Иерархия памяти CUDA. Глобальная память. Параллельные решения задач умножения матриц и решения СЛАУ.

- Лекторы:
  - Боресков А.В. (ВМиК МГУ)
  - Харламов А.А. (NVidia)

Типы памяти в CUDA

Тип памяти	Доступ	Уровень выделения	Скорость работы
Регистры	R/W	Per-thread	Высокая(on-chip)
Локальная	R/W	Per-thread	Низкая (DRAM)
Shared	R/W	Per-block	Высокая(on-chip)
Глобальная	R/W	Per-grid	Низкая (DRAM)
Constant	R/O	Per-grid	Высокая(L1 cache)
Texture	R/O	Per-grid	Высокая(L1 cache)

Типы памяти в CUDA

- Самая быстрая – shared (on-chip)
- Самая медленная – глобальная (DRAM)
- Для ряда случаев можно использовать кэшируемую константную и текстурную память
- Доступ к памяти в CUDA идет отдельно для каждой половины warp’a (*half-warp*)

Работа с памятью в CUDA

- Основа оптимизации – оптимизация работы с памятью
- Максимальное использование shared-памяти
- Использование специальных паттернов доступа к памяти, гарантирующих эффективный доступ
- Паттерны работают независимо в пределах каждого half-warp'a

Умножение матриц

- Произведение двух квадратных матриц A и B размера N*N, N кратно 16
- Матрицы расположены в глобальной памяти
- По одной нити на каждый элемент произведения
- 2D блок – 16*16
- 2D grid

Умножение матриц. Простейшая реализация.

```
#define BLOCK_SIZE 16

__global__ void matMult ( float * a, float * b, int n, float * c )
{
  int   bx = blockIdx.x;
  int   by = blockIdx.y;
  int   tx = threadIdx.x;
  int   ty = threadIdx.y;
  float sum = 0.0f;
  int   ia = n * BLOCK_SIZE * by + n * ty;
  int   ib = BLOCK_SIZE * bx + tx;
  int   ic = n * BLOCK_SIZE * by + BLOCK_SIZE * bx;

  for ( int k = 0; k < n; k++ )
    sum += a [ia + k] * b [ib + k*n];

  c [ic + n * ty + tx] = sum;
}
```

Умножение матриц. Простейшая реализация.

```
int          numBytes = N * N * sizeof ( float );
float      * adev, * bdev, * cdev ;
dim3         threads ( BLOCK_SIZE, BLOCK_SIZE );
dim3         blocks ( N / threads.x, N / threads.y);

cudaMalloc      ( (void**)&adev, numBytes );        // allocate DRAM
cudaMalloc      ( (void**)&bdev, numBytes );        // allocate DRAM
cudaMalloc      ( (void**)&cdev, numBytes );        // allocate DRAM

cudaMemcpy ( adev, a, numBytes, cudaMemcpyHostToDevice ); // from CPU to DRAM
cudaMemcpy ( bdev, b, numBytes, cudaMemcpyHostToDevice ); // from CPU to DRAM

matMult<<<blocks, threads>>> ( adev, bdev, N, cdev );
cudaThreadSynchronize();

cudaMemcpy             ( c, cdev, numBytes, cudaMemcpyDeviceToHost );

cudaFree               ( adev );
cudaFree               ( bdev );
cudaFree               ( cdev );
```

Простейшая реализация.

- На каждый элемент
  - 2*N арифметических операций
  - 2*N обращений к глобальной памяти
- Memory bound (тормозит именно доступ к памяти)

Оптимизация работы с глобальной памятью.

- Обращения идут через 32/64/128-битовые слова
- При обращении к t[i]
  - sizeof(t [0]) равен 4/8/16 байтам
  - t [i] выровнен по sizeof (t [0])
- Вся выделяемая память всегда выровнена по 256 байт

Использование выравнивания.

```
struct vec3
{
  float x, y, z;
};
```

- Размер равен 12 байт
- Элементы массива не будут выровнены в памяти

```
struct __align__(16) vec3
{
  float x, y, z;
};
```

