

GP-GPU

Advanced CUDA programming Part 1

Stéphane Vialle

université
PARIS-SACLAYÉCOLE DOCTORALE
Sciences et technologies
de l'information
et de la communication (STIC)Stephane.Vialle@centralesupelec.fr
<http://www.metz.supelec.fr/~vialle>

1

Advanced CUDA programming Part 1

1. Principles of the *Shared Memory*
 - Basic concepts
 - Scheme of a basic ShM 2D-kernel
 - Scheme of a ShM 2D-kernel with loop
2. Examples of the use of *Shared Memory*
3. Atomic operations
4. Dynamic parallelism
5. Conclusion on CUDA programming

2

Principles of the *shared memory*

Basic concepts

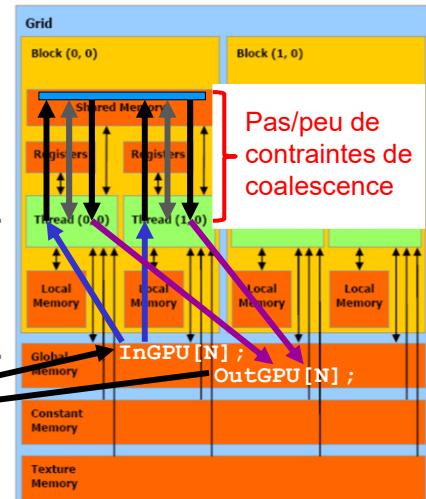
Avantages des kernels utilisant la mémoire globale et la mémoire **shared :**

Motivations/Problèmes :

- besoin que les threads d'un bloc puissent partager des données
- besoin de plus de mémoire (rapide) que celle des registres,
- besoin de diminuer le nombre d'accès à la mémoire globale

Assurer la coalescence
(en **lecture** et **écriture**)

CPU



3

Principles of the *shared memory*

Basic concepts

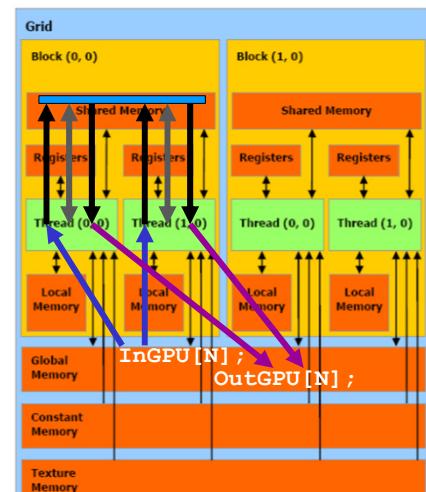
Avantages des kernels utilisant la mémoire globale et la mémoire **shared :**

Motivations/Problèmes :

- besoin que les threads d'un bloc puissent partager des données
- besoin de plus de mémoire (rapide) que celle des registres,
- besoin de diminuer le nombre d'accès à la mémoire globale

Shared memory d'un multiprocesseur :

- 164 KB max par StreamMultiprocessor
- 2x48KB en static sur archi Turing ou Ampere (**48KB par bloc**)
- même technologie que le cache L1 (un peu plus lent que les registres)
- **partagée par tous les threads du bloc**
- **accès rapide sans contrainte**



4

Basic concepts

Kernel utilisant la *shared memory* ... sans partager de données (!)

Calcul : `res[i] = data[i]*data[i];`

Objectif : disposer de plus de mémoire qu'avec uniquement les registres.

Principe : les *threads* utilisent des tables partagées,
...mais différents *thread* accèdent à des cases différentes.

Hyp : $N_d = k \cdot \text{BLOCK_SIZE_X}$

```

global__ void k1D(void)
{
    // Collective definition of table in the shared memory
    shared__ float shdata[BLOCK_SIZE_X];
    // Local computation result
    float res;
    // Compute data idx of the thread
    int idx = threadIdx.x + blockIdx.x * BLOCK_SIZE_X;
    // Read data from the global memory, store in the shared memory
    shdata[threadIdx.x] = InGPU[idx];
    // Compute result (just a computation example ...)
    res = shdata[threadIdx.x] * shdata[threadIdx.x];
    // Write result in the global memory
    OutGPU[idx] = res;
}


```

`Db = {BLOCK_SIZE_X, 1, 1}`
`Dg = {Nd/BLOCK_SIZE_X, 1, 1}`

Le programmeur
« remplace l'algo
de cache » !

Les blocs sont juxtaposés

5

Advanced CUDA programming

Part 1

- 1. **Principles of the *Shared Memory***
 - Basic concepts
 - Scheme of a basic ShM 2D-kernel
 - Scheme of a ShM 2D-kernel with loop
- 2. Examples of the use of *Shared Memory*
- 3. Atomic operations
- 4. Dynamic parallelism
- 5. Conclusion on CUDA programming

6

Scheme of a basic ShM 2D-kernel

```

__global__ void k2D(void)
{
    // Collective definition of table in shared memory
    __shared__ float shdata[BLOCK_SIZE_Y][BLOCK_SIZE_X];
    // Local computation result
    float res;
    // Local definition and computation of indexes in global memory
    int idxX = f(threadIdx.x, blockIdx.x, BLOCK_SIZE_X);
    int idxY = g(threadIdx.y, blockIdx.y, BLOCK_SIZE_Y);
    // Loading input data into the ShM, respecting certain index
    // limits in the global memory
    if (...) {      No constraint           Ensure coalescence
        shdata[threadIdx.y][threadIdx.x] = Input[idxY][idxX];
    }
    __syncthreads(); // REQUIRED: wait for all data loaded in ShM

    // Calculations using any data in the shared memory, but
    // respecting certain limits (boundaries)
    if (...) {      No constraint
        res = ... shdata[...][...] ... ;
        Output[idxY][idxX] = res;
    }              Ensure coalescence
}

```

7

Advanced CUDA programming

Part 1

1. Principles of the *Shared Memory*

- Basic concepts
- Scheme of a basic ShM 2D-kernel
- **Scheme of a ShM 2D-kernel with loop**

