Текстуры и поверхности в CUDA

Романенко А.А.
arom@ccfit.nsu.ru

Новосибирский государственный университет

Что такое текстура?

- Способ доступа к данным

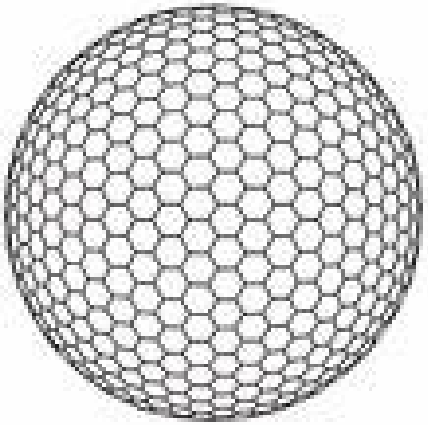

+

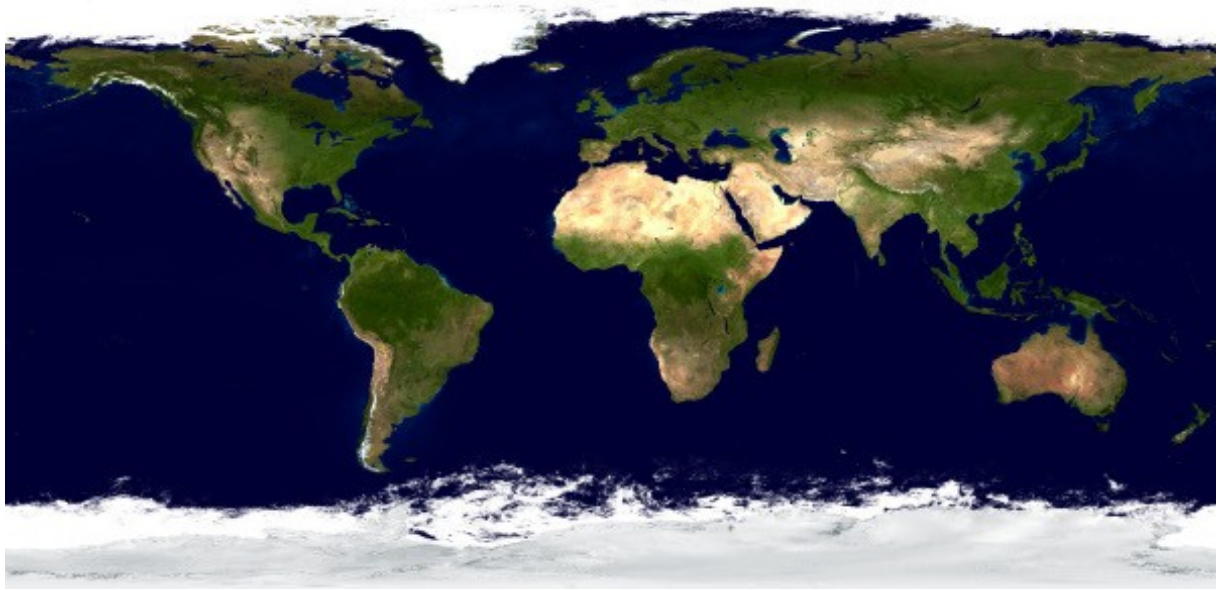

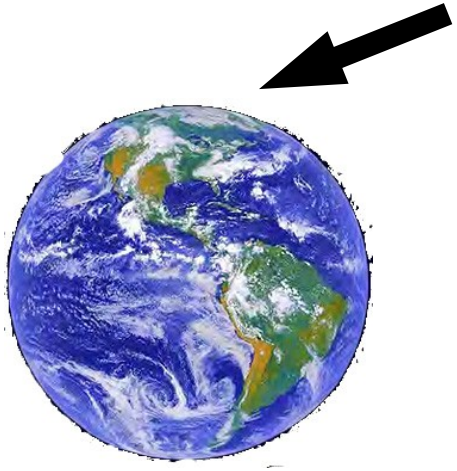

Особенности текстур

- Латентность больше, чем у прямого обращения в память
  - Дополнительные стадии в конвейере:
    - Преобразование адресов
    - Фильтрация
    - Преобразование данных
- Но зато есть кэш
- Разумно использовать, если:
  - Объем данных не влезает в shared память
  - Паттерн доступа хаотичный
  - Данные переиспользуются разными потоками

