Párhuzamos és Grid rendszerek (10. ea)

GPGPU

Szeberényi Imre
BME IIT

<szebi@iit.bme.hu>

Az ábrák egy része az NVIDIA oktató anyagaiból és dokumentációiból származik.

MŰEGYETEM 1782

Általános célú GPU

- A programozható vertex és fragment shaderek beépítésével általános célú eszközzé vált.
- Vektorprocesszor (SIMD), de pipeline egységek is vannak benne (MISD).
- Jellemzően SIMD
- Programozás: CUDA, OpenCl, Cg, …

Egy példa

NVIDIA Quadro FX5800 grafikus kártya

- PCIe x16
- 240 CUDA mag
- 4 GB DDR3
- 78 GFlos double
- 933 Gflops single
- 189 W
- 300Millió háromszög / sec
- NVIDIA CUDA

Compute Unified Device Arch.

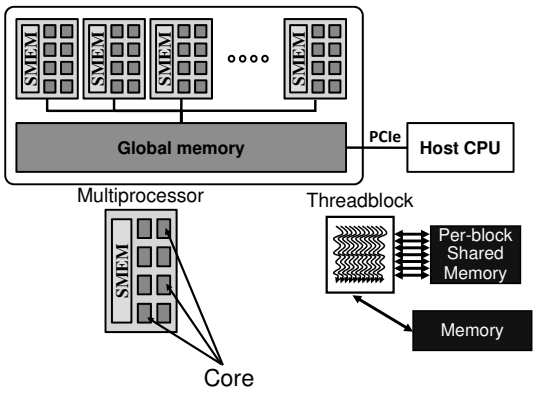

CUDA modell

- Ún. thread modell (SIMT)
- A szálak ütemezésével nem kell a programozónak foglalkozni.
- Elrejti a konkrét architektúrát
- Támogatja a heterogén feldolgozás (CPU+GPU)

Grid-be szervezett szálak

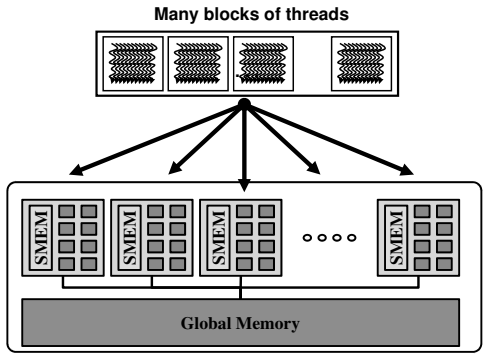

Block ID & Thread ID

- Minden szálnak és blokknak van egyedi azonosítója.
  - Block ID: 1D v 2D
  - Thread ID: 1D, 2D, v. 3D
  - gridDim, blockIdx
  - blockDim, threadIdx

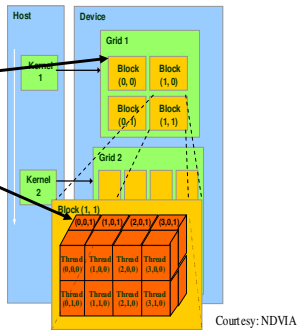

Szálak kommunikációja

- Szálak párhuzamosan futnak.
- Sorrendjük nem meghatározható
- Csak egy blokkban levő szálak tudnak kommunikálni egymással.
- A blokkok futási sorrendje nem meghatározott.
- warp általában 32 szál

Host kommunikáció

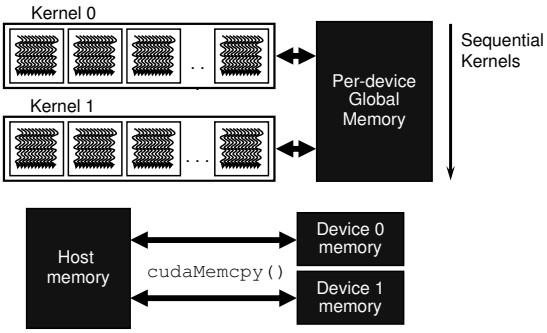

C nyelv kiegészítései

```
Függvény típus módósítói:
   __global__ void my_kernel() { }
   __device__ float my_device_func() { }

Változók típusmódosítói::
   __constant__ float
     my_constant_array[32];
   __shared__    float
     my_shared_array[32];

Beépített változók:
   dim3 gridDim;    // Grid dimension
   dim3 blockDim;   // Block dimension
   dim3 blockIdx;   // Block index
   dim3 threadIdx; // Thread index
```


C/C++ megkötések

- Kernel kód csak a GPU memóriáját éri el
- Nem lehet rekurzió
- Nincs változó argumentumszám
- Nincs static
- Nincs dinamikus polimofrizmus