2. Examples of the use of *Shared Memory*
3. Atomic operations
4. Dynamic parallelism
5. Conclusion on CUDA programming

8

Scheme of a ShM 2D-kernel with loop

```

__global__ void k2D(void)
{
    // Collective definition of table in shared memory
    __shared__ float shdata[BLOCK_SIZE_Y][BLOCK_SIZE_X];
    // Local computation result
    float res;
    // Local definition and computation of indexes in global memory
    int idxX = f(threadIdx.x, blockIdx.x, BLOCK_SIZE_X);
    int idxY = g(threadIdx.y, blockIdx.y, BLOCK_SIZE_Y);
    for (int step = 0; step < ...; step++) {
        // - shared memory update
        ...
        __syncthreads();
        // - local computation
        res += ...
        __syncthreads();
    }
    if (...) {
        Output[idxY][idxX] = res;
    }
}

```

9

Scheme of a ShM 2D-kernel with loop

```

__global__ void k2D(void)
{
    .....
    for (int step = 0; step < ...; step++) {
        // - shared memory update: loading input data into the ShM
        if (...) {
            shdata[threadIdx.y][threadIdx.x] =
                Input[gg(idxY,step)][ff(idxX,step)];
        }
        __syncthreads(); // REQUIRED: wait for all ShM update are done
        // - local computation: using any data into the shared memory,
        if (...) {
            res += ... shdata[...][...] ...
        }
        __syncthreads(); // REQUIRED: wait for all ShM read are done
    }
    .....
}

```

10

Advanced CUDA programming

Part 1

1. Principles of the *Shared Memory*
2. Examples of the use of *Shared Memory*
 - **Ex 1: Filtering & juxtaposed blocks**
 - Ex 2: Filtering & overlapping blocks
 - Ex 3: Matrix transposition & juxtaposed blocks
3. Atomic operations
4. Dynamic parallelism
5. Conclusion on CUDA programming

11

Examples of the use of *Shared Memory*

Ex 1: Filtering & juxtaposed blocks

Kernel utilisant la *shared memory* et partageant des données – v1

Calcul : `if (i > 0 && i < Nd-1)`
`res[i] = data[i-1]/4+data[i]/2+data[i+1]/4;`

Objectif : accélérer les accès répétés à une même donnée,
 éviter de lire plusieurs fois une même donnée en mémoire globale

Principe : table partagée, et accès à une même case par plusieurs *threads*

Hyp : $Nd = k \cdot \text{BLOCK_SIZE_X}$

```
__global__ void k1D(void)
{
    // Collective definition of table in the shared memory
    __shared__ float shdata[BLOCK_SIZE_X];
    // Local computation result
    float res;
    // Compute data idx of the thread, read one element and sync.
    int idx = threadIdx.x + blockIdx.x * BLOCK_SIZE_X;
    shdata[threadIdx.x] = InGPU[idx];
    __syncthreads(); // REQUIRED !!
    .....
}
```

Db = {BLOCK_SIZE_X, 1, 1}
 Dg = {Nd / (BLOCK_SIZE_X), 1, 1}

Chaque thread du bloc a fini de charger une donnée en *shm*

Les blocs sont juxtaposés

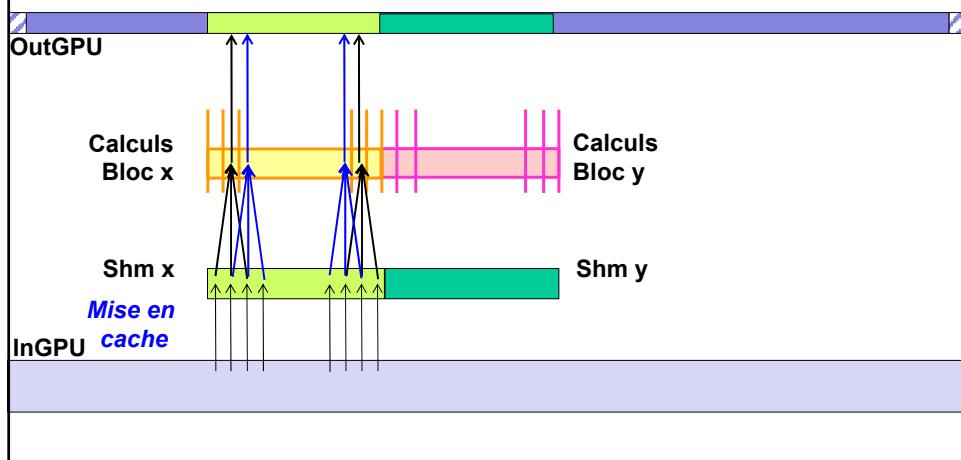


12

Ex 1: Filtering & juxtaposed blocks

Kernel utilisant la **shared memory** et partageant des données – v1

Objectif : accélérer les accès répétés à une même donnée,
 → ramener chaque donnée en *shared memory* (une seule fois)
 → « faire BSX accès en mémoire globale au lieu de 3xBSX » par bloc

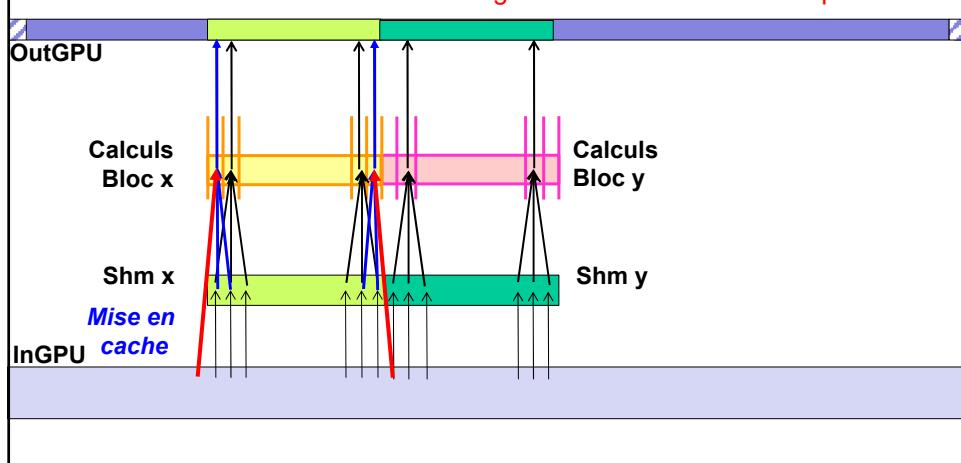


13

Ex 1: Filtering & juxtaposed blocks

Kernel utilisant la **shared memory** et partageant des données – v1

Objectif : accélérer les accès répétés à une même donnée,
 → ramener chaque donnée en *shared memory* (une seule fois)
 → « faire BSX accès en mémoire globale au lieu de 3xBSX » par bloc



