Атомарные операции. Потоки. Параллельное копирование и выполнение ядра. Интероперабельность с OpenGL Библиотека thrust

Лекторы:

Боресков А.В. (ВМиК МГУ)

План

- Атомарные операции
- Потоки, их использование
- Реализация одновременного копирования данных и выполнения ядра
- Интероперабельность с OpenGL
- thrust

Атомарность операции

Рассмотрим традиционную операцию инкремента

```
x++
```

На практике она переводится в следующие операции

```
r = x; load into register
inc r; increment value in register
x = r; store incremented value
```

Атомарность операции

Теперь рассмотрим ситуацию когда две нити пытаются одновременно выполнить операцию инкремента над одной и той же переменной

```
; Thread 1          ; Thread 2
r1 = x;             r2 = x;
inc r1;             inc r2;
x = r1;             x = r2;
```

Тут уже возможны варианты наложения операций друг на друга

Атомарность операции. Конфликт

```
; Thread 1
; x = 0
r1 = x; r1 = 0
inc r1; r1 = 1
x = r1; x = 1
```

```
; Thread 2
; x = 0
r2 = x; r2 = 0
inc r2; r2 = 1
x = r2; x = 1
```

Операция прошла некорректно - значение переменной было инкрементировано всего один раз

Атомарные операции

CUDA поддерживает специальные операции, гарантирующие атомарность

- Они выполняются медленнее
- CC 1.1 поддерживает целочисленные атомарные операции в глобальной памяти
- CC 1.1 поддерживает целочисленные атомарные операции в разделяемой памяти

Атомарные операции

- Над 64-битовыми целыми с CC 2.0
- atomicAdd для float – CC 2.0

Атомарные операции

```
  // возвращают старое значение
int atomicAnd ( int * addr, int value );
uint atomicAnd ( uint * addr, uint value );
unsigned long long atomicAdd ( unsigned long long * addr, unsigned long long value );
float atomicAdd ( float * addr, float value );

int  atomicSub ( int * address, int value );
uint atomicSub ( uint * address, uint value );

  // записывает значение по адресу, возвращает старое значение
int atomicExch ( int * addr, int value );
uint atomicExch ( uint * addr, uint value );
unsigned long long atomicExch ( unsigned long long * addr, unsigned long long value );

  // записывает результат операции, возвращает старое значение
int  atomicMin ( int  * addr, int value );
uint atomicMin ( uint * addr, uint value );
int  atomicMax ( int  * addr, int value );
uint atomicMax ( uint * addr, uint value );

uint atomicInc ( uint * addr, uint value );
uint atomicDec ( uint * addr, uint value );

int  atomicAnd ( int  * addr, int  value );
uint atomicAnd ( uint * addr, uint value );
int  atomicOr  ( int  * addr, int  value );
uint atomicOr  ( uint * addr, uint value );
int  atomicXor ( int  * addr, int  value );
uint atomicXor ( uint * addr, uint value );
```

Потоки (Streams)

- GPU умеют выполнять многие вещи параллельно
  - Выполнение ядер и копирование памяти между CPU и GPU может выполняться параллельно
  - GPU с CC 2.x умеют выполнять до 16 ядер одновременно
- Для использования этой параллельности вводятся потоки
  - Поток (stream) в CUDA представляет собой очередь запросов, которые должны быть выполнены а заданном порядке
    - Внутри потока все выполняется последовательно
  - По умолчанию используется всегда существующий поток 0
    - Если вы не задали явно поток – это поток 0
  - Однако можно создать несколько потоков, тогда операции из разных потоков могут выполняться параллельно
    - Но последовательно внутри каждого потока

Потоки

- Поток (stream) в CUDA представляет собой очередь запросов, которые должны быть выполнены а заданном порядке
- По умолчанию используется всегда существующий поток 0
- Однако можно создать несколько потоков, тогда операции из разных потоков могут выполняться параллельно

Потоки

- Создание и уничтожение потоков
  - Поток имеет тип cudaStream_t
  - Поток должен явно создаваться и уничтожаться
    - Кроме потока 0 - он всегда существует и его не надо уничтожать

```
cudaStream_t stream;
cudaStreamCreate  ( &stream );
cudaStreamDestroy ( &stream );
```

Потоки (пример)

