3 Технология GPGPU

General-Purpose computation on Graphics Processing Units - высокопроизводительные общие вычисления на GPU.

Graphics Processing Unit (GPU) - высокопроизводительный многопроцессорный блок, использующийся в графическом конвейере видеокарты для ускорения графических операций.

Два основных производителя видеокарт, NVIDIA и AMD, разработали и анонсировали соответствующие платформы под названием **CUDA (Compute Unified Device Architecture)** и **CTM (Close To Metal или AMD Stream Computing)**

3.1 Графический конвейер

1. *Построение геометрической модели*
2. *Деление поверхности объекта на плоские простейшие элементы (тесселяция, tesselation)*
3. *Трансформация*
4. *Освещенность (lighting) и затенение (shading)*
5. *Проецирование*
6. *Обработка координат вершин*

7. *Удаление скрытых поверхностей*
8. *Наложение текстур*
9. *Эффекты прозрачности и полупрозрачности*
10. *Коррекция дефектов*
11. *Интерполяция цветов (disering)*

Выходная информация 3D-конвейера - это комплекс рассчитанных данных о каждом пикселе, которые помещаются в видеопамять.

Схема графического конвейера

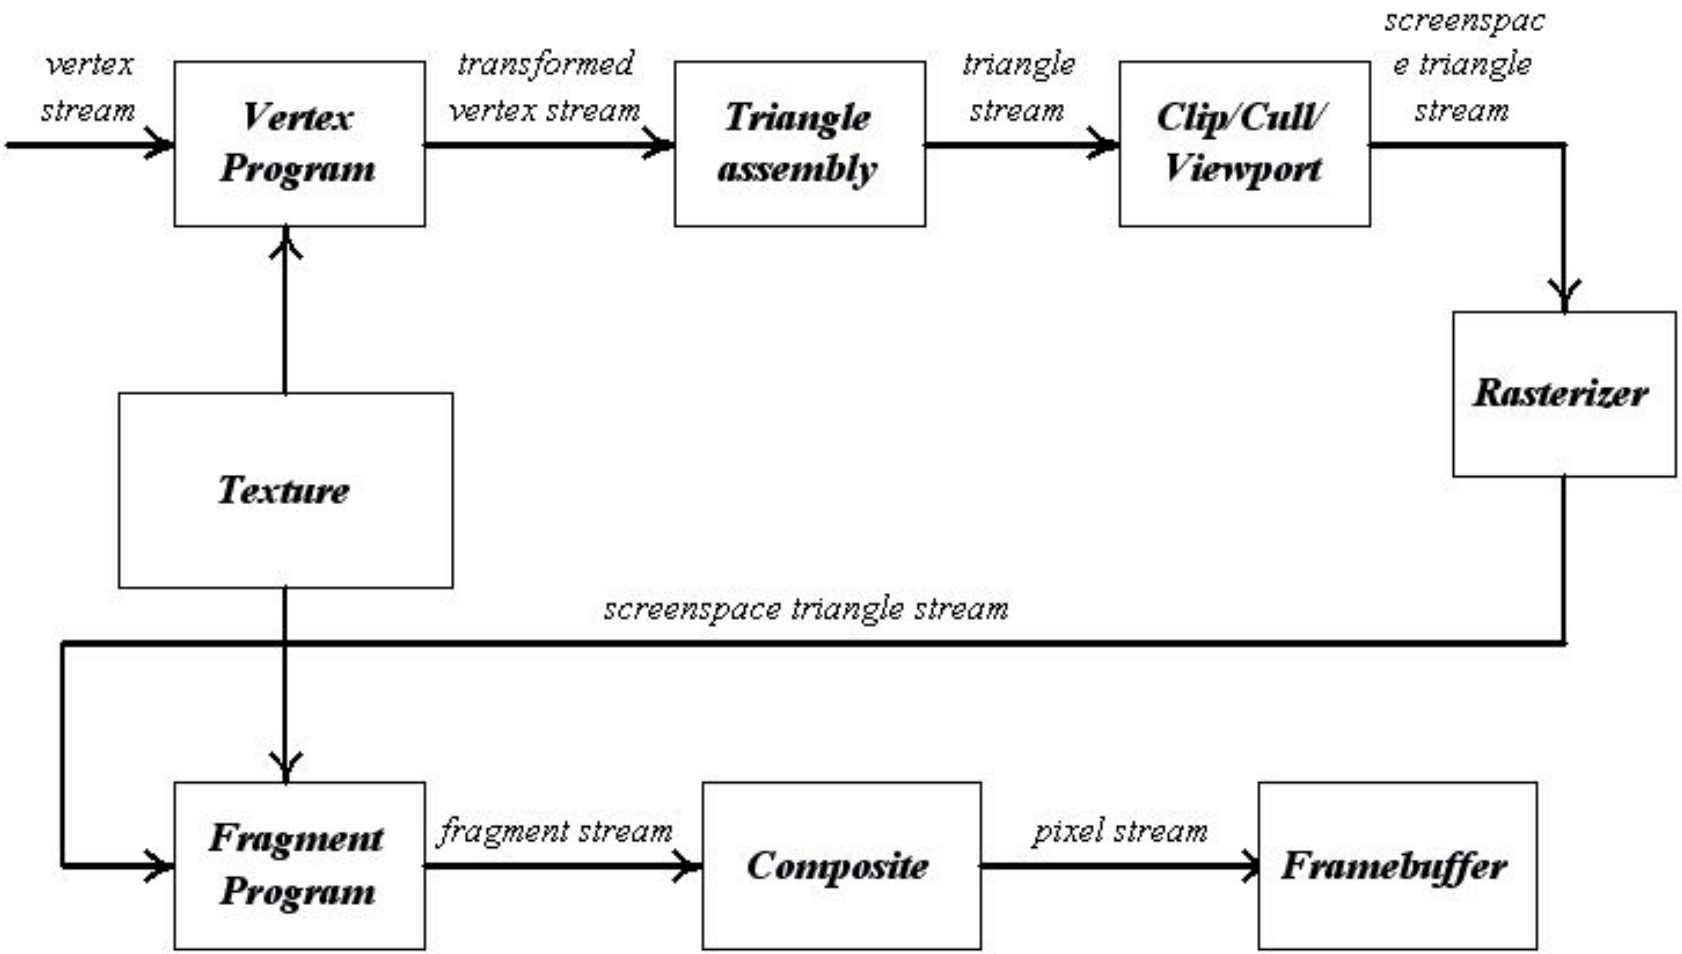

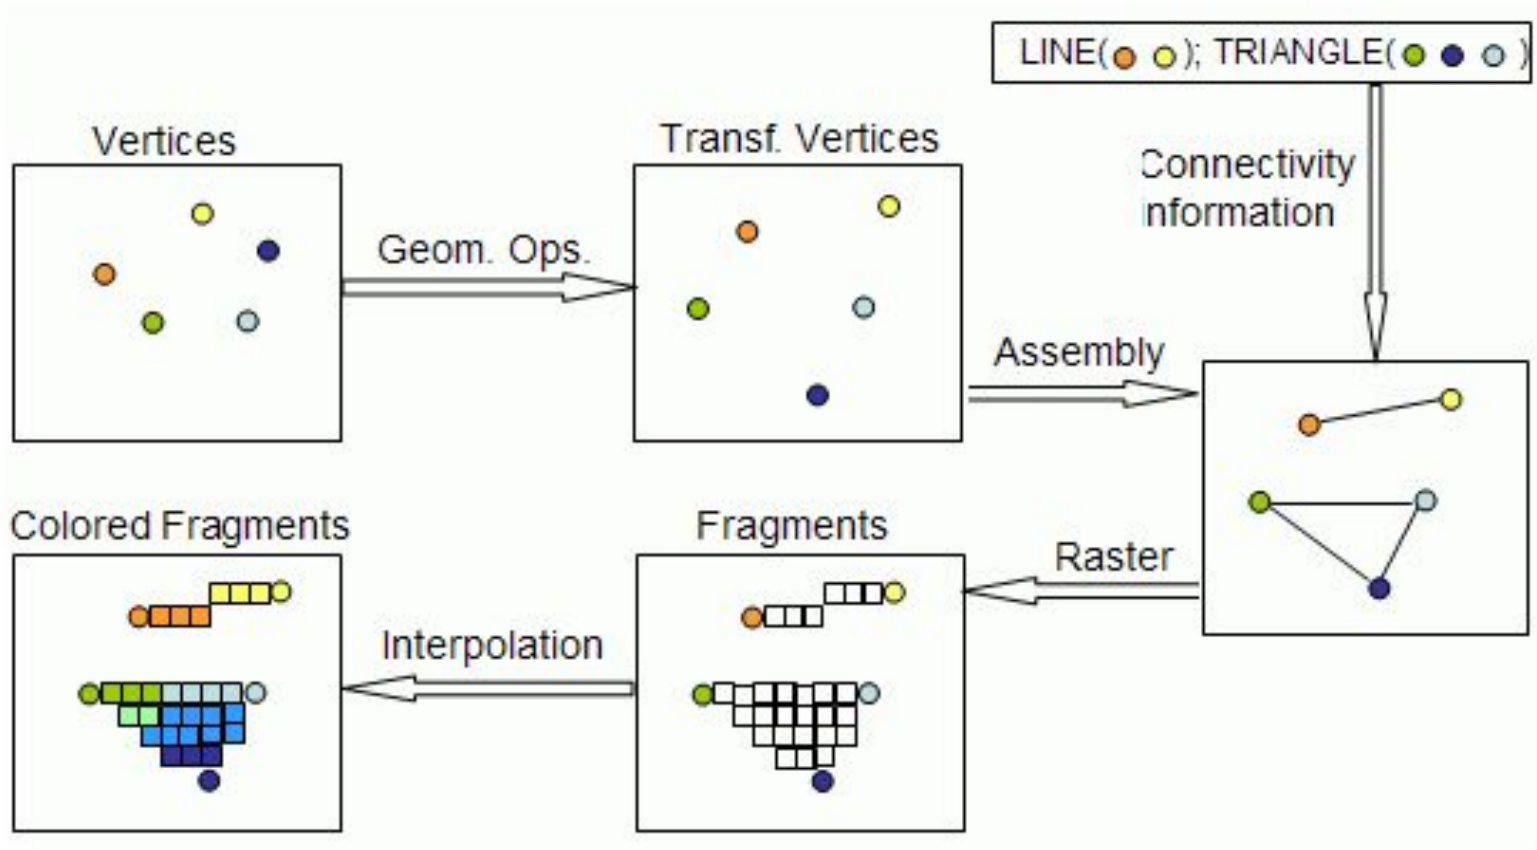
LINE( ); TRIANGLE( )
Vertices
Geom. Ops.
Transf. Vertices
Connectivity
nformation
Assembly
Colored Fragments
Interpolation
Fragments
Raster

