

Архитектура и программирование массивно- параллельных вычислительных систем

Лекторы:

Боресков А.В. (ВМиК МГУ)

Харламов А. (NVIDIA)

План

- Существующие архитектуры
- Классификация
- Эволюция GPU
- GP GPU
- Несколько слов о курсе
- Дополнительные слайды

План

- Существующие архитектуры
 - Intel CPU
 - SMP
 - CELL
 - BlueGene
 - NVIDIA Tesla/GeForce
- Классификация
- CUDA
- Несколько слов о курсе
- Дополнительные слайды

Существующие многоядерные системы

Посмотрим на частоты CPU:

- 2004 г. - Pentium 4, 3.46 GHz
- 2005 г. - Pentium 4, 3.8 GHz
- 2006 г. - Core Duo T2700, 2333 MHz
- 2007 г. - Core 2 Duo E6800, 3 GHz
- 2008 г. - Core 2 Duo E8600, 3.33 Ghz
- 2009 г. - Core i7 950, 3.06 GHz
- 2010 г. - Core i5, 3.6 GHz
- 2011 г. - Core i7 Extreme 3.9 Ghz

Существующие многоядерные системы

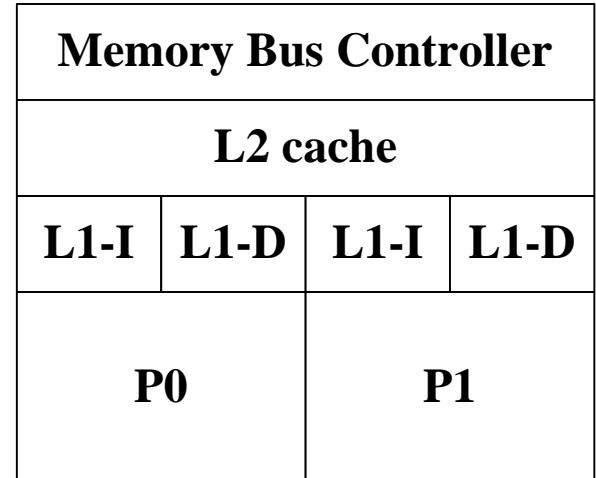
- Роста частоты практически нет
 - Энерговыделение ~ второй степени частоты
 - Ограничения техпроцесса
 - Одноядерные системы зашли в тупик

Существующие многоядерные системы

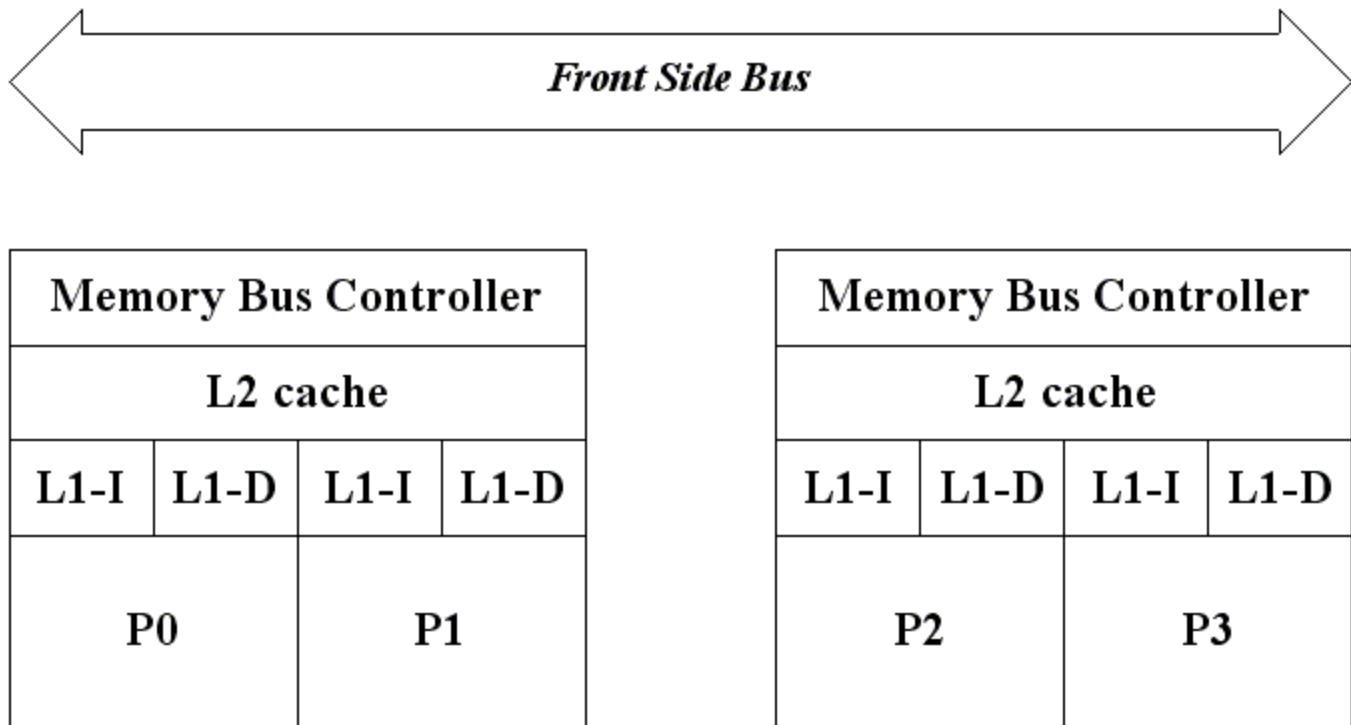
- Повышение быстродействия следует ждать от параллельности.
- CPU используют параллельную обработку для повышения производительности
 - Конвейер
 - Multithreading
 - SSE

Intel Core 2 Duo

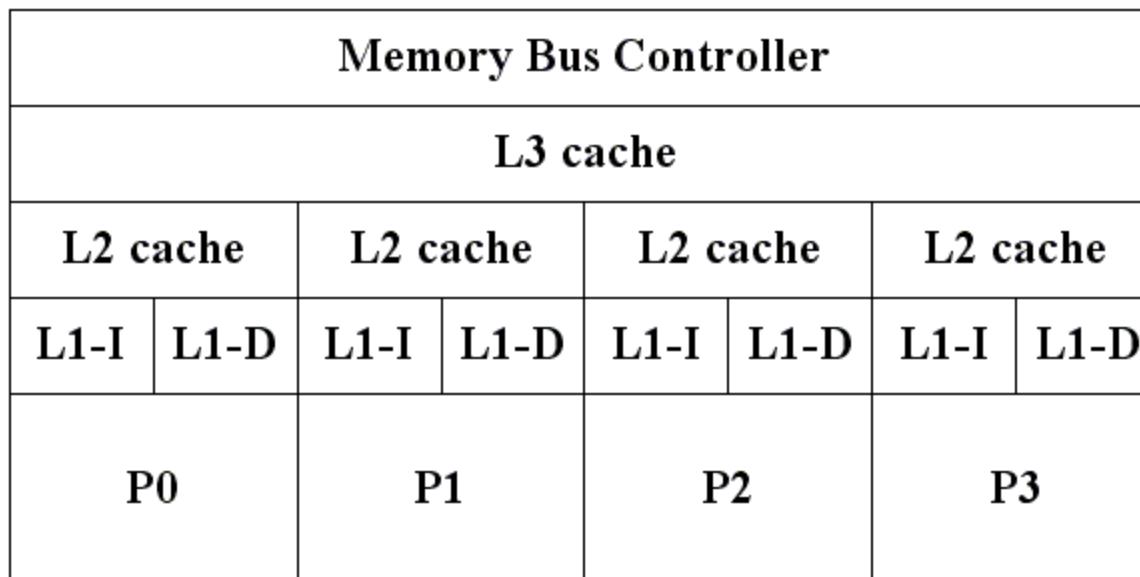
- 32 Кб L1 кэш для каждого ядра
- 2/4 Мб общий L2 кэш
- Единый образ памяти для каждого ядра - необходимость синхронизации кэшей



