

GP-GPU

Advanced CUDA programming Part 1

Stéphane Vialle


université
ÉCOLE NATIONALE
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

InGPU[N]; OutGPU[N];

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

Principles of the shared memory
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 : $Nd = k \cdot BLOCK_SIZE_X$

```

global__ void k1D(void)
{
    Db = {BLOCK_SIZE_X,1,1}
    Dg = {Nd/BLOCK_SIZE_X,1,1}

    // 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;
}

```

Le programmeur « remplace l'algorithme 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

POLYTECH
PARIS-SACLAY

Principles of the shared memory

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

POLYTECH
PARIS-SACLAY

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

POLYTECH
PARIS-SACLAY

Principles of the shared memory

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

POLYTECH
PARIS-SACLAY

Principles of the shared memory

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

POLYTECH
PARIS-SACLAY

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

POLYTECH
PARIS-SACLAY

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

```

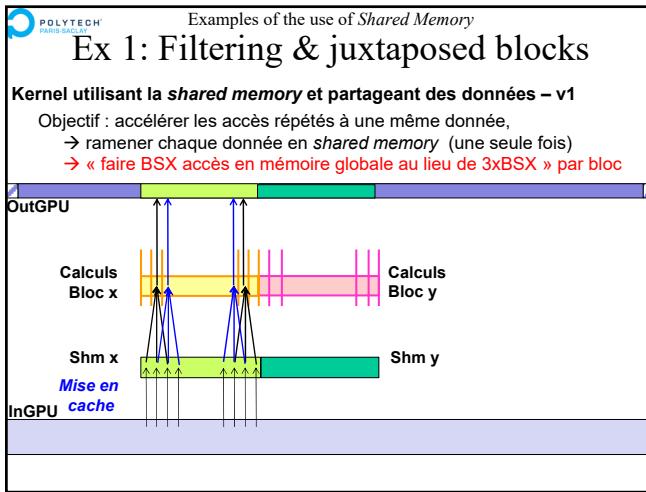
global__ void k1d(void)
{
    // Collective definition of table in the shared memory
    shared__ float shdata[BLOCK_SIZE_X];
    // Local computation result
    float res;
    // Compute data idx of the thread, read one element and sync.
    int idx = threadIdx.x + blockIdx.x * BLOCK_SIZE_X;
    shdata[threadIdx.x] = InGPU[idx];
    __syncthreads(); // REQUIRED !!
    .....
}

```

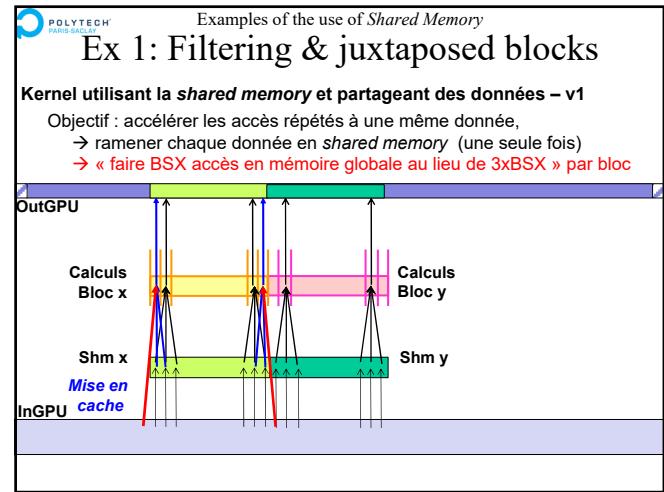
Chaque thread du bloc a fini de charger une donnée en *shm*

