Разработка параллельных программ для GPU

Обзор CUDA API

Виды CUDA APIs и возможности CUDA-устройств

ОСОБЕННОСТИ CUDA APIs

Виды CUDA APIs

- CUDA Driver API
  - Ручная инициализация контекста GPU
  - Отсутствуют CUDA-расширения для C++
  - Код CPU может компилироваться без nvcc

- CUDA Runtime API
  - Автоматическая инициализация контекста GPU
  - Наличие CUDA-расширений для C++

Выбор CUDA API

- CUDA Driver API
  - Больше гибкости (+)
  - Сложность кода (–)

- **CUDA Runtime API**
  - Меньше гибкости (–)
  - Простота кода (+)

Совместимость CUDA API

- Имеется обратная совместимость версий

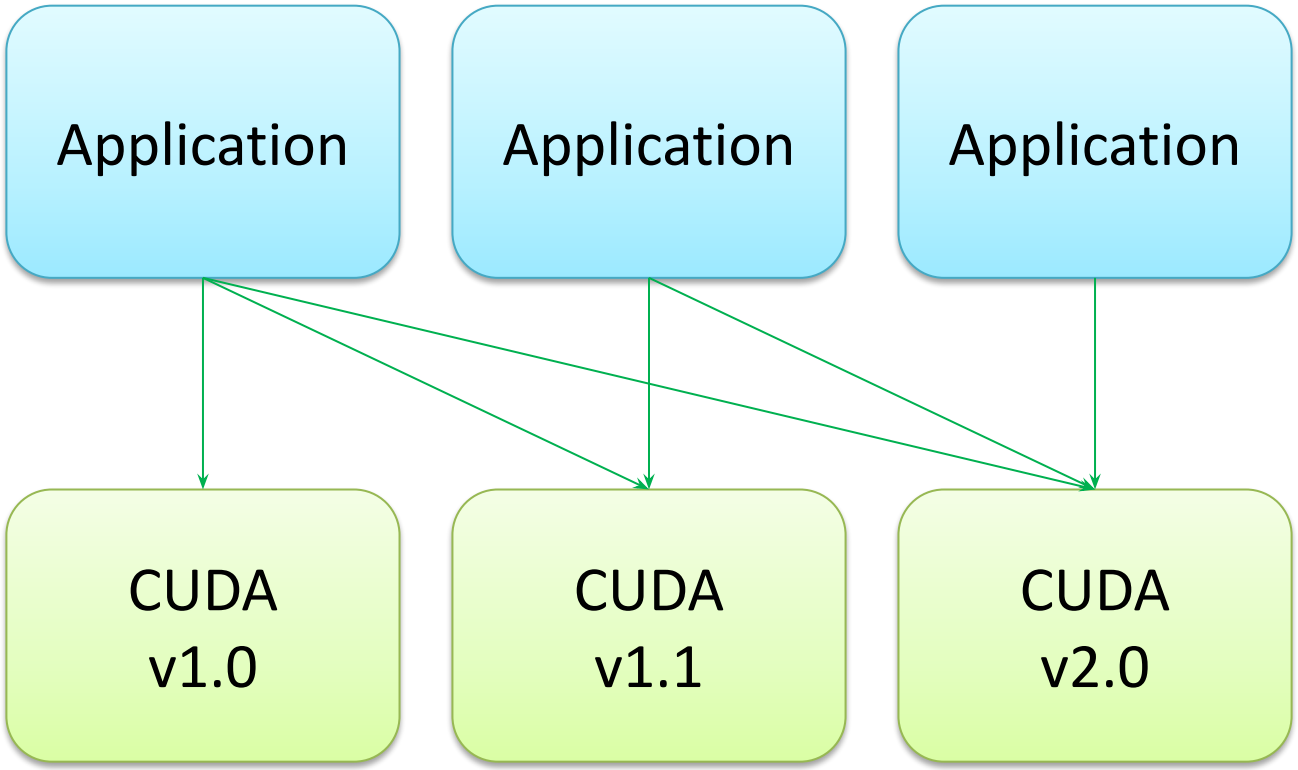

Вычислительные возможности GPU

- **Capability** – это версия архитектуры CUDA GPU, которая указывает на его вычислительные возможности и особенности