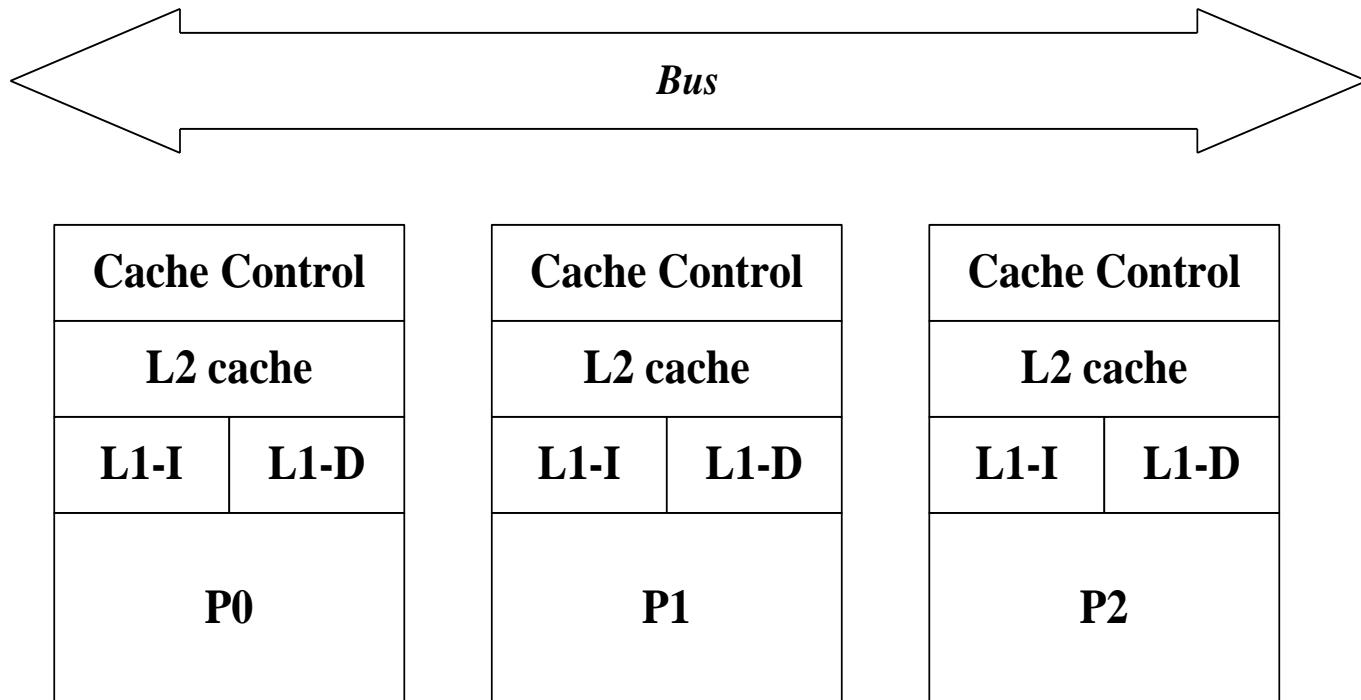
Intel Core 2 Quad



Intel Core i7



Symmetric Multiprocessor Architecture (SMP)



Symmetric Multiprocessor Architecture (SMP)

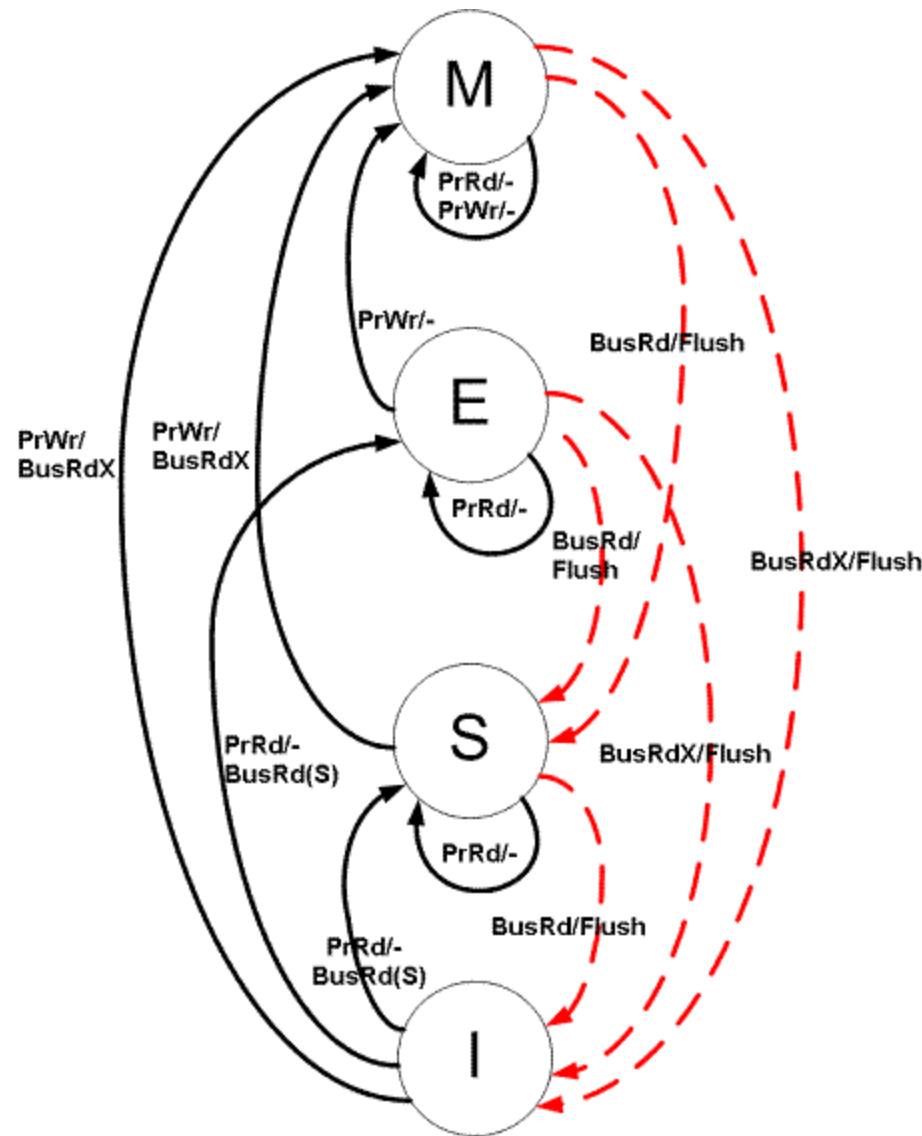
Каждый процессор

- имеет свои L1 и L2 кэши
- подсоединен к общей шине
- **отслеживает доступ других процессоров к памяти** для обеспечения единого образа памяти (например, один процессор хочет изменить данные, кэшированные другим процессором)

Отслеживание кэшей для обеспечения целостности памяти

- Протокол MESI
 - (M)odified - есть только в одном кэше и dirty
 - (E)xclusive - есть только в одном кэше и clean
 - (S)hared - есть в нескольких кэшах и clean
 - (I)nvalid

Конечный автомат для MESI



Пример

- Есть массив данных длины N
- Нужно на 4-ядерном процессоре найти число «7» в этом массиве
- Запускаем 4 нити (по одной на каждый процессор), каждая нить получает четверть массива

Пример

- Общий счетчик для всех нитей
 - На каждой записи будет синхронизация всех кэшей
- Отдельный счетчик на каждую нить
 - Все зависит от их расположения в памяти