- Рассмотрим следующую задачу – есть операция, берущая на вход два массива и по каждой паре элементов из соответствующих массивов строящая элемент третьего (выходного) массива
  - ***c[i] = foo(a[i], b[i])***
- Традиционный способ
  - Сперва целиком копируем оба массива CPU->GPU
  - Выполняем ядро
  - Целиком копируем выходной массив GPU->CPU
  - В каждый момент времени мы выполняем что-то одно
    - Все остальное простаивает

Потоки (пример)

- Для того, чтобы воспользоваться возможностью параллельного копирования и выполнения
  - Выделим pinned-память
  - Разобьем массивы на блоки
  - Одновременно будем копировать два входных блока, выполнять ядро и копировать результат обратно
  - Должны *вроде-бы* получить перекрывание по времени для всех операций
    - Выполнения ядра
    - Копирование на GPU
    - Копирования с GPU

Потоки

- Как мы хотим получить
  - По очереди для каждого потока
    - Copy A
    - Copy B
    - Kernel
    - Copy C

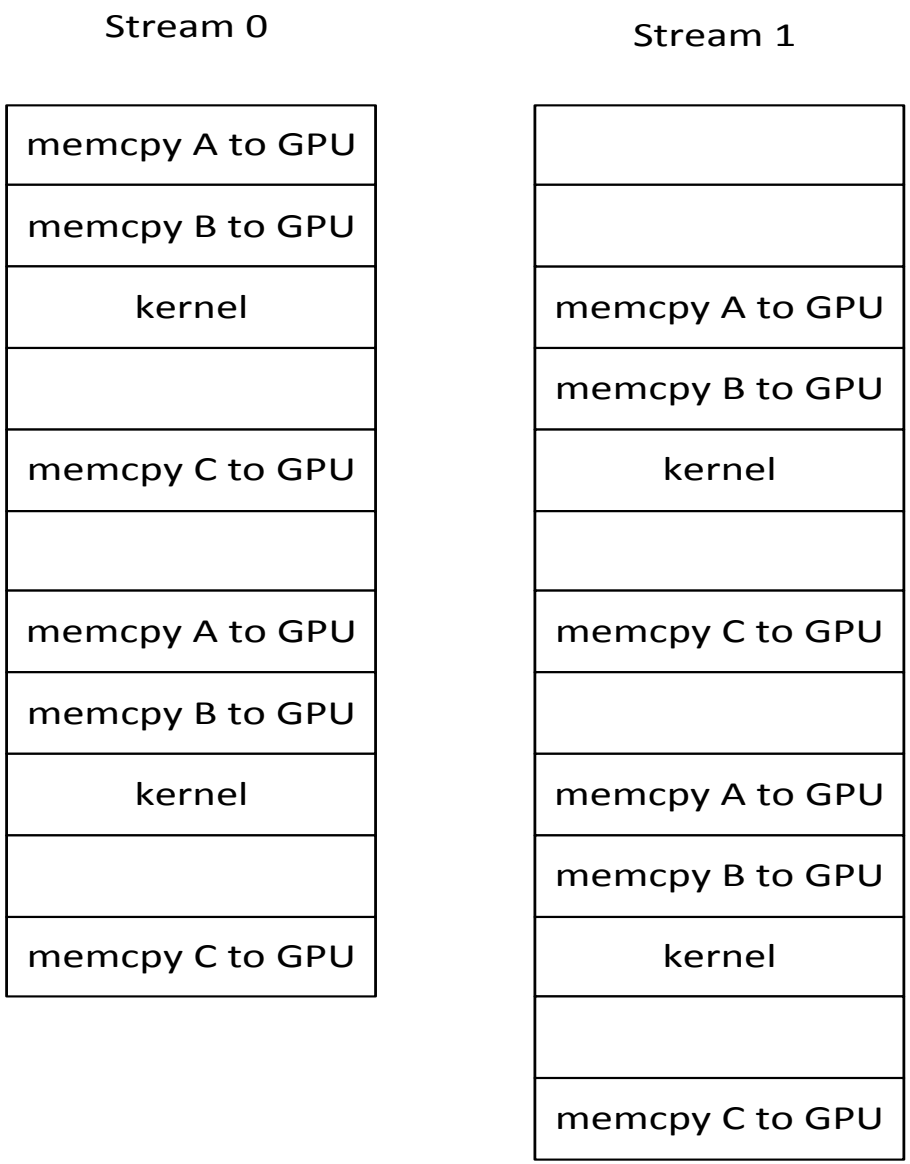

Потоки, как все на самом деле

- На самом деле на GPU есть независимые подсистемы
  - Подсистема расчета (выполнения ядер)
  - Подсистема копирования
  - Про потоки эти подсистемы вообще ничего не знают
- Таким образом мы в каждом потоке ставим в очередь в подсистему копирования
  - Copy A
  - Copy B
  - Copy C
- В каждом потоке ставим в подсистему расчета
  - Kernel
- Для подсистем “Copy C” зависит от ядра соответствующего потока – так драйвер отслеживает зависимости в потоке