GPU	ВЫЧИСЛИТЕЛЬНЫЕ ВОЗМОЖНОСТИ
Tesla C2050/C2070	2.0
Tesla C1060	1.3
Tesla C870	1.0
Tesla D870	1.0

cudaGetDeviceProperties()

Способы оценки эффективности приложений CUDA

ОЦЕНКА ПРОИЗВОДИТЕЛЬНОСТИ

Время выполнения

- Общее время вычислений на GPU
- Время выполнения участка кода GPU

Таймеры CPU

- Таймеры CPU позволяют замерять общее время выполнения вычислений на GPU

```
LARGE_INTEGER frequency;
LARGE_INTEGER start, finish;

QueryPerformanceFrequency(&frequency);
QueryPerformanceCounter(&start);

// Обращение к GPU...

QueryPerformanceCounter(&finish);

double seconds = ((finish.QuadPart - start.QuadPart) / (double)(frequency.QuadPart));
```

cudaThreadSynchronize()

Таймеры CUDA

```
float time;
cudaEvent_t start, stop;

cudaEventCreate(&start);
cudaEventCreate(&stop);

cudaEventRecord(start, 0);

// Обращение к GPU...

cudaEventRecord(stop, 0);
cudaEventSynchronize(stop);

cudaEventElapsedTime(&time, start, stop);

cudaEventDestroy(start);
cudaEventDestroy(stop);
```

- Таймеры CUDA позволяют замерять время выполнения участка кода GPU

Скорость передачи данных

- Теоретическая пропускная способность

  $F_{DDRAM} * (R_{DDRAM}/8) * sizeof(float)$,
  где F_{DDRAM} – частота, R_{DDRAM} – разрядность шины