Расположение счетчиков в памяти

```
int counts [4];
```

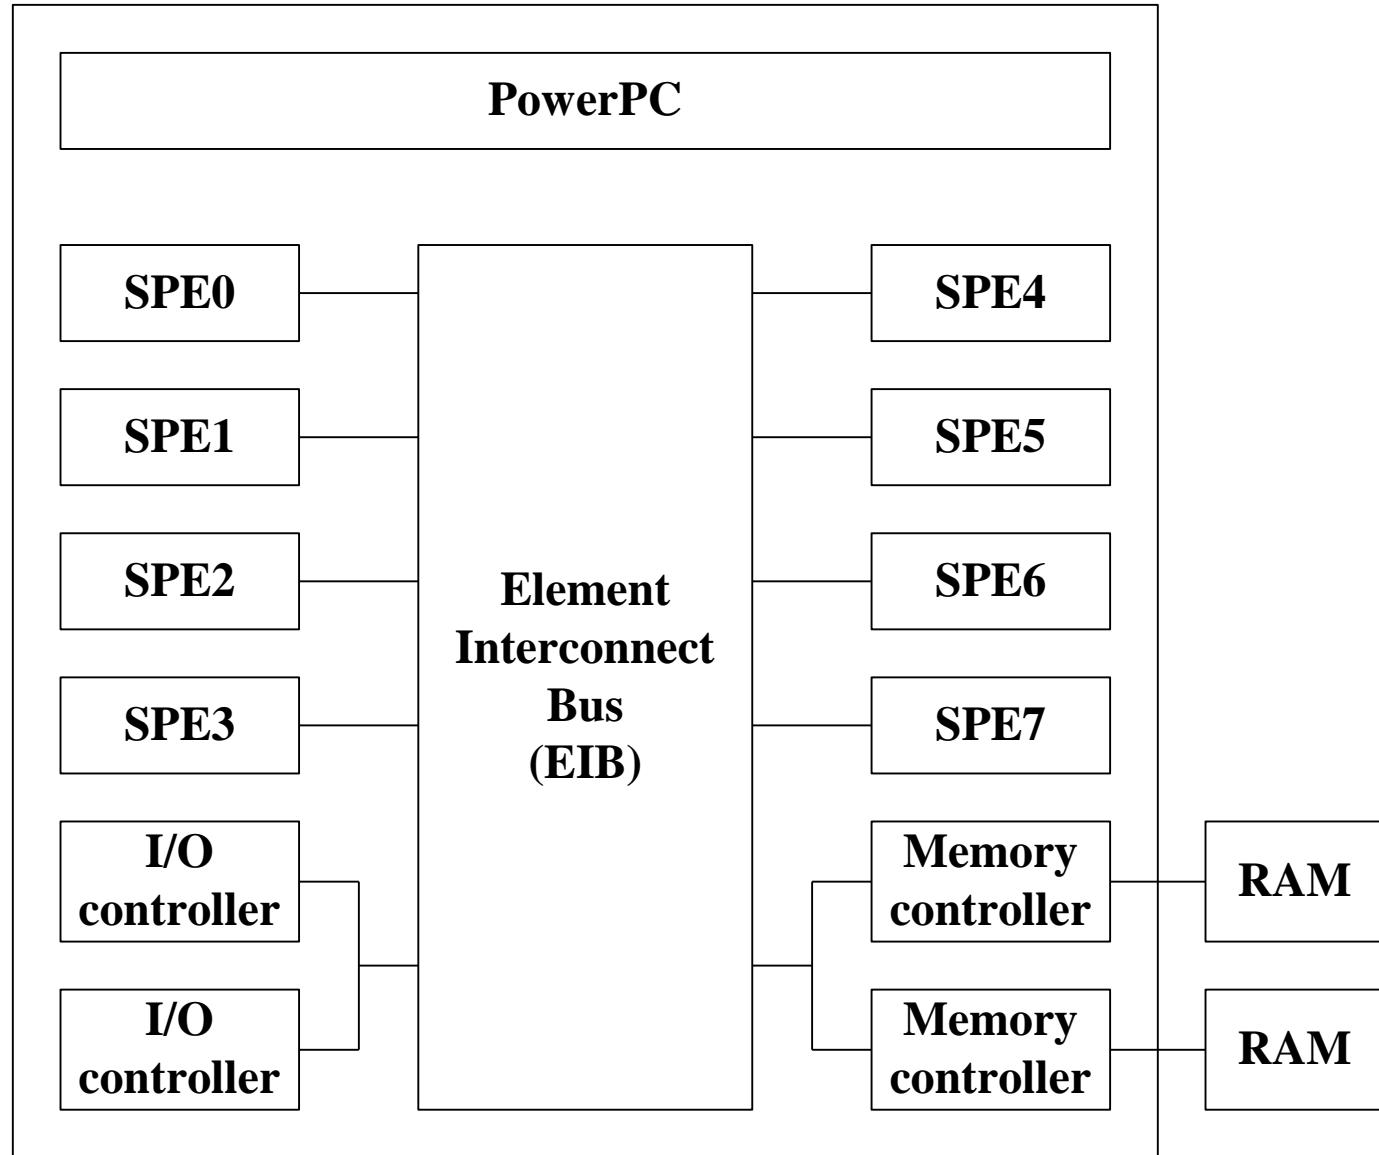
- Кэш работает группами байтов (линейками), обычно 32-64 байта
- Скорее всего они попадут в одну линейку и на каждую запись в один из счетчиков будет идти полная синхронизация всей линейки

Расположение счетчиков в памяти

```
struct {  
    int count;  
    char dummy [32-4];  
} counts [4];
```

- Тогда каждый счетчик попадает в свою 32-байтовую линейку

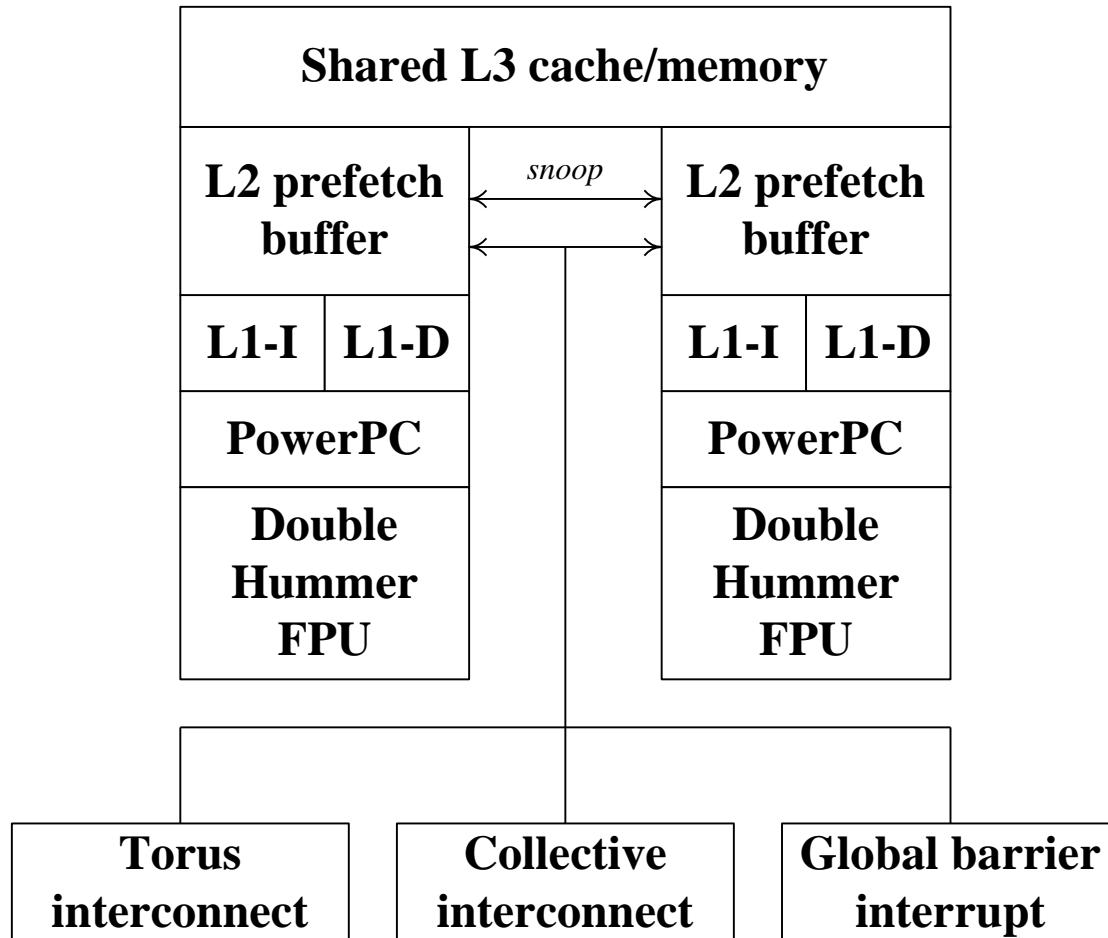
Cell



Cell

- Dual-threaded 64-bit PowerPC
- 8 Synergistic Processing Elements (SPE)
- 256 Kb on-chip на каждый SPE