- Размер равен 16 байт
- Элементы массива всегда будут выровнены в памяти

Device Compute Capability

- Compute Caps. – доступная версия CUDA
  - Разные возможности HW
  - Пример:
    - В 1.1 добавлены атомарные операции в global memory
    - В 1.2 добавлены атомарные операции в shared memory
    - В 1.3 добавлены вычисления в double
- Узнать доступный Compute Caps. можно через cudaGetDeviceProperties()
  - См. CUDAHelloWorld
- Сегодня Compute Caps:
  - Влияет на правила работы с глобальной памятью

Device Compute Capability

GPU	Compute Capability
Tesla S1070	1.3
GeForce GTX 260	1.3
GeForce 9800 GX2	1.1
GeForce 9800 GTX	1.1
GeForce 8800 GT	1.1
GeForce 8800 GTX	1.0

RTM **Appendix A.1** CUDA Programming Guide

Объединение запросов к глобальной памяти.

- GPU умеет объединять рад запросов к глобальной памяти в один блок (транзакцию)
- Независимо происходит для каждого half-warp’a
- Длина блока должна быть 32/64/128 байт
- Блок должен быть выровнен по своему размеру

Объединение (coalescing) для GPU с CC 1.0/1.1

- Нити обращаются к
  - 32-битовым словам, давая 64-байтовый блок
  - 64-битовым словам, давая 128-байтовый блок
- Все 16 слов лежат в пределах блока
- *k*-ая нить half-warp'а обращается к *k*-му слову блока

