

Иерархия памяти в CUDA. Глобальная память.

Лекторы:

[Боресков А.В. \(ВМК МГУ\) \(steps3d@narod.ru\)](#)

План

- CUDA Compute Capability
- Типы памяти в CUDA
- Основы CUDA C API

План

- CUDA Compute Capability
 - Получение информации о GPU
- Типы памяти
- Основы CUDA C API

CUDA Compute Capability

- Возможности GPU обозначаются при помощи *Compute Capability*, например 1.1
- Старшая цифра соответствует архитектуре
- Младшая – небольшим архитектурным изменениям
- Можно получить из полей *major* и *minor* структуры ***cudaDeviceProp***



CUDA Compute Capability

GPU Family	Compute Capability Major
Tesla (GeForce 8800 GTX)	1
Fermi (GeForce 480 GTX)	2
Kepler (GeForce 660)	3
Maxwell (GeForce 960)	5
Pascal	6

Определяется архитектурой GPU, не имеет ничего общего с версией CUDA

CUDA 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
 - В 2.0 добавлены управление кэшем и др. операции
- Сегодня Compute Caps:
 - Влияет на правила работы с глобальной памятью
- На курсе рассмотрим 2.0 - 5.2

Получение информации о GPU

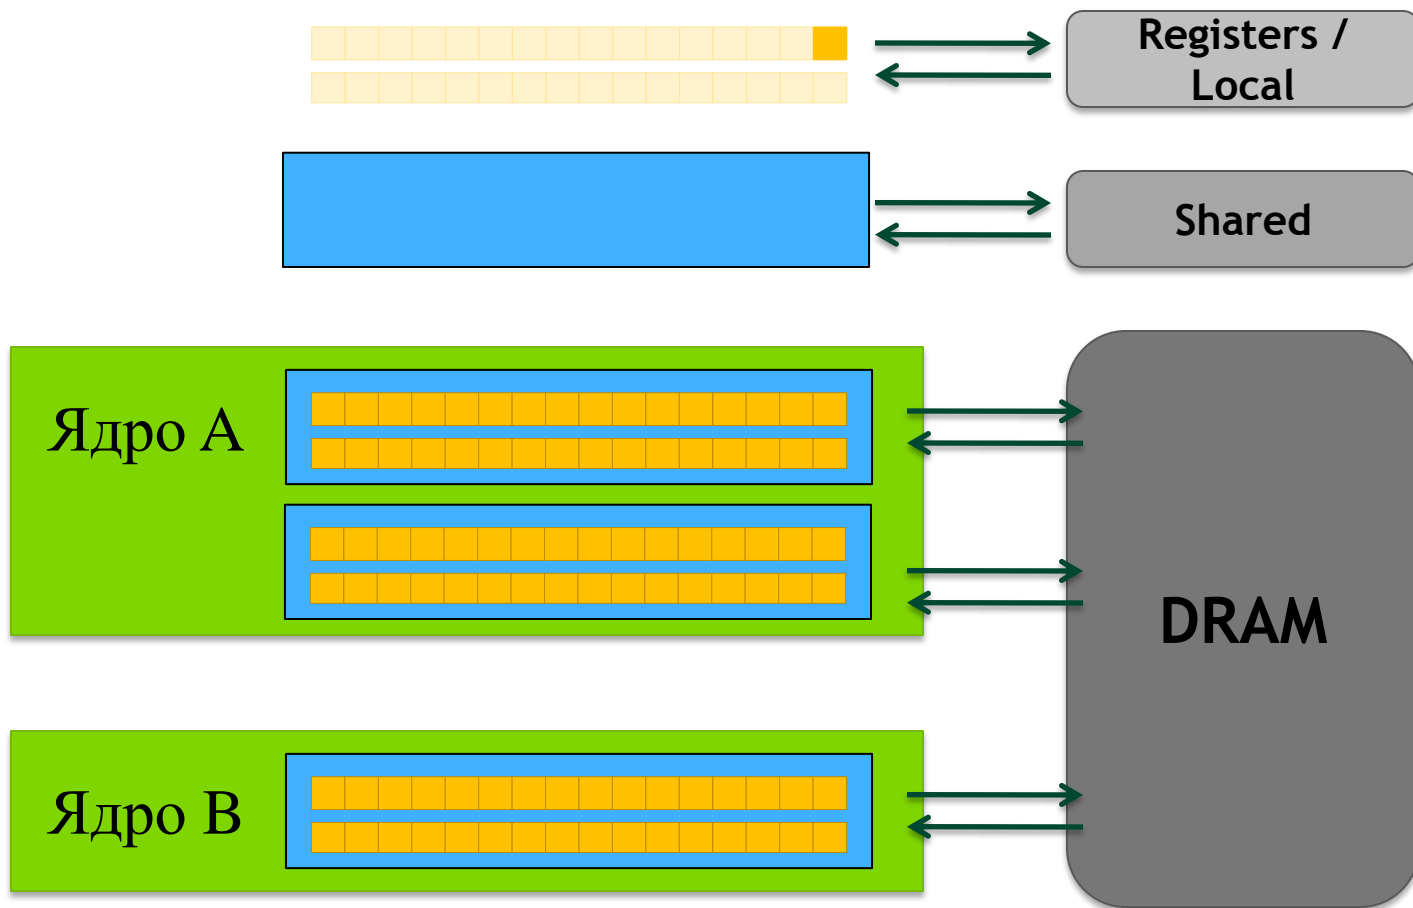
```
int main ( int argc, char * argv [] )
{
    int          deviceCount;
    cudaDeviceProp devProp;

    cudaGetDeviceCount ( &deviceCount );
    printf              ( "Found %d devices\n", deviceCount );
    for ( int device = 0; device < deviceCount; device++ )
    {
        cudaGetDeviceProperties ( &devProp, device );
        printf ( "Device %d\n", device );
        printf ( "Compute capability      : %d.%d\n", devProp.major, devProp.minor );
        printf ( "Name                    : %s\n", devProp.name );
        printf ( "Total Global Memory      : %d\n", devProp.totalGlobalMem );
        printf ( "Shared memory per block: %d\n", devProp.sharedMemPerBlock );
        printf ( "Registers per block      : %d\n", devProp.regsPerBlock );
        printf ( "Warp size                 : %d\n", devProp.warpSize );
        printf ( "Max threads per block   : %d\n", devProp.maxThreadsPerBlock );
        printf ( "Total constant memory   : %d\n", devProp.totalConstMem );
    }
    return 0;
}
```

