

Иерархия памяти CUDA. Разделяемая память. Основные алгоритмы.

Лектор:

[Боресков А.В. \(ВМК МГУ\)](mailto:steps3d@narod.ru), steps3d@narod.ru

План


- Разделяемая память
- Константная память
- Базовые алгоритмы

План

- **Разделяемая память**
- Константная память
- Базовые алгоритмы

Типы памяти в CUDA

Тип памяти	Доступ	Уровень выделения	Скорость работы	Расположение
Регистры	R/W	Per-thread	Высокая	SM
Локальная	R/W	Per-thread	Низкая	DRAM
Shared	R/W	Per-block	Высокая	SM
Глобальная	R/W	Per-grid	Низкая	DRAM
Constant	R/O	Per-grid	Высокая	DRAM
Texture	R/O	Per-grid	Высокая	DRAM

Легенда:
-интерфейсы
доступа 

Разделяемая память в CUDA

- Самая быстрая память (кроме регистров) - это разделяемая
- Изначально было всего 16 Кбайт на мультипроцессор
- CC 3.x - shared + L1 cache = 64 Кбайта
 - 16:48, что 16, а что 48 вы определяете сами для каждого ядра
 - `cudaFuncSetCacheConfig(MyKernel, cudaFuncCachePreferShared)`
 - `cudaFuncSetCacheConfig(MyKernel, cudaFuncCachePreferEqual)`
 - `cudaFuncSetCacheConfig(MyKernel, cudaFuncCachePreferL1)`
- Режимы доступа - 32 и 64 битовые (`cudaDeviceSetSharedMemConfig`)
- CC 5.x 64 (или 96 для 5.2)
- CC 6.x 64 (или 96 для 6.1)
- CC 7.0 128 Кбайт (0, 8, 16, 32, 64 или 96)

Разделяемая память в CUDA

- Разбита на 32 независимых банка
- Доступ идет по варпам
- Если два и более варпа обращаются к разным 32-битовым словам разных банков - bank conflict
- Вся разделяемая память разбивается на банки следующим образом - подряд идущие слова попадают в подряд идущие банки
- 32 подряд идущих слова попадают в 32 банка
 - В этом (типичном) случае мы получаем бесконфликтный доступ
- Обращения к разным частям одного слова не дает конфликт
- Обращения к одному и тому же слову не дает конфликта
- Конфликт N-го порядка снижает скорость в N раз

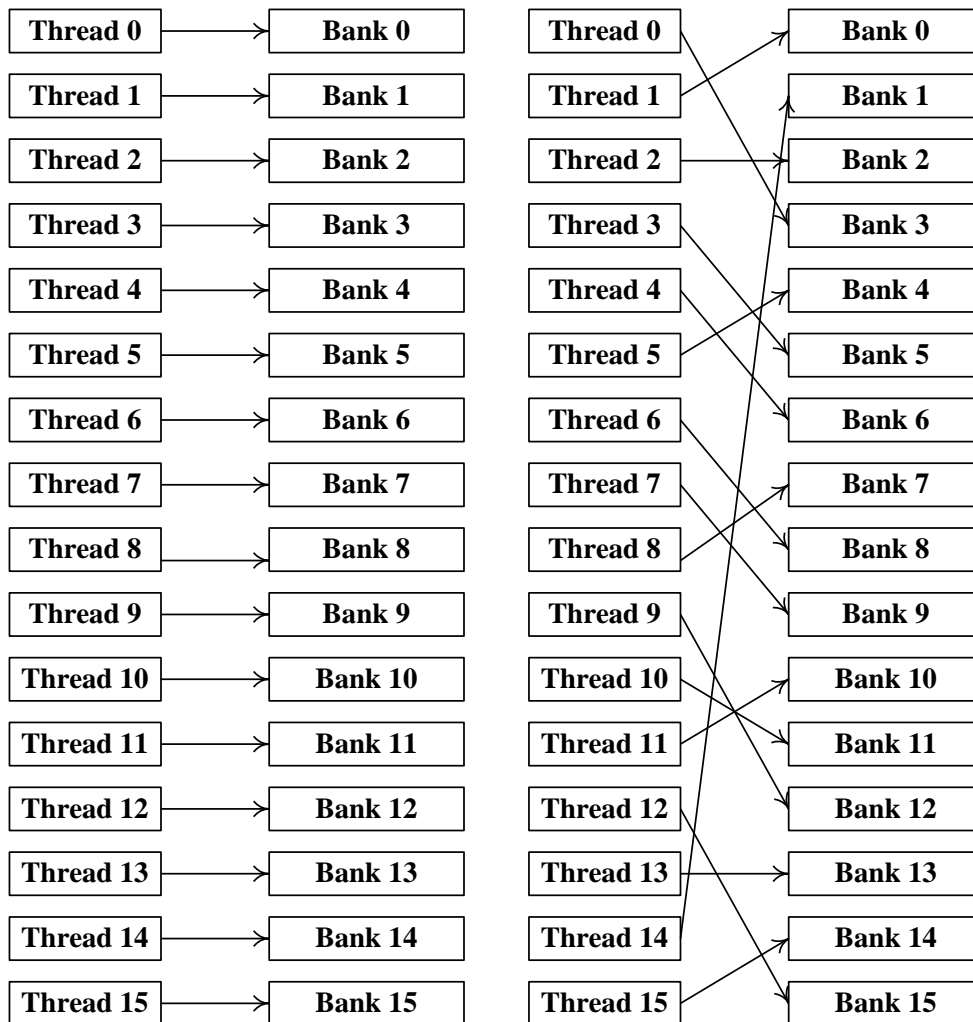
Типичное использование

- Загрузить необходимые данные в *shared*-память (из глобальной)
- `__syncthreads ()`
- Выполнить вычисления над загруженными данными
- `__syncthreads ()`
- Записать результат в глобальную память