14

Ex 1: Filtering & juxtaposed blocks

Kernel utilisant la **shared memory** et partageant des données – v1

Principe : table partagée, et accès à une même case par plusieurs *threads*

Hyp : $Nd = k * \text{BLOCK_SIZE_X}$

```

Db = {BLOCK_SIZE_X,1,1}
Dg = {Nd/(BLOCK_SIZE_X),1,1}

if (idx > 0 && idx < Nd-1) {
    // Compute the left and right values
    float left, right;
    if (threadIdx.x == 0)
        left = InGPU[idx-1];
    else
        left = shdata[threadIdx.x-1];
    if (threadIdx.x == BLOCK_SIZE_X-1)
        right = InGPU[idx+1];
    else
        right= shdata[threadIdx.x+1];
    // Compute result
    res = left*0.25f + shdata[threadIdx.x]*0.5f + right*0.25f;
    // Write result in the global memory
    OutGPU[idx] = res;
}
  
```

Les blocs sont juxtaposés

Accès à des données non chargées dans la *shm* par les *threads* du bloc

Exploitation de données dans la *shm*

15

Ex 1: Filtering & juxtaposed blocks

Kernel utilisant la **shared memory** et partageant des données – v2

Objectif : ne ramener chaque donnée qu'une seule fois en mémoire locale

Principe : tables partagées, et accès aux mêmes cases

Hyp : $Nd \neq k * \text{BLOCK_SIZE_X}$

```

__global__ void k1D(void)
{
    // Collective definition of table in the shared memory
    __shared__ float shdata[BLOCK_SIZE_X];
    // Local computation result
    float res;
    // Compute data idx of the thread, read one element and sync.
    idx = threadIdx.x + blockIdx.x*BLOCK_SIZE_X;
    if (idx < Nd) {
        shdata[threadIdx.x] = InGPU[idx];
    }
    __syncthreads(); // REQUIRED !!
    .....
  
```

Les blocs sont juxtaposés

mais le dernier bloc déborde

16

Ex 1: Filtering & juxtaposed blocks

Kernel utilisant la *shared memory* et partageant des données – v2

Objectif : ne ramener chaque donnée qu'une seule fois en mémoire locale

Principe : tables partagées, et accès aux même cases

Hyp : $Nd \neq k * \text{BLOCK_SIZE_X}$

$$\begin{aligned} Db &= \{\text{BLOCK_SIZE_X}, 1, 1\} \\ Dg &= \{Nd / (\text{BLOCK_SIZE_X}) + \\ &\quad (Nd \% \text{BLOCK_SIZE_X} ? 1 : 0), 1, 1\} \end{aligned}$$

```
.....
```

```

if (idx > 0 && idx < Nd-1 /* && idx < Nd */) {
    // Compute the left and right values
    float left, right;
    if (threadIdx.x == 0)
        left = InGPU[idx-1];
    else
        left = shdata[threadIdx.x-1];
    if (threadIdx.x == BLOCK_SIZE_X-1)
        right = InGPU[idx+1];
    else
        right = shdata[threadIdx.x+1];
    // Compute result
    res = left*0.25f + shdata[threadIdx.x]*0.5f + right*0.25f;
    // Write result in the global memory
    OutGPU[idx] = res;
}
  
```

Les blocs sont juxtaposés
mais le dernier bloc déborde



17

Advanced CUDA programming

Part 1

1. Principles of the *Shared Memory*
2. Examples of the use of *Shared Memory*
 - Ex 1: Filtering & juxtaposed blocks
 - **Ex 2: Filtering & overlapping blocks**
 - Ex 3: Matrix transposition & juxtaposed blocks
3. Atomic operations
4. Dynamic parallelism
5. Conclusion on CUDA programming

18

Ex 2: Filtering & overlapping blocks

Kernel utilisant la *shared memory* et partageant des données – v3

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*

→ afin de pouvoir écrire le code suivant :

```
__global__ void k1D(void)
{
    ....
    if (...) {
        // Compute result (another computation example...)
        res = shdata[threadIdx.x-1]*0.25f +
              shdata[threadIdx.x]*0.50f +
              shdata[threadIdx.x+1]*0.25f;
        // Write result in the global memory
        OutGPU[idx] = res;
    }
}
```



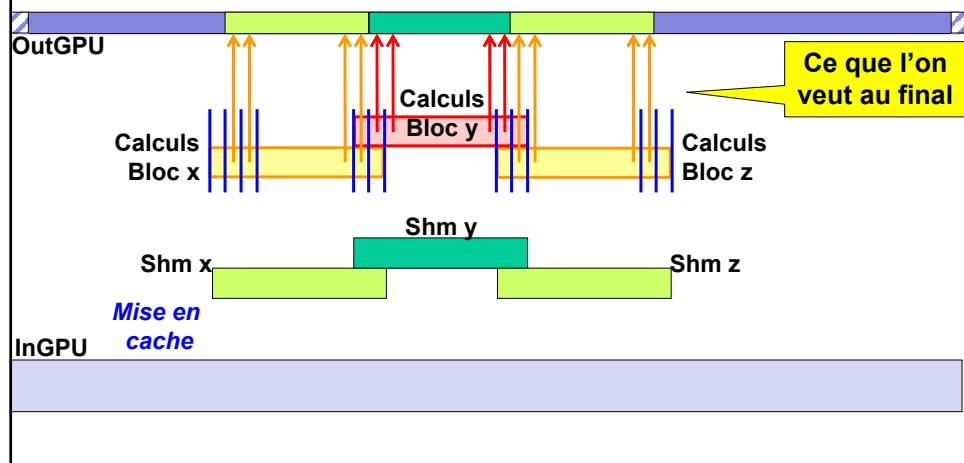
→ Des blocs juxtaposés ne suffisent plus