Объединение (coalescing) для GPU с CC 1.0/1.1

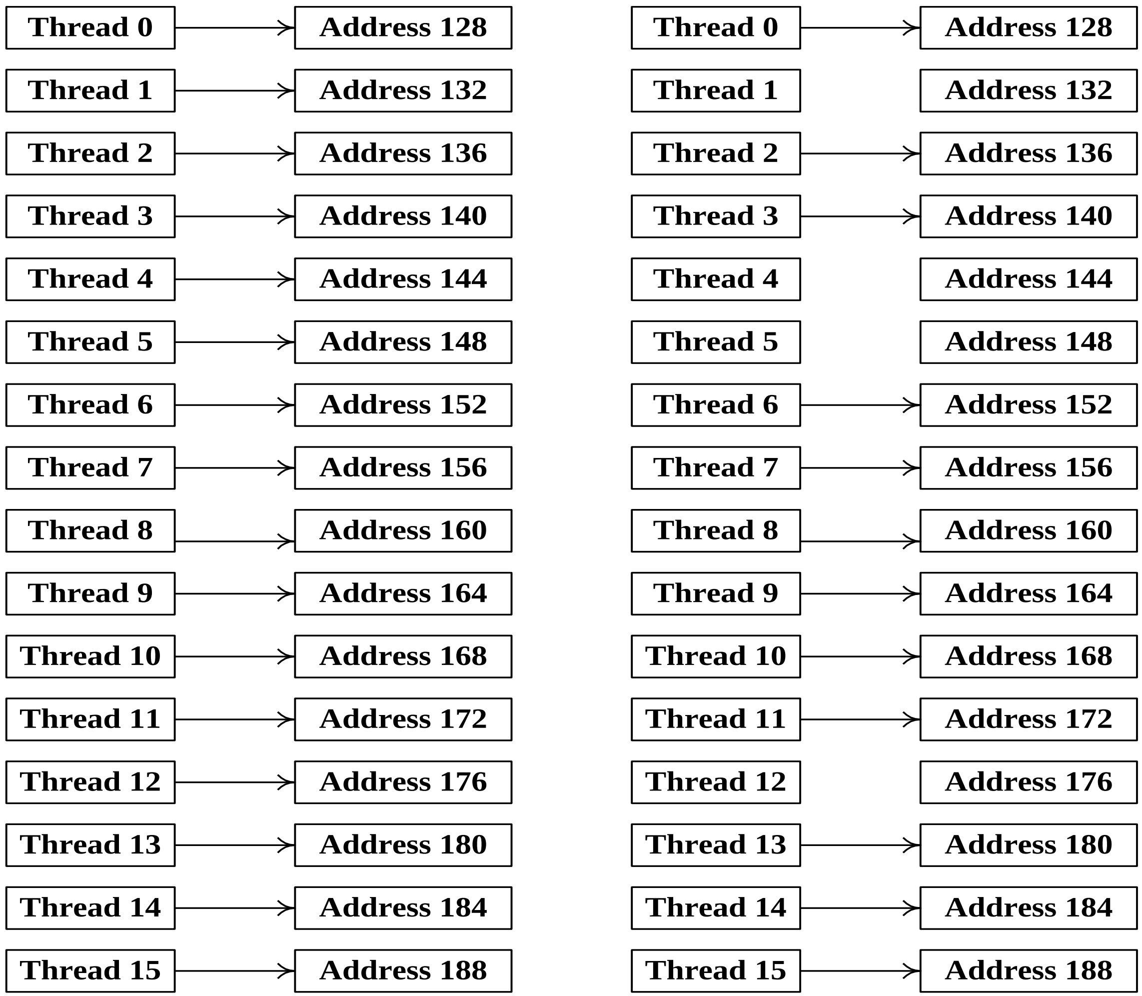

Coalescing

Объединение (coalescing) для GPU с CC 1.0/1.1

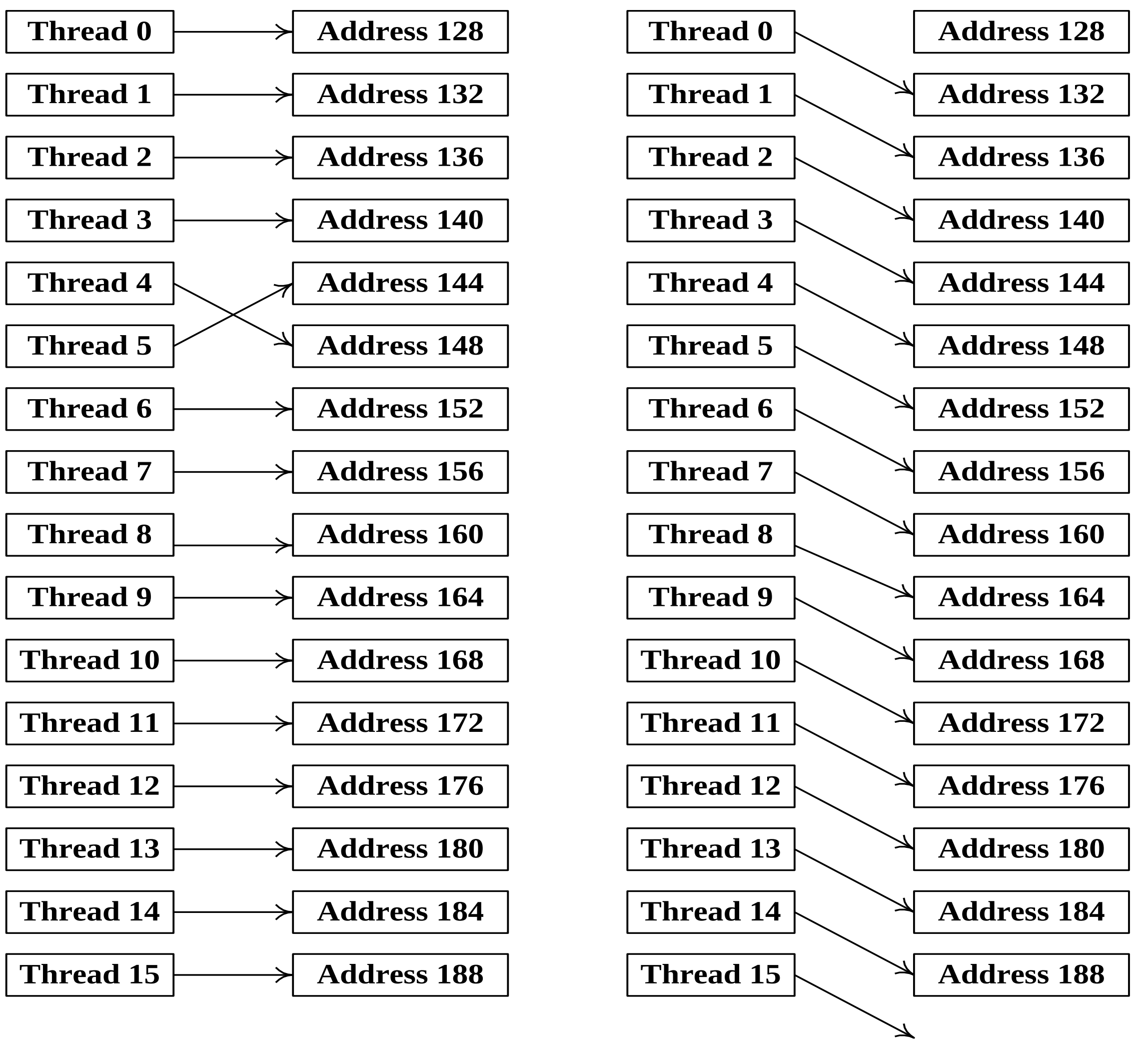

Not Coalescing

Объединение (coalescing) для GPU с CC 1.2/1.3

- Нити обращаются к
  - 8-битовым словам, дающим один 32-байтовы сегмент
  - 16-битовым словам, дающим один 64-байтовый сегмент
  - 32-битовым словам, дающим один 128-байтовый сегмент
- Получающийся сегмент выровнен по своему размеру

Объединение (coalescing)

- Если хотя бы одно условие не выполнено
  - 1.0/1.1 – 16 отдельных транзаций
  - 1.2/1.3 – объединяет их в блоки (2,3,…) и для каждого блока проводится отдельная транзакция
- Для 1.2/1.3 порядок в котором нити обращаются к словам внутри блока не имеет значения (в отличии от 1.0/1.1)

Объединение (coalescing)

- Можно добиться заметного увеличения скорости работы с памятью
- Лучше использовать не массив структур, а набор массивов отдельных компонент – это позволяет использовать coalescing

Использование отдельных массивов

```
struct vec3
{
  float x, y, z;
};
vec3 * a;

float x = a [threadIdx.x].x;
float y = a [threadIdx.x].y;
float z = a [threadIdx.x].z;
```

Не можем использовать coalescing при чтении данных

```
float * ax, * ay, * az;

float x = ax [threadIdx];
float y = ay [threadIdx];
float z = az [threadIdx];
```

Поскольку нити одновременно обращаются к последовательно лежащим словам памяти, то будет происходить coalescing

Решение системы линейных алгебраических уравнений

$Ax=f$,

A – матрица размера N*N,