Эффективная работа с shared-памятью

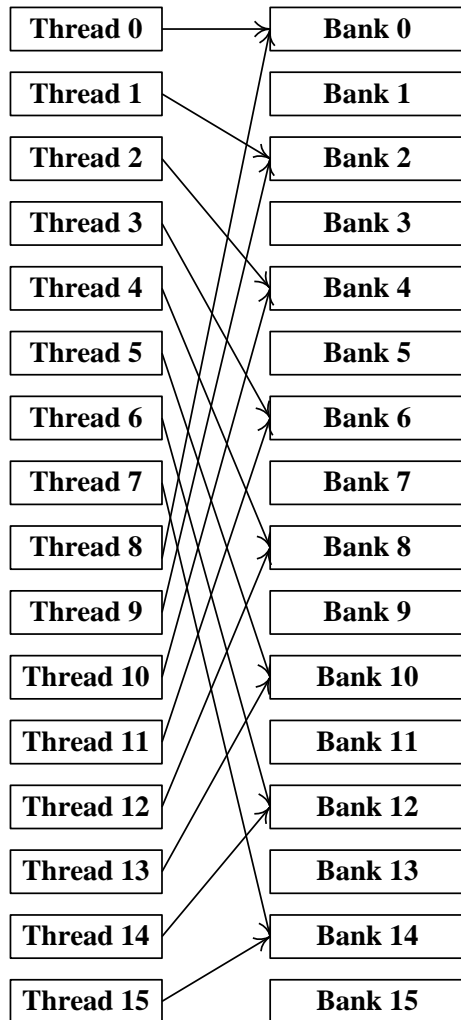
- Банки строятся из 32-битовых слов
- Подряд идущие 32-битовые слова попадают в подряд идущие банки
- *Bank conflict* - несколько нитей из одного *half-warp*'а обращаются к одному и тому же банку
- Конфликта не происходит если все 16 нитей обращаются к одному слову (*broadcast*)

Бесконфликтные паттерны доступа

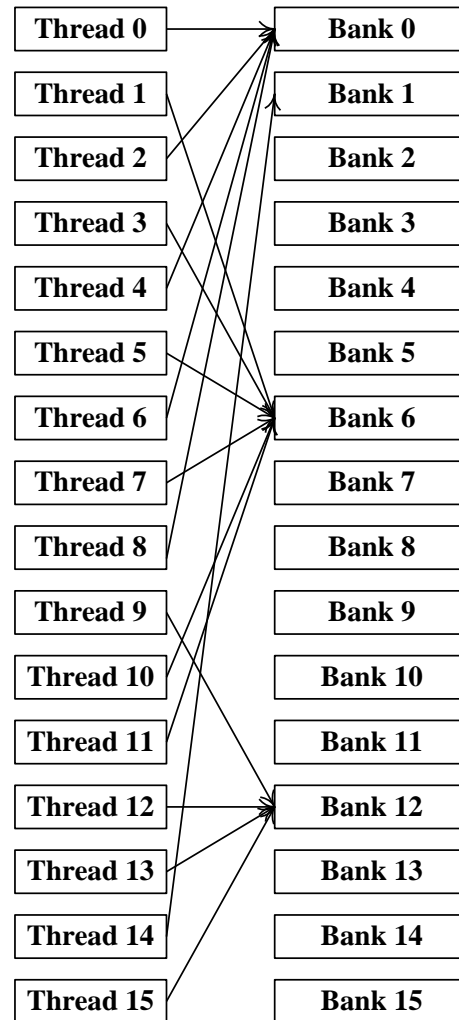


Паттерны с конфликтами банков

X2



X6



Эффективная работа с *shared*-памятью Tesla 20

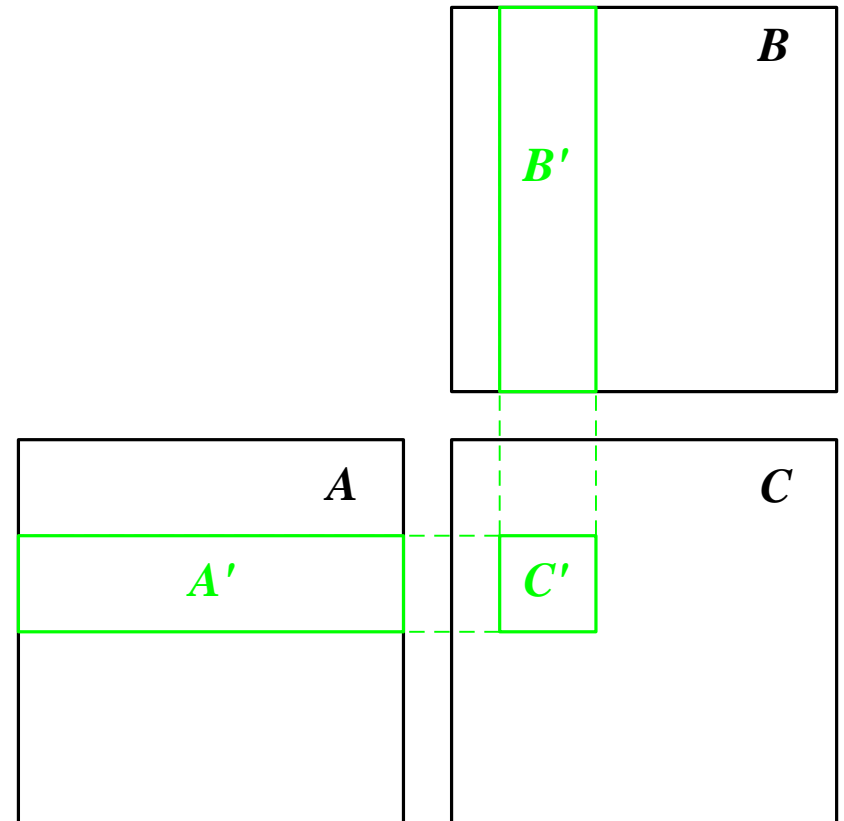
- Вся *shared*-память разбита на 32 банка
- Все нити варпа обращаются в память совместно.
- Каждый банк работает независимо от других
- Можно одновременно выполнить до 32 обращений к *shared*-памяти

Эффективная работа с shared-памятью Tesla 20

- Банк конфликты:
 - При обращении >1 нити варпа к разным 32битным словам из одного банка
- При обращении >1 нити варпа к разным байтам одного 32битного слова, конфликта нет
 - При чтении: операция broadcast
 - При записи: результат не определен