Свойства текстур

- Доступ к данным через кэш
  - Оптимизированы для доступа к данным которые расположены рядом в двумерном пространстве
- Фильтрация
  - Линейная
- Свертывание (выход за границы)
  - Повторение/ближайшая граница
- Адресация в 1D, 2D и 3D
  - Целые/нормализованные координаты

Свойства в картинках

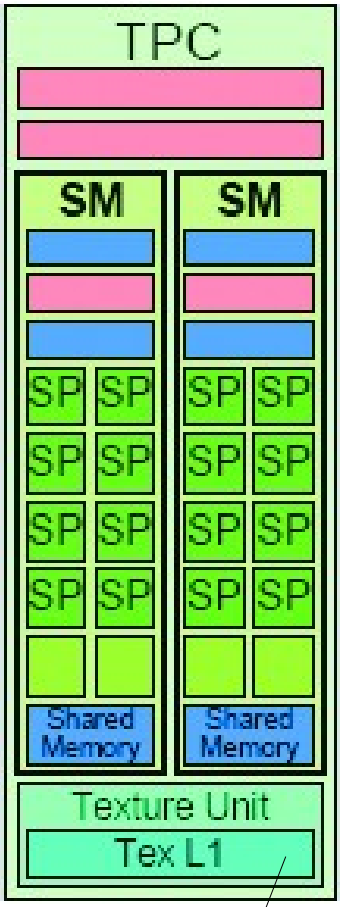

Кэш текстуры

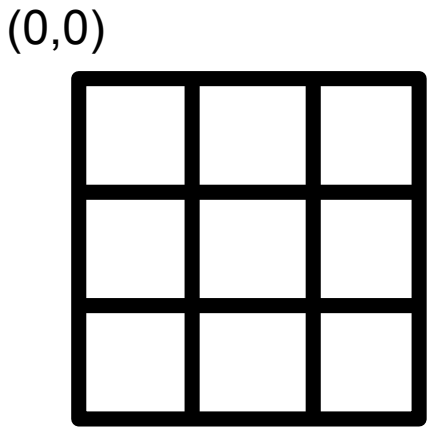

Повторение

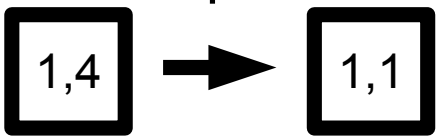

Ближайшая граница

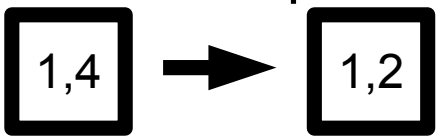

- tex1Dfetch(texRef, x)
- tex1D(texRef, x)
- tex2D(texRef, x, y)
- tex3D(texRef, x, y, z)

