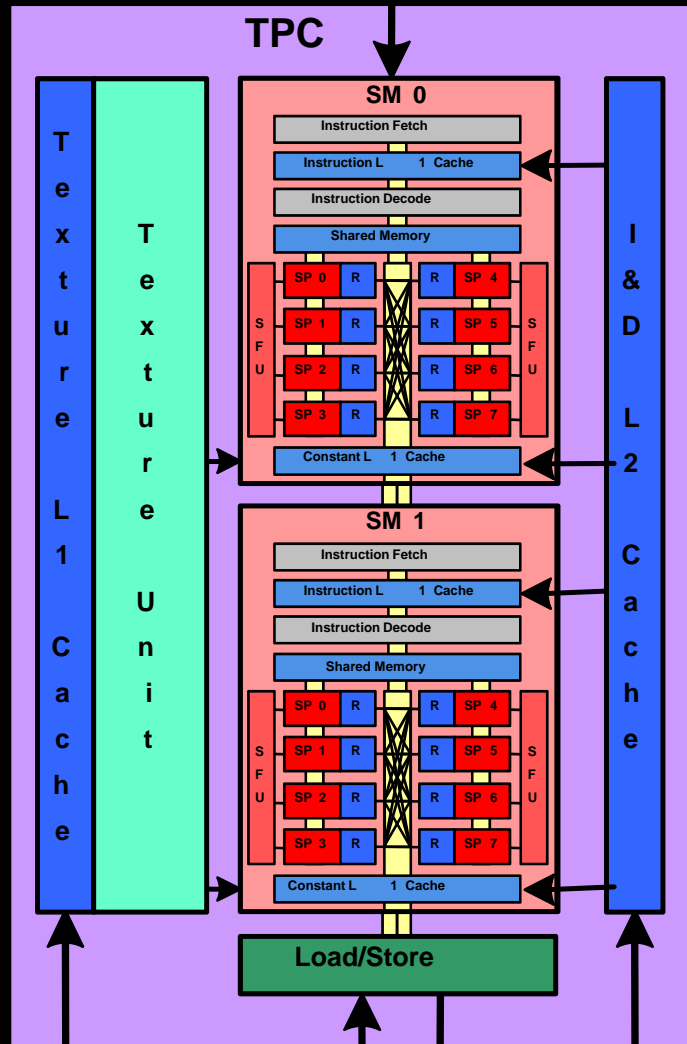
Уровень производительности (продолжение)

- Возможный альтернативный график вычислений

```
Loop {  
  
Load to Shared Memory  
  
Syncthread()  
  
Compute current subblock  
  
Syncthreads()  
}
```

```
Load to Shared Memory  
Syncthread()  
  
Loop {  
  
Compute current subblock  
Load to Shared Memory  
  
Syncthreads()  
}
```

Texture Processor Cluster (TPC)



- TEX – Текстурный блок – логика адресации текстурных массивов в 1D, 2D, 3D
 - + L1 Кэш Текстур
- L2 Кэш инструкций и данных для обоих SM
- x2 Поточковых Мультипроцессора (Streaming Multiprocessor)
- x8 потоковых процессоров (streaming processors) = 8 MAD/clock cycle
- Регистры для хранения промежуточных результатов у выполняемых тредов => больше тредов лучше скрыты операции чтения, но может не хватить регистров

Использование текстур (обзор)

- ❑ Текстуры - удобный способ обращения с табличными исходными данными
- ❑ Кэшированы – для каждых 2-х SM – общий L1 кэш, общий L2 кэш для всего кристалла
 - Замена разделяемой памяти для RO операндов
 - Нет жёстких требований к правильности адресации
- ❑ Адреса – числа с плавающей точкой (**возможно с нормализацией**)
 - Позволяют выделять объекты с адресом, находящимся между табличными значениями
 - ❑ Аппроксимация ближайшим
 - ❑ Линейная и билинейная аппроксимация (исходя из значений соседей)
- ❑ Варианты “tile” и “center”
 - Поведение текстуры при выходе адреса за пределы сетки

Использование текстур (детали)

- **Объявление** вне тела функции - `texture<Type, Dim, ReadMode> texRef;`
 - Type = тип
 - Dim = 1 | 2
 - ReadMode = **cudaReadModeNormalizedFloat** | **CudaReadModeElementType**

- **Определение** – привязывание объявленной ссылки на 1D (линейный массив) или 2D (CudaArray) объекту в глобальной памяти
 - `cudaBindTexture()`
 - `cudaBindTextureToArray()`
 - `cudaUnbindTexture()`

