

GPGPU

General Purpose GPU programming,
ou la programmation SIMD avec CUDA



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

1

Sources de toute les figures et exemples



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



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

2

Plan du cours

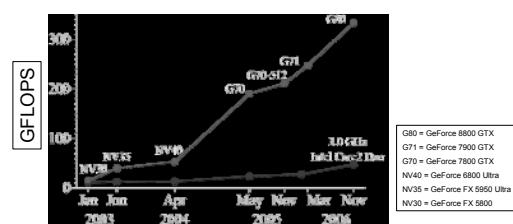
- Introduction
Pourquoi programmer sur GPU ?
- Le langage CUDA
- Exemple
- Différentes mémoires
- Exemple : le retour
- Optimisation de la mémoire partagée
- Optimisation de la mémoire globale
- Divergence



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

3

Performances GPU/CPU ces dernières années



Tendance durable ?



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

4

CPU

(Intel single core)

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



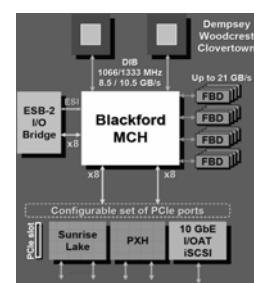
(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

5

CPU

(Intel bi Duo Core2)

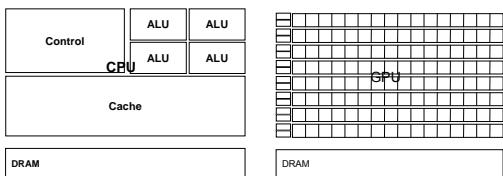
- CPU : ~ 2 x 10 Go/s
- PCIe 16x 4Go/S (R+W)
- 4 x 4.8 GFlops



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

6

GPU : architecture SIMD



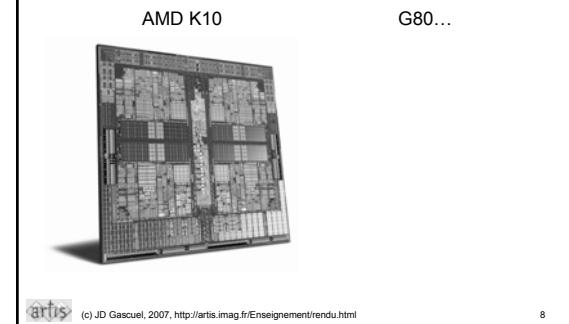
- Single Instruction / Multiple Data
- Similaire au phénomène RISC des années 90 ?



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

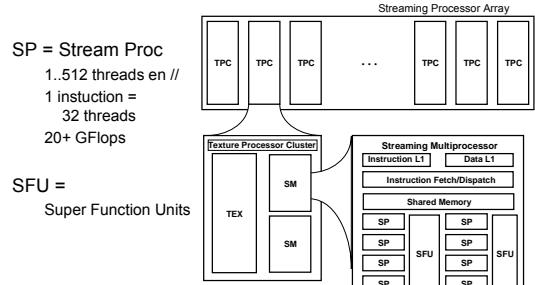
7

Puces



8

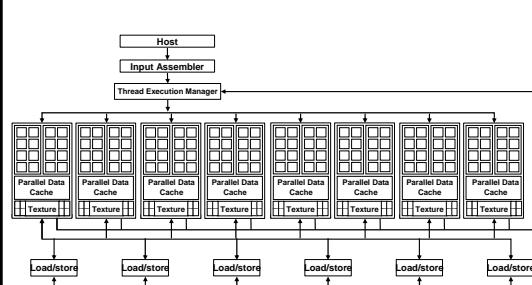
Architecture G80 1/3



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

9

Architecture G80 2/3



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

10

Architecture G80 3/3

- Architecture massivement parallel, 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
- Parallelisme massif, des 1000s de threads en parallèle
- ➔ 30-100 x plus rapide sur des applications régulières (Images, Volumes 3D, Matrices, etc.)

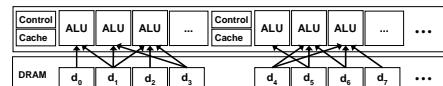


(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

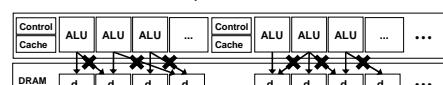
11

Achitecture mémoire pré G80 (OpenGL)

- Gather : lecture multiples
→ textures



- Scatter : écritures multiples



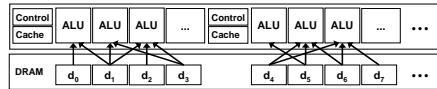
(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

12

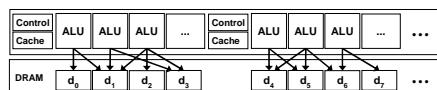
Architecture mémoire G80 (et CUDA)