3.2 Сравнение архитектуры центрального процессора и графического процессора

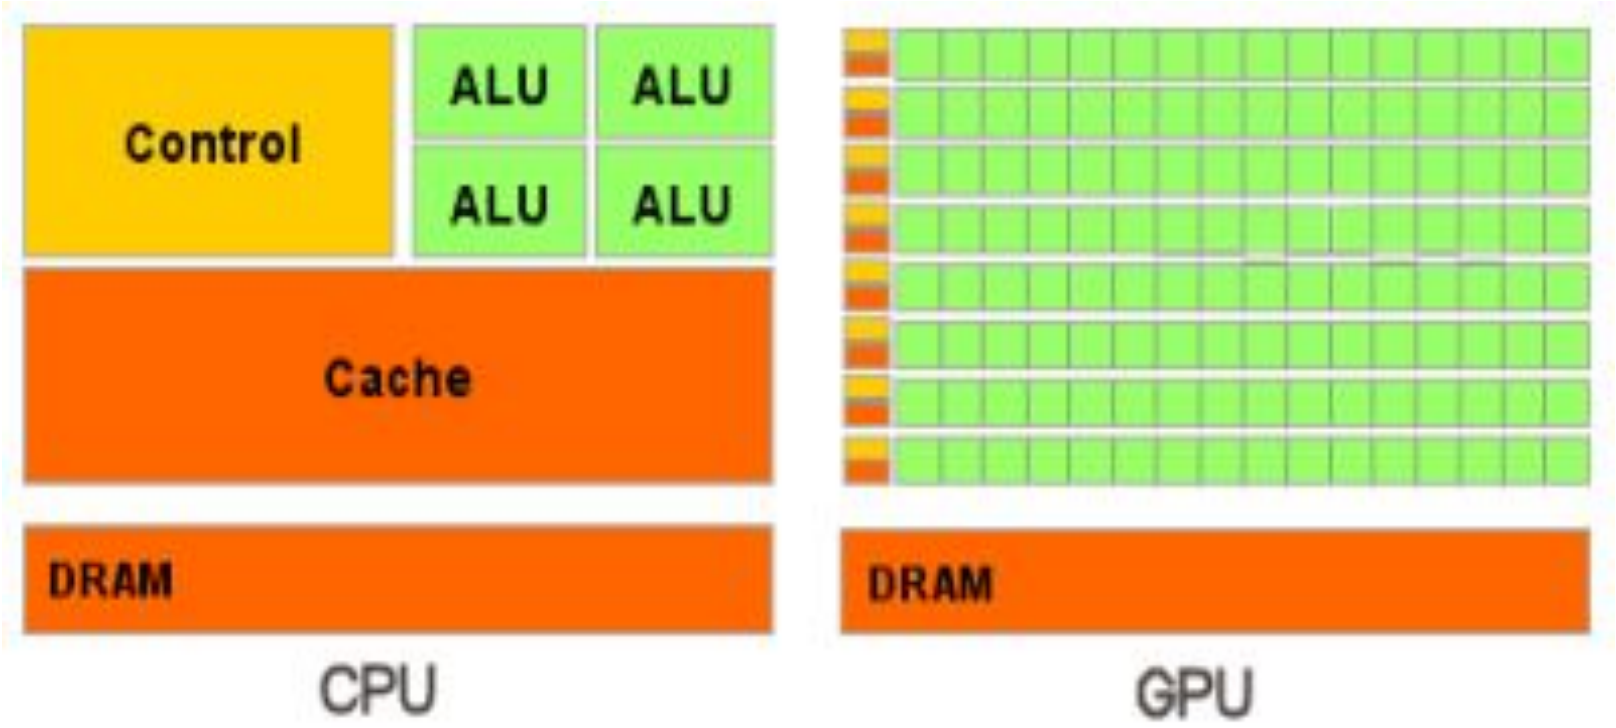

Пример: Характеристики Nvidia GeForce GTX 590

- Технология производства 40 нм;
- 2 чипа по 3 миллиарда транзисторов каждый;
- Унифицированная архитектура с массивом процессоров для потоковой обработки различных видов данных: вершин, пикселей и др.;
- Аппаратная поддержка DirectX 11;
- Двойная 384-битная шина памяти: дважды по шесть независимых контроллеров шириной по 64 бита каждый, с поддержкой GDDR5 памяти;
- Частота ядра 607 МГц;
- Удвоенная частота АЛУ 1215 МГц;
- 2×16 потоковых мультипроцессоров, включающих в общем 1024 скалярных АЛУ для расчётов с плавающей точкой (целочисленные и плавающие форматы, поддержка одинарной и двойной точности в рамках стандарта IEEE 754-2008);
- 2×64 блока текстурной адресации и фильтрации с поддержкой FP16- и FP32-компонент в текстурах и поддержкой трилинейной и анизотропной фильтрации для всех текстурных форматов;
- 2×6 широких блоков ROP (всего 96 пикселей) с поддержкой режимов антиалиасинга до 32 выборок на пиксель, в том числе при FP16- или FP32-формате буфера кадра. Каждый блок состоит из массива конфигурируемых ALU и отвечает за генерацию и сравнение Z, MSAA, блендинг;
- Для каждого GPU интегрированная поддержка RAMDAC, двух портов Dual Link DVI, а также HDMI и DisplayPort.