f – вектор размера N

- Традиционные методы ориентированы на последовательное вычисление элементов и нам не подходят
- Есть еще итеративные методы

Итеративные методы

$$x^{k+1} - x^{k} = \alpha \cdot \left(A \cdot x^{k} - f \right)$$

- Эффективны когда
  - Матрица *A* сильна разрежена
  - Параллельные вычисления
- В обоих случаях цена (по времени) одной итерации *O(N)*

Сходимость

$$Ax^* = f,$$

$$d^{k+1} = x^{k+1} - x^*,$$

$$d^{k+1} = \alpha \cdot A d^k,$$

$$\left\| d^{k+1} \right\| \le |\alpha| \cdot \|A\| \cdot \left\| d^k \right\|,$$

$$|\alpha| \cdot \|A\| < 1$$

- **Если есть сходимость, то только к решению системы**
- **Записав уравнения для погрешности получаем достаточное условие сходимости**
- **За счет выбора достаточно малого значения параметра получаем сходимость**

Код на CUDA

```
//
// one iteration
//
__global__ void kernel ( float * a, float * f, float alpha,
                         float * x0, float * x1, int n )
{
  int   idx = blockIdx.x * blockDim.x + threadId.x;
  int   ia  = n * idx;
  float sum = 0.0f;

  for ( int I = 0; i < n; i++ )
    sum += a [ia + I] * x0 [I];

  x1 [idx] = x0 [idx] + alpha * (sum - f [idx] );
}
```

Ресуры нашего курса

- CUDA.CS.MSU.SU
  - Место для вопросов и дискуссий
  - Место для материалов нашего курса
  - Место для ваших статей!
    - Если вы нашли какой-то интересный подход!
    - Или исследовали производительность разных подходов и знаете, какой из них самый быстрый!
    - Или знаете способы сделать работу с CUDA проще!
- www.steps3d.narod.ru
- www.nvidia.ru

Вопросы