Потоки - как все работает

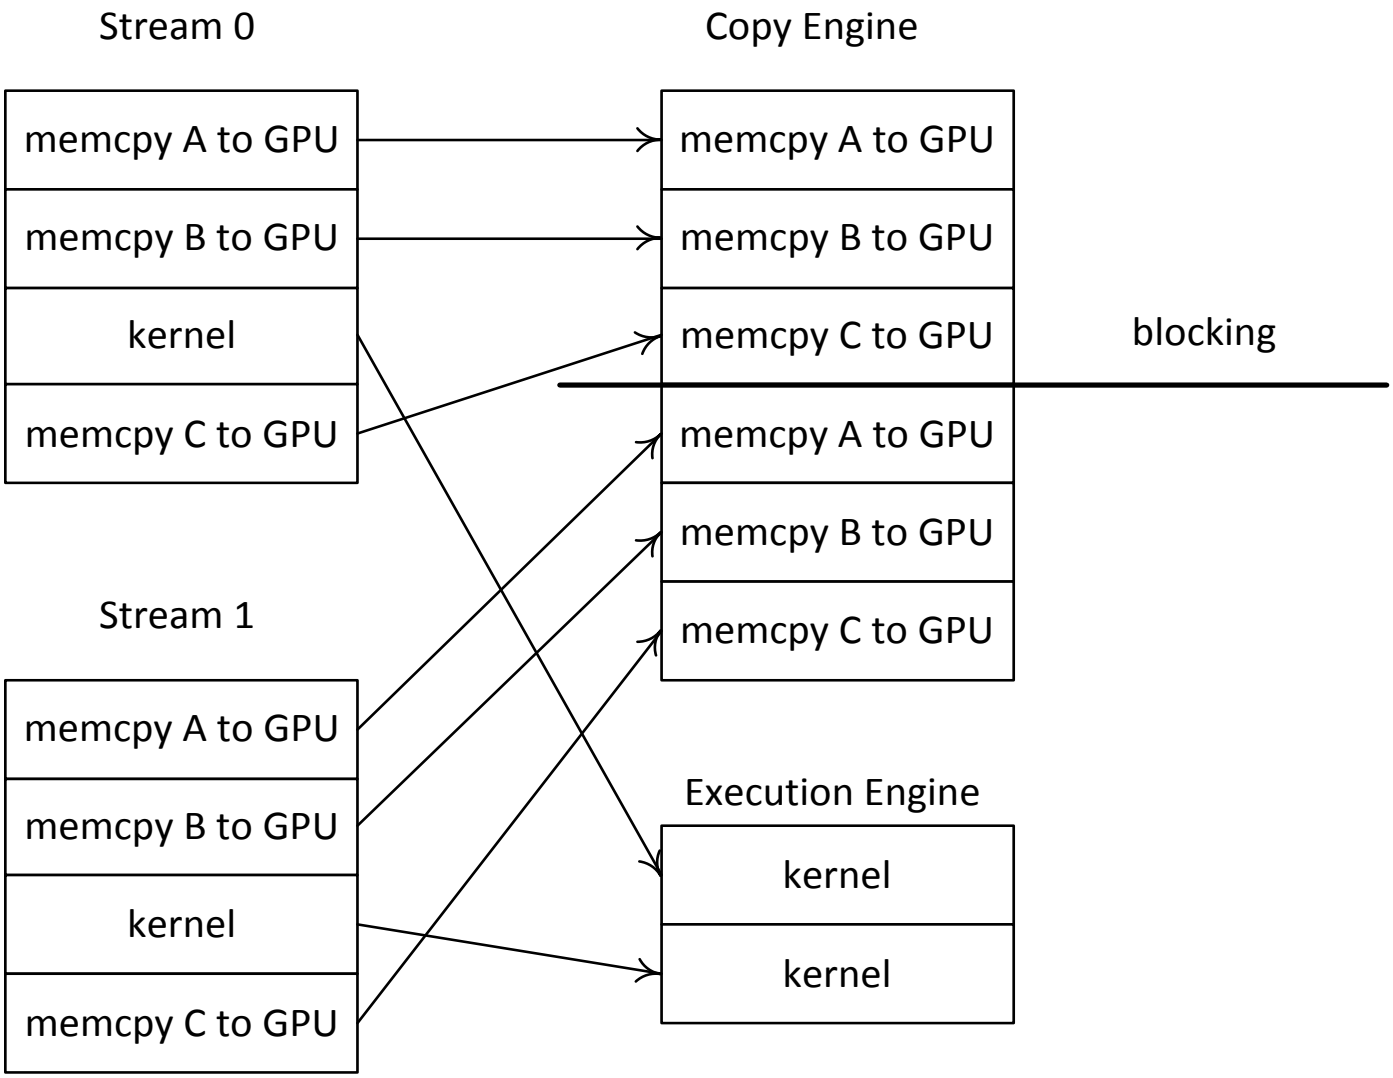

Потоки - как нужно

- Раньше вы ставили задачи по принципу «в глубину»
- Теперь будем ставить «в ширину»
  - Copy A (stream 0)
  - Copy A (stream 1)
  - Copy B (stream 0)
  - Copy B (stream 1)
  - Kernel (stream 0)
  - Kernel (stream 1)
  - Copy C (stream 0)
  - Copy C (stream 1)