19

Ex 2: Filtering & overlapping blocks

Kernel utilisant la *shared memory* et partageant des données – v3

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*

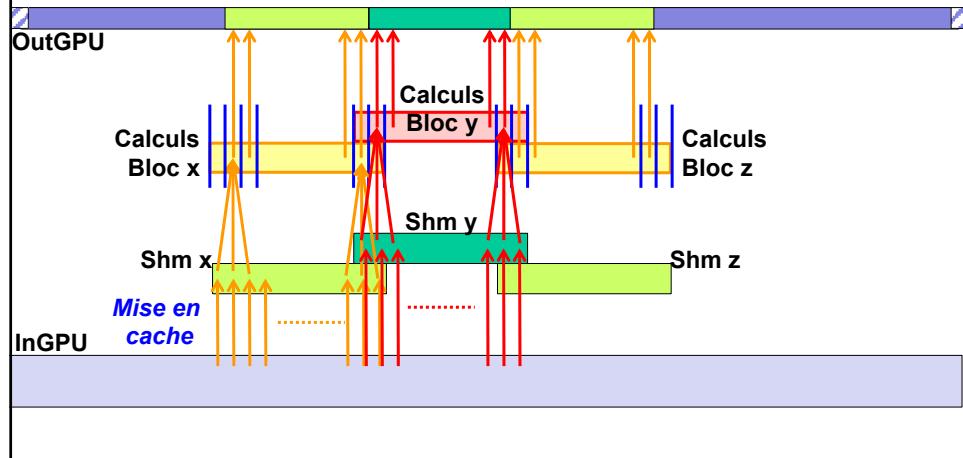


20

Ex 2: Filtering & overlapping blocks

Kernel utilisant la **shared memory** et partageant des données – v3

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*

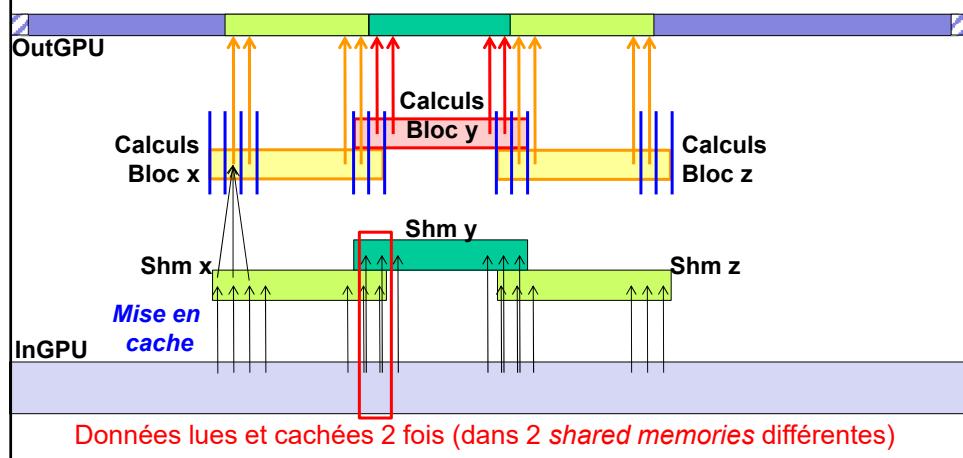


21

Ex 2: Filtering & overlapping blocks

Kernel utilisant la **shared memory** et partageant des données – v3

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*

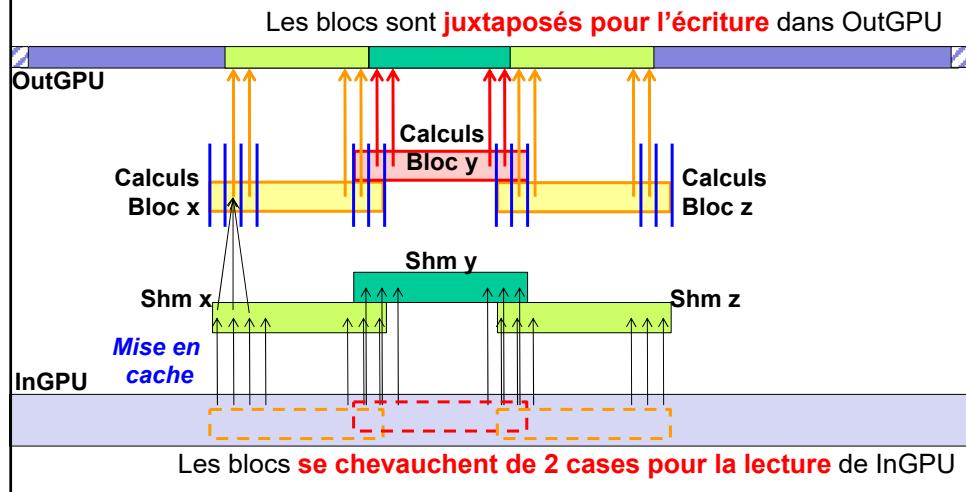


22

Ex 2: Filtering & overlapping blocks

Kernel utilisant la **shared memory** et partageant des données – v3

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*

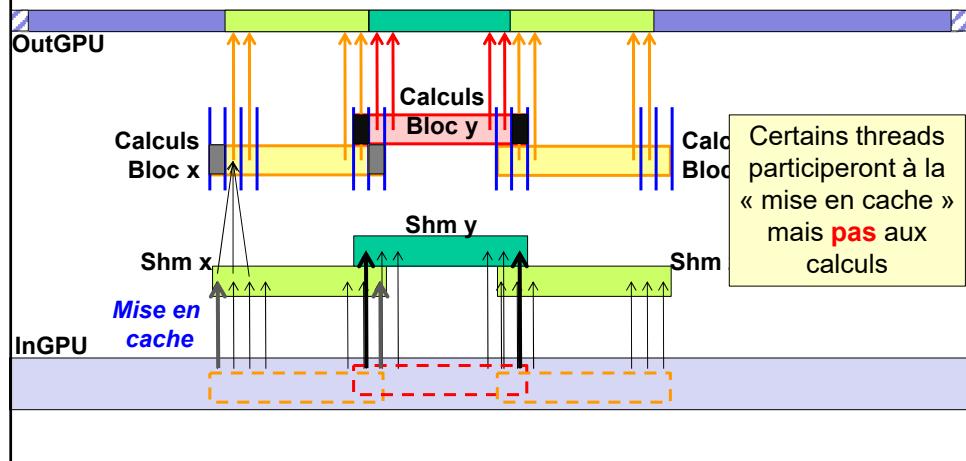


23

Ex 2: Filtering & overlapping blocks

Kernel utilisant la **shared memory** et partageant des données – v3

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*

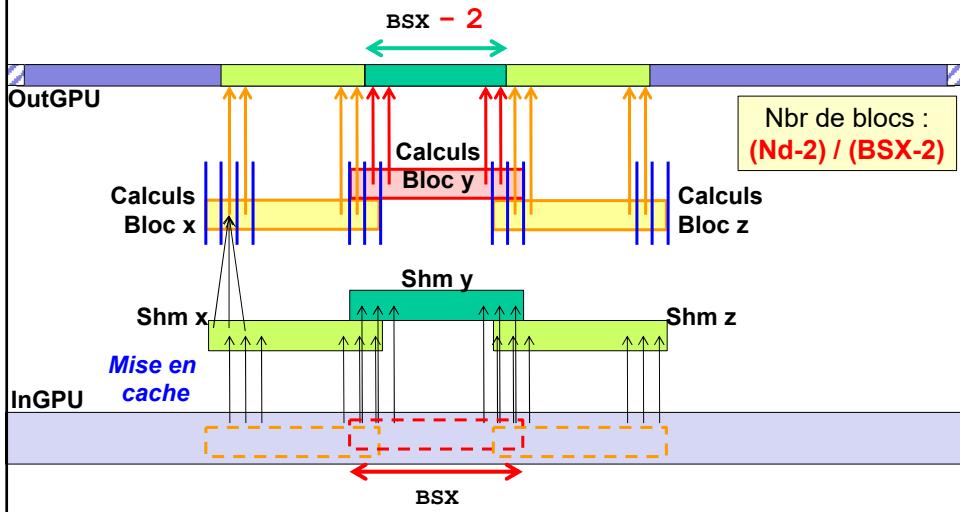


24

Ex 2: Filtering & overlapping blocks

Kernel utilisant la *shared memory* et partageant des données – v3

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*



25

Ex 2: Filtering & overlapping blocks

Kernel utilisant la *shared memory* et partageant des données – v3

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*

Principe : table partagée, et accès aux même cases depuis plusieurs threads

Hyp : $Nd-2 = k \cdot (BSX-2)$

$D_b = \{BSX, 1, 1\}$
 $D_g = \{(Nd-2) / (BSX-2), 1, 1\}$

```
global__ void k1D(void)
{
    __shared__ float shdata[BSX]; // Collective shm definition
    float res; // Local variable (register)

    // Compute data idx of the thread, read one element and sync.
    int idx = threadIdx.x + blockIdx.x * (BSX-2);
    shdata[threadIdx.x] = InGPU[idx];
    __syncthreads(); // REQUIRED !!

    // Computation
    if (threadIdx.x > 0 && threadIdx.x < BSX-1
        /* && idx > 0 && idx < Nd-1 */ ) {
        res = shdata[threadIdx.x-1]*0.25f + // Computation example
            shdata[threadIdx.x]*0.50f +
            shdata[threadIdx.x+1]*0.25f;