Függvény deklaráció

	Hol hajtódik végre?	Honnan hívható?
`__device__ float DeviceFunc()`	device	device
`__global__ void KernelFunc()`	device	host
`__host__ float HostFunc()`	host	host

Memória elérés

Minden thread tudja:
- Írni/olvasni a thread regisztereket
- Írni/olvasni a lokalis memóriát
- Írni/olvasni a shared memóriát
- Írni/olvasni a globális memóriát
- Olvasni a konstans memóriát

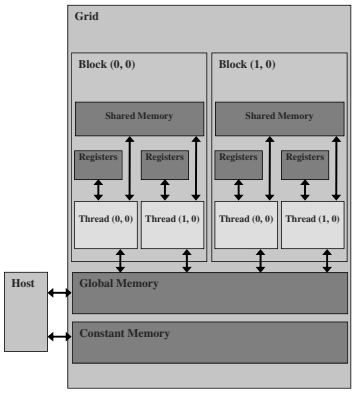

Változó helye

Variable declaration	Memory	Scope	Lifetime
`int var;`	register	thread	thread
`int array_var[10];`	local	thread	thread
`__shared__ int shared_var;`	shared	block	block
`__device__ int global_var;`	global	grid	application
`__constant__ int constant_var;`	constant	grid	application

Elérés sebessége

Variable declaration	Memory	Penalty
`int var;`	register	1x
`int array_var[10];`	local	100x
`__shared__ int shared_var;`	shared	1x
`__device__ int global_var;`	global	100x
`__constant__ int constant_var;`	constant	1x

Példa

- Vektor négyzetgyöke
- Bemenet/kimenet:
  - input, output vektor
- Host program
- Device program

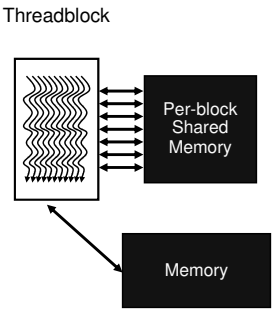

Példa (sqrt #1)

```
// Device code
__global__ void sqrtVec(const double* in,
                        double* out, int N) {
  int i = blockDim.x * blockIdx.x + threadIdx.x;
  if (i < N)
        out[i] = sqrt(in[i]);
}
```

```
int main() {
....
 sqrtVec<<<20, 256>>>(d_inp, d_res, SIZE);
....
}
```


Példa (sqrt #2)

```
int main() {
  double *h_inp, *h_res, *d_inp, *d_res;
  size_t size = 100 * sizeof(double);
  h_inp = (double*)malloc(size);
  h_res = (double*)malloc(size);
  cudaMalloc((void**)&d_inp, size);
  cudaMalloc((void**)&d_res, size);
  for (int i = 0; i < SIZE; i++) h_inp[i] = i*i;
  cudaMemcpy(d_inp, h_inp, size,
                          cudaMemcpyHostToDevice);
  sqrtVec<<<1, 100>>>(d_inp, d_res, 100);
  cudaMemcpy(h_res, d_res, size,
                          cudaMemcpyDeviceToHost);
  ..... cudaTreadExit();
  return 0;
}
```

Versenyhelyzet

threadId:0	threadId:1917

vector[0] = 5;
...
a = vector[0];
	vector[0] = 1;
	...
	a = vector[0];

Mi az a változó értéke a 0. ill. 191. szálban ?

Atomi művelet

```
atomic{Add, Sub, Exch, Min, Max, Inc,
            Dec, CAS, And, Or, Xor}

CAS:
int compare_and_swap(int* register,
                int oldval, int newval){
     int old_reg_val = *register;
     if(old_reg_val == oldval)
          *register = newval;
     return old_reg_val;
}
```


Szinkronizációs veszély

```
__global__
void global_max(int* values, int*
gl_max){
  int i = threadIdx.x
        + blockDim.x * blockIdx.x;
  int val = values[i];
  atomicMax(gl_max,val);
}

A gyakori közös memória hozzáférés miatt
a szálak elakadnak, szinkronozódnak.
```


Kicsit jobb max. keresés

```
__global__
void global_max(int* values, int* max,
    int *regional_maxes, int num_regions)
   {
  int i = threadIdx.x
        + blockDim.x * blockIdx.x;
  int val = values[i];
  int region = i % num_regions;
  if(atomicMax(&reg_max[region],val) <
   val){
    atomicMax(max,val);
  }
}
```


Vezérlés divergencia

A ClearSpeed-nél már megismert probléma, ami rontja a párhuzamosítás hatékonságát.