Потоки - как нужно

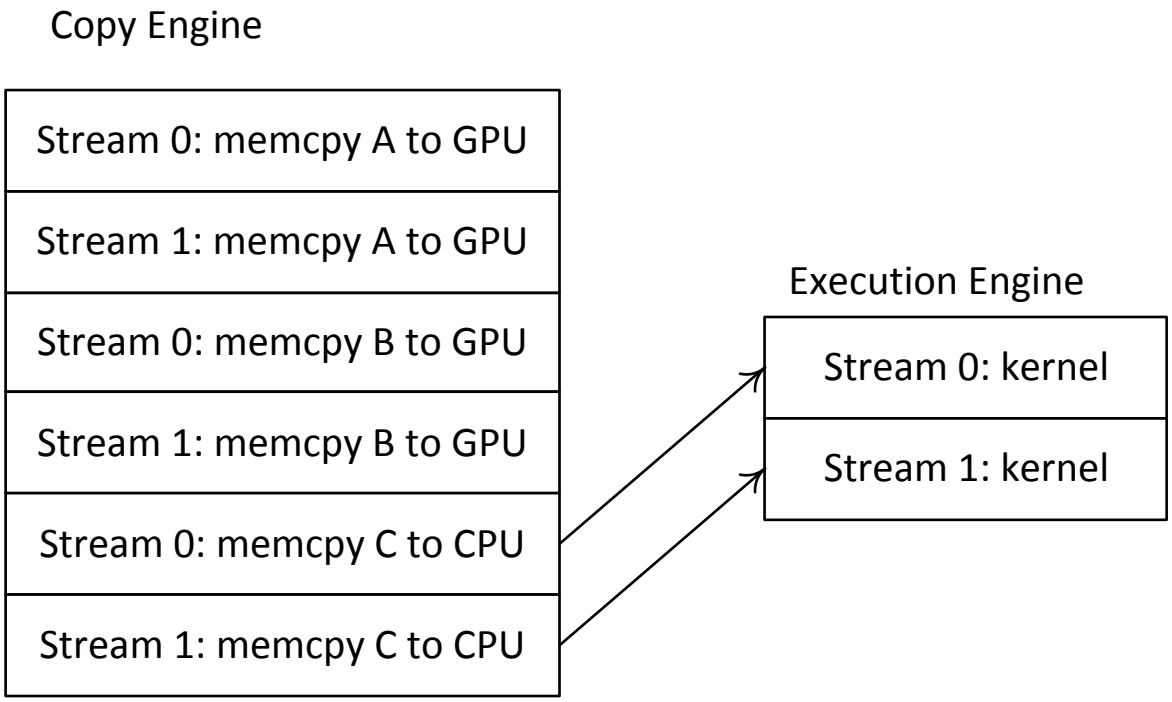

Потоки - как нужно

```
for ( int i = 0; i < DATA_SIZE; i += N*2)
{
  cudaMemcpyAsync( devA0, hostA + i, N * sizeof (int),
                   cudaMemcpyHostToDevice, stream0 );
  cudaMemcpyAsync( devA1, hostA + i + N, N * sizeof (int),
                   cudaMemcpyHostToDevice, stream1 );

  cudaMemcpyAsync( devB0, hostB + i, N * sizeof (int),
                   cudaMemcpyHostToDevice, stream0 );
  cudaMemcpyAsync( devB1, hostB + i + N, N * sizeof (int),
                   cudaMemcpyHostToDevice, stream1 );

  kernel<<<blocks, threads, 0, stream0>>> ( devA0, devB0, devC0 );
  kernel<<<blocks, threads, 0, stream1>>> ( devA1, devB1, devC1 );

  cudaMemcpyAsync( hostC + i, devC0, N * sizeof (int),
                   cudaMemcpyDeviceToHost, stream0 );
  cudaMemcpyAsync( hostC + i + N, devC1, N * sizeof (int),
                   cudaMemcpyDeviceToHost, stream1 );
}
```

Интероперабельность с OpenGL

- Возможность непосредственно в CUDA использовать данные OpenGL без необходимости их копировать
  - Поддерживаются текстуры
  - Поддерживаются VBO (Vertex Buffer Object)
  - Соответствующий ресурс необходимо зарегистрировать вначале
  - И разрегистрировать в конце
  - Для отображения ресурса в адресное пространство CUDA используется соответствующие функции отображения
  - При этом ресурс не может одновременно использоваться и CUDA и OpenGL – мы отображаем его в CUDA, работаем, потом закрываем отображение и OpenGL может снова его использовать
  - Довольно легко завернуть в классы C++
  - Изменения в работе с текстурами в последних версиях CUDA

Интероперабельность с OpenGL - VBO

- Регистрируем буфер в CUDA
  - Получаем указатель на cudaGraphicsResource
  - В конце работы нужно разрегистрировать
  - Можно задавать флаги через cudaGraphicsResourceSetMapFlags