        OutGPU[idx] = res; // Result storage
    }
}
```

Les blocs doivent se chevaucher

26

Ex 2: Filtering & overlapping blocks

Kernel utilisant la *shared memory* et partageant des données – v4

Objectif : toutes les données des calculs de chaque bloc cachées en *shm*

Principe : table partagée, et accès aux même cases depuis plusieurs *threads*

Hyp : $Nd-2 \neq k*(BSX-2)$

```

global __ void k1D(void)
{
    __shared__ float shdata[BSX]; // Local variable (register)
    float res;
    Db = {BSX,1,1};
    Dg = {(Nd-2)/(BSX-2) + ((Nd-2)%(BSX-2)?1:0),1,1}; new !
    // Compute data idx of the thread, read one element and sync.
    int idx = threadIdx.x + blockIdx.x*(BSX-2);
    if (idx < Nd) {shdata[threadIdx.x] = InGPU[idx];} new !
    __syncthreads(); // REQUIRED !!

    // Computation
    if (threadIdx.x > 0 && threadIdx.x < BSX-1
        /* && idx > 0 */ && idx < Nd-1) {
        res = shdata[threadIdx.x-1]*0.25f + // Computation example
              shdata[threadIdx.x]*0.50f +
              shdata[threadIdx.x+1]*0.25f;
        OutGPU[idx] = res;
    }
}

```

Les blocs doivent se chevaucher, et le dernier déborde



27

Advanced CUDA programming

Part 1

1. Principles of the *Shared Memory*
2. Examples of the use of *Shared Memory*
 - Ex 1: Filtering & juxtaposed blocks
 - Ex 2: Filtering & overlapping blocks
 - **Ex 3: Matrix transposition & juxtaposed blocks**
3. Atomic operations
4. Dynamic parallelism
5. Conclusion on CUDA programming

28

Ex 3: Matrix transposition & juxtaposed blocks

Kernel naïf de transposition d'une matrice

```

__global__ void Transpose_v0(float *MT, float *M,
                             int nbLigM, int nbColM)
{
    int ligM = threadIdx.y + blockIdx.y*BSIZE_XY_KT0;
    int colM = threadIdx.x + blockIdx.x*BSIZE_XY_KT0;

    if (ligM < nbLigM && colM < nbColM)
        MT[colM*nbLigM + ligM] = M[ligM*nbColM + colM];
        //MT[colM][ligM]           = M[ligM][colM]
}
    
```

Accès NON coalescent

Accès coalescent

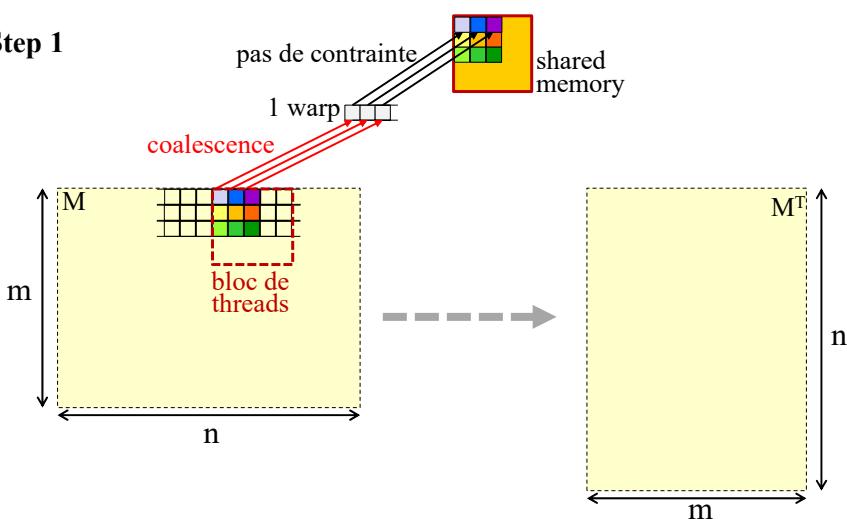
→ Utiliser la *shared memory* pour être coalescent à la lecture et à l'écriture...