План


- CUDA Compute Capability
- **Типы памяти в CUDA**
 - Глобальная
- Основы CUDA C API

Типы памяти в CUDA



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 

Типы памяти в CUDA

- Самая быстрая – *shared* (on-chip) и регистры
- Самая медленная – глобальная (DRAM)
- Для ряда случаев можно использовать кэшируемую константную и текстурную память
- Доступ к памяти в CUDA
 - Целиком для warp'а в CC 2.x и выше

План

- CUDA Compute Capability
- Типы памяти в CUDA
- Основы CUDA C API
 - Выделение глобальной памяти
 - Пример: умножение матриц
 - Coalescing
 - Pitch linear
 - Pinned
 - Работа с глобальной памятью

Основы CUDA C API

- Не требуют явной инициализации
- Все функции возвращают `cudaError_t`
 - `cudaSuccess` в случае успеха
- Начинаются с `cuda`
- Многие функции API асинхронны:
 - Запуск ядра
 - Копирование функциями `*Async`
 - Копирование `device <-> device`
 - Инициализация памяти

ОСНОВЫ CUDA C API

```
// Получение информации о существующих в системе GPU
cudaError_t cudaGetDeviceCount    ( int * );
cudaError_t cudaGetDevicePropertis ( cudaDeviceProp * props, int deviceNo );
// Получение информации об ошибках
char      * cudaGetErrorString    ( cudaError_t );
cudaError_t cudaGetLastError      ( );
// Синхронизация исполнения в текущем CPU потоке и в CUDA stream'e
cudaError_t cudaDeviceSynchronize ( );
cudaError_t cudaStreamSynchronize ( );
// Средства управления событиями
cudaError_t cudaEventCreate       ( cudaEvent_t * );
cudaError_t cudaEventRecord       ( cudaEvent_t *, cudaStream_t );
cudaError_t cudaEventQuery        ( cudaEvent_t );
cudaError_t cudaEventSynchronize ( cudaEvent_t );
cudaError_t cudaEventElapsedTime  ( float * time, cudaEvent_t st, cudaEvent_t sp );
cudaError_t cudaEventDestroy      ( cudaEvent_t );
```