Свойства в картинках

- Нормализация координат

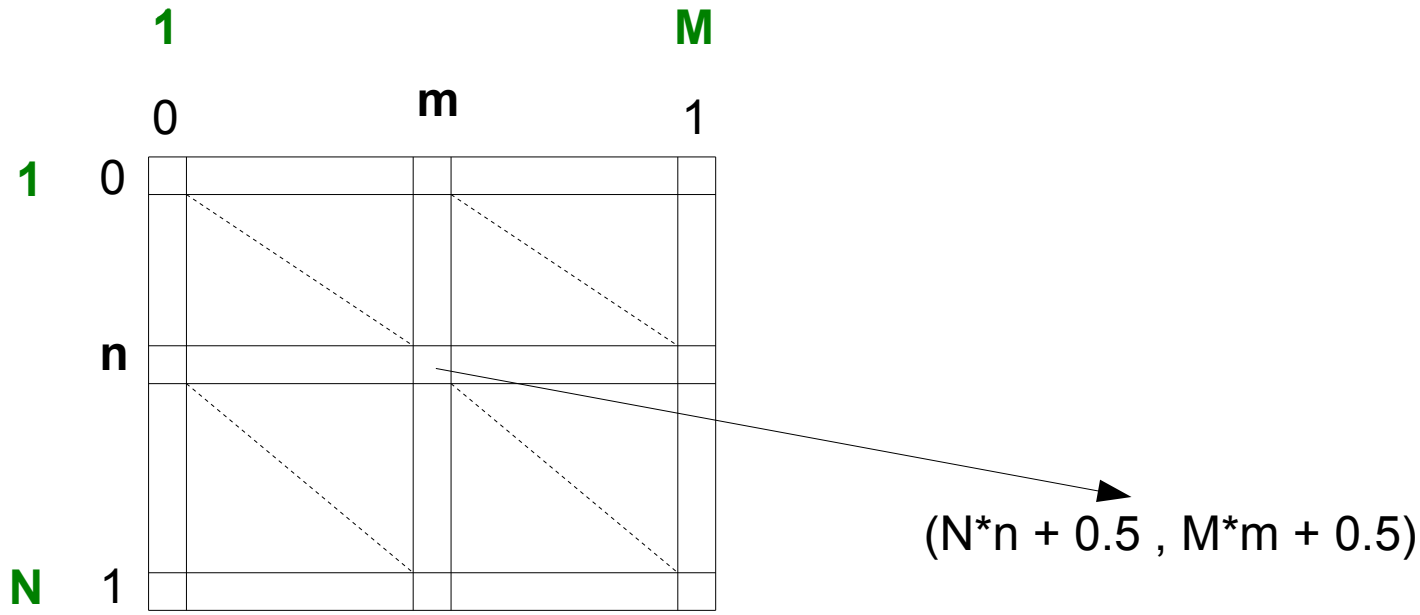

- Фильтрация

Свойства текстур

- Преобразование данных:
  - **cudaReadModeNormalizedFloat** :
    - Исходный массив содержит данные в integer,
    - возвращаемое значение во **floating point** представлении (доступный диапазон значений отображается в интервал [0, 1] или [-1,1])
  - **cudaReadModeElementType**
    - Возвращаемое значение то же, что и во внутреннем представлении

Типы/свойства текстур

- Привязанные к линейной памяти
  - Только 1D
  - Целочисленная адресация
  - Фильтры и свертывание отсутствуют
- Привязанные к массивам CUDA
  - 1D, 2D или 3D
  - целые/нормализованные координаты
  - Фильтрация
  - Свертывание

Работа с текстурами

- Host:
  - Выделить память (malloc/cudaMallocArray/...)
  - Объявить указатель на текстуру
  - Связать указатель на текстуру с областью памяти
  - После использования:
    - Отвязать текстуру, освободить память
- Device:
  - Чтение данных через указатель текстуры
  - Текстуры для линейной памяти: tex1Dfetch()
  - Текстуры на массивах: tex1D() or tex2D() or tex3D()

Работа с текстурами (Host)

```
texture<float, 2, cudaReadModeElementType> tex;

  ...

cudaChannelFormatDesc channelDesc =
        cudaCreateChannelDesc(32, 0, 0, 0, cudaChannelFormatKindFloat);

cudaArray* cu_arr;

cudaMallocArray(&cu_arr, &channelDesc, width, height );
cudaMemcpyToArray(cu_arr, 0, 0, h_dta, size, cudaMemcpyHostToDevice);

// 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
  cudaBindTextureToArray(tex, cu_arr, channelDesc);
```

Работа с текстурами (Device)

```
__global__ void Kernel( 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;

    // transform coordinates
    u -= 0.5f;
    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);
}
```

Тип double и текстуры

- Тип double не поддерживается.
- Представить double как два значения типа int
  - texture<int2,1> my_texture;

```
static __inline__ __device__
    double fetch_double(texture<int2, 1> t, int i) {
        int2 v = tex1Dfetch(t,i);
        return __hiloint2double(v.y, v.x);
}
```

Пример

```
__global__ void kern(double *o){
        unsigned int x = blockIdx.x*blockDim.x + threadIdx.x;
        if(x<32){
              o[x] = fetch_double(my_texture, x)*2.0;
        }
}

int main(int argc, char *argv[]){
        double hbuf[32];    double *dob;    int2 *dbuf;
        size_t ii;
        cudaMalloc((void**)&dbuf, sizeof(int2)*32);
        cudaMalloc((void**)&dob, sizeof(double)*32);

        cudaBindTexture(&ii, my_texture, dbuf,
           cudaCreateChannelDesc(32,32,0,0, cudaChannelFormatKindSigned));

        for(i = 0 ; i < 32 ; i++)   hbuf[i]=1.0/3.0*i;

        cudaMemcpy(dbuf, hbuf, 32*sizeof(double), cudaMemcpyHostToDevice);
        kern<<<1, 32>>>(dob);
        cudaMemcpy(hbuf, dob, 32*sizeof(double), cudaMemcpyDeviceToHost);

        for(i = 0 ; i < 32 ; i++)   printf("%lf\t", hbuf[i]);
        printf("\n");
        return 0;
}
```

