

GPGPU

General Purpose GPU programming,
ou la programmation SIMD avec CUDA

Sources de toute les figures et exemples




© David Kirk/NVIDIA and Wen-mei W. Hwu, 2007
ECE 498AL1, University of Illinois, Urbana-Champaign

Plan du cours

- Introduction
 - Pourquoi programmer sur GPU ?*
- Le langage CUDA
- Exemple
- Différentes mémoires
- Exemple : le retour
- Optimisation de la mémoire partagée
- Optimisation de la mémoire globale
- Divergence

Performances GPU/CPU ces dernières années



Tendance durable ?

CPU

(Intel single core)


- CPU <-> RAM : 6.4 Go/s
- PCIe 16x 4Go/S (R+W)
- 4.8 GFLOps




CPU

(Intel bi Duo Core2)

- CPU : ~ 2 x 10 Go/s
- PCIe 16x 4Go/S (R+W)
- 4 x 4.8 GFLOps



GPU : architecture SIMD




- Single Instruction / Multiple Data
- Similaire au phénomène RISC des années 90 ?

Puces

AMD K10

G80...

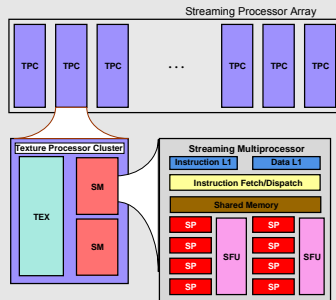


Architecture G80

1/3

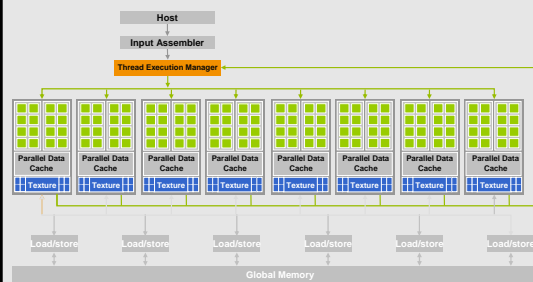
SP = Stream Proc
1..512 threads en //
1 instruction =
32 threads
20+ GFlops

SFU =
Super Function Units



Architecture G80

2/3



Architecture G80

3/3


- Architecture massivement parallèle, 128 cores, 90W
 - 367 GFlops maximum théorique
 - 265 GFlops mesurés en situation réelles.
 - 768 Mo DRAM,
86 Go/S GPU ↔ RAM,
4 Go/S CPU ↔ RAM
 - Parallélisme massif, des 1000s de threads en parallèle
- 30-100 x plus rapide sur des applications régulières (Images, Volumes 3D, Matrices, etc.)

Architecture mémoire pré G80 (OpenGL)

- Gather : lecture multiples
→ textures




- Scatter : écritures multiples




Architecture mémoire G80 (et CUDA)

- Gather : lecture multiples
→ adressage libre (textures, vecteur 1D, array 2D)




- Scatter : écritures multiples



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

13

Architecture mémoire G80 : mémoire locale



Mémoire partagée sur les multi-processeurs

- Optimisation du bus GPU ↔ RAM (limitée à 86 Go/s)
- Bus interne à ~ 768 Go/s



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

14


Threads et Warps



« GigaThreads »

1 Stream Processor exécute des 100s de threads en //


1 accès mémoire ~ 200..400 cycles



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

15

Multiplexage temporel de l'exécution



Pour cacher la latence mémoire:

- Plusieurs bloc en parallèle sur un même multi-processeur
- Time slicing par warp de 32 threads




(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

16

Kernels, blocs et threads

Vision abstraite:

- Kernel = procédure sur GPU
- Organisation 2D x 3D
- blockIdx, threadIdx
- gridDim, blockDim

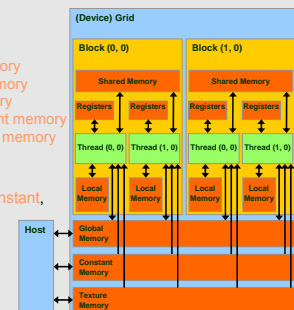


(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

17

Mémoires

- Each thread can:
 - R/W per-thread registers
 - R/W per-thread local memory
 - R/W per-block shared memory
 - R/W per-grid global memory
 - Read only per-grid constant memory
 - Read only per-grid texture memory
- The host can R/W global, constant, and texture memories