29

Ex 3: Matrix transposition & juxtaposed blocks

Kernel optimisé de transposition d'une matrice

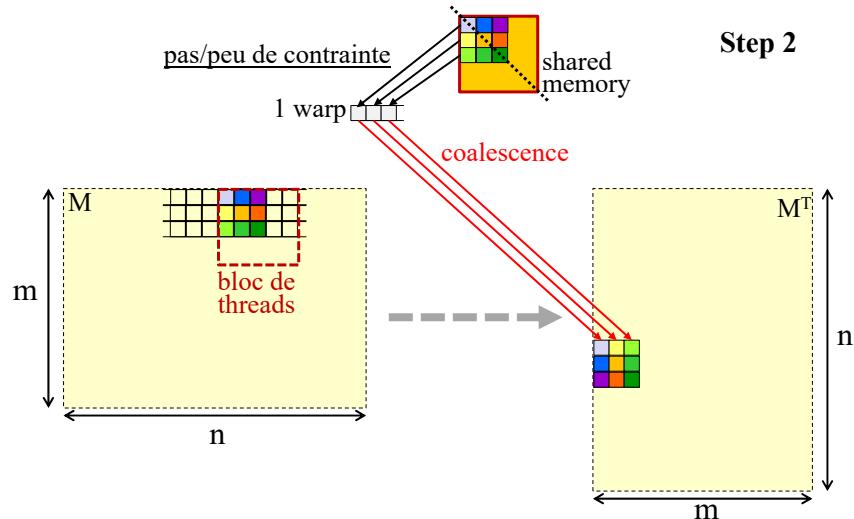
Step 1



30

Ex 3: Matrix transposition & juxtaposed blocks

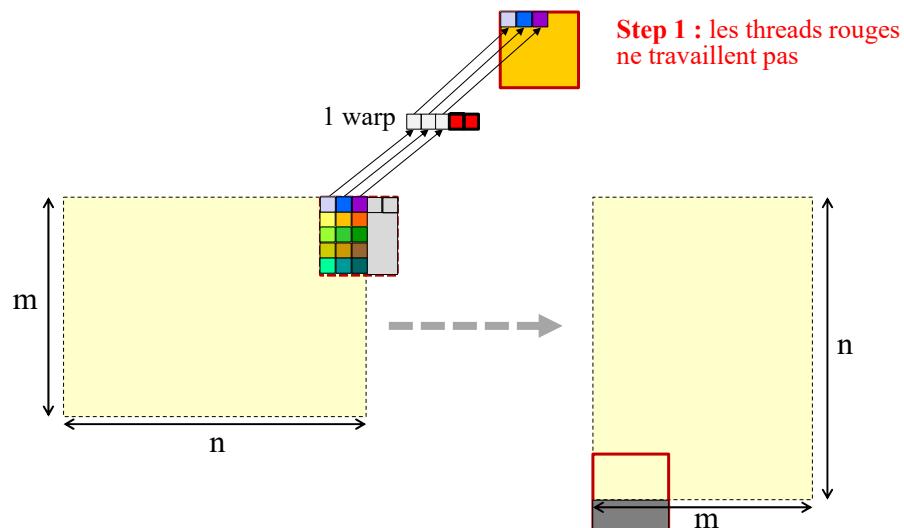
Kernel optimisé de transposition d'une matrice



31

Ex 3: Matrix transposition & juxtaposed blocks

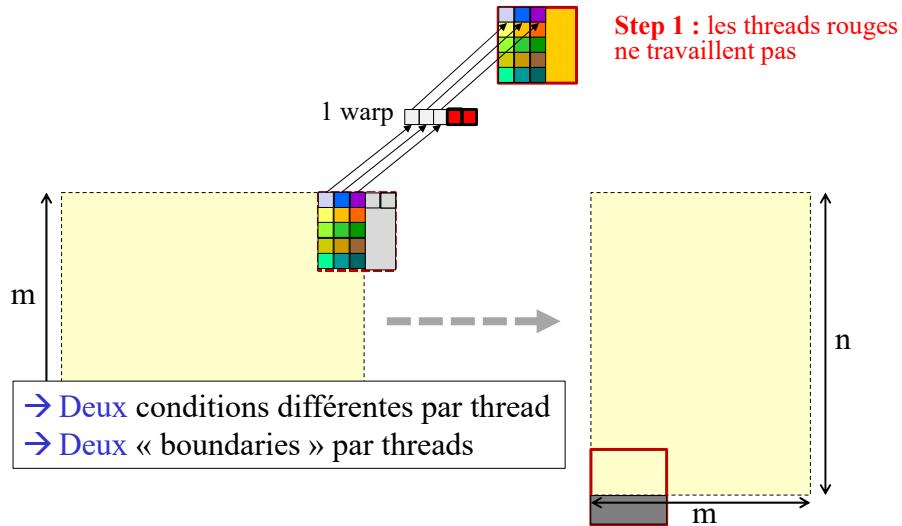
Kernel optimisé de transposition d'une matrice