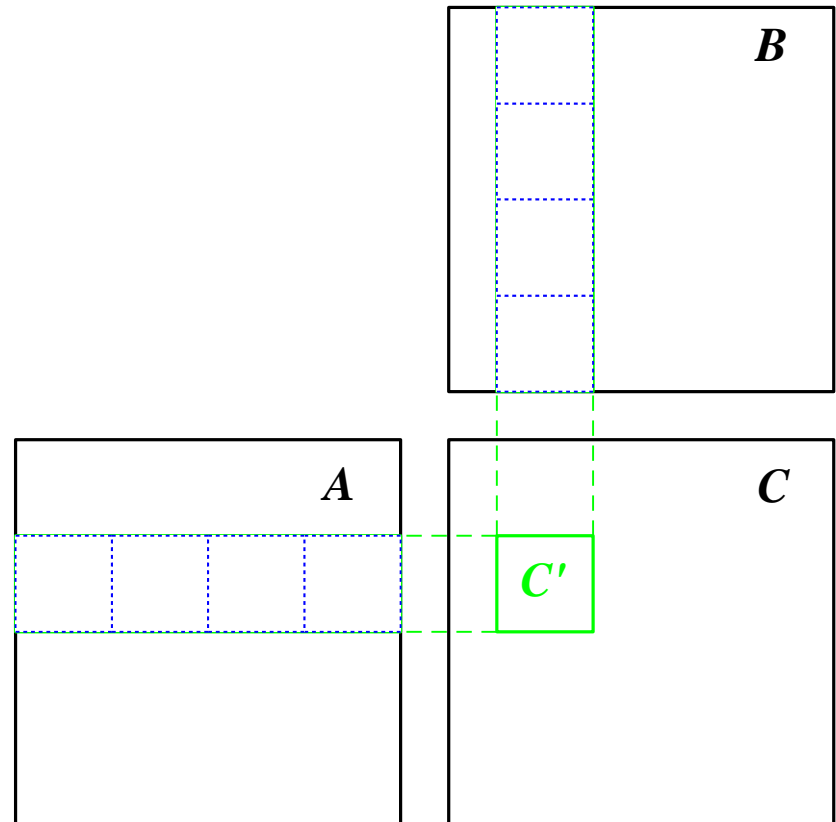
Умножение матриц (2)

- При вычислении C' постоянно используются одни и те же элементы из A и B
 - По много раз считываются из глобальной памяти
- Эти многократно используемые элементы формируют полосы в матрицах A и B
- Размер такой полосы $N*16$ и для реальных задач даже одна такая полоса не помещается в *shared*-память



Умножение матриц (2)

- Разбиваем каждую полосу на квадратные матрицы (16*16)
- Тогда требуемая подматрица произведения C' может быть представлена как сумма произведений таких матриц 16*16
- Для работы нужно только две матрицы 16*16 в *shared*-памяти



$$C' = A'_1 * B'_1 + \dots + A'_{N/16} * B'_{N/16}$$

Эффективная реализация

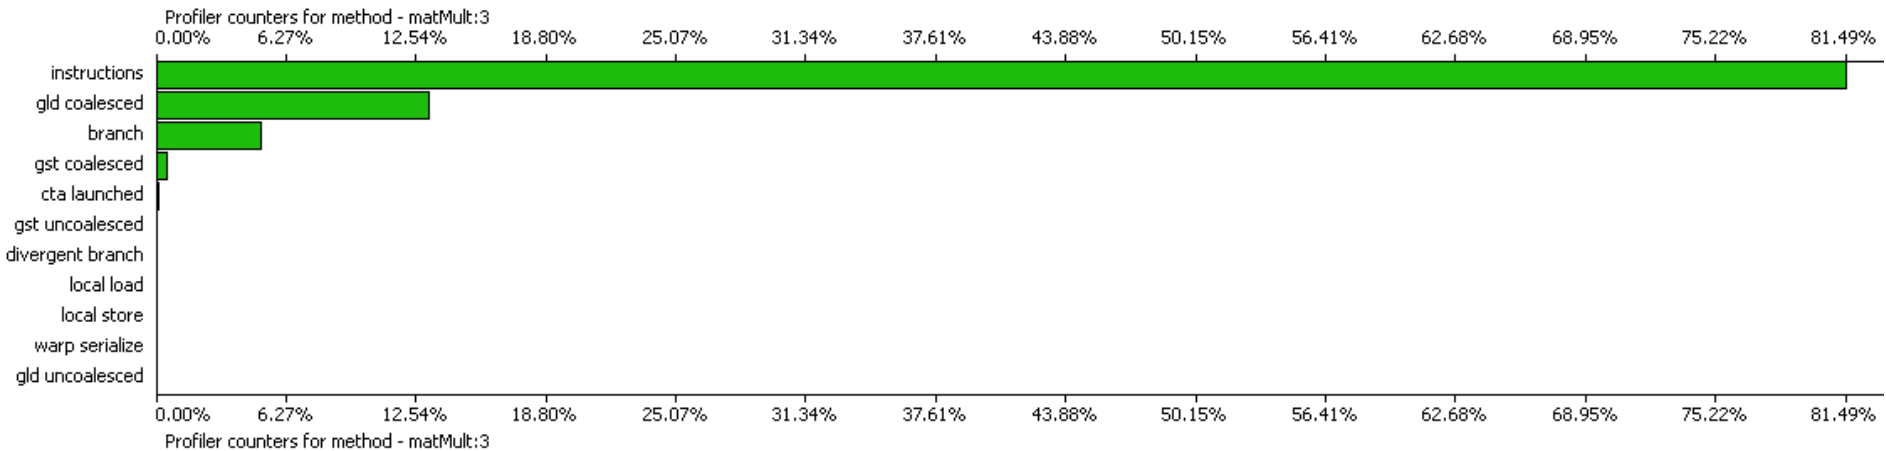
```
__global__ void matMult ( float * a, float * b, int n, float * c ) {  
    int bx      = blockIdx.x,  by = blockIdx.y;  
    int tx      = threadIdx.x, ty = threadIdx.y;  
    int aBegin = n * BLOCK_SIZE * by;  
    int aEnd   = aBegin + n - 1;  
    int bBegin = BLOCK_SIZE * bx;  
    int aStep  = BLOCK_SIZE, bStep  = BLOCK_SIZE * n;  
    float sum  = 0.0f;  
    for ( int ia = aBegin, ib = bBegin; ia <= aEnd; ia += aStep, ib += bStep ){  
        __shared__ float as [BLOCK_SIZE][BLOCK_SIZE];  
        __shared__ float bs [BLOCK_SIZE][BLOCK_SIZE];  
        as [ty][tx] = a [ia + n * ty + tx];  
        bs [ty][tx] = b [ib + n * ty + tx];  
        __syncthreads ();    // Synchronize to make sure the matrices are loaded  
        for ( int k = 0; k < BLOCK_SIZE; k++ )  
            sum += as [ty][k] * bs [k][tx];  
        __syncthreads ();    // Synchronize to make sure submatrices not needed  
    }  
    c [n * BLOCK_SIZE * by + BLOCK_SIZE * bx + n * ty + tx] = sum;  
}
```