- Gather : lecture multiples

→ adressage libre (textures, vecteur 1D, array 2D)



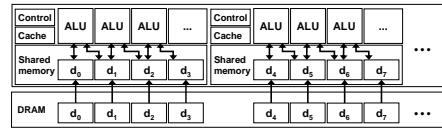
- Scatter : écritures multiples



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

13

Architecture mémoire G80 : mémoire locale



Mémoire partagé sur les multi-processeurs

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



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

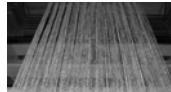
14

Threads et Warps

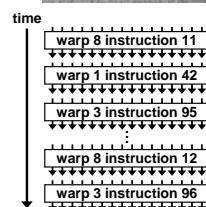
« GigaThreads »

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

1 accès mémoire ~ 200..400 cycles



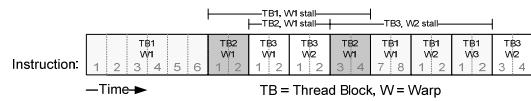
time



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

15

Multiplément 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



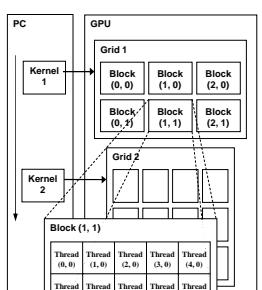
(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

16

Kernels, blocs et threads

Vision abstraite:

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



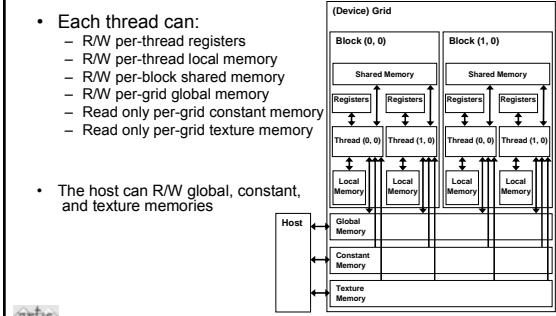
17

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



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, expml
- log, log2, log10, log1p
- 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>

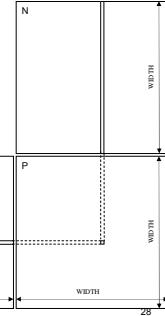
27

## 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 < M.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(...)
```



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

31

## 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)



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

32

## 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



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

33

## Mémoires

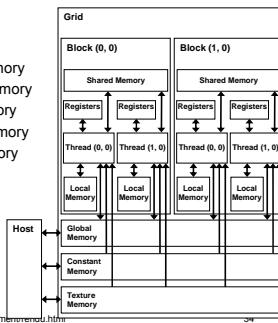
1/2

- 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



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



34

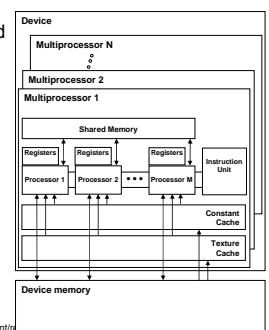
## Mémoires

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.



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



## 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__`



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

35

## 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

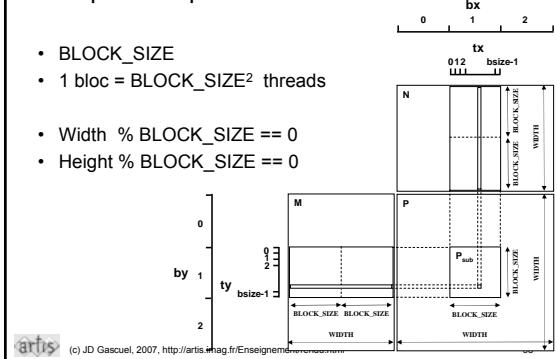


(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

37

## Multiplication par bloc

- BLOCK\_SIZE
- 1 bloc =  $BLOCK\_SIZE^2$  threads
- Width % BLOCK\_SIZE == 0
- Height % BLOCK\_SIZE == 0



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

## 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



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

39

## Utilisation de la mémoire partagée

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

 float sum = 0.0f;
 for(int m=0; m<Md.width/BLOCK_SIZE; ++m) {
 Matrix Msub = GetSubMatrix(Md, m, by);
 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;
}
```

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

40

## 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*



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

41

## Plan du cours

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

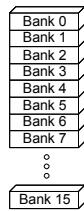
(c) JD Gascuel, 2007, <http://artis.imag.fr/Enseignement/rendu.html>

42

## 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° banc = (adresse 32 bits) % 16
- Accès multiples == conflits == sérialisation
- Pas de conflits entre (demi) warps différents