32

Ex 3: Matrix transposition & juxtaposed blocks

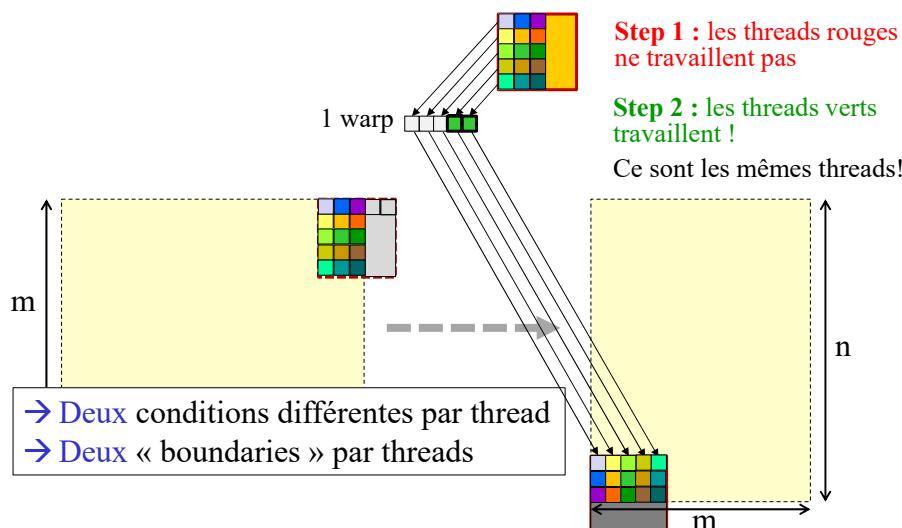
Kernel optimisé de transposition d'une matrice



33

Ex 3: Matrix transposition & juxtaposed blocks

Kernel optimisé de transposition d'une matrice



34

Ex 3: Matrix transposition & juxtaposed blocks

Kernel optimisé de transposition d'une matrice

```

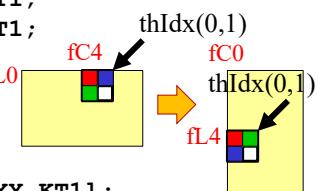
__global__ void Transpose_v1(float *MT, float *M,
                             int nbLigM, int nbColM)
{
    int firstLigBlock = blockIdx.y*BSIZE_XY_KT1;
    int firstColBlock = blockIdx.x*BSIZE_XY_KT1;
    int ligM = firstLigBlock + threadIdx.y;          thIdx(0,1)
    int colM = firstColBlock + threadIdx.x;          fL0
    int ligMT = firstColBlock + threadIdx.y;          fC4
    int colMT = firstLigBlock + threadIdx.x;          fL4
    __shared__ float shM[BSIZE_XY_KT1][BSIZE_XY_KT1];

    if (ligM < nbLigM && colM < nbColM) // Load data in cache
        shM[threadIdx.y][threadIdx.x] = M[ligM*nbColM + colM];

    __syncthreads();                                // Wait for all data in cache

    if (ligMT < nbColM && colMT < nbLigM) // Write back the cache
        MT[ligMT*nbLigM + colMT] = shM[threadIdx.x][threadIdx.y];
}

```



35

Advanced CUDA programming

Part 1

- 1. Principles of the *Shared Memory*
- 2. Examples of the use of *Shared Memory*
- 3. Atomic operations**
- 4. Dynamic parallelism
- 5. Conclusion on CUDA programming

36

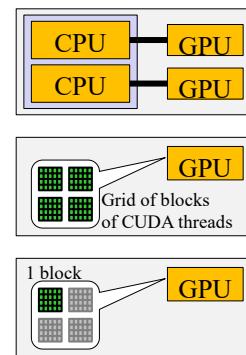
3 kinds of atomic functions

Principes :

- Des fonctions qui doivent s'exécuter sur le GPU
- Des fonctions qui apportent une section critique et une « mutex »

Mais 3 types de « mutex » :

- **atomicXxx_system(...)** : exclusion avec tous les threads du même programme sur le(s) GPU et sur le(s) CPU
- **atomicXxx(...)** : exclusion avec tous les threads CUDA du même programme sur le même GPU
- **atomicXxx_block(...)** : exclusion avec tous les threads CUDA du même bloc de threads

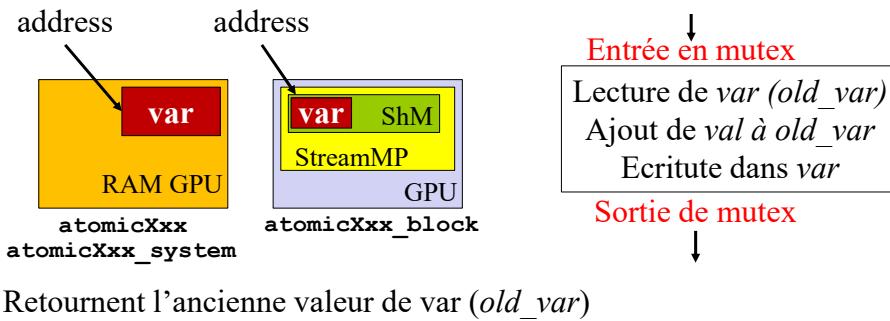


37

Classical atomic functions

Les atomicAdd :

```
int atomicAdd(int* address, int val);
unsigned int atomicAdd(unsigned int* address, unsigned int val);
unsigned long long int atomicAdd(unsigned long long int* address,
                                 unsigned long long int val);
float atomicAdd(float* address, float val);
double atomicAdd(double* address, double val);
```



38

Classical atomic functions

Les `atomicSub` :

```
int atomicSub(int* address, int val);
unsigned int atomicSub(unsigned int* address, unsigned int val);
```

Les `atomicExch` :

```
int atomicExch(int* address, int val);
unsigned int atomicExch(unsigned int* address, unsigned int val);
unsigned long long int atomicExch(unsigned long long int* address,
                                  unsigned long long int val);
float atomicExch(float* address, float val);
```



Retournent l'ancienne valeur de var (*old_var*)

39

Classical atomic functions

Les `atomicMin` :

```
int atomicMin(int* address, int val);
unsigned int atomicMin(unsigned int* address, unsigned int val);
unsigned long long int atomicMin(unsigned long long int* address,
                                 unsigned long long int val);
```



Les `atomicMax` :

```
int atomicMax(int* address, int val);
unsigned int atomicMax(unsigned int* address, unsigned int val);
unsigned long long int atomicMax(unsigned long long int* address,
                                 unsigned long long int val);
```

Retournent l'ancienne valeur de var (*old_var*)

40

Classical atomic functions

Les `atomicInc` :

```
unsigned int atomicInc(unsigned int* address, unsigned int val);
```

address

$$\text{var} \leftarrow ((\text{old_var} \geq \text{val}) ? 0 : (\text{old_var} + 1))$$