Поверхности (Surface)

- Появились в CUDA 3.2
- Из поверхностей можно как читать, так и писать в них.
- Объявление
  - surface<void, Dim> surface_ref;
- Привязка к массивам
  - surface <void, 2> surfRef;
    cudaBindSurfaceToArray(surfRef, cuArray);

Поверхности. Адресация

- Побайтовая адресация
- При указатели на float
  - Текстуры tex1d(texRef1D, x)
  - Поверхности surf1Dread(surfRef1D, 4*x)
  - Текстуры tex2d(texRef2D, x, y)
  - Поверхности surf2Dread(surfRef2D, 4*x, y)

Пример

```
// 2D surfaces
surface<void, 2> inputSurfRef;
surface<void, 2> outputSurfRef;
// Simple copy kernel
__global__ void copyKernel(int width, int height) {
  // Calculate surface coordinates
  unsigned int x = blockIdx.x * blockDim.x
       + threadIdx.x;
  unsigned int y = blockIdx.y * blockDim.y
       + threadIdx.y;
  if (x < width && y < height) {
    uchar4 data;
    // Read from input surface
    surf2Dread(&data, inputSurfRef, x * 4, y);
    // Write to output surface
    surf2Dwrite(data, outputSurfRef, x * 4, y);
  }
}
```

Пример. Продолжение

```
int main() {
    cudaChannelFormatDesc channelDesc =
    cudaCreateChannelDesc(8,8,8,8,
                                cudaChannelFormatKindUnsigned);
    cudaArray* cuInputArray; cudaArray* cuOutputArray;
    cudaMallocArray(&cuInputArray, &channelDesc, width,
                        height, cudaArraySurfaceLoadStore);
    cudaMallocArray(&cuOutputArray, &channelDesc, width,
                        height, cudaArraySurfaceLoadStore);
    cudaMemcpyToArray(cuInputArray, 0, 0, h_data, size,
                                        cudaMemcpyHostToDevice);
    cudaBindSurfaceToArray(inputSurfRef, cuInputArray);
    cudaBindSurfaceToArray(outputSurfRef, cuOutputArray);
    // Invoke kernel
    dim3 dimB(16, 16);
    dim3 dimG((width + dimB.x - 1)/dimB.x,
              (height + dimB.y - 1)/ dimB.y);
    copyKernel<<<dimGrid, dimBlock>>>(width, height);
    cudaFreeArray(cuInputArray); cudaFreeArray(cuOutputArray);
}
```

Текстуры и поверхности в CUDA

Романенко А.А.
arom@ccfit.nsu.ru

Новосибирский государственный университет

В обычном понимании текстура — это некая картинка, которая натягивается на объект. Для GPU текстура — это способ доступа к данным.

Особенности текстур

- Латентность больше, чем у прямого обращения в память
  - Дополнительные стадии в конвейере:
    - Преобразование адресов
    - Фильтрация
    - Преобразование данных
- Но зато есть кэш
- Разумно использовать, если:
  - Объем данных не влезает в shared память
  - Паттерн доступа хаотичный
  - Данные переиспользуются разными потоками

Каждый кластер обработки текстур имеет свой блок работы с текстурами и текстурный кэш. За счет него скорость обращения к глобальной памяти через текстуры существенно выше, чем на прямом обращении. Кроме того в кэш помещаются данные, которые в памяти лежат рядом в 2D области.

Свойства текстур

- Доступ к данным через кэш
  - Оптимизированы для доступа к данным которые расположены рядом в двумерном пространстве
- Фильтрация
  - Линейная
- Свертывание (выход за границы)
  - Повторение/ближайшая граница
- Адресация в 1D, 2D и 3D
  - Целые/нормализованные координаты

Дополнительная стадия конвейеризации в текстурах дает возможность производить интерполяцию данных между узлами сетки, сворачивать текстуры в тор, работать в истинных или нормализованных координатах.