Эффективная реализация

- На каждый элемент
 - $2*N$ арифметических операций
 - $2*N/16$ обращений к глобальной памяти
- Чтение обеих матриц происходит оптимальным образом
- Поскольку разные *warp*'ы могут выполнять разные команды нужна явная синхронизация всех нитей блока
- Быстродействие выросло более (12.80 vs 23.66 миллисекунд)
 - На первом поколении выигрыш был гораздо больше из-за отсутствия кэша

Эффективная реализация

Profiler Counter Plot

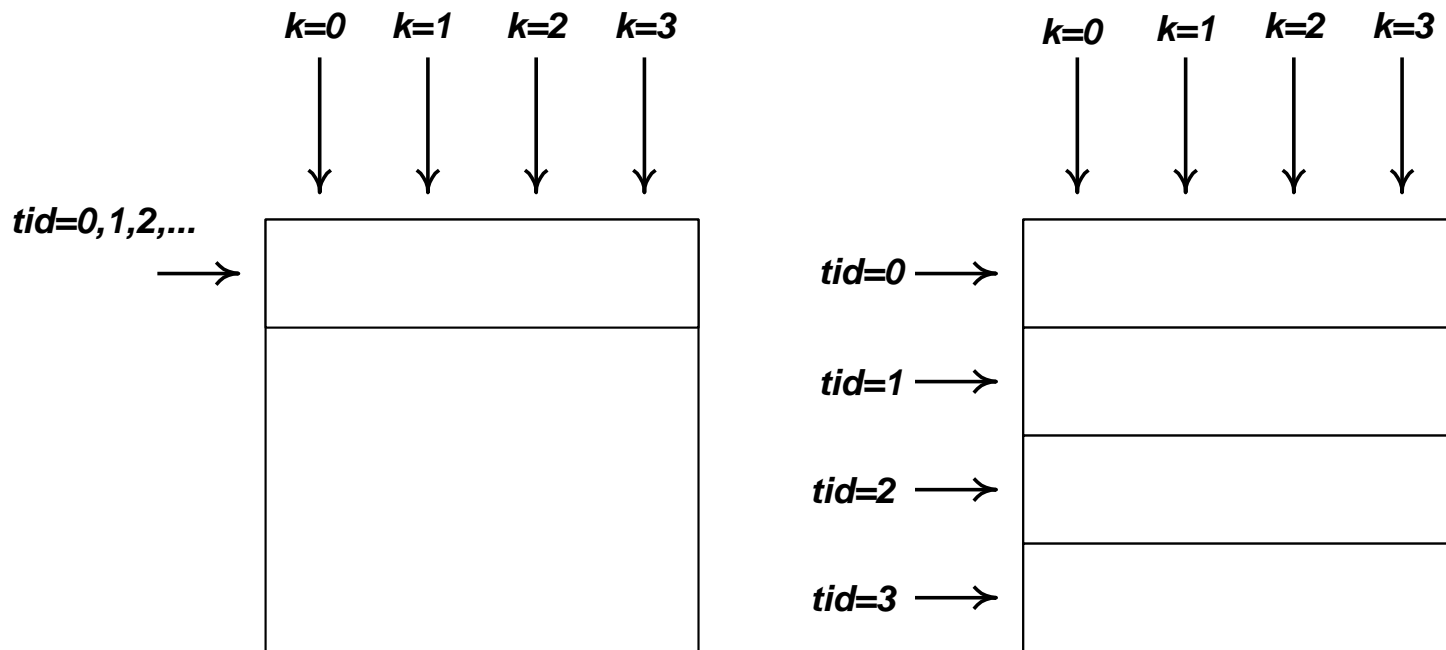


- Теперь основное время (81.49%) ушло на вычисления
- Чтение из памяти стало *coalesced* и заняло всего 12.5 %

Пример - матрицы 32*32

- Перемножение $A \cdot B^T$ двух матриц 32*32, расположенных в *shared*-памяти
 - Доступ к обеим матрицам идет по строкам
- Все элементы строки распределены равномерно по 32 банкам
- Каждый столбец целиком попадает в один банк
- Получаем конфликт 32-го порядка при чтении матрицы B

Пример - матрицы 32×32



Работа с разделяемой памятью

- Разделяемая память - ограниченный ресурс
 - Чем больше нужно блоку, тем меньше блоков на SM
- Если конфликт 2-4 порядка и нет очевидного фикса - ignore it
- Фактически это просто управляемый кэш
 - Загружаем блок часто используемых данных
 - `__syncthreads()`
 - Используем этот блок
 - `__syncthreads()`
 - Можем перейти к следующему блоку
 - Синхронизация обычно бывает необходима - разные варпы могут выполнять разные команды
 - Кто-то уже загрузил данные и хочет их использовать
 - Кто-то еще не начал загружать
 - Если данные общие - то возможна попытка использовать данные до загрузки

План

- Разделяемая память
- **Константная память**
- Базовые алгоритмы

КОНСТАНТНАЯ ПАМЯТЬ

```
__constant__ float constData [256];  
float          hostData  [256];
```

```
cudaMemcpyToSymbol ( constData, hostData, sizeof ( data ), 0,  
                    cudaMemcpyHostToDevice );
```

```
////////////////////////////////////
```

```
template <class T>  
cudaError_t cudaMemcpyToSymbol ( const T& symbol, const void * src,  
                                size_t count, size_t offset, enum cudaMemcpyKind kind );
```

```
template <class T>  
cudaError_t cudaMemcpyFromSymbol ( void * dst, const T& symbol,  
                                   size_t count, size_t offset, enum cudaMemcpyKind kind );
```