Les blocs sont juxtaposés

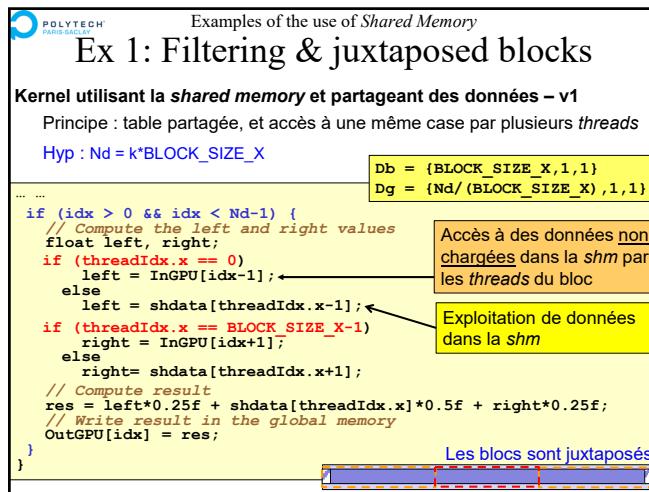
12



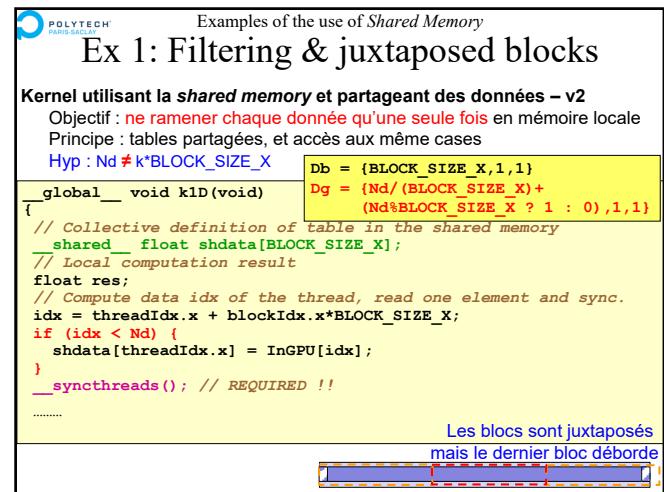
13



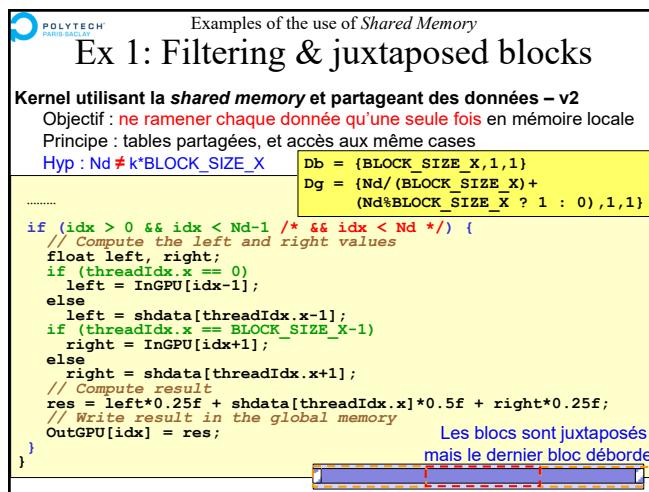
14



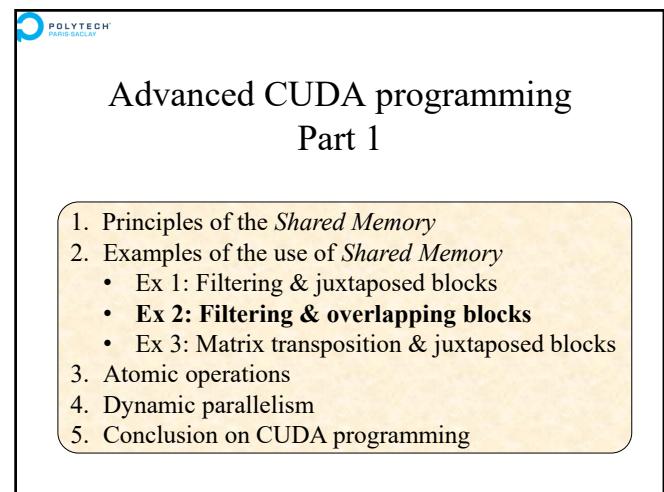
15



16



17



POLYTECH PARIS-SACLAY Examples of the use of Shared Memory

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

POLYTECH PARIS-SACLAY Examples of the use of Shared Memory

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

Ce que l'on veut au final

Calculs Bloc x

Calculs Bloc y

Calculs Bloc z

Shm x

Shm y

Shm z

Mise en cache

20

POLYTECH PARIS-SACLAY Examples of the use of Shared Memory

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

OutGPU

InGPU

Calculs Bloc x

Calculs Bloc y

Calculs Bloc z

Shm x

Shm y

Shm z

Mise en cache

21

POLYTECH PARIS-SACLAY Examples of the use of Shared Memory

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

OutGPU

InGPU

Calculs Bloc x

Calculs Bloc y

Calculs Bloc z

Shm x

Shm y

Shm z

Mise en cache

Données lues et cachées 2 fois (dans 2 shared memories différentes)