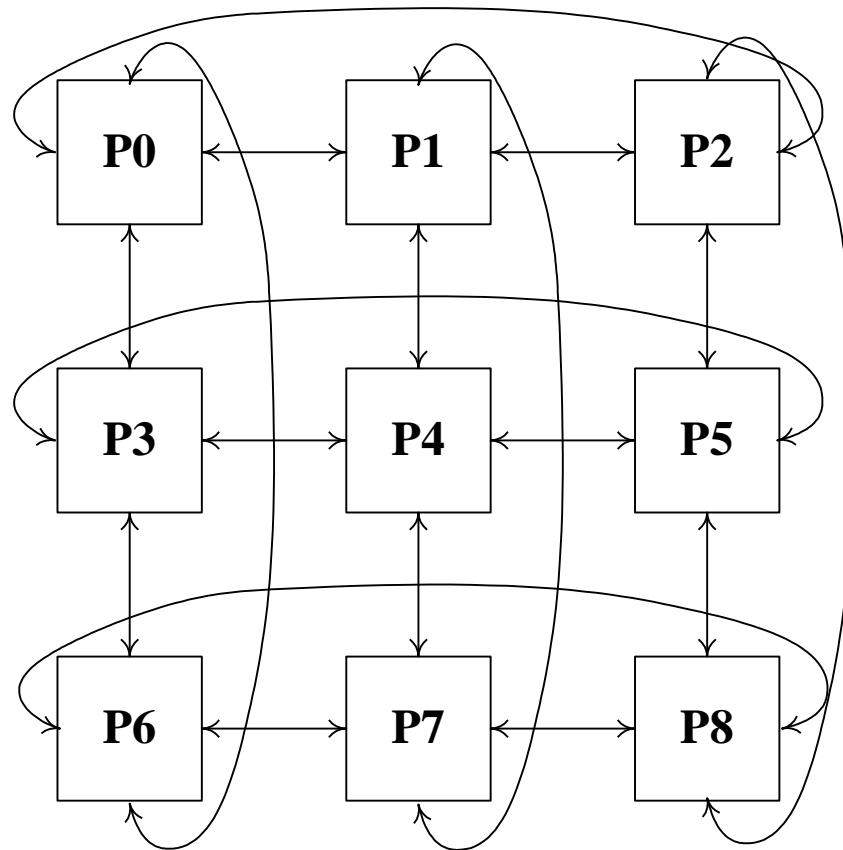
BlueGene/L



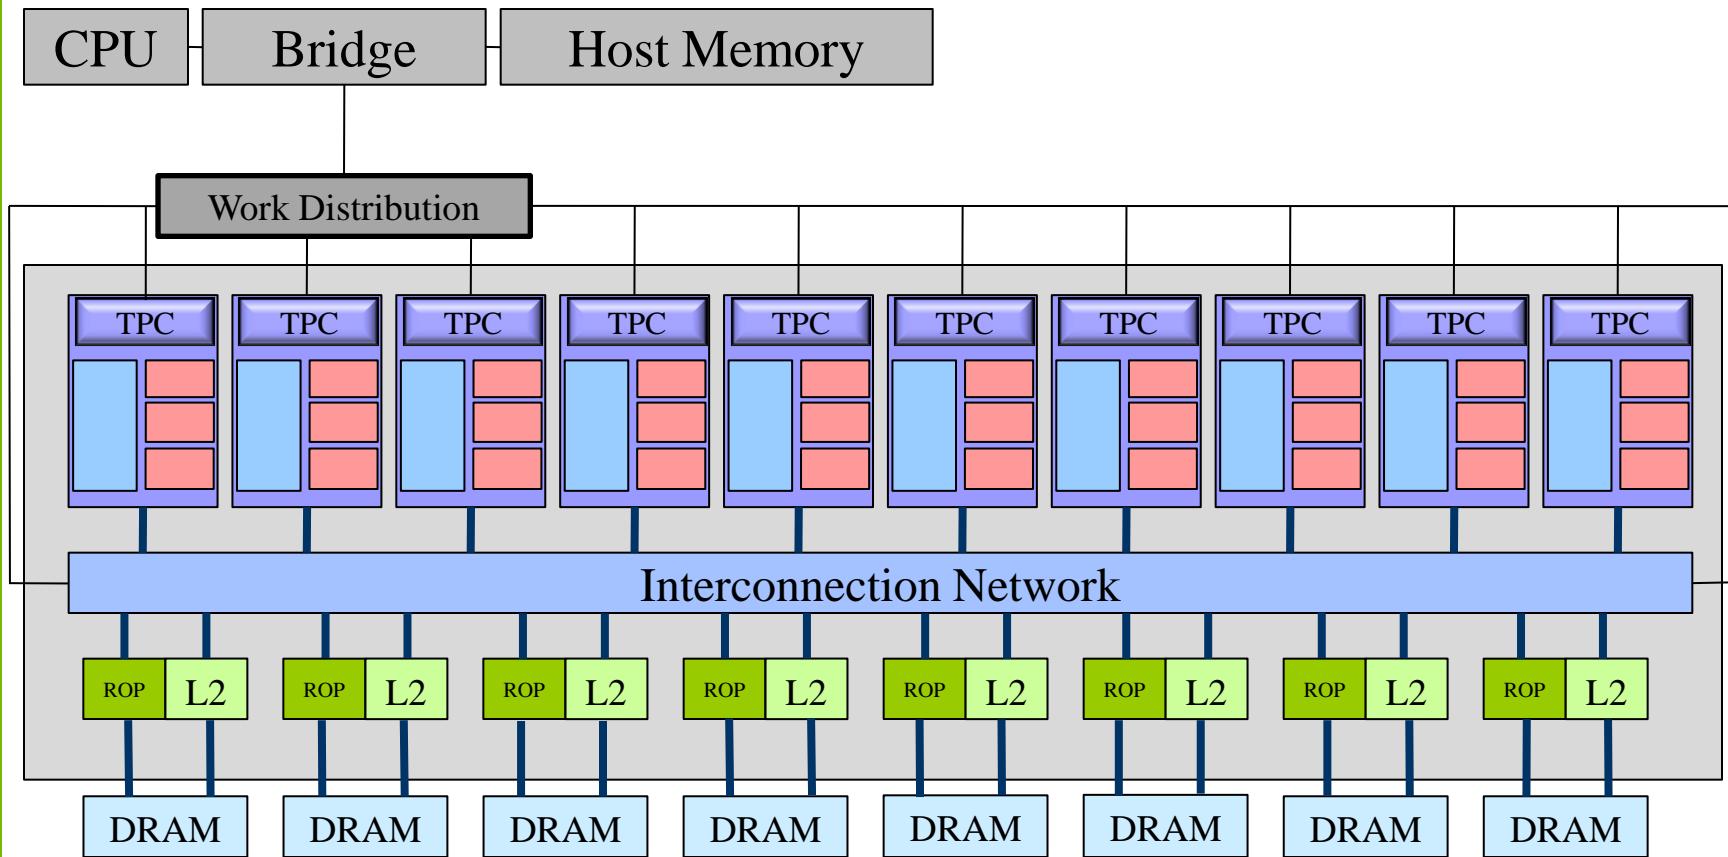
BlueGene/L

- 65536 dual-core nodes
- node
 - 770 Mhz PowerPC
 - Double Hammer FPU (4 Flop/cycle)
 - 4 Mb on-chip L3 кэш
 - 512 Mb off-chip RAM
 - 6 двухсторонних портов для 3D-тора
 - 3 двухсторонних порта для collective network
 - 4 двухсторонних порта для barrier/interrupt