- Эффективная пропускная способность

  $(B_R + B_W) / time$,
  где B_R и B_W – объем прочитанной/записанной информации

- Реальная пропускная способность

Способы оптимизации работы с памятью CUDA GPU

ОПТИМИЗАЦИЯ РАБОТЫ С ПАМЯТЬЮ

Архитектура CUDA GPU

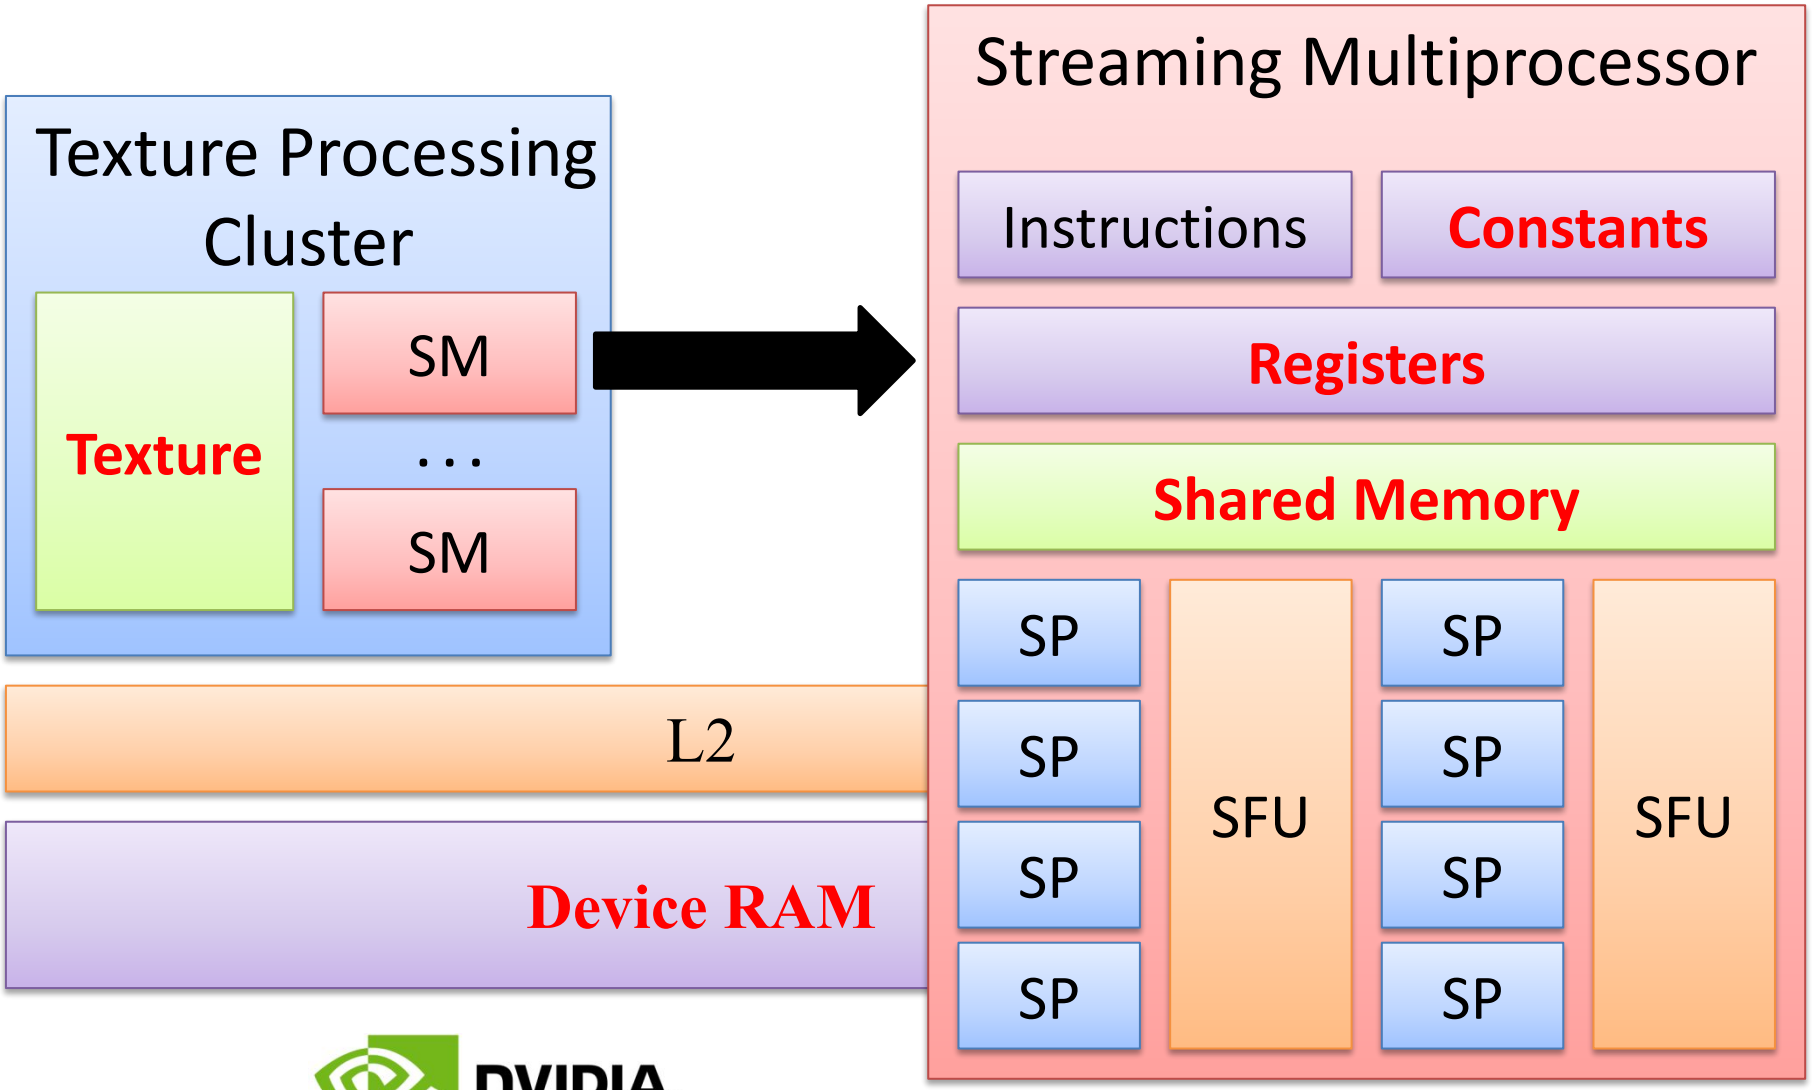

NVIDIA

Типы памяти устройства

- Streaming Multiprocessor
  - Регистровая память
  - Разделяемая память
  - Память констант
- Texture Processing Cluster
  - Память текстур
- DDRAM
  - Локальная память
  - Глобальная память

Передача данных Host/Device

- Является дорогостоящей операцией
- Возможна асинхронная передача

cudaMemcpy()
cudaMemcpyAsync()

Асинхронная передача данных

- Копирование данных и выполнение ядра можно осуществлять параллельно

```
for (int i = 0; i< countStreams; ++i)
{
   ...
   cudaMemcpyAsync(..., stream[i]);
}

for (int i = 0; i< countStreams; ++i)