22

POLYTECH PARIS-SACLAY Examples of the use of Shared Memory

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

Les blocs sont juxtaposés pour l'écriture dans OutGPU

OutGPU

InGPU

Calculs Bloc x

Calculs Bloc y

Calculs Bloc z

Shm x

Shm y

Shm z

Mise en cache

Les blocs se chevauchent de 2 cases pour la lecture de InGPU

23

POLYTECH PARIS-SACLAY Examples of the use of Shared Memory

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

OutGPU

InGPU

Calculs Bloc x

Calculs Bloc y

Calculs Bloc z

Shm x

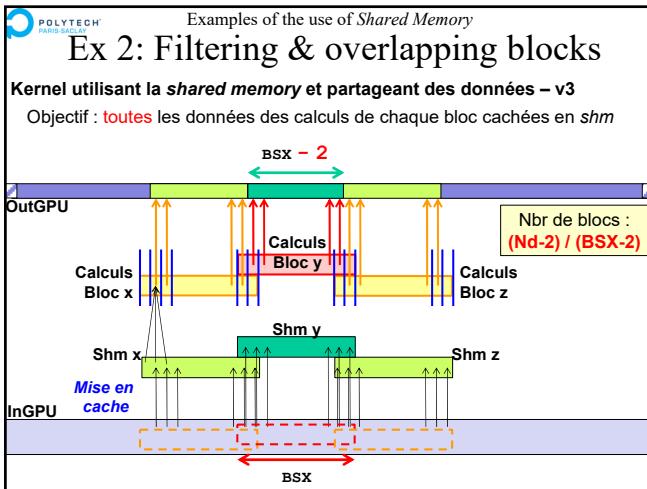
Shm y

Shm z

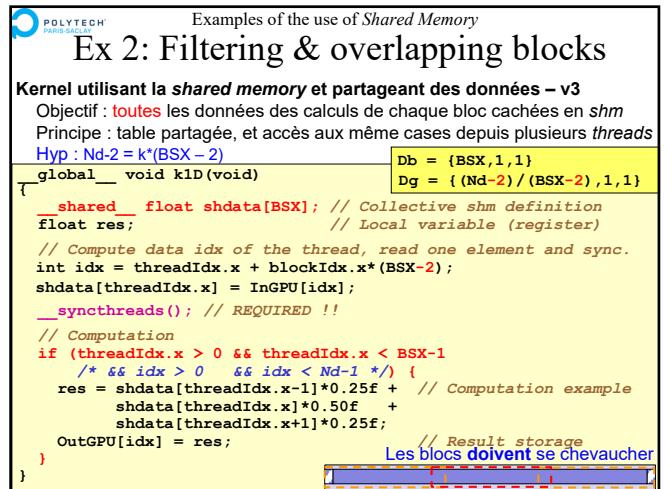
Mise en cache

Certains threads participeront à la « mise en cache » mais pas aux calculs

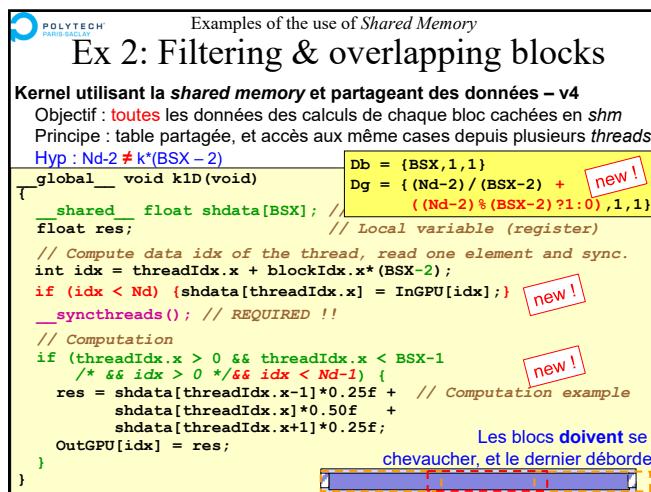
24



25



26