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

18

Plan du cours

- Introduction
- **Le langage CUDA**
Compute Unified Device Architecture
- Exemple
- Différentes mémoires
- Exemple : le retour
- Optimisation de la mémoire partagée
- Optimisation de la mémoire globale
- Divergence



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

19

Langage CUDA

- Extension du langage C/C++

```

__device__ __host__ __global__      (fonctions)
__device__ __shared__ __constant__ (variables)

float3, dim3, ...                    (classes)

__syncthreads()

cudaMalloc(), cudaFree(), ...

cudaMemcpy(), ...

kernelFunction<<<grid, bloc, shared, stream>>>(...parameters...)
    
```



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

20

Types spécifiques

Vecteurs 1..4 :

```

char, uchar
short, ushort
int, uint
long, ulong
float
double
dim3
    
```

variante de uint3, initialisé à 1

```

float3 P = make_float3(1.0,2.0,3.0), Q(3,2,1);
P.x += Q.x;
    
```



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

21

Fonctions standards

- pow, sqrt, cbrt, hypot
- exp, exp2, expm1
- log, log2, log10, loglp
- sin, cos, tan, asin, acos, atan, atan2
- sinh, cosh, tanh, asinh, acosh, atanh
- ceil, floor, trunc, round
- Etc. etc.



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

22

Déclaration des fonctions

	Executed on the:	Only callable from the:
<code>__device__ float DeviceFunc()</code>	device	device
<code>__global__ void KernelFunc()</code>	device	host
<code>__host__ float HostFunc()</code>	host	host

- `__global__` defines a kernel function
 - Must return void
- `__device__` and `__host__` can be used together



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

23

Lancement des calculs sur le GPU

- `__global__ void kernel(float p) { ... }`
- `kernel<<<grid, threads, shared, stream>>>(1.0f);`
 - dim3 grid; grid.x * grid.y
 - dim3 threads; threads.x * threads.y * threads.z
 - size_t shared; taille de la mémoire partagée
 - cudaStream_t stream; gestion de la synchronisation.



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

24

Plan du cours

- Introduction
- Le langage CUDA
- **Exemple**
 - **Produit matrice x matrice**
- Différentes mémoires
- Exemple : le retour
- Optimisation de la mémoire partagée
- Optimisation de la mémoire globale
- Divergence



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

25

Un exemple : produit de matrices

- Matrices 2 D
 - Simple précision 32 bits (float)
 - $width * height$ éléments
- ```
typedef struct {
 int width;
 int height;
 int pitch;
 float* elements;
} Matrix;
```
- Générique:
- malloc() et organisation 1D
  - *pitch* allocation spéciale, et sous matrices.



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

26

## Transferts CPU/GPU

1. Matrix Md, M;  
size\_t size = Md.width \* Md.height \* sizeof(float);
2. cudaMalloc((void\*\*)&Md.elements, size);
3. cudaMemcpy(Md.elements, M.elements, size,  
cudaMemcpyHostToDevice);
4. ... calculs sur le GPU ...
5. cudaMemcpy(M.elements, Md.elements, size,  
cudaMemcpyDeviceToHost);
6. cudaFree(Md.elements);

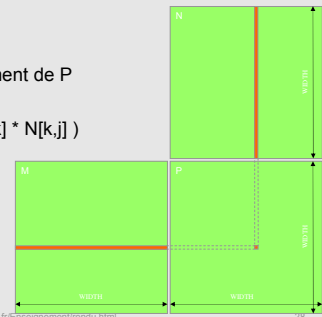


(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

27

## Multiplication de matrices

- $P = M \times N$
- Une thread par élément de P
- $P[i,j] = \text{somme}(M[i,k] * N[k,j])$