{
   ...
   kernel<<<N / (countThreads * countStreams), countThreads, 0, stream[i]>>>(...);
}
```

Возможная оптимизация

- Синхронная передача данных в GPU

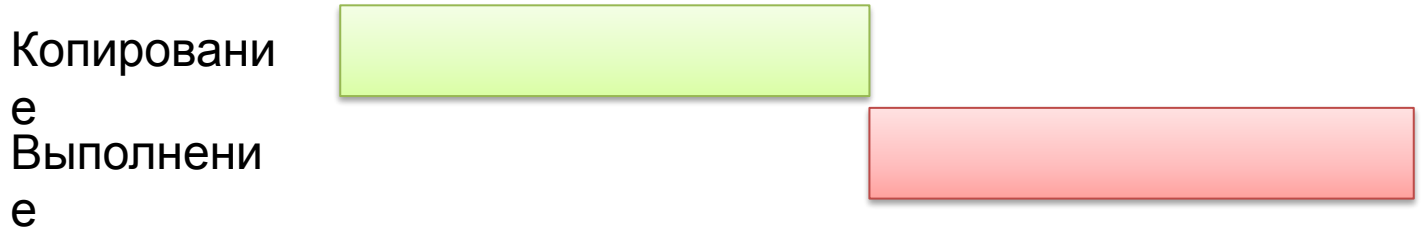

- Асинхронная передача данных в GPU

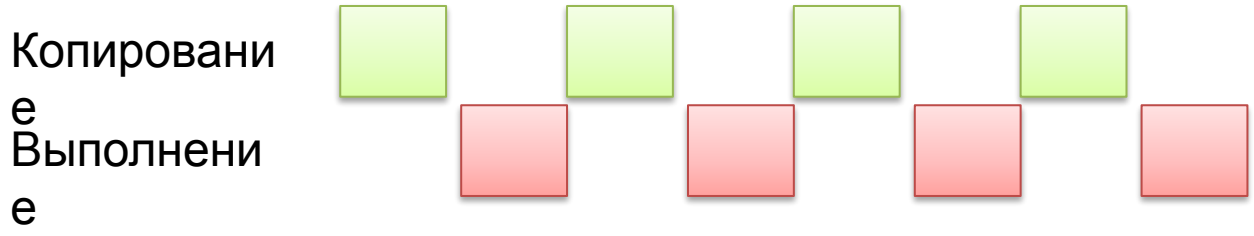

Нулевое копирование (Zero Copy)

- Прямое обращение к памяти Host’а
  - **Встроенные видеокарты**
    - Использование кэша CPU

Объединенное чтение DDRAM

- Выравнивание исходных данных по границе слова

- Потоки warp’а должны осуществлять одновременное чтение DDRAM

Разделяемая память и конфликты

- Общая для всех потоков блока
- Распределяется между блоками
- Разбивается на банки (32-битные слова)

Регистровое давление

- Регистры жестко распределяются между потоками мультипроцессора
- При большом количестве потоков возникает конфликт доступа к регистрам