Работа с глобальной памятью в CUDA

- Функции для работы с глобальной памятью

```
cudaError_t cudaMalloc      ( void ** devPtr, size_t size );
cudaError_t cudaMallocPitch ( void ** devPtr, size_t * pitch,
                               size_t width, size_t height );
cudaError_t cudaFree       ( void * devPtr );
cudaError_t cudaMemcpy     ( void * dst, const void * src, size_t count,
                               enum cudaMemcpyKind kind );
cudaError_t cudaMemcpyAsync ( void * dst, const void * src,
                               size_t count,
                               enum cudaMemcpyKind kind,
                               cudaStream_t stream );
cudaError_t cudaMemset     ( void * dst, int value, size_t count );
```

Работа с глобальной памятью в CUDA

- Пример работы с глобальной памятью

```
float * devPtr;           // pointer to device memory
                          // allocate device memory
cudaMalloc ( (void **) &devPtr, 256*sizeof ( float ) );

                          // copy data from host to device memory
cudaMemcpy ( devPtr, hostPtr, 256*sizeof ( float ), cudaMemcpyHostToDevice );

                          // process data ...

                          // copy results from device to host
cudaMemcpy ( hostPtr, devPtr, 256*sizeof( float ), cudaMemcpyDeviceToHost );

                          // free device memory
cudaFree   ( devPtr );
```