BlueGene/L

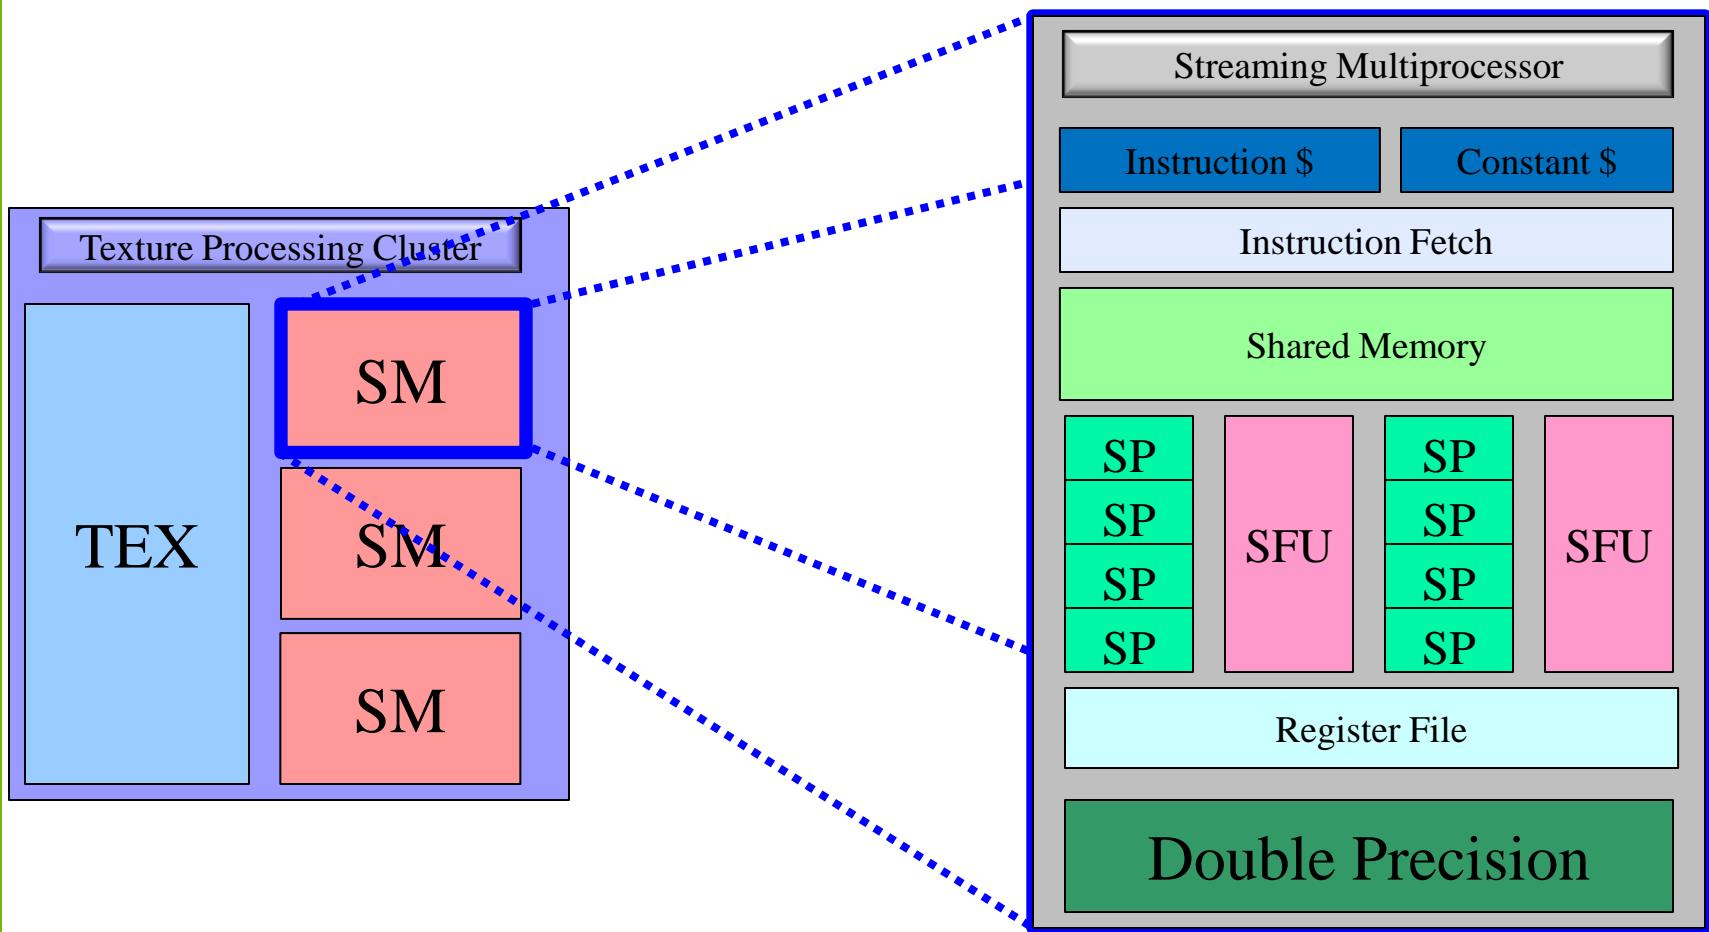


Архитектура Tesla 10



Архитектура Tesla

Мультипроцессор Tesla 10



Технические детали

- RTM CUDA Programming Guide
- Run CUDAHelloWorld
 - Печатает аппаратно зависимые параметры
 - Размер shared памяти
 - Кол-во SM
 - Размер warp'a
 - Кол-во регистров на SM
 - т.д.

План

- Существующие архитектуры
- Классификация
 - Примеры для CPU
- CUDA
- Несколько слов о курсе
- Дополнительные слайды

Классификация

	Single Instruction	Multiple Instruction
Single Data	SISD	MISD
Multiple Data	SIMD	MIMD

Классификация

- CPU - SISD
 - Multithreading: позволяет запускать множество потоков - параллелизм на уровне задач (MIMD) или данных (SIMD)
 - SSE: набор 128 битных регистров ЦПУ
 - можно запаковать 4 32битных скаляра и проводить над ними операции одновременно (SIMD)
- GPU - SIMD*

MultiThreading “Hello World”

```
#include <stdio.h>
#include <windows.h>
#include <process.h>    // для beginthread()
void mtPrintf( void * pArg);

int main()
{
    int t0 = 0; int t1 = 1;
    _beginthread(mtPrintf, 0, (void*)&t0 );
    mtPrintf( (void*)&t1 );
    Sleep( 100 );
    return 0;
}

void mtPrintf( void * pArg )
{
    int * pIntArg = (int *) pArg;
    printf( "The function was passed %d\n", (*pIntArg) );
}
```

MultiThreading “Hello World”

```
// создание нового потока  
// необходимо указать:  
// entry point функцию,  
// размер стека, при 0 - OS выберет сама  
// (void *) - указатель на аргументы функции  
_beginthread(mtPrintf, 0, (void*)&t1 );  
  
// напечатать из основного потока  
mtPrintf( (void*)&t0 );  
  
// подождать 100 мс  
// создание потока windows требует времени  
// если основной поток закончит выполнение  
// то и все дочерние потоки будут прерваны  
Sleep( 100 );
```

SSE “Hello World”

```
#include <xmmmintrin.h>
#include <stdio.h>

struct vec4
{
    union
    {
        float    v[4];
        __m128   v4;
    };
};

int main()
{
    vec4 c, a = {5.0f, 2.0f, 1.0f, 3.0f}, b = {5.0f, 3.0f, 9.0f, 7.0f};
    c.v4 = _mm_add_ps(a.v4, b.v4);
    printf("c = %.3f, %.3f, %.3f, %.3f\n", c.v[0], c.v[1], c.v[2], c.v[3]);
    return 0;
}
```