    - cudaGraphicsMapFlagsReadOnly
    - cudaGraphicsMapFlagsWriteDiscard
- Когда нужны данные
  - Вызываем cudaGraphicsMapResources
  - Получаем указатель на глобальную память буфера через cudaGraphicsResourceGetMappedPointer
  - Используем указатель
  - Чтобы сделать буфер снова доступным OpenGL вызываем cudaGraphicsUnmapResources

Интероперабельность с OpenGL - VBO

```
class     CudaGlBuffer                                          // VBO
{
  cudaGraphicsResource * resource;
  VertexBuffer         * buffer;
  GLenum                 target;

public:
  CudaGlBuffer ( VertexBuffer * buf, GLenum theTarget,
                 unsigned int flags = cudaGraphicsMapFlagsWriteDiscard )
  {
          buffer = buf;
          target = theTarget;

          buffer -> bind ( target );
          cudaGraphicsGLRegisterBuffer ( &resource, buffer -> getId (), flags );
          buffer -> unbind ();
  }
  ~CudaGlBuffer ()
  {
          cudaGraphicsUnregisterResource ( resource );
  }
  bool    mapResource ( cudaStream_t stream = 0 )
  {
          return cudaGraphicsMapResources ( 1, &resource, stream ) == cudaSuccess;
  }
  bool    unmapResource ( cudaStream_t stream = 0 )
  {
          return cudaGraphicsUnmapResources ( 1, &resource, stream ) == cudaSuccess;
  }
```

Интероперабельность с OpenGL - VBO

```
  void * mappedPointer ( size_t& numBytes ) const
  {
          void * ptr;

          if ( cudaGraphicsResourceGetMappedPointer ( &ptr, &numBytes, resource )
               != cudaSuccess )
                    return NULL;

          return ptr;
  }

  GLuint  getId () const
  {
          return buffer -> getId ();
  }

  GLenum getTarget () const
  {
          return target;
  }

  cudaGraphicsResource * getResource () const
  {
          return resource;
  }
};
```