Пример: 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
           // copy from CPU to DRAM
cudaMemcpy  ( adev, a, numBytes, cudaMemcpyHostToDevice );
cudaMemcpy  ( bdev, b, numBytes, cudaMemcpyHostToDevice );
matMult<<<blocks, threads>>> ( adev, bdev, N, cdev );
cudaThreadSynchronize();
cudaMemcpy  ( c, cdev, numBytes, cudaMemcpyDeviceToHost );
           // free GPU memory
cudaFree    ( adev );
cudaFree    ( bdev );
cudaFree    ( cdev );
```

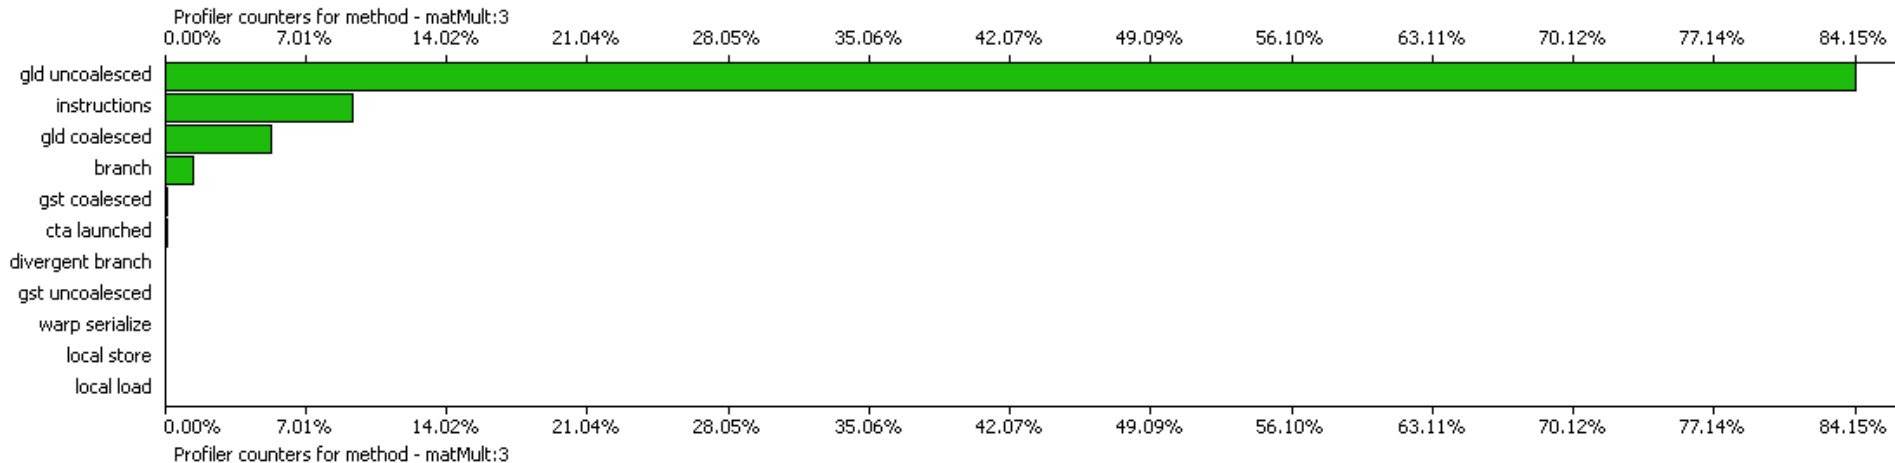
Простейшая реализация.

- На каждый элемент
 - $2 * N$ арифметических операций
 - $2 * N$ обращений к глобальной памяти
- *Узкое место – доступ в память*



Используем CUDA Profiler

Profiler Counter Plot



- Основное время (84.15%) ушло на чтение из глобальной памяти
- Вычисления заняли всего около 10%



Работа с памятью в CUDA

- Основа оптимизации – правильная работа с памятью:
 - Максимальное использование *shared*-памяти
 - Лекция 4
 - Использование специальных шаблонов доступа к памяти
 - Coalescing



Оптимизация работы с глобальной памятью.

- Команды поддерживают чтение за раз 1/2/4/8/16-байтовых слов
- 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**
- **Вся структура может прочитана за одну команду**



Объединение запросов к глобальной памяти.

- GPU умеет объединять ряд запросов к глобальной памяти в транзакцию одного сегмента
- Длина сегмента должна быть 32/64/128 байт
- Сегмент должен быть выровнен по своему размеру





Объединение (coalescing) 2.x

- На мультипроцессоре есть L1 кэш