CPU

- Параллельное программирование CPU требует специальных API
 - MPI, OpenMP
- Программирование ресурсов CPU ограничено
 - Multithreading
 - SSE
 - Ограничивает пропускная способность памяти

SIMD

- На входе поток однородных элементов, каждый из которых может быть обработан независимо
- На выходе – однородный поток
- Обработкой занимается ядро (kernel)

SIMD



- Каждый элемент может быть обработан независимо от других
 - Их можно обрабатывать параллельно
- Можно соединять между собой отдельные ядра для получения более сложного конвеера обработки

План

- Существующие архитектуры
- Классификация
- CUDA
 - Программная модель
 - Связь программной модели с HW
 - SIMD
 - Язык CUDA C
 - Примеры для CUDA
- Несколько слов о курсе
- Дополнительные слайды

Эволюция GPU

- 3DFx Voodoo
 - Растеризация треугольников (вершины уже спроектированы)
 - Буфер глубины
 - Текстурирование треугольников
 - Альфа-блэндинг

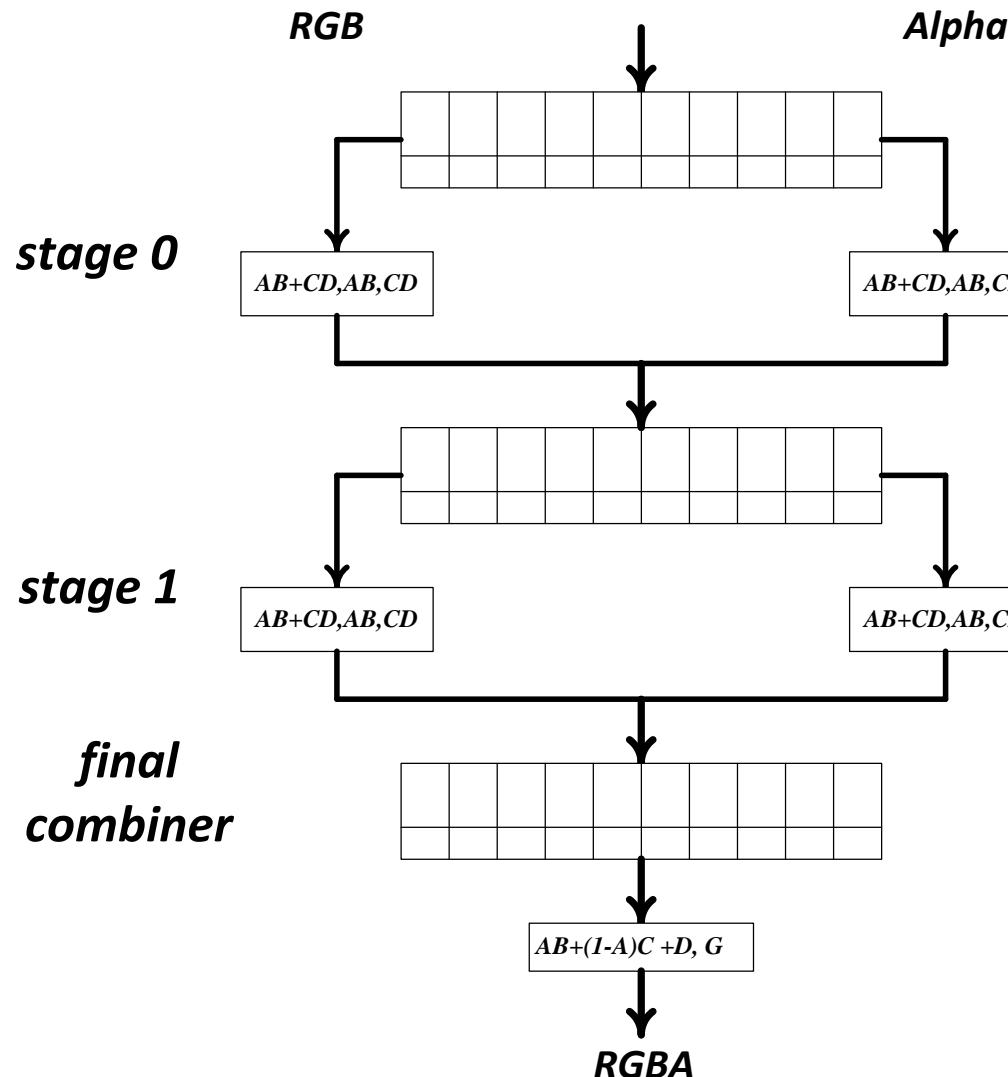
GPU как SIMD

- Потоки вершин и фрагментов
- Каждая вершина может обрабатываться независимо от других но по одним и тем же правилам
- Каждый фрагмент может обрабатываться независимо от других но по тем же правилам

Развитие GPU

- Увеличение быстродействия
 - Достаточно увеличить число вершинных и фрагментных блоков
- Увеличение гибкости
 - Хочется задавать законы обработки вершин и фрагментов

Развитие GPU, register combiners



Развитие GPU. Шейдеры

- Наибольшая гибкость - возможность задания программы для обработки (шейдера)
- Первыми появились вершинные шейдеры (GeForce 2/3)
- Затем фрагментные (GeForceFX 5xxx)
- Изначально писались на специальном ассемблере

Пример вершинного шейдера

```
!!ARBvp1.0

ATTRIB pos      = vertex.position;
PARAM mat [4] = { state.matrix.mvp };

# transform by concatenation of modelview and projection matrices

DP4 result.position.x, mat [0], pos;
DP4 result.position.y, mat [1], pos;
DP4 result.position.z, mat [2], pos;
DP4 result.position.w, mat [3], pos;

# copy primary color

MOV result.color, vertex.color;
END
```

Высокоуровневые шейдерные языки

```
varying vec3 lt;
varying vec3 ht;
uniform sampler2D tangentMap;
uniform sampler2D decalMap;
uniform sampler2D anisoTable;
void main (void)
{
    const vec4 specColor = vec4 ( 0, 0, 1, 0 );
    vec3 tang = normalize ( 2.0*texture2D ( tangentMap, gl_TexCoord [0].xy ).xyz - 1.0 );
    float dot1 = dot ( normalize ( lt ), tang );
    float dot2 = dot ( normalize ( ht ), tang );
    vec2 arg = vec2 ( dot1, dot2 );
    vec2 ds = texture2D ( anisoTable, arg*arg ).rg;
    vec4 color = texture2D ( decalMap, gl_TexCoord [0].xy );
    gl_FragColor = color * ds.x + specColor * ds.y;
    gl_FragColor.a = 1.0;
}
```

Развитие GPU

- Набор вершинных процессоров
- Набор фрагментных процессоров
- Поддержка текстур с компонентами типа float (полноценные многомерные массивы)
- Все операции выполняются над float'ми
- Итоговое быстродействие на порядок выше чем у CPU

GPGPU

- Использование вычислительной мощи GPU для решения неграфических задач
 - Сортировка
 - N-частиц
 - Быстрое преобразование Фурье
- Код пишется сразу на двух языках – традиционном (C++) и шейдерном (GLSL)

Ограничение GPGPU

- Необходимость использовать графического API (OpenGL, DX)
- Отсутствует возможность взаимодействия между параллельно обрабатываемыми элементами
- Отсутствие поддержки операции типа *scatter*

Специализированные API для GPGPU

- CUDA
- OpenCL
- DX Compute Shaders
- OpenGL compute shaders

CUDA “Hello World”

```
#define N (1024*1024)

__global__ void kernel ( float * data )

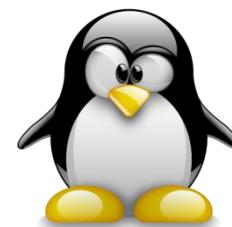
{
    int idx = blockIdx.x * blockDim.x + threadIdx.x;
    float x = 2.0f * 3.1415926f * (float) idx / (float) N;
    data [idx] = sinf ( sqrtf ( x ) );
}

int main ( int argc, char * argv [] )

{
    float a [N];
    float * dev = NULL;
    cudaMalloc ( (void**)&dev, N * sizeof ( float ) );
    kernel<<<dim3((N/512),1), dim3(512,1)>>> ( dev );
    cudaMemcpy ( a, dev, N * sizeof ( float ), cudaMemcpyDeviceToHost );
    cudaFree ( dev );
    for (int idx = 0; idx < N; idx++) printf("a[%d] = %.5f\n", idx, a[idx]);
    return 0;
}
```