Свойства в картинках

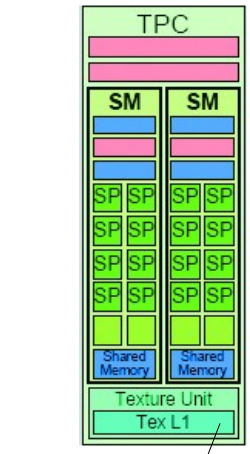

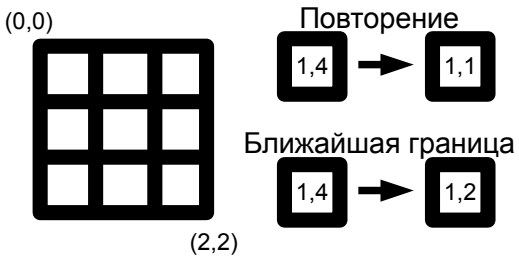

- tex1Dfetch(texRef, x)
- tex1D(texRef, x)
- tex2D(texRef, x, y)
- tex3D(texRef, x, y, z)

Для выборки данных из текстур пользователю доступны 4 функции.

Свойства в картинках

- Нормализация координат

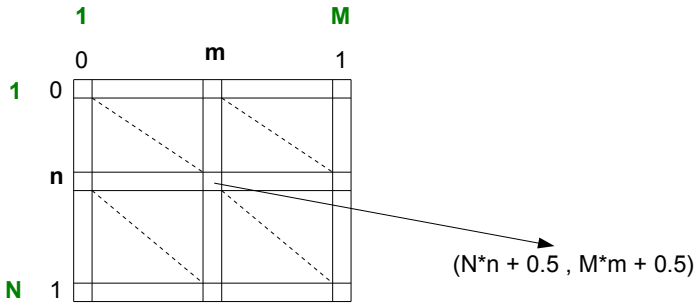

- Фильтрация

Свойства текстур

- Преобразование данных:
  - **cudaReadModeNormalizedFloat** :
    - Исходный массив содержит данные в integer,
    - возвращаемое значение во **floating point** представлении (доступный диапазон значений отображается в интервал [0, 1] или [-1,1])
  - **cudaReadModeElementType**
    - Возвращаемое значение то же, что и во внутреннем представлении

