CUDA. API

Романенко А.А.
arom@ccfit.nsu.ru

Новосибирский государственный университет

CUDA, компоненты

- Драйвер
  - /lib/modules/...
- Toolkit
  - /usr/local/cuda
- SDK
  - /usr/local/cudasdk

Сборка программы

- Компилятор — nvcc
- Исходные коды - *.cu или *.cuh
- Рекомендуется собирать с помощью **make**
  - Скопировать к себе из примеров Makefile и common.mk
  - Поправить пути для выходных файлов
- Сборка
  - **make emu=1** — в режиме эмуляции определен макрос __DEVICE_EMULATION__
  - **make dbg=1** — с отладочной информацией
  - **make** — финальной версии программы

Модификаторы функций

- **__device__**
  - Исполняется на GPU
  - Запускается только из GPU
- **__host__**
  - Исполняется на CPU
  - Запускается только с CPU
- **__global__**
  - Исполняется на GPU
  - Запускается только с CPU

Модификаторы функций Ограничения

- __**device**__ и __**global**__ не поддерживают рекурсию
- В теле __**device**__ и __**global**__ не должны объявлять статические переменные
- В __**device**__ и __**global**__ не может быть переменное число параметров
- __**global**__ и __**host**__ не могут использоваться одновременно
- __**global**__ должна возвращать void и суммарный объем параметров должен быть не больше 256 байт

Модификаторы типов

- __device__
  - Располагается в глобальной памяти устройства
  - Имеет время жизни приложения
  - Доступна всем потокам в сети и через библиотеки для CPU
- __constant__
  - Располагается в константной памяти устройства
  - Имеет время жизни приложения
  - Доступна всем потокам в сети и через библиотеки для CPU
- __shared__
  - Располагается в разделяемой памяти потокового блока
  - Имеет время жизни потокового блока
  - Доступна только потокам внутри потокового блока

Модификаторы типов Ограничения

- **__shared__** переменная не может быть инициализирована при объявлении
- **__constant__** переменная может быть инициализирована только со стороны CPU
- Область видимости переменных **__device__** и **__constant__** - файл
- **__shared__** и **__constant__** переменные неявно имеют статическое хранилище
- Модификаторы не могут применяться к полям типов **struct** и **union**

Конфигурация времени выполнения

- Определяется при запуске ядра (__global__ функции)
  - **`__global__ void Func(float* data);`**
  - **`Func<<<Dg, Db, Ns, S>>>(data);`**
- Dg — размер сети. Тип dim3
  - Dg.x, Dg.y задают размер. Dg.z не используется
- Db — размер блока. Тип dim3
  - Db.x * Db.y * Db.z — количество потоков в блоке
- Ns — размер дополнительной разделяемой памяти на блок. Тип size_t. Опциональный. По-умолчанию - 0
- S — номер потока. Тип cudaStream_t. Опциональный. По-умолчанию — 0.
- **Выполнение ядра асинхронно**

Встроенные переменные

- **gridDim** — размер сети. Тип dim3.
- **blockIdx** — индекс блока в сети. Тип uint3.
- **blockDim** — размерность блока. Тип dim3.
- **threadIdx** — индекс потока в блоке. Тип uint3.
- uint3 и dim3 - структуры из трех полей: x, y, z
- Встроенные переменные нельзя модифицировать
- Нельзя получить адрес встроенной переменной

Пример

- Графическое представление разбиения след примера

Пример

```
__global__ void my_sum(float* a, float* b,
                       float* c, int len){
   unsigned int index;
   index  = blockIdx.x *blockDim.x + threadIdx.x;
   if(index<len){
      c[index] = a[index] + b[index];
   }
}

dim3 GS(100);
dim3 BS(512);

my_sum<<<GS, BS>>>(a, b, c, 5000);
```

Встроенные векторные типы данных

- char1, char2, char3, char4
- uchar1, uchar2, uchar3, uchar4
- short1, short2, short3, short4
- ushort1, ushort2, ushort3, ushort4
- int1, int2, int3, int4
- uint1, uint2, uint3, uint4
- long1, long2, long3, long4
- ulong1, ulong2, ulong3, ulong4
- float1, float2, float3, float4
- Поля: x,y,z,w

Инициализация устройства

- **cudaGetDeviceCount** — количество устройств GPU
- **cudaGetDeviceProperties**(cudaDeviceProp*, uint) — получить параметры устройства
- **cudaSetDevice**(uint) — сделать устройство активным
  - Перед первым вызовом любого ядра или функции из runtime API
- Если требуется работать с несколькими устройствами, необходимо несколько потоков (threads) в программе

Параметры устройства

```
struct cudaDeviceProp{
  char   name[256];
  size_t totalGlobalMem;
  size_t sharedMemPerBlock;
  int    regsPerBlock;
  int    warpSize;
  size_t memPitch;
  int    maxThreadsPerBlock;
  int    maxThreadsDim[3];
  int    maxGridSize[3];
  int    clockRate;
  size_t totalConstMem;
  int    major;
  int    minor;
  size_t textureAlignment;
  int    deviceOverlap;
  int    multiProcessorCount;
  int    __cudaReserved[40];
};
```