Несколько слов о курсе

- Математический спецкурс
- Несколько практических заданий
 - Оценка ставится по практическим заданиям



Отчетность по курсу

- Практические задания
 - Задания сдаются на лекции
 - Либо по почте 
 - с темой **CUDA Assignment #**
 - В течении недели с момента публикации
 - Если у вас не получается - дайте нам знать
 - **Заранее**
- Альтернатива
 - Дайте нам знать
 - **Заранее**

Отчетность по курсу

- Если тема email отличается от **CUDA Assignment #**
 - MINOR FAIL
- Если ваш код не собирается или не запускается
 - MAJOR FAIL
- Если обнаруживается дубликат
 - EPIC FAIL

Недвусмысленный
намек от кэпа



Отчетность по курсу

- Если вы не сдадите задания и не предупредите **заранее**
 - FAIL
- Если вы выбрали альтернативу, но нас не предупредили **заранее**
 - EPIC FAIL

Недвусмысленный
намек от кэпа



Ресурсы нашего курса

- [Steps3d.Narod.Ru](#)
- [Google Site CUDA.CS.MSU.SU](#)
- [Google Group CUDA.CS.MSU.SU](#)
- [Google Mail CS.MSU.SU](#)
- [Google SVN](#)
- [Tesla.Parallel.Ru](#)
- [Twirpx.Com](#)
- [Nvidia.Ru](#)



План

- Существующие архитектуры
- Классификация
- CUDA
- Несколько слов о курсе
- Дополнительные слайды
 - Эволюция GPU
 - Архитектура Tesla 8
 - Архитектура Tesla 20

Эволюция GPU

- Voodoo - растеризация треугольников, наложение текстуры и буфер глубины
- Очень легко распараллеливается
- На своих задачах легко обходил CPU

Эволюция GPU

- Быстрый рост производительности
- Добавление новых возможностей
 - Мультитекстурирование (RivaTNT2)
 - Т&L
 - Вершинные программы (шейдеры)
 - Фрагментные программы (GeForceFX)
 - Текстуры с floating point-значениями

Эволюция GPU: Шейдеры

- Работают с 4D float-векторами
- Специальный ассемблер
- Компилируется драйвером устройства
- Отсутствие переходов и ветвления
 - Вводились как vendor-расширения

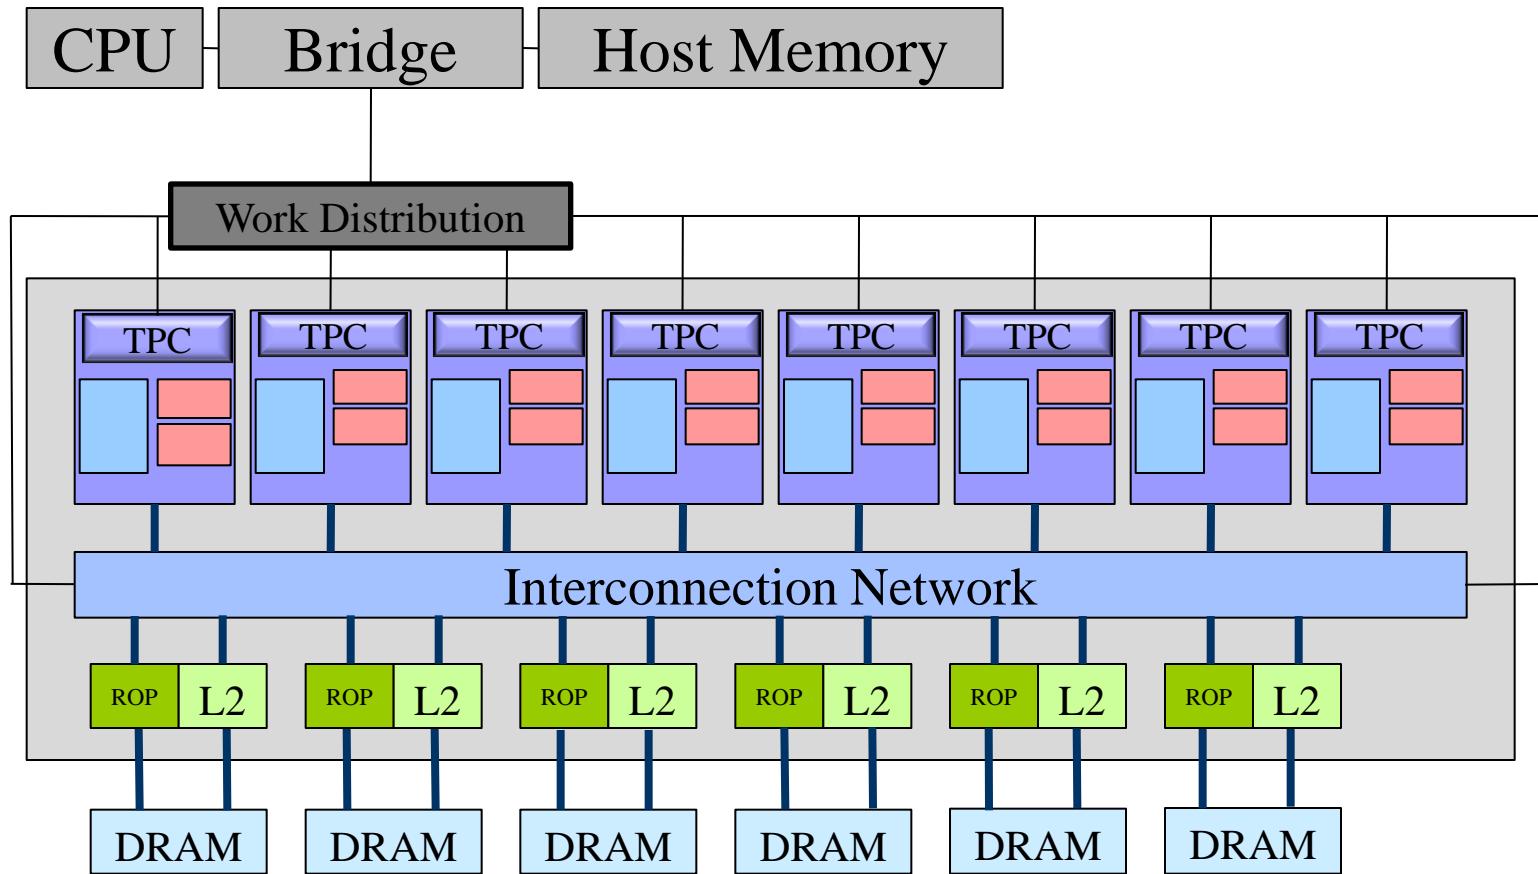
GPGPU

- Использование GPU для решения не графических задач
- Вся работа с GPU идет через графический API (OpenGL, D3D)
- Программы используют сразу два языка – один традиционный (C++) и один шейдерный
- Ограничения, присущие графическим API