- **Использование** – “texture fetch”
 - 1D-массив
 - `Texture_type tex1Dfetch(texture<uchar4, 1, cudaReadModeNormalizedFloat> texRef, int x);`
 - 2D-массив
 - `Texture_type tex1D(texture<Type, 1, readMode> texRef, float x);`
 - `Texture_type tex2D(texture<Type, 2, readMode> texRef, float x, float y);`

Использование текстур (пример часть 1)

```
texture<float, 2, cudaReadModeElementType> tex; // declare texture reference for 2D float texture
__global__ void transformKernel( float* g_odata, int width, int height, float theta)
{
    // calculate normalized texture coordinates
    unsigned int x = blockIdx.x*blockDim.x + threadIdx.x;
    unsigned int y = blockIdx.y*blockDim.y + threadIdx.y;

    float u = x / (float) width;
    float v = y / (float) height;

    u -= 0.5f; // transform coordinates
    v -= 0.5f;
    float tu = u*cosf(theta) - v*sinf(theta) + 0.5f;
    float tv = v*cosf(theta) + u*sinf(theta) + 0.5f;

    // read from texture and write to global memory
    g_odata[y*width + x] = tex2D(tex, tu, tv);
}
```

Использование текстур (пример часть 2)

```
// set texture parameters
tex.addressMode[0] = cudaAddressModeWrap;
tex.addressMode[1] = cudaAddressModeWrap;
tex.filterMode = cudaFilterModeLinear;
tex.normalized = true; // access with normalized texture coordinates

// Bind the array to the texture
CUDA_SAFE_CALL( cudaBindTextureToArray( tex, cu_array, channelDesc));

dim3 dimBlock(8, 8, 1);
dim3 dimGrid(width / dimBlock.x, height / dimBlock.y, 1);

// warmup
transformKernel<<< dimGrid, dimBlock, 0 >>>( d_data, width, height, angle);

CUDA_SAFE_CALL( cudaThreadSynchronize() );

// execute the kernel
transformKernel<<< dimGrid, dimBlock, 0 >>>( d_data, width, height, angle);
```

Обращение с памятью из ворпа

- ❑ НЕАТОМАРНЫЕ ИНСТРУКЦИИ (G80)
- ❑ ЕСЛИ какая-либо инструкция исполняемая ворпом **пишет** в одно место в **глобальной или общей** памяти
- ❑ ТО **количество** записей и их **очерёдность недетерминированы**
- ❑ **ОДНАКО по крайней мере одна запись** состоится

- ❑ АТОМАРНЫЕ ИНСТРУКЦИИ (G92+)
- ❑ ЕСЛИ какая-либо инструкция исполняемая ворпом **пишет/читает/модифицирует** одно место в **глобальной** памяти
- ❑ ТО их **очерёдность** записей **недетерминирована**
- ❑ **ОДНАКО все записи** состоятся **последовательно**

Атомарные функции

- ❑ Функции чтения/модификации/записи данных в глобальную память – основа построения алгоритмов **стекового декодирования**
 - ❑ Работают **только с целыми значениями (!)**
 - ❑ **Гарантируют неизменность операнда в процессе операции**
 - Арифметические функции: **atomicAdd, atomicSub, atomicExch, atomicMax, atomicInc, atomicDec**
 - ❑ `int atomicAdd(int* address, int val);`
 - Функция **atomicCAS – Compare and store**
 - ❑ `int atomicCAS(int* address, int compare, int val);`
 - Битовые функции **atomicAnd, atomicOr, atomicXor**
 - ❑ `int atomicAnd(int* address, int val);`
-

Библиотека cutil

- ❑ Набор утилит для различных служебных целей (**cut*** - функции)
 - Макросы типа `CUDA_SAFE_CALL` - различные ситуации, с синхронизацией, без неё, для эмуляции
 - Утилиты профайлинга
 - ❑ измерение длительности исполнения
 - ❑ `CUT_SAFE_CALL(cutCreateTimer(&timer));`
 - ❑ `CUT_SAFE_CALL(cutStartTimer(timer));`
 - ❑ `CUT_SAFE_CALL(cutStopTimer(timer));`
 - ❑ `CUT_SAFE_CALL(cutDeleteTimer(&timer));`
 - ❑ Определение конфликтных ситуаций операций чтения
 - ❑ И т.д. => см **cutil.h**
 - ❑ Находится в директории `common` в составе SDK
 - ❑ В отличие от других библиотек предоставляется в виде исходных текстов
 - ❑ Необходимо скомпилировать до работы над своим проектом
-

Итоги лекции

- В результате лекции студенты должны :
 - Получить **практический пример** составления вычислительного ядра для типовой задачи.
 - Получить представление о свойствах **текстур** и возможности их применения в научных вычислениях
 - Получить представление о свойствах и возможности применения в научных вычислениях **атомарных функций**
 - **Достаточные знания для начала самостоятельной работы**