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

28

## Implémentation CPU

```
void MatrixMulOnHost(Matrix M, Matrix N, Matrix P)
{
 for (int i = 0; i < M.height; ++i)
 for (int j = 0; j < N.width; ++j) {
 float sum = 0.0;
 for (int k = 0; k < M.width; ++k) {
 float a = M.elements[i * M.pitch + k];
 float b = N.elements[k * N.pitch + j];
 sum += a * b;
 }
 P.elements[i * N.pitch + j] = sum;
 }
}
```



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

29

## Implémentation GPU

```
__global__ void MatrixMulKernel(Matrix Md, Matrix Nd,
Matrix Pd)
{
 int tx = threadIdx.x; // 2D Thread ID
 int ty = threadIdx.y;

 float sum = 0;
 for (int k = 0; k < Md.width; ++k) {
 float a = Md.elements[ty * Md.pitch + k];
 float b = Nd.elements[k * Nd.pitch + tx];
 sum += a * b;
 }

 Pd.elements[ty * Pd.pitch + tx] = Pvalue;
}
```



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

30

## Lancement du calcul

Appel:

```
dim3 dimBlock(WIDTH, WIDTH);
MatrixMulKernel<<<1, dimBlock>>>(Md, Nd, Pd);
```

Asynchrone

I/O bloquantes : `cudaMemcpy(...)`

I/O non bloquantes :  
`cudaStreamCreate() + cudaMemcpyAsync(...)`

## Limitations

- La matrice est relue WIDTH fois
- 1 seul bloc
- Taille limite 512x512
- N'utilise que la mémoire globale.
- Limité par la bande passante !  
8 octets par instruction MADD, ou 4 octet par Flop  
→ 86/8 = 21 GFlops max (théorique),  
15 GFlops mesurés (D. Kirk 2007/02)

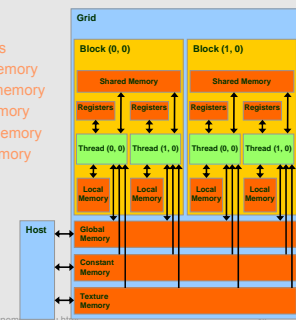
## Plan du cours

- Introduction
- Le langage CUDA
- Exemple
- Différentes mémoires  
*Shared, constant, global, host, ...*
- Exemple : le retour
- Optimisation de la mémoire partagée
- Optimisation de la mémoire globale
- Divergence

## Mémoires

1/2


- Each thread can:
  - Read/write per-thread registers
  - Read/write per-thread local memory
  - Read/write per-block shared memory
  - Read/write per-grid global memory
  - Read only per-grid constant memory
  - Read only per-grid texture memory



## Mémoires

2/2

- Cache ~ Registers ~ Shared  
32 bits / cycle / SP
- Caches  
Constantes, instructions (1D)  
Textures, cudaArray (2D)  
1..10s..100s cycle / 32 bits
- Sans cache  
Mémoire globale  
100s cycles / 32 bits.



## Mémoires

3/3

| Memory   | Location       | Cached         | Access     | Who                    |
|----------|----------------|----------------|------------|------------------------|
| Local    | Off-chip ????? | No             | Read/write | One thread             |
| Shared   | On-chip        | N/A - resident | Read/write | All threads in a block |
| Global   | Off-chip       | No             | Read/write | All threads + host     |
| Constant | Off-chip       | Yes            | Read       | All threads + host     |
| Texture  | Off-chip       | Yes            | Read       | All threads + host     |


- `cudaMalloc()` == global memory
- variables → register (+ local) memory
- `__shared__` + appel → shared memory
- `__constant__`

## Plan du cours

- Introduction
- Le langage CUDA
- Exemple
- Différentes mémoires
- **Exemple : le retour**  
*Cache (à la main) en mémoire partagée*
- Optimisation de la mémoire partagée
- Optimisation de la mémoire globale
- Divergence

## Multiplication par bloc

- BLOCK\_SIZE
- 1 bloc = BLOCK\_SIZE<sup>2</sup> threads
- Width % BLOCK\_SIZE == 0
- Height % BLOCK\_SIZE == 0