Интероперабельность с OpenGL - Текстуры

- Регистрируем текстуру в CUDA
  - Получаем указатель на cudaGraphicsResource
  - В конце работы нужно разрегистрировать
  - Можно задавать флаги через cudaGraphicsResourceSetMapFlags
    - cudaGraphicsMapFlagsReadOnly
    - cudaGraphicsMapFlagsWriteDiscard
- Когда нужны данные
  - Вызываем cudaGraphicsMapResources
  - Доступ к текстуре идет через
    - cudaGraphicsResourceGetMappedMipmappedArray
    - cudaGraphicsSubResourceGetMappedArray (cudaArray)
  - Используем указатель
  - Чтобы сделать буфер снова доступным OpenGL вызываем cudaGraphicsUnmapResources

Интероперабельность с OpenGL - Текстуры

- Либо получаем доступ ко всей текстуре со всеми уровнями пирамидального фильтрования
  - cudaMipmappedArray_t
  - Является полем mipmap структуры cudaResourceDesc
  - Можем создать texture object для доступа
- Либо получаем доступ к одному слою/уровню текстуры через cudaArray (сразу задаем их)
  - Можем создать textureObject для доступа

Интероперабельность с OpenGL - Текстуры

```
class     CudaGlImage
{
  GLuint                                    image;
  GLenum                                    target;
  cudaGraphicsResource * resource;

public:
  CudaGlImage ( GLuint theImage, GLenum theTarget,
    unsigned int  flags = cudaGraphicsMapFlagsWriteDiscard )
  {
          image  = theImage;
          target = theTarget;
          cudaGraphicsGLRegisterImage ( &resource, image, target, flags );
  }
  ~CudaGlImage ()
  {
          cudaGraphicsUnregisterResource ( resource );
  }

  bool    mapResource ( cudaStream_t stream = 0 )
  {
          return cudaGraphicsMapResources ( 1, &resource, stream ) == cudaSuccess;
  }

  bool    unmapResource ( cudaStream_t stream = 0 )
  {
          return cudaGraphicsUnmapResources ( 1, &resource, stream ) == cudaSuccess;
  }
```

Интероперабельность с OpenGL - Текстуры

```
cudaArray * mappedArray ( unsigned int index = 0, unsigned int mipLevel = 0 ) const
{
        cudaArray * array;

        if ( cudaGraphicsSubResourceGetMappedArray  ( &array, resource, index,
                                                      mipLevel ) != cudaSuccess )
                return NULL;

        return array;
}
```

Библиотека thrust

- Полностью на шаблонах
- Напоминает STL
- Свой namespace thrust
- Свои контейнеры, итераторы, алгоритмы (почти как STL)
- Поддерживает функторы и лямбды
  - Для лямбд нужна опция nvcc --expt-extended-lambda
- Многие операции над данными записываются в одну строку
- Все алгоритмы работают и для CPU и для GPU

Библиотека thrust - контейнеры

- Всего два типа контейнеров (самые эффективные с точки зрения доступа к памяти) – thrust::host_vector, thrust_device_vector
- Управляют памятью, можно динамически менять размер
- По интерфейсу напоминают STL
- Произвольный доступ к элементам (даже для device_vector на стороне CPU)
- Простое копирование (c-tor, copy)
- Типизированные
- Можно получить указатель на область глобальной памяти для device_vector

Библиотека thrust - контейнеры

```
thrust::host_vector<int>   hv ( 1000 );
thrust::device_vector<int> dv ( 1000 );
          // заполняем данными,
          // sequence – функция, функтор, лямбда
thrust::generate ( hv.begin (), hv.end (), sequence );
          // копирование
dv = hv;
          // операция над данными
int sum = thrust::reduce ( dv.begin (), dv.end () );
          // обращение на стороне CPU
int value = dv [10];
```

Библиотека thrust - контейнеры

- Можно получить указатель на данные контейнера

```
thrust::device_vector<int> v (1000);
int * rawPtr = thrust::raw_pointer_cast(v.data()));
myKernel<<<threads, blocks>>> ( rawPtr, v.size () );
```

- Если есть готовый указатель в память GPU, то для получения нужного типа итератора следует обернуть его в класс device_ptr

```
int * rawPtr;
cudaMalloc ( (void**)&rawPtr, N * sizeof ( int ) );
thrust::device_ptr ptr ( rawPtr );
// some operations on ptr
cudaFree ( rawPtr );
```