Работа с константной памятью

- Фактически это память для uniform-ов в графике
- Кэшируется
- Со стороны GPU возможно только чтение
- Со стороны CPU доступ через специальные функции
- Быстро работает, когда все нити варпа обращаются к одному и тому же слову
- Если паттерн обращения имеет регулярный характер и все нити варпа обращаются за раз к одному и тому же элементу, то имеет смысл использовать
- Если характер обращения нерегулярный (разные нити обращаются к случайным элементам), то возможно использование текстурной памяти будет более удачным вариантом

План

- Разделяемая память
- Константная память
- **Базовые алгоритмы**

Базовые алгоритмы на CUDA

- Reduce
- Scan (prefix sum)
- Histogram
- Sort
- Все это сейчас есть в thrust, цель - рассмотреть оптимизацию алгоритмов и типичные приемы
 - Сам thrust мы рассмотрим позже

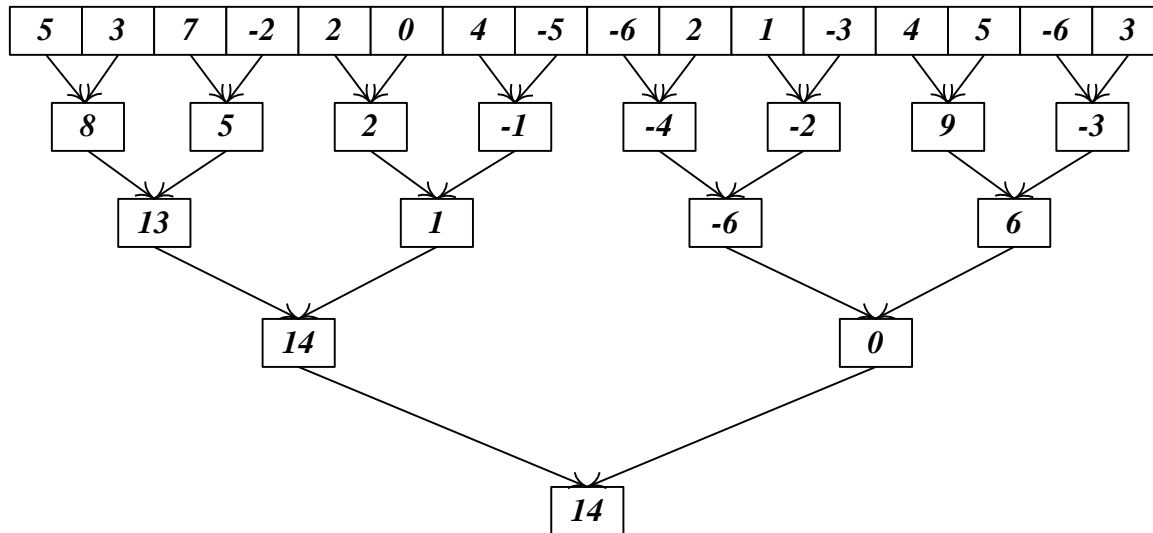
Параллельная редукция (reduce)

- Дано:
 - Массив элементов a_0, a_1, \dots, a_{n-1}
 - Бинарная ассоциативная операция '+'
- Необходимо найти $A = a_0 + a_1 + \dots + a_{n-1}$
- Лимитирующий фактор – доступ к памяти
- В качестве операции также может быть *min*, *max* и т.д.
- Легко реализовать последовательно за $O(N)$ шагов
 - Мы хотим гораздо быстрее
 - *Divide at impera*
 - сперва разбиваем на массив на части и каждый блок получает свою часть и независимо суммирует ее
 - Внутри блока выполняем иерархическое суммирование (в разделяемой памяти, так как нужно много обращений)