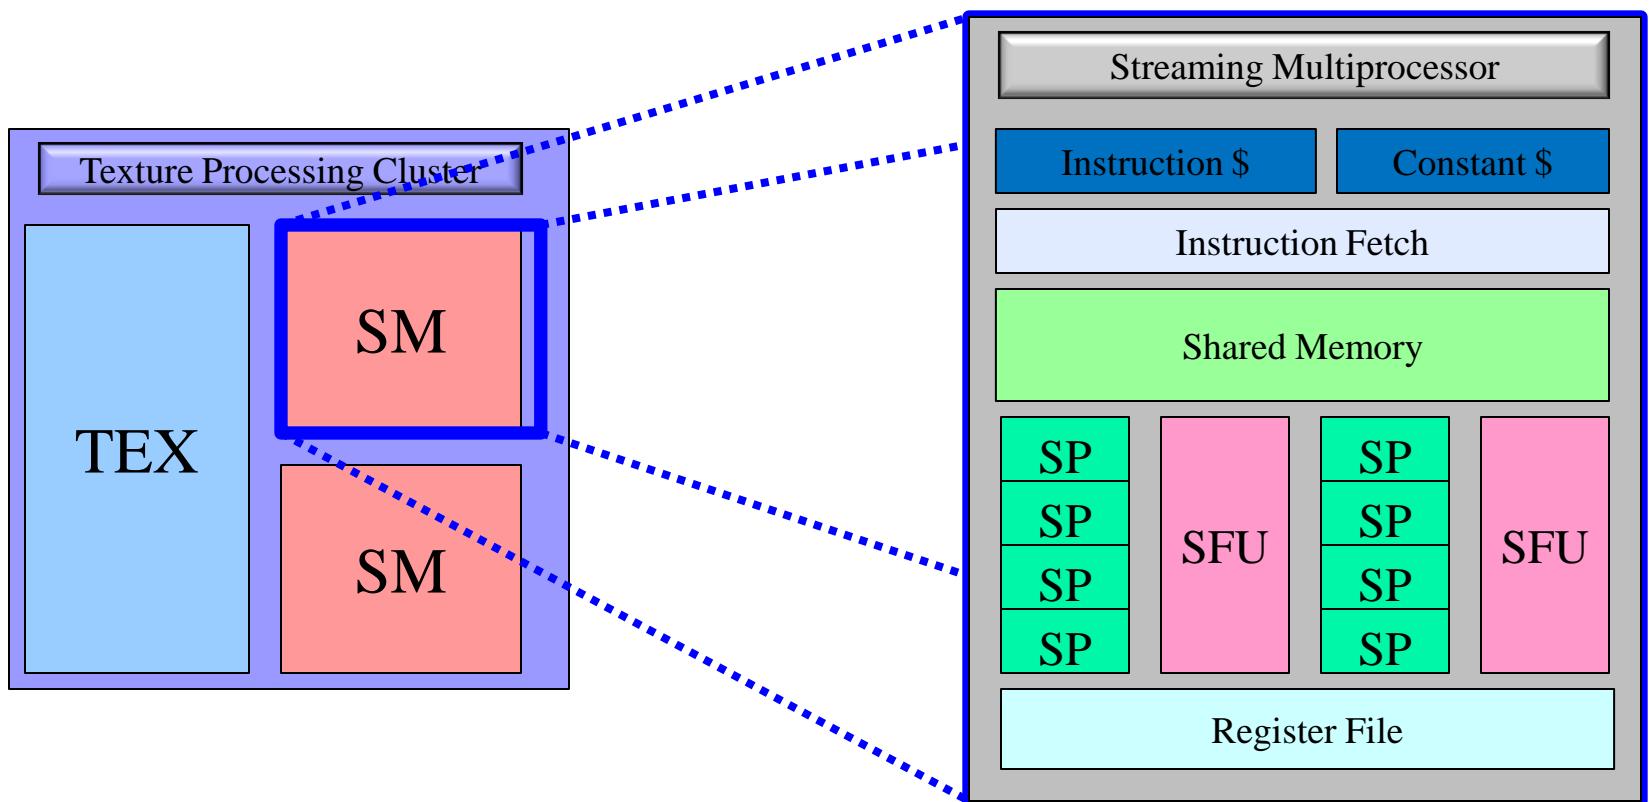
Эволюция GPU: Шейдеры

- Появление шейдерных языков высокого уровня (Cg, GLSL, HLSL)
- Поддержка ветвлений и циклов (GeForce 6xxx)
- Появление GPU, превосходящие CPU в 10 и более раз по Flop'ам

Архитектура Tesla 8



Архитектура Tesla: Мультипроцессор Tesla 8

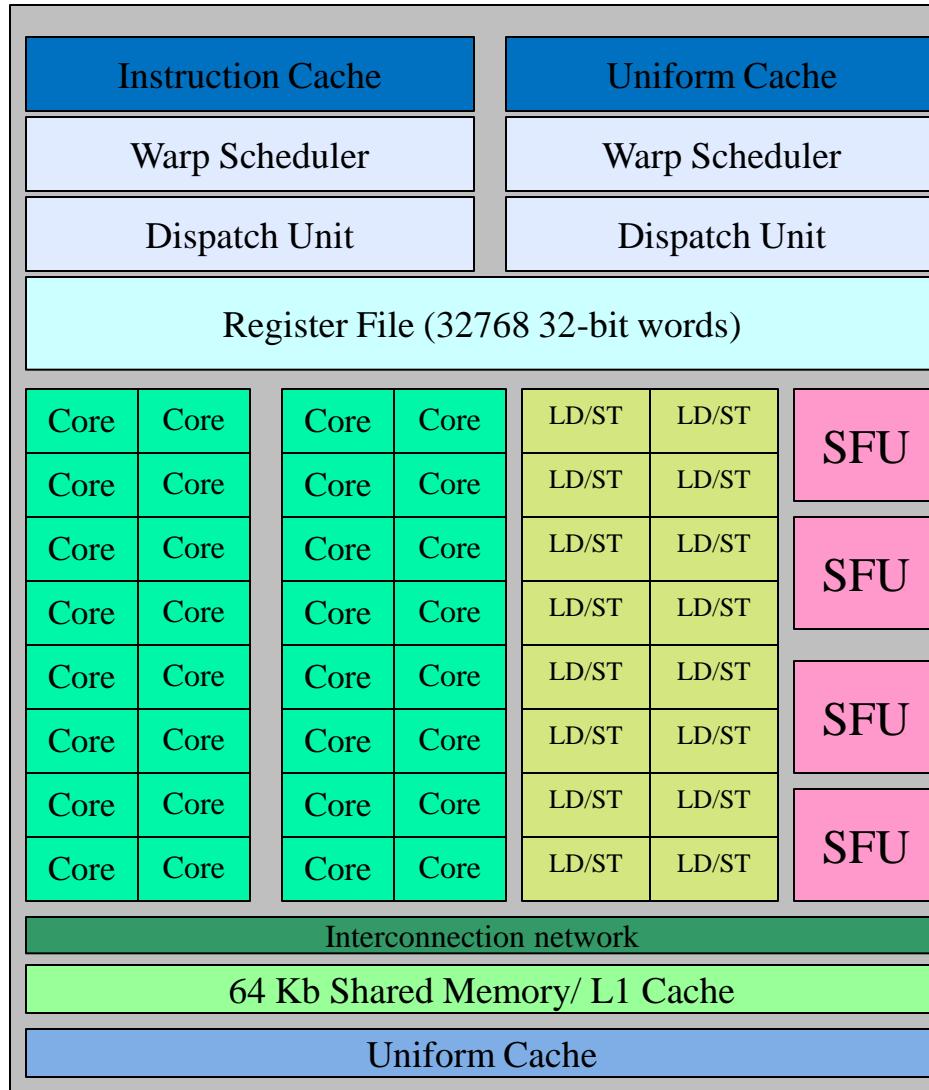


Архитектура Tesla 20

- Объединенный L2 кэш (768 Kb)
- До 1 Tb памяти (64-битная адресация)
- Общее адресное пространство памяти
- ККО (DRAM, регистры, разделяемая память, кэш)
- Одновременное исполнение ядер, копирования памяти (CPU->GPU, GPU->CPU)
- Быстрая смена контекста (10x)
- Одновременное исполнение ядер (до 16)

Архитектура Tesla 20

Потоковый мультипроцессор



Архитектура Tesla 20

- 32 ядра на SM
- Одновременное исполнение 2x варпов.
- 48 Kb разделяемой памяти
- 16 Kb кэш
 - или 16 Kb разделяемый + 48 Kb кэш
- Дешевые атомарные операции