Incrémente *var* et retour à 0 quand il a atteint *val*

Les `atomicDec` :

```
unsigned int atomicDec(unsigned int* address, unsigned int val);
```

address

$$\text{var} \leftarrow (((\text{old_var} == 0) \parallel (\text{old_var} > \text{val})) ? \text{val} : (\text{old_var} - 1))$$

Décrémente *var* et retour à *val* s'il avait atteint 0

Retournent l'ancienne valeur de *var* (*old_var*)

41

Classical atomic functions

Les `atomicCAS` (*compare and set*) :

```
int atomicCAS(int* address, int compare, int val);
unsigned int atomicCAS(unsigned int* address,
                      unsigned int compare, unsigned int val);
unsigned long long int atomicCAS(unsigned long long int* address,
                                   unsigned long long int compare,
                                   unsigned long long int val);
unsigned short int atomicCAS(unsigned short int *address,
                            unsigned short int compare,
                            unsigned short int val);
```

address

$$\text{var} \leftarrow (\text{old_var} == \text{compare} ? \text{val} : \text{old_var})$$

Change *var* s'il vaut une certaine valeur

Retournent l'ancienne valeur de *var* (*old_var*)

42

Classical atomic functions

Les fct atomiques « bitwise » :

```
int atomicAnd(int* address, int val);
unsigned int atomicAnd(unsigned int* address, unsigned int val);
unsigned long long int atomicAnd(unsigned long long int* address,
                                unsigned long long int val);
```

Opération « and » sur chaque bit de var

var ← (old_var & val)

```
int atomicOr(int* address, int val);
unsigned int atomicOr(unsigned int* address, unsigned int val);
unsigned long long int atomicOr(unsigned long long int* address,
                                unsigned long long int val);
```

```
int atomicXor(int* address, int val);
unsigned int atomicXor(unsigned int* address, unsigned int val);
unsigned long long int atomicXor(unsigned long long int* address,
                                unsigned long long int val);
```

43

« System » and « block » atomic functions

L'exclusion des fonctions atomique précédentes porte :

- sur les threads CUDA du même programme
- sur le même GPU

→ Des versions « _system » et « _block » existent

Toutes les fct atomiques ne sont pas disponibles sur tous les GPU :

- compute capability < 6.0 only **atomicxxx** only (device wide)
- compute capability < 7.2 no **atomicXXX_system** (system-wide)
- Autres restrictions sur les fct portant sur les doubles ou sur les half

44

Advanced CUDA programming

Part 1

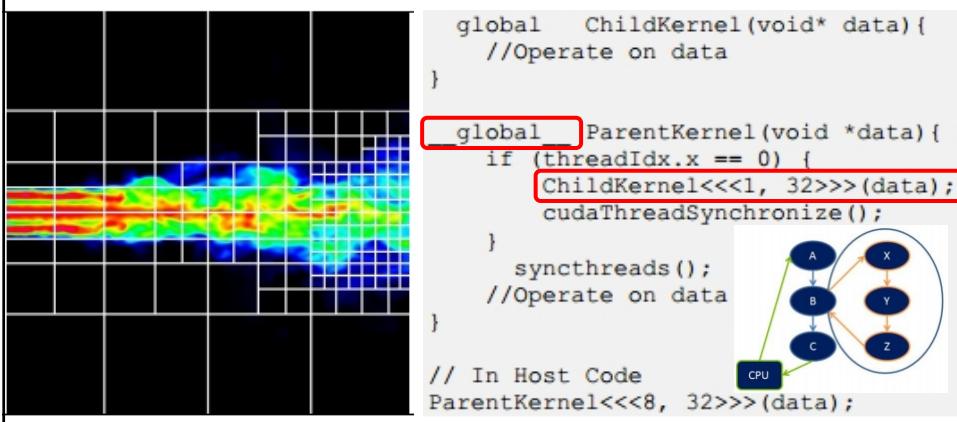
1. Principles of the *Shared Memory*
2. Examples of the use of *Shared Memory*
3. Atomic operations
- 4. Dynamic parallelism**
5. Conclusion on CUDA programming

45

Dynamic parallelism

Un thread GPU peut lancer d'autres threads GPU

- Un thread définit et lance lui-même une grille de blocs de threads
- Très utile pour des maillages adaptatifs



46

Dynamic parallelism

Un thread GPU peut lancer d'autres threads GPU

Remplacer une grosse grille de blocs par :

- une petite grille mère dont les threads créent des grilles filles (même de tailles identiques)
 - avec un *stream* différent par grille fille
- Permet parfois de gagner du temps à l'exécution et d'augmenter les performances !
(permet de mieux saturer les ressources d'un GPU)

47

Advanced CUDA programming Part 1

1. Principles of the *Shared Memory*
2. Examples of the use of *Shared Memory*
3. Atomic operations
4. Dynamic parallelism
- 5. Conclusion on CUDA programming**

48

Conclusion on CUDA programming

Une nouvelle façon de programmer :

- Remplace la programmation *vectorielle* sur les architectures *vectorielles* disparues
- Partage des concepts avec la programmation *threads+vectorisation* des architectures CPU *multicores+SIMD*
- Demande une période d'apprentissage et debug difficile...

Démarche d'apprentissage conseillée :

- Apprendre les bases de CUDA puis les optimisations principales (*CUDA C Best Practices Guide*)
- Guider les développements par la mesure de la performance atteinte
- Apprendre à identifier si un algorithme est adapté au GPU
... avant de le développer sur GPU

49

Conclusion on CUDA programming

Les bonnes pratiques :

- Ecrire des kernels coalescents et non-divergents
- Utiliser la *shared memory* avec un « algo de cache dédié au pb »
... ne pas oublier de resynchroniser les threads si nécessaire !
- Sur des structures de données 2D ou plus : planter des grilles et des blocs 2D (ou 3D) et chercher les bonnes tailles de blocs

Performances :

- Parfois des gains *spectaculaires* vis-à-vis d'un cœur CPU et en ne considérant que les temps de calculs
- Mais souvent un gain de 2 à 10 seulement en considérant les transferts de données et vis-à-vis d'un code parallèle et optimisé sur un serveur dual-CPU (serveur standard) !

50

Advanced CUDA programming

Part 1

End