Реализация параллельной редукции

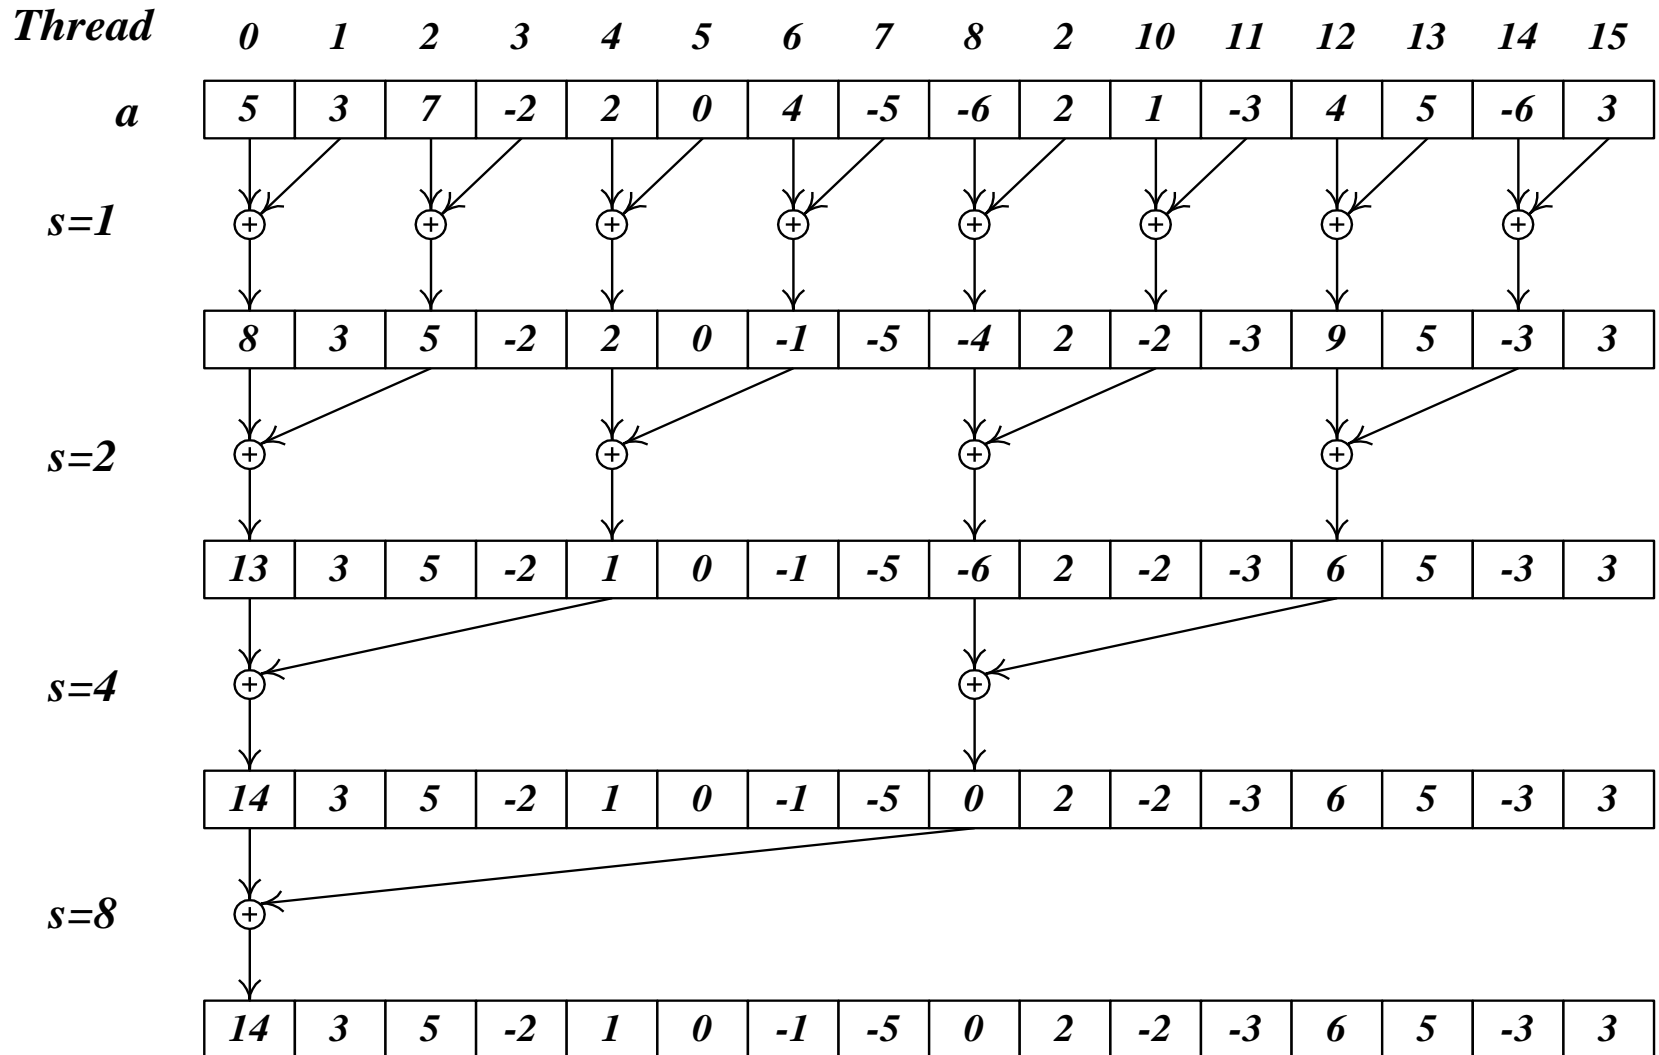
- Каждому блоку сопоставляем часть массива
- Блок
 - Копирует данные в *shared*-память
 - Иерархически суммирует данные в *shared*-памяти
 - Сохраняет результат в глобальной памяти

Иерархическое суммирование



- Позволяет проводить суммирование параллельно, используя много нитей
- Требуется $\log(N)$ шагов