## Tunning

- 1 bloc = multiple de 32 threads (tout les warps sont complets)
  - 1 bloc > 192 threads (optimisation)
  - 1 bloc < 512 threads (limite hardware)
  - 1 multiproc ≤ 8 blocs en parallèle et ≤ 768 threads
  - 1 kernel < 65536 x 65536 x 1 blocs
  - Au moins 64 blocs pour « remplir » le GPU, plus c'est mieux...
- BLOCK\_SIZE = 16
- 1 bloc =
- Lit deux matrices 16x16 floats
  - 256 threads font 16 MADDs
- Max théorique 172 GFlops (du point de vue de la mémoire globale)
- 1 bloc = 2Ko et 16Ko par SM → 8 blocs par MultiProc  
1 bloc = 256 threads → 3 blocs par MultiProc

## Utilisation de la mémoire partagée

```

__global__ void blocMatrixMultiply(Matrix Md, Matrix Nd, Matrix Pd)
{
 int bx = blockIdx.x; // Block index
 int by = blockIdx.y;
 int tx = threadIdx.x; // Thread index
 int ty = threadIdx.y;

 float sum = 0.0f;
 for(int m=0; m<Md.width/BLOCK_SIZE; ++m) {
 Matrix Msub = GetSubMatrix(Md, m, by); // Sous-matrices globales
 Matrix Nsub = GetSubMatrix(Nd, bx, m);
 __shared__ float Ms[BLOCK_SIZE][BLOCK_SIZE]; // Copie partagées
 __shared__ float Ns[BLOCK_SIZE][BLOCK_SIZE];

 Ms[ty][tx] = Msub.elements[tx + Msub.pitch*ty];
 Ns[ty][tx] = Nsub.elements[tx + Nsub.pitch*ty];

 __syncthreads();

 for (int k = 0; k < Md.width/BLOCK_SIZE; ++k)
 sum += Ms[ty][k] * Ns[k][tx];

 __syncthreads();
 }

 Matrix Psub = GetSubMatrix(Pd, bx, by);
 Psub.elements[tx + ty * Psub.pitch] = sum;
}

```

## Lancement du calcul

```

dim3 dimBlock(BLOCK_SIZE, BLOCK_SIZE);
dim3 dimGrid(N.width / dimBlock.x,
 M.height / dimBlock.y);
Size_t shared = 2 * BLOCK_SIZE * BLOCK_SIZE
 * sizeof(float);

blocMatrixMultiply<<<dimGrid, dimBlock,
shared>>>(Md, Nd, Pd);

```

*This code should run at about 45 GFLOPS*

## Plan du cours


- Introduction
- Le langage CUDA
- Exemple
- Différentes mémoires
- Exemple : le retour
- **Optimisation de la mémoire partagée**
- Optimisation de la mémoire globale
- Divergence

## Conflits sur la mémoire partagée

Optimisation de la mémoire partagée

→ Utilisation de 16 banc de mémoire en parallèle

- Débit = 32 bits par cycle, et par banc mémoire
- $N^{\circ} \text{ banc} = (\text{adresse } 32 \text{ bits}) \% 16$
- Accès multiples == conflits == sérialisation
- Pas de conflits entre (demi) warps différents




(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

43

## Adressage sans conflits


Pas de conflit

Adressage linéaire  
pas == 1



Pas de conflit

Permutation quelconque




(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>


44

## Conflits adresse dans la mémoire partagée

Conflit double accès  
Adressage linéaire  
pas == 2



Conflit octuple accès  
Adressage linéaire  
pas == 8





(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

45

## Cas d'un adressage linéaire

```
__shared__ float shared[256];
float foo = shared[baseIndex + s * threadIdx.x];
```



Pas de conflit quand  $s$  est premier avec le nombre de bancs  
Donc pas un multiple de 2, 4, 8 ou 16.




(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

46

## Adressage des types de base en mémoire partagée


- 8 bits

```
__shared__ char shared[];
foo = shared[baseIndex + threadIdx.x];
```



- 16 bits

```
__shared__ short shared[];
foo = shared[baseIndex + threadIdx.x];
```



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

47

## Adressage des structures en mémoire partagée


Ok → 3 cycles

```
struct vec3 { float x, y, z; };
__shared__ struct vec3 P3[64];
struct vec3 v = P3[baseIndex + tid];
```

Conflit double accès → 4 cycles

```
struct vec2 {
 float f;
 int c;
};
__shared__ struct vec2 Q2[64];
struct vec2 m = Q2[baseIndex + tid];
```

Egalement : int2, float2, float4, ...