 - Физически там, где разделяемая память
- Мультипроцессоры имеют общий L2 кэш
- Флаги компиляции
 - Использовать L1 и L2 :`-Xptxas -dlcm=ca`
 - Использовать L2 :`-Xptxas -dlcm=cg`
- Кэш линия 128В
- Объединение происходит на уровне варпов





Объединение (coalescing) 3.x

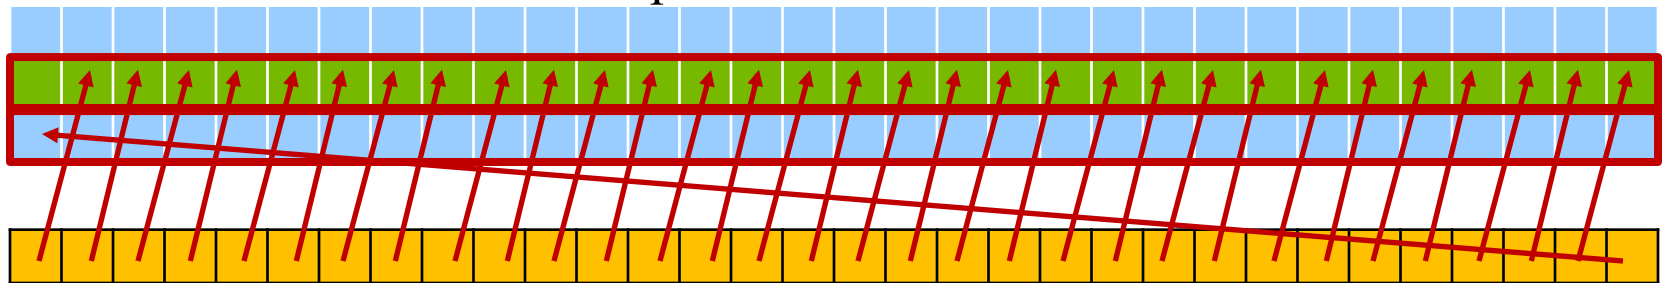
- Обычно кэшируется только в L2 также как и для 2.x
- Объединение происходит на уровне варпов
- Read-only данные могут также кэшироваться КОНСТАНТНЫМ КЭШЕМ



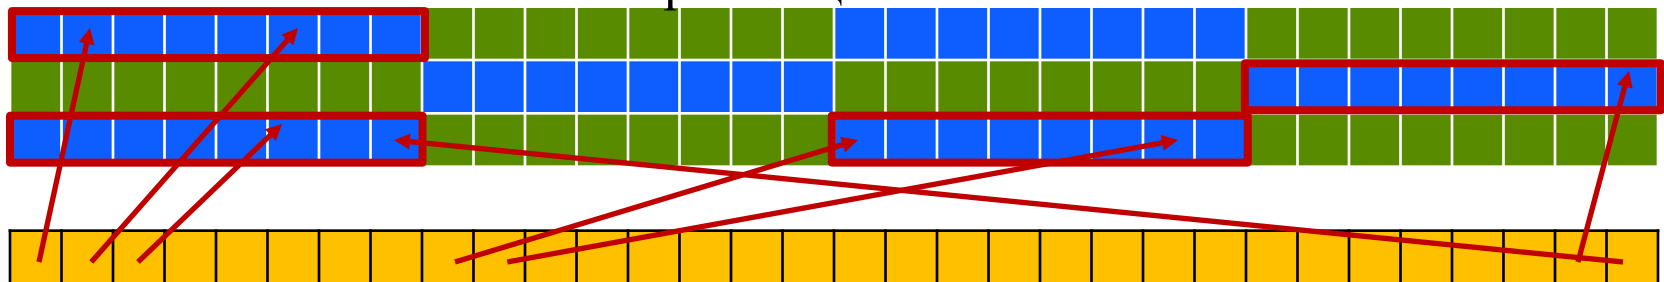


Объединение (coalescing) 2.x






- Если L1 кэш включен: всегда 128В сегменты
2 транзакция по 128В



- Если L2 кэш выключен: всегда 32В сегменты
4 транзакция по 32В



Легенда:

- нить 
- 128В сегмент  
- 32В сегменты  



Объединение (coalescing)

- Увеличения скорости работы с памятью на порядок
- Лучше использовать не массив структур, а набор массивов отдельных компонент
 - Проще гарантировать условия выполнения *coalescing'a*



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;

float * ax, * ay, * az;

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

Не можем использовать *coalescing* при чтении данных

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



Pitch linear

- Для работы с 2D данными
 - `cudaMallocPitch(&ptr, &p, w, h)`
 - В `p` возвращает ширину выделенной памяти в байтах
 - $p \geq w * \text{sizeof}()$
- Для 1.x `p` кратно 64
- Для 2.x `p` кратно 128



cudaMalloc3D

- Для работы с 3D данными

- `cudaMalloc3D(&ptr, extent)`