Выделение памяти

- CPU
  - malloc, calloc, free, cudaMallocHost, cudaFreeHost
- GPU
  - cudaMalloc, cudaMallocPitch, cudaFree,
  -

```
float* ptr;
cudaMalloc((void**)ptr, 256*sizeof(float));
....
cudaFree(ptr);
....
cudaMallocPitch((void**)ptr, &pitch,
                256*sizeof(float), 256);
....
cudaFree(ptr);
```

Выделение памяти

- **cudaMallocPitch((void**)ptr, &pitch, size, blocks);**

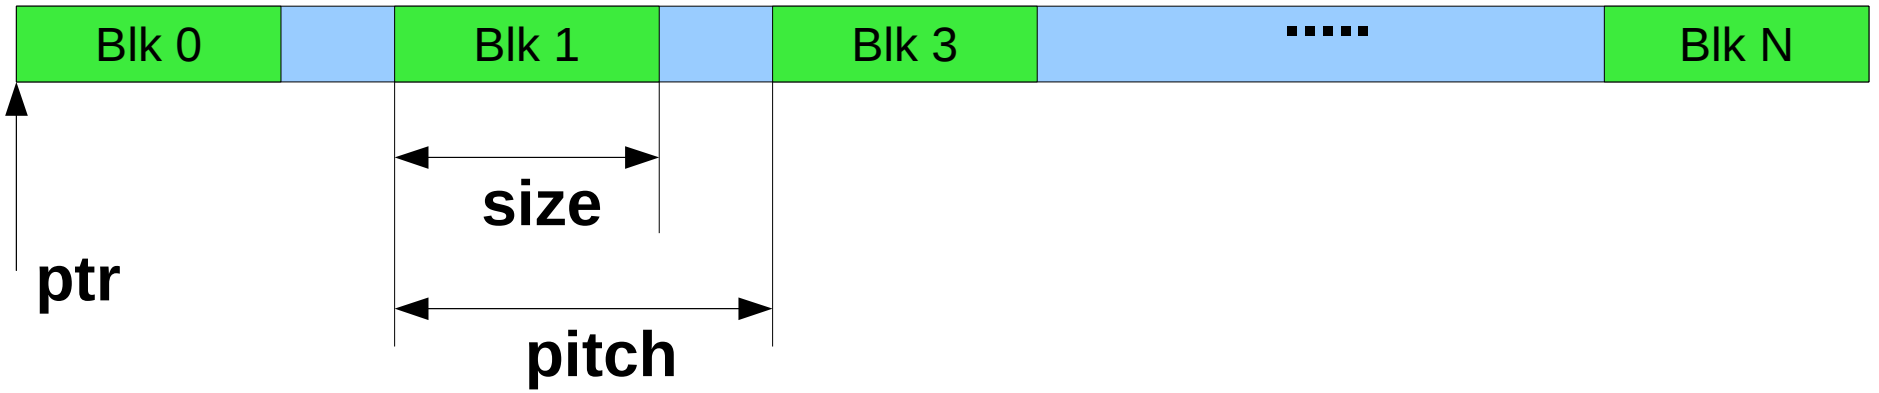

- **cudaMallocArray(struct cudaArray **array,**
  const struct cudaChannelFormatDesc* desc,
  size_t width, size_t height);
- **cudaFreeArray(struct cudaArray *array);**
- **cudaCreateChannelDesc(int x, int y, int z, int w,**
  enum cudaChannelFormatKind f);

Копирование данных в/из GPU

- cudaMemcpy(void* dst, void* src, size_t size, direction)
- direction:
  - cudaMemcpyHostToDevice
  - cudaMemcpyDeviceToHost
  - cudaMemcpyDeviceToDevice
- cudaMemcpy2D(void* dst, size_t dpitch, const void* src, size_t spitch, size_t width, size_t hight, direction)
- и т.д.

Атомарные операции

- Только знаковые и беззнаковые целые
- Операции над 32-битными словами в глобальной памяти
- atomicAdd, atomicSub, atomicExch, atomicMin, atomicInc, atomicDec, atomicCAS, atomicOr, atomicAnd, atomicXor

Математические функции

- Есть функции, которые исполняются как на GPU так и на CPU; есть те, которые выполняются только на GPU
- Вычисление может идти с погрешностью (см. документацию)
- Точность указана в ULP -**U**nit in the **L**ast **P**lace или **U**nit of **L**east **P**recision
- Время вычисления функций различно
- Существуют быстрые аналоги функций, но с ограничениями на диапазон/точность

CUDA Utilities library

- #include <cutil.h>
- Не является частью CUDA
- Назначение
  - Разбор командной строки
  - Чтение/запись бинарных файлов и изображений (PPM)
  - Сравнение массивов данных
  - Таймеры
  - Макросы проверки ошибок/инициализации
  - Проверка конфликтов банков разделяемой памяти

CUDA Utilities library

- CUT_DEVICE_INIT(ARGC, ARGV)
- CUT_EXIT(ARGC, ARGV)
- CUDA_SAFE_CALL(call) — в режиме отладки
- CUT_BANK_CHECKER(array, index) — в режиме эмуляции + отладки
- cutCreateTimer(unsigned int* name);
- cutDeleteTimer(unsigned int name);
- cutStartTimer(const unsigned int name);
- cutStopTimer(const unsigned int name);
- cutGetTimerValue(const unsigned int name);