Редукция, вариант 1

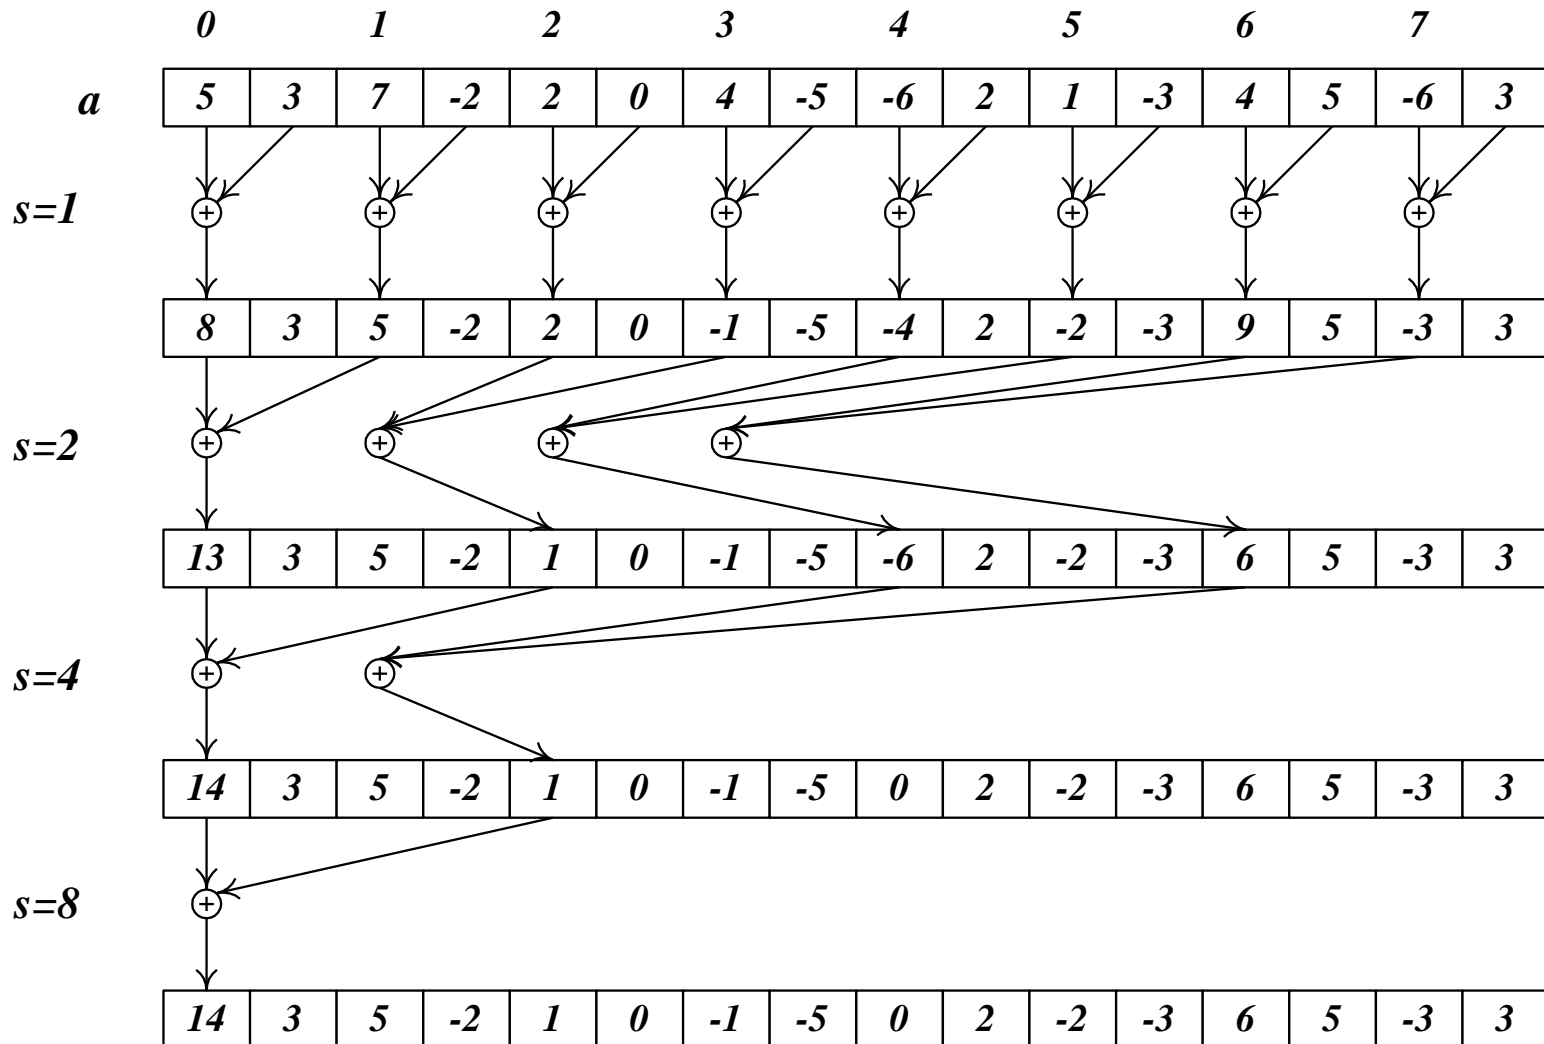


Редукция, вариант 1

```
__global__ void reduce1 ( int * inData, int * outData )
{
    __shared__ int data [BLOCK_SIZE];
    int tid = threadIdx.x;
    int i    = blockIdx.x * blockDim.x + threadIdx.x;

    data [tid] = inData [i];    // load into shared memory
    __syncthreads ();
    for ( int s = 1; s < blockDim.x; s *= 2 ) {
        if ( tid % (2*s) == 0 )    // heavy branching !!!
            data [tid] += data [tid + s];
        __syncthreads ();
    }
    if ( tid == 0 )    // write result of block reduction
        outData[blockIdx.x] = data [0];
}
```

Редукция, вариант 2



Редукция, вариант 2

```
__global__ void reduce2 ( int * inData, int * outData )
{
    __shared__ int data [BLOCK_SIZE];
    int tid = threadIdx.x;
    int i    = blockIdx.x * blockDim.x + threadIdx.x;
    data [tid] = inData [i];    // load into shared memory
    __syncthreads ();
    for ( int s = 1; s < blockDim.x; s <<= 1 )
    {
        int index = 2 * s * tid; // better replace with >>
        if ( index < blockDim.x )
            data [index] += data [index + s]; // bank conflict !!!
        __syncthreads ();
    }
    if ( tid == 0 )                // write result of block reduction
        outData [blockIdx.x] = data [0];
}
```