```
cudaExtent extent;
```

```
cudaPitchedPtr ptr;
```

```
extent = make_cudaExtent(width, height, depth);
```

```
cudaMalloc3D (&ptr, extent);
```


```
// Access: ptr.pitch, ptr.ptr
```





Pinned память

X2 производительности

- Для ускорения передачи по PCI-E
 - `cudaMallocHost(&hostPtr, size)`
 - `cudaHostAlloc(&hostPtr, size, flag)`
 - `cudaHostFree(hostPtr)`
 - Флаги при выделении памяти
 - **DEFAULT** : эквивалентно `cudaMallocHost`
 - **PORTABLE** : для работы со множеством GPU из одного потока
 - **MAPPED** : для систем с общей памятью
 - **WRITE-COMBINED** : память не кэшируется на CPU, передача по PCI-E быстрее, чтение на CPU медленное
- 

Работа с глобальной памятью

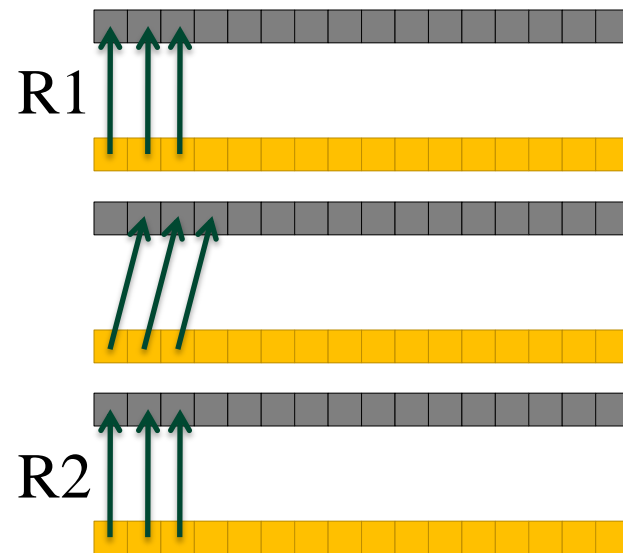
- `threadfence()` - дождаться, когда для всех активных блоков, текущие обращения в память завершатся
 - Не является средством синхронизации блоков
 - Блоки могут быть в разных состояниях
- `threadfence_block()` - дождаться пока все операции записи в память завершатся для вызвавшего блока



Работа с глобальной памятью



- **volatile** указывает, что переменная может быть изменена извне.

```
__global__ foo(float *p)
{
    float R1 = p[threadIdx.x];
    p[threadIdx.x + 1] = 0.0f;
    float R2 = p[threadIdx.x];
}
```



- В примере $R1 == R2$
- Слишком умный компилятор ☹️

Легенда:

-нить 
-float *p 



Работа с глобальной памятью (2.x)

- Глобальный и локальный контроль за кэшем
 - `cudaThreadSetCacheConfig()`
 - `cudaFuncSetCacheConfig`
- `cudaFuncCachePreferNone`: значение по умолчанию
- `cudaFuncCachePreferShared`: бОльший объем разделяемой памяти предпочтительней
- `cudaFuncCachePreferL1`: бОльший объем L1 кэша предпочтительней



Работа с управляемой памятью (32- и 64-битная ОС)

- Единое адресное пространство для CPU и GPU
- Выделение через `cudaMallocManaged`
- Может обращаться и CPU и GPU
- Во время активности GPU CPU не может обращаться
- Прозрачно обрабатывает внутренние ссылки
- `cudaMemcpy` определяет местоположение по последнему аргументу



Работа с управляемой памятью (32- и 64-бититная ОС)

```
__global__ void AplusB(int *ret, int a, int b)
{
    ret[threadIdx.x] = a + b + threadIdx.x;
}

int main()
{
    int *ret;

    cudaMallocManaged(&ret, 1000 * sizeof(int));

    AplusB<<< 1, 1000 >>>(ret, 10, 100);
    cudaDeviceSynchronize();
    for(int i=0; i<1000; i++)
        printf("%d: A+B = %d\n", i, ret[i]);
    cudaFree(ret);
    return 0;
}
```



Работа с управляемой памятью (32- и 64-бититная ОС)

```
__device__ __managed__ int ret[1000];

__global__ void AplusB(int a, int b)
{
    ret[threadIdx.x] = a + b + threadIdx.x;
}

int main()
{
    AplusB<<< 1, 1000 >>>(10, 100);

    cudaDeviceSynchronize();

    for(int i=0; i<1000; i++)
        printf("%d: A+B = %d\n", i, ret[i]);

    return 0;
}
```



Работа с управляемой памятью (32- и 64-бититная ОС)

```
__device__ __managed__ int x, y=2;