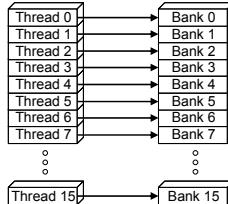


43

## Adressage sans conflits

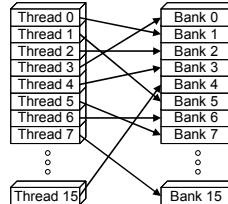
Pas de conflit

Adressage linéaire  
pas == 1



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

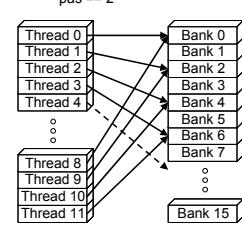
Pas de conflit  
Permutation quelconque



44

## Conflits adresse dans la mémoire partagée

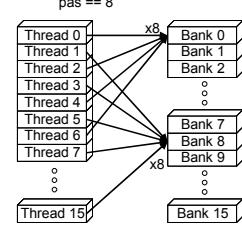
Conflit double accès  
Adressage linéaire  
pas == 2



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

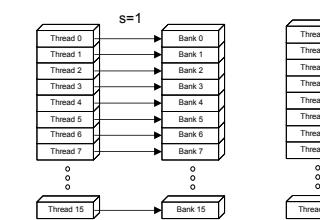
45

Conflit octuple accès  
Adressage linéaire  
pas == 8



## 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, ou 16.

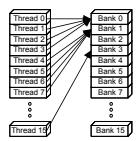
(c) JD Gascuel, 2007, http://artis.imag.fr/Enseignement/rendu.html

46

## Adressage des types de base en mémoire partagée

• 8 bits

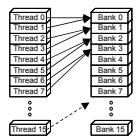
```
_shared__ char shared[];
foo = shared[baseIndex + threadIdx.x];
```



47

• 16 bits

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



## Adressage des structures en mémoire partagée

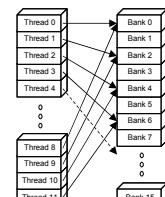
Ok → 3 cycles

```
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, ...



48

## Diffusion depuis un même banc

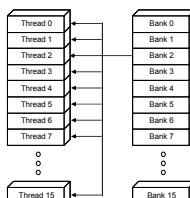
```

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

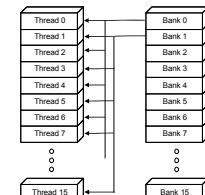
## Diffusion multiples

```

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] = ...

```

|   |   |   |   |   |   |   |   |     |    |    |
|---|---|---|---|---|---|---|---|-----|----|----|
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 0  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 1  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 2  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 3  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 4  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 5  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 6  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 7  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 8  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 9  |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 10 |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 11 |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 12 |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 13 |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 14 |
| 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | ... | 15 | 15 |



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

|    |    |    |    |    |    |    |    |     |    |    |
|----|----|----|----|----|----|----|----|-----|----|----|
| 0  | 1  | 2  | 3  | 4  | 5  | 6  | 7  | ... | 15 | 0  |
| 1  | 2  | 3  | 4  | 5  | 6  | 7  | 8  | ... | 15 | 1  |
| 2  | 3  | 4  | 5  | 6  | 7  | 8  | 9  | ... | 15 | 2  |
| 3  | 4  | 5  | 6  | 7  | 8  | 9  | 10 | ... | 15 | 3  |
| 4  | 5  | 6  | 7  | 8  | 9  | 10 | 11 | ... | 15 | 4  |
| 5  | 6  | 7  | 8  | 9  | 10 | 11 | 12 | ... | 15 | 5  |
| 6  | 7  | 8  | 9  | 10 | 11 | 12 | 13 | ... | 15 | 6  |
| 7  | 8  | 9  | 10 | 11 | 12 | 13 | 14 | ... | 15 | 7  |
| 8  | 9  | 10 | 11 | 12 | 13 | 14 | 15 | ... | 15 | 8  |
| 9  | 10 | 11 | 12 | 13 | 14 | 15 | 16 | ... | 15 | 9  |
| 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | ... | 15 | 10 |
| 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | ... | 15 | 11 |
| 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | ... | 15 | 12 |
| 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 | ... | 15 | 13 |
| 14 | 15 | 16 | 17 | 18 | 19 | 20 | 21 | ... | 15 | 14 |
| 15 | 16 | 17 | 18 | 19 | 20 | 21 | 22 | ... | 15 | 15 |

## 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>

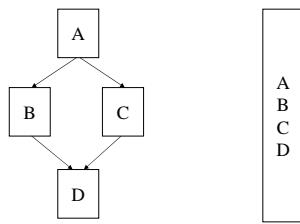
56

## 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

```

:
:
if (x == 10)
 c = c + 1;
:

```

Assembleur PTX

```

:
:
LDR r5 <- X
p1 <- r5 eq 10
<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 <p1> inst 1 from C
<p1> :
:
<p2> inst 1 from C <p1> inst 2 from B
<p2> inst 2 from C <p2> inst 2 from C
<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