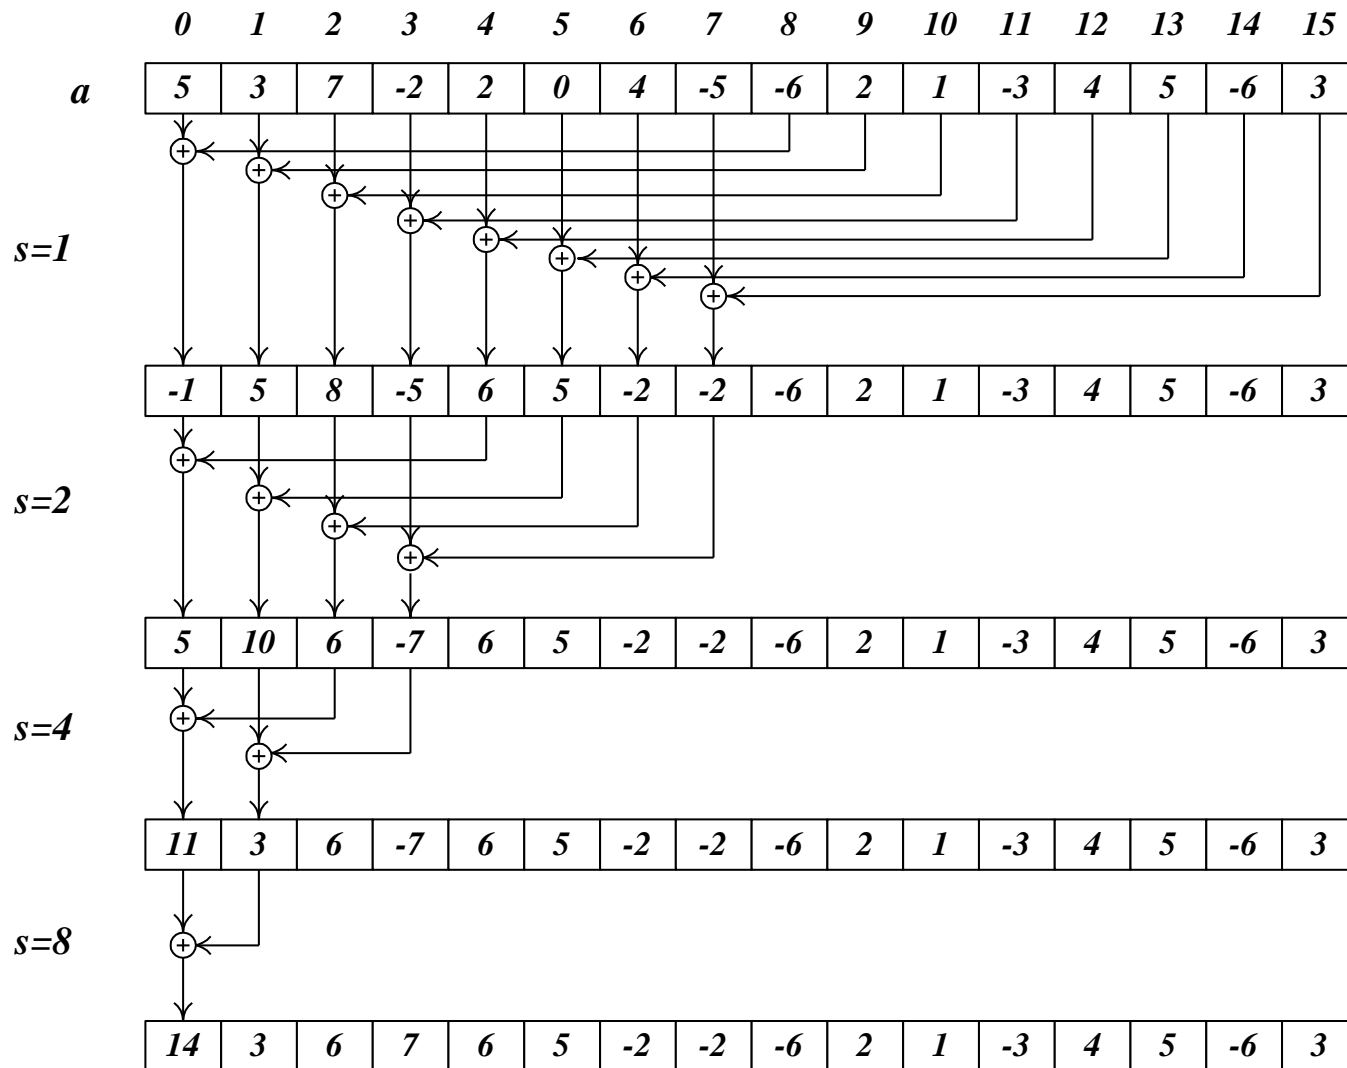
Редукция, вариант 2

- Практически полностью избавились от ветвления
- Однако получили много конфликтов по банкам
 - Для каждого следующего шага цикла степень конфликта удваивается

Редукция, вариант 3

- Изменим порядок суммирования
 - Раньше суммирование начиналось с соседних элементов и расстояние увеличивалось вдвое
 - Начнем суммирование с наиболее удаленных (на $dimBlock.x/2$) и расстояние будем уменьшать вдвое на каждой итерации цикла

Редукция, вариант 3



Редукция, вариант 3

```
__global__ void reduce3 ( int * inData, int * outData )
{
    __shared__ int data [BLOCK_SIZE];
    int tid = threadIdx.x;
    int i    = blockIdx.x * blockDim.x + threadIdx.x;

    data [tid] = inData [i];
    __syncthreads ();
    for ( int s = blockDim.x / 2; s > 0; s >>= 1 )
    {
        if ( tid < s )
            data [tid] += data [tid + s];
        __syncthreads ();
    }
    if ( tid == 0 )
        outData [blockIdx.x] = data [0];
}
```

Редукция, вариант 3

- Избавились от конфликтов по банкам
- Избавились от ветвления
- Но, на первой итерации половина нитей простаивает
 - Просто сделаем первое суммирование при загрузке

Редукция, вариант 4

```
__global__ void reduce4 ( int * inData, int * outData )
{
    __shared__ int data [BLOCK_SIZE];
    int tid = threadIdx.x;
    int i    = 2 * blockIdx.x * blockDim.x + threadIdx.x;

    data [tid] = inData [i] + inData [i+blockDim.x]; // sum
    __syncthreads ();
    for ( int s = blockDim.x / 2; s > 0; s >>= 1 )
    {
        if ( tid < s )
            data [tid] += data [tid + s];
        __syncthreads ();
    }
    if ( tid == 0 )
        outData [blockIdx.x] = data [0];
}
```

Редукция, вариант 5

- При $s \leq 32$ в каждом блоке останется всего по одному *warp*'у, поэтому
 - синхронизация уже не нужна
 - проверка $tid < s$ не нужна (она все равно ничего в этом случае не делает).
 - развернем цикл для $s \leq 32$

Редукция, вариант 5

...

```
for ( int s = blockDim.x / 2; s > 32; s >>= 1 )
{
    if ( tid < s )
        data [tid] += data [tid + s];
    __syncthreads ();
}

if ( tid < 32 ) // unroll last iterations
{
    data [tid] += data [tid + 32];
    data [tid] += data [tid + 16];
    data [tid] += data [tid + 8];
    data [tid] += data [tid + 4];
    data [tid] += data [tid + 2];
    data [tid] += data [tid + 1];
}
```

Редукция, вариант 5 (fixed)

```
for ( int s = blockDim.x / 2; s > 32; s >>= 1 )
{
    if ( tid < s )
        data [tid] += data [tid + s];
    __syncthreads ();
}

if ( tid < 32 ) // unroll last iterations
{
    // compile can be "oversmart here"
    volatile float * smem = data;

    smem [tid] += smem [tid + 32];
    smem [tid] += smem [tid + 16];
    smem [tid] += smem [tid + 8];
    smem [tid] += smem [tid + 4];
    smem [tid] += smem [tid + 2];
    smem [tid] += smem [tid + 1];
}
```

Редукция, быстродействие

Вариант алгоритма	Время выполнения (миллисекунды)
reduction1	19.09
reduction2	11.91
reduction3	10.62
reduction4	9.10
reduction5	8.67



Ресурсы нашего курса

- [Steps3d.Narod.Ru](#)
- [Google Site CUDA.CS.MSU.SU](#)
- [Google Group CUDA.CS.MSU.SU](#)
- [Google Mail CS.MSU.SU](#)
- [Google SVN](#)
- [Tesla.Parallel.Ru](#)
- [Twirpx.Com](#)
- [Nvidia.Ru](#)