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

48



## Diffusion depuis un même banc

1 cycle:


```
__shared__ float shared[256];
float foo = shared[constant];
```

2 cycles (64 bits):

```
struct vec2 m = Q2[constant];
```

3 cycles (96 bits):

```
struct vec3 v = P3[constant];
```



**constant** == la même valeur pour toutes les threads d'un warp



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>


49

## Diffusion multiples

2 cycles:

```
__shared__ float shared[256];
float foo = shared[tid % 2];
```

Idem dans les cas mixtes...




(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

50

## Cas des adressages 2D


- Matrice partagée 16x16 floats

```
int tx = threadIdx.x;
int ty = threadIdx.y;
__shared__ float Ms[16][16];
Ms[ty][tx] = ...
```



- Matrice partagée 16x17 floats

```
__shared__ float Ms[16][17];
```



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>


51

## Cas des adressages 2D

- Matrice partagée 16x16 floats + décalage

```
int ty = threadIdx.y;
int tx = (threadIdx.x + ty) % 16;
```

Ms[ty][tx] = ...



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

52

## Plan du cours

- Introduction
- Le langage CUDA
- Exemple
- Différentes mémoires
- Exemple : le retour
- Optimisation de la mémoire partagée
- Optimisation de la mémoire globale**
- Divergence




(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

53

## Coalescence des accès globaux

- Bus mémoire en mode « burst » sur un demi-warp

- Coalescence** == lecture d'un bloc consécutif  
Optimisé pour des accès 32, 64, ou 128 bits.  
Contraintes de taille + d'alignement



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

54

## Coalescence en CUDA

```
float x = globalFloat[tid]; OUI
float2 v = globalVec2[tid]; OUI
float3 w = globalVec3[tid]; NON

float x = globalVec2[tid].x; NON
v.x = globalX[tid]; OUI
v.y = globalY[tid];

struct __align__(16) { 2 x 128 bits << 5 x 32 bits
 float a;
 float b;
 float c;
 float d;
 float e;
};
```



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

55

## Plan du cours

- Introduction
- Le langage CUDA
- Exemple
- Différentes mémoires
- Exemple : le retour
- Optimisation de la mémoire partagée
- Optimisation de la mémoire globale
- **Divergence**




(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

56

## Contrôle de flux et SIMD 1/3

Multi-processeur == SIMD

Divergence == Les 16 *Stream processors* ne font pas la même chose...



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

57

## Contrôle de flux et SIMD 2/3

| CUDA         | Assembleur PTX     |
|--------------|--------------------|
| :            | :                  |
| :            | :                  |
| :            | LDR r5 <- X        |
| if (x == 10) | p1 <- r5 eq 10     |
| c = c + 1;   | <p1> LDR r1 <- C   |
| :            | <p1> ADD r1, r1, 1 |
| :            | <p1> STR r1 -> C   |
| :            | :                  |
| :            | :                  |



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

58

## Contrôle de flux et SIMD 3/3

|                    |                    |
|--------------------|--------------------|
| :                  | :                  |
| :                  | :                  |
| p1,p2 <- r5 eq 10  | p1,p2 <- r5 eq 10  |
| <p1> inst 1 from B | <p1> inst 1 from B |
| <p1> inst 2 from B | <p2> inst 1 from C |
| <p1> :             | <p1> inst 2 from B |
| :                  | <p2> inst 2 from C |
| <p2> inst 1 from C | <p1> :             |
| <p2> inst 2 from C | <p2> :             |
| <p2> :             | <p2> :             |
| :                  | :                  |



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

59

## Références

- <http://developer.nvidia.com/object/cuda.htm>  
CUDA 1.1  
Toolkit = compilateur nvcc  
SDK = 18 exemples  
Linux/Windows XP et 32/64 bits
- <http://courses.ece.uiuc.edu/ece498/al1>  
> Syllabus



(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

60