Методы оценки топологии вычислений CUDA

ВЫБОР ОПТИМАЛЬНОЙ ТОПОЛОГИИ

Степень покрытия

- Степень покрытия мультипроцессора – это отношение числа активных warp'ов к максимально возможному числу активных warp'ов
  - По количеству используемых регистров
    - С учетом топологии вычислений
    - Без учета топологии вычислений
  - По размеру используемой разделяемой памяти

Определение степени покрытия

- CUDA GPU:
  - 8192 регистра
  - 768 потоков на мультипроцессор
- Топология:
  - 12 регистров на ядро
  - 128 потоков в блоке

T_{max} = 8192 регистров / 12 регистров = 682 потока
T_{real} = int(682 / 128) * 128 = 640 потоков
$C = T_{real} / T_{max}$ = 83%

Оптимизация инструкций CUDA

ОПТИМИЗАЦИЯ КОДА

Регистровая зависимость

- Инструкция использует регистр, значение которого было получено при выполнении предыдущей инструкции

```
register = instruction1();
instruction2(register);
```

Float vs Double

- Арифметические операции с float-числами осуществляются быстрей, чем с double-числами
  - Рекомендуется использовать суффикс «f» при объявлении числовых констант, например, 3.14f

Деление чисел

- При делении чисел на **степень двойки** рекомендуется использовать оператор сдвига

$$X / N \rightarrow X >> \log_2(N)$$

$$X \% N \rightarrow X \& (N-1)$$

Степень числа

- Для известных целых значений степеней рекомендуется использовать явное умножение вместо вызова **pow()**

```
pow(X, 2) → X * X
pow(X, 3) → X * X * X
```

Часто используемые функции

- Обратный квадратный корень
  - rsqrtf() / rsqrt()

- Прочие арифметические операции
  - expf2() / exp2() – экспонента во **2**-й степени
  - expf10() / exp10() – экспонента в **10**-й степени
  - cbrtf() / cart() – экспонента в степени **1/3**
  - rcbrtf() / rebut() – экспонента в степени **-1/3**

Точность vs Скорость

- Аппаратные аналоги функций
  __sinf() / sinf()
  __cosf() / cosf()
  __expf() / expf()

- Совмещенные функции
  sincosf() / sincos()

Общие рекомендации по написанию кода

УПРАВЛЕНИЕ ПОТОКОМ КОМАНД

Операторы ветвления

- Инструкции управления потоком команд (if, switch, for, while, do-while) отрицательно сказываются на производительности
  - **В идеале все потоки warp'а должны идти по одному пути**, иначе увеличивается количество выполняемых инструкций и возможно последовательное выполнение

Предикативная запись

```
if (a >= b)
{
    c = a;
}
else
{
    c = b;
}
```

```
c = (a >= b) & a + (a < b) & b;
```

Отладка и профилирование приложений CUDA

ОТЛАДКА И ПРОФИЛИРОВАНИЕ

Существующие утилиты

- Linux
  - **CUDA-GDB**
  - http://developer.nvidia.com/cuda-gdb

- Windows Vista & Windows 7
  - **NVIDIA Parallel Nsight**
  - http://developer.nvidia.com/nvidia-parallel-nsight

Краткий обзор архитектурных особенностей GPU

АППАРАТНЫЕ ОСОБЕННОСТИ GPU

Причины рассогласования

- Основные причины рассогласования результатов вычислений на GPU и CPU
  - Усечение double чисел до float при отсутствии аппаратной поддержки double
  - Неассоциативность арифметических операций с дробными числами
  - Небольшие отклонения от стандарта IEEE 754
  - Особенности архитектуры процессоров x86

Литература

- NVIDIA Developer Zone
  - http://developer.nvidia.com/cuda
- NVIDIA Parallel Nsight
  - http://developer.nvidia.com/cuda-gdb
- CUDA C Best Practices Guide
  - http://developer.download.nvidia.com/compute/cuda/**4_0**/toolkit/docs/CUDA_C_Best_Practices_Guide.pdf

ВОПРОСЫ?