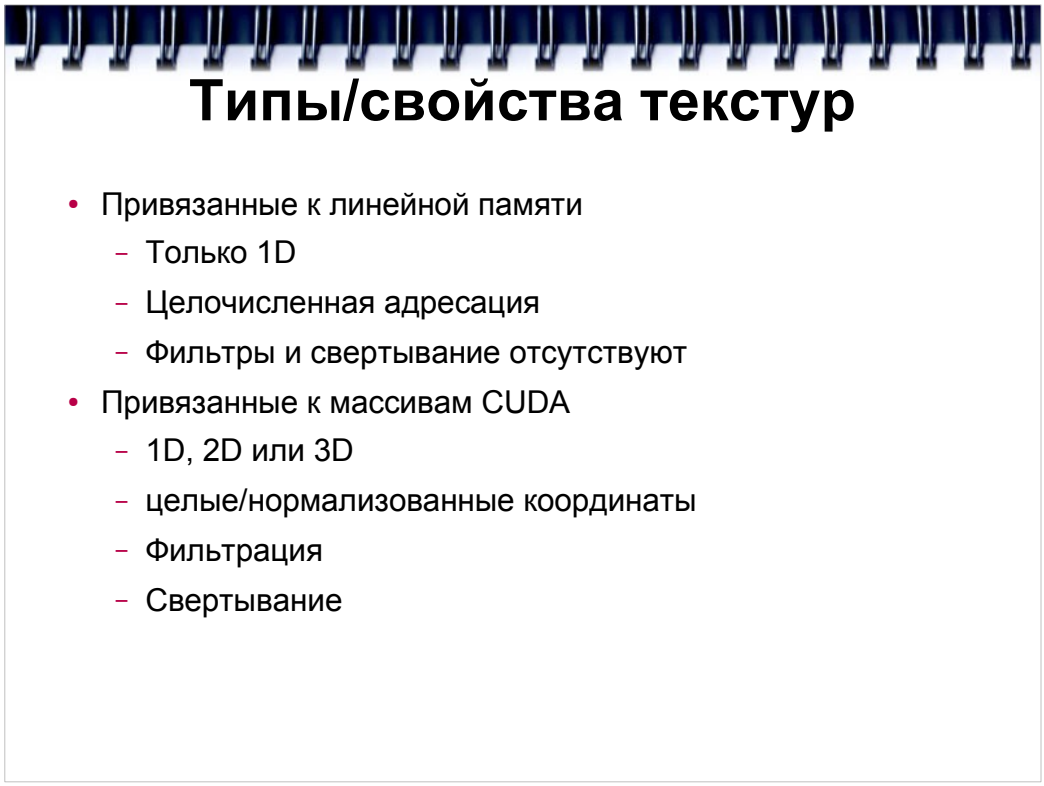

В зависимости от способа выделения памяти, которая в дальнейшем привязывается к текстурам, текстуры обладают, или не обладают некоторыми свойствами.

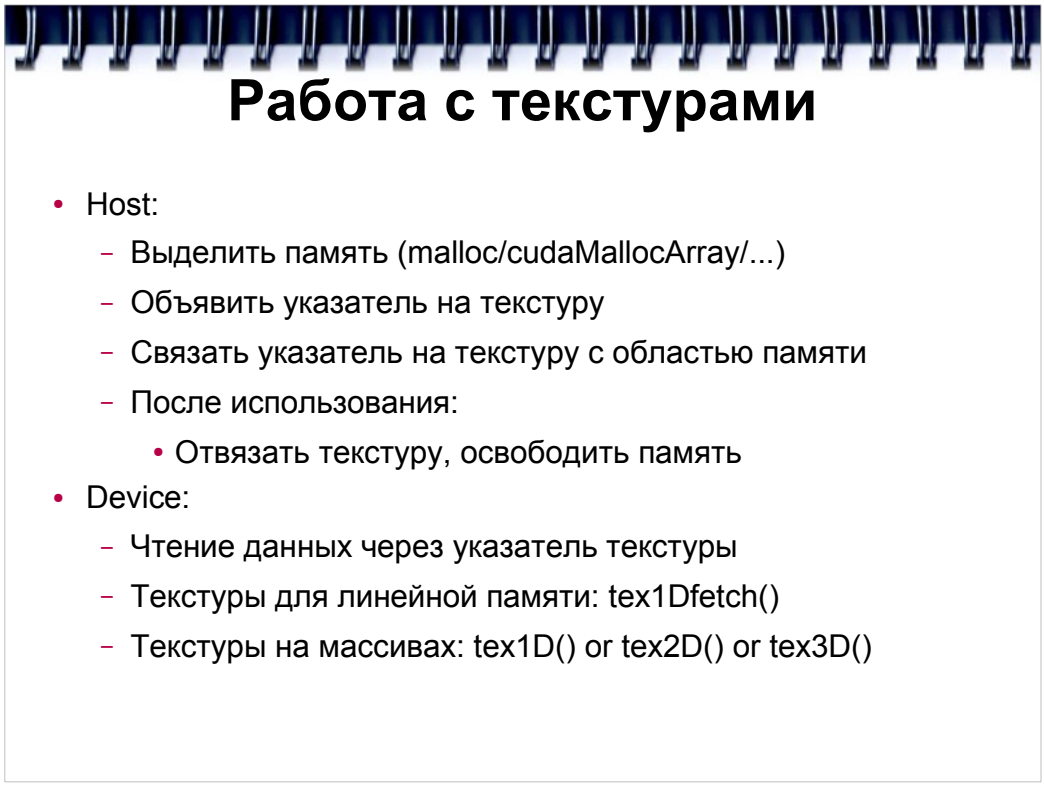

Работа с текстурами ведется в последовательности, которая указана на слайде. Придерживаясь правила хорошего тона надо не забывать освобождать ресурсы (память и текстуру)

Работа с текстурами (Host)

```
texture<float, 2, cudaReadModeElementType> tex;

  ...
cudaChannelFormatDesc channelDesc =
        cudaCreateChannelDesc(32, 0, 0, 0, cudaChannelFormatKindFloat);
cudaArray* cu_arr;
cudaMallocArray(&cu_arr, &channelDesc, width, height );
cudaMemcpyToArray(cu_arr, 0, 0, h_dta, size, cudaMemcpyHostToDevice);
// 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
  cudaBindTextureToArray(tex, cu_arr, channelDesc);
```

Пример программы, которая поворачивает на заданный угол картинку вокруг ее центра.