__global__ void kernel()
{
    x = 10;
}

int main1()
{
    kernel<<< 1, 1 >>>();
    y = 20; // ERROR: CPU access concurrent with GPU
    cudaDeviceSynchronize();

    kernel<<< 1, 1 >>>();
    cudaDeviceSynchronize();
    y = 20; // Success - GPU is idle so access is OK
    return 0;
}
```




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](#)

Дополнительные слайды

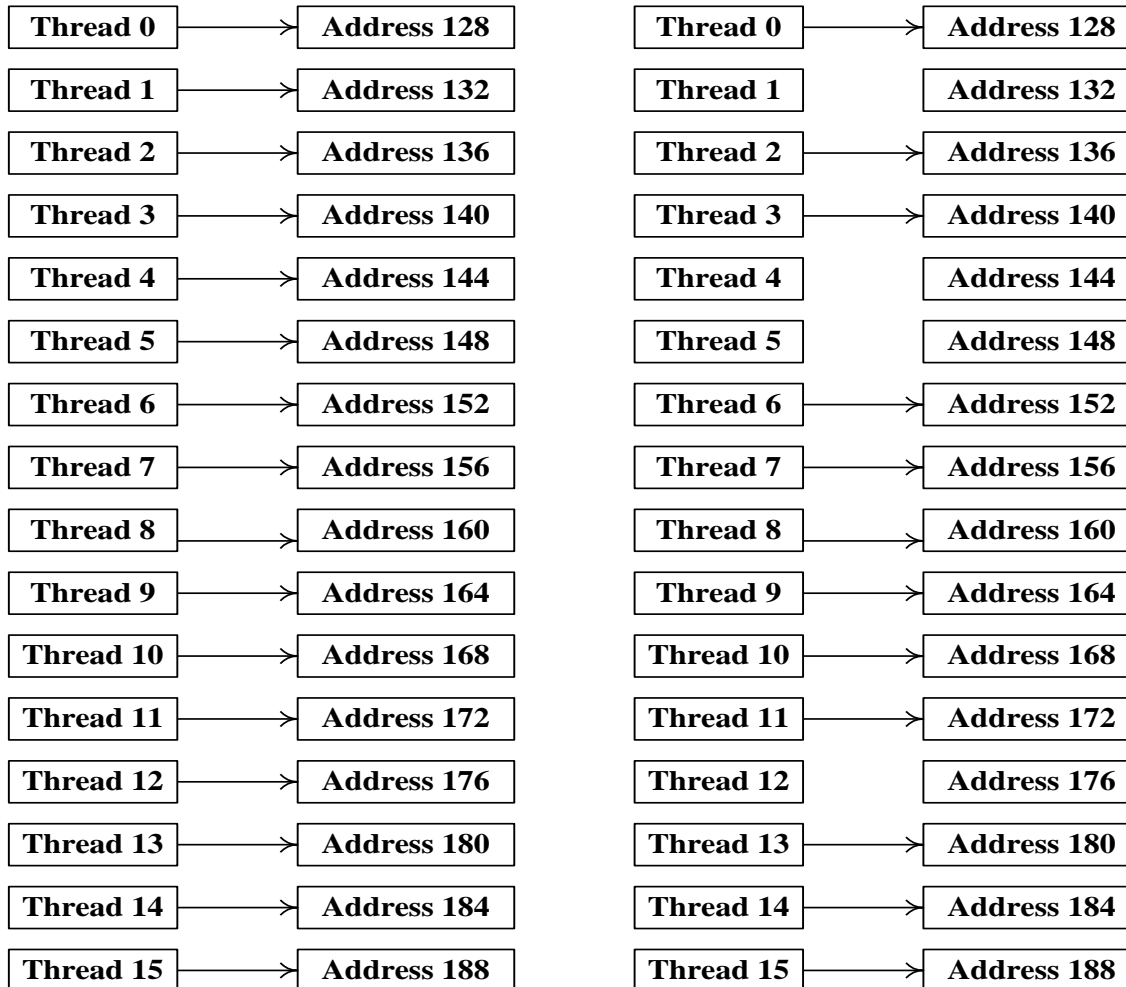
- Объединение (coalescing) для GPU с CC 1.0/1.1

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



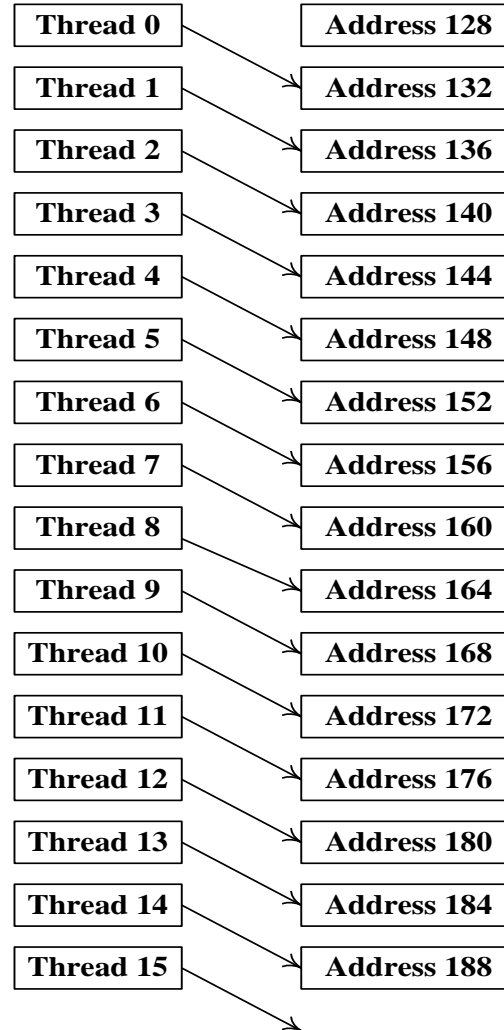
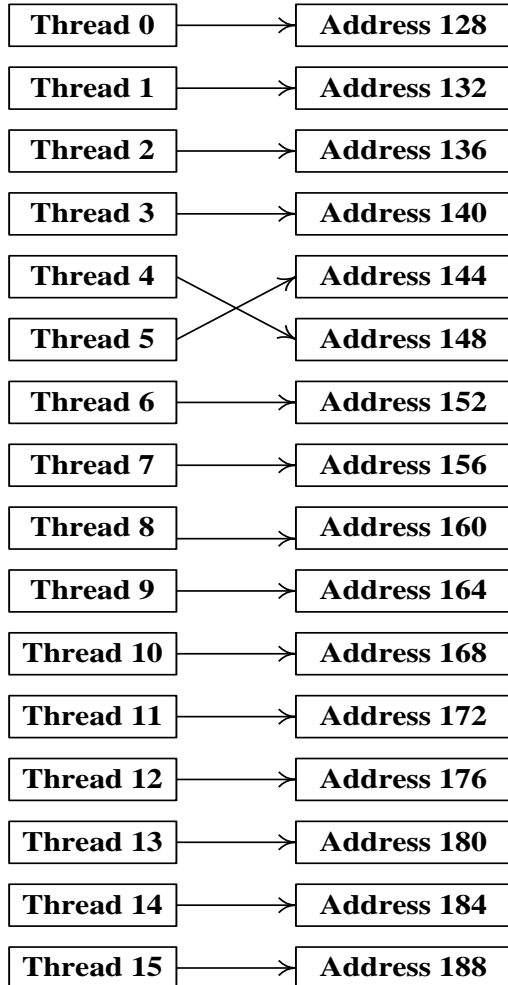
Объединение (coalescing) для GPU с CC 1.0/1.1



Coalescing



Объединение (coalescing) для GPU с CC 1.0/1.1



No Coalescing



Объединение (coalescing)

- Если хотя бы одно условие не выполнено
 - 1.0/1.1 – 16 отдельных транзакций
- Для 1.0/1.1 порядок в котором нити обращаются к словам внутри блока имеет значения (в отличии от 1.1/1.3)



Intelligence для CUDA

- Start → Run → Regedit
- HKEY_LOCAL_MACHINE
 - Software
 - Microsoft
 - Visual Studio
 - 9.0 MSVS 2008 или
 - 8.0 MSVS 2005
 - Languages
 - Language Services
 - C/C++
 - NCB Default C/C++ Extensions
 - Добавить .cu;
- Перезапустить VS