Аппаратная архитектура GPU

GPU – набор мультипроцессоров

- SPA – Streaming Processor Array
- TPC - Texture Processor Cluster
- SM – Streaming Multiprocessor
  - Multi-threaded processor core
  - Fundamental processing unit for CUDA thread block
- SP - Streaming Processor
  - Scalar ALU for a single CUDA thread

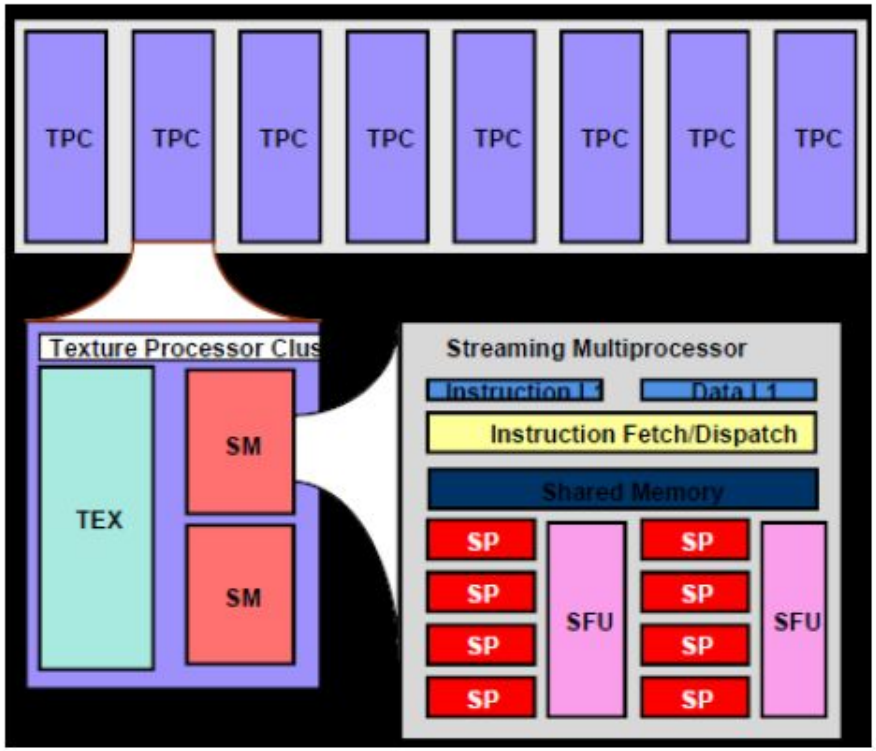

Аппаратная реализация : Модель исполнения

- **Каждый блок потоков состоит из warp'ов**
  - Warp – SIMD-группа потоков фиксированного размера, состоящая из скалярных потоков с последовательными координатами.
- **Блок потоков всегда исполняется только на одном мультипроцессоре**
  - Разделяемые переменные блока потоков хранятся в on-chip модуле разделяемой памяти мультипроцессора
  - Файл локальных регистров делится между всеми потоками, обрабатываемыми мультипроцессором
    - ✓ Слишком большого размер блока потоков для ядра, использующего слишком много локальных регистров, вызывает сбой этапа исполнения
- **Мультипроцессор может обрабатывать несколько блоков потоков одновременно**
  - Локальный регистровый файл и разделяемая память делятся между всеми потоками / блоками потоков, работающими одновременно
  - Тем самым, с уменьшением числа используемых локальных регистров (на поток) и размера используемой разделяемой памяти (на блок) увеличивается число потоков / блоков потоков, способных одновременно находиться в обработке
  - Не влияет на логику работы, только на производительность
    - ✓ На логическом уровне блоки потоков всегда изолированы