Работа с текстурами (Device)

```
__global__ void Kernel( 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;

    // transform coordinates
    u -= 0.5f;
    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);
}
```

Тип double и текстуры

- Тип double не поддерживается.
- Представить double как два значения типа int
  - texture<int2,1> my_texture;

```
static __inline__ __device__
    double fetch_double(texture<int2, 1> t, int i) {
        int2 v = tex1Dfetch(t,i);
        return __hiloint2double(v.y, v.x);
}
```

Пример

```
__global__ void kern(double *o){
        unsigned int x = blockIdx.x*blockDim.x + threadIdx.x;
        if(x<32){
              o[x] = fetch_double(my_texture, x)*2.0;
        }
}

int main(int argc, char *argv[]){
        double hbuf[32];    double *dob;    int2 *dbuf;
        size_t ii;
        cudaMalloc((void**)&dbuf, sizeof(int2)*32);
        cudaMalloc((void**)&dob, sizeof(double)*32);

        cudaBindTexture(&ii, my_texture, dbuf,
           cudaCreateChannelDesc(32,32,0,0, cudaChannelFormatKindSigned));

        for(i = 0 ; i < 32 ; i++)   hbuf[i]=1.0/3.0*i;

        cudaMemcpy(dbuf, hbuf, 32*sizeof(double), cudaMemcpyHostToDevice);
        kern<<<1, 32>>>(dob);
        cudaMemcpy(hbuf, dob, 32*sizeof(double), cudaMemcpyDeviceToHost);

        for(i = 0 ; i < 32 ; i++)   printf("%lf\t", hbuf[i]);
        printf("\n");
        return 0;
}
```

Поверхности (Surface)

- Появились в CUDA 3.2
- Из поверхностей можно как читать, так и писать в них.
- Объявление
  - surface<void, Dim> surface_ref;
- Привязка к массивам
  - surface <void, 2> surfRef;
    cudaBindSurfaceToArray(surfRef, cuArray);

Поверхности. Адресация

- Побайтовая адресация
- При указатели на float
  - Текстуры tex1d(texRef1D, x)
  - Поверхности surf1Dread(surfRef1D, 4*x)
  - Текстуры tex2d(texRef2D, x, y)
  - Поверхности surf2Dread(surfRef2D, 4*x, y)

Пример

```
// 2D surfaces
surface<void, 2> inputSurfRef;
surface<void, 2> outputSurfRef;
// Simple copy kernel
__global__ void copyKernel(int width, int height) {
  // Calculate surface coordinates
  unsigned int x = blockIdx.x * blockDim.x
       + threadIdx.x;
  unsigned int y = blockIdx.y * blockDim.y
       + threadIdx.y;
  if (x < width && y < height) {
    uchar4 data;
    // Read from input surface
    surf2Dread(&data, inputSurfRef, x * 4, y);
    // Write to output surface
    surf2Dwrite(data, outputSurfRef, x * 4, y);
  }
}
```

Пример. Продолжение

```
int main() {
    cudaChannelFormatDesc channelDesc =
    cudaCreateChannelDesc(8,8,8,8,
                          cudaChannelFormatKindUnsigned);
    cudaArray* cuInputArray; cudaArray* cuOutputArray;
    cudaMallocArray(&cuInputArray, &channelDesc, width,
                    height, cudaArraySurfaceLoadStore);
    cudaMallocArray(&cuOutputArray, &channelDesc, width,
                    height, cudaArraySurfaceLoadStore);
    cudaMemcpyToArray(cuInputArray, 0, 0, h_data, size,
                                    cudaMemcpyHostToDevice);
    cudaBindSurfaceToArray(inputSurfRef, cuInputArray);
    cudaBindSurfaceToArray(outputSurfRef, cuOutputArray);
    // Invoke kernel
    dim3 dimB(16, 16);
    dim3 dimG((width + dimB.x - 1)/dimB.x,
              (height + dimB.y - 1)/ dimB.y);
    copyKernel<<<dimGrid, dimBlock>>>(width, height);
    cudaFreeArray(cuInputArray); cudaFreeArray(cuOutputArray);
}
```