Библиотека thrust - итераторы

- begin(), end(), ++, --, арифметика указателей
- Тип итератора несет в себе информацию о том, в чьей памяти
  - Используется при компиляции для выбора алгоритма
- Обычный указатель - тоже итератор, но только в память CPU
  - Поэтому указатель на глобальную память нельзя напрямую передавать в thrust
  - Перевод device-указателя в итератор

```
thrust::device_ptr<int> ptr ( rawPtr );
```

- Есть специальные классы итераторов

Библиотека thrust

Простейшие операции, работают с памятью CPU и GPU

```
      // заполнение заданным значением
thrust::fill ( d.begin (), d.end (), 77 );
       // заполнение арифметической прогрессией
thrust::sequence ( d.begin (), d.end (), 7, -2 );
       // использование функции для генерации
thrust::generate ( d.begin (), d.end (), rand );
       // копирование
thrust::copy ( src.begin (), src.end (), dst.begin () );
```

Библиотека thrust - алгоритмы

- Принимают на вход функторы и итераторы
- Есть набор стандартных функторов
- Можно делать свои функторы как в STL
  - указываем __device__ (__host__)
- Есть «хитрая замена» лямбд через thrust::placeholders
- Можно использовать лямбды с описателем __device__
  - Это расширение языка - нужен флаг компиляции --expt-extended-lambda

Библиотека thrust - алгоритмы

```
// преобразование одного массива в другой
thrust::transform ( a.begin (), a.end (), b.begin (),
            output.begin (), thrust::multiplies<float> () );
    // редукция с заданной операцией
int sum = thrust::reduce( a.begin (), a.end (), 0,
                          thrust::plus<int> () );
    // задаем свой функтор
template<typename T> struct square
{
  __device__ __host__ T operator ()( const T& x ) const
  { return x*x; }
};
    // используем функтор, reduce для преобразованных значений
float s = thrust::transform_reduce ( v.begin (),
         v.end (), square<float>(), 0, thrust::plus<float>() );
```

Библиотека thrust - алгоритмы

```
// первый вариант префиксной суммы
thrust::inclusive_scan ( x.begin (), x.end (), x.begin () );
    // второй вариант префиксной суммы
thrust::exclusive_scan ( a.begin (), a.end (), b.begin () );
    // сортировка (не устойчивая)
thrust::sort ( v.begin (), v.end () );
    // устойчивая – не меняет порядок равных элементов
thrust::stable_sort ( v.begin (), v.end () );
    // ключи сортировки отдельно от данных
thrust::sort_by_key ( keys.begin (), keys.end (),
                      data.begin (), compare );
```

Библиотека thrust - итераторы

- thrust::constant_iterator<T> - всегда возвращает одно значение
- thrust::counting_iterator<T> - арифметическая последовательность
- thrust::transform_iterator<T> - объединение итератора и преобразования
  - thrust::make_transform_iterator (a.begin (), thrust::negate<int> ())
- thrust::zip_iterator – объединение нескольких итераторов в один (возвращающий tuple)

Библиотека thrust

Аналог лямбд

```
#include <thrust/functional.h>
using namespace thrust::placeholders;
thrust::for_each(x.begin(), x.end(), _1++);

int a = 42;
thrust::transform(x.begin(), x.end(), y.begin(),
                  x.begin(), a * _1 + _2);

thrust::for_each(x.begin(), x.end(), _1++);
```

Библиотека thrust - лямбды

- Выставляем флаг компиляции
- Задаем __device__ в описании
- Используем где хотим

```
        // сортируем по критерию – сначала те элементы
        // для который true
thrust::partition ( dv2.begin (), dv2.end (),
                [] __device__ ( int x ) { return x % 2 == 0; } );
```

Библиотека thrust – еще алгоритмы

- bool flag = thrust::all_of (a.begin (), a.end (), _1 < 0);
- bool flag = thrust::any_of (a.begin (), a.end (), _1 > 10);
- bool flag = thrust::none_of (a.begin (), a.end (), _1 < 0);
- thrust::copy_if (a.begin(), a.end (), result.begin (), _1 % 2 != 0);
- thrust::for_each
- int c = thrust::count_if (a.begin (), a.end (), _1 > 7);

Библиотека thrust

Есть еще много различных алгоритмов

Есть много специальных итераторов, например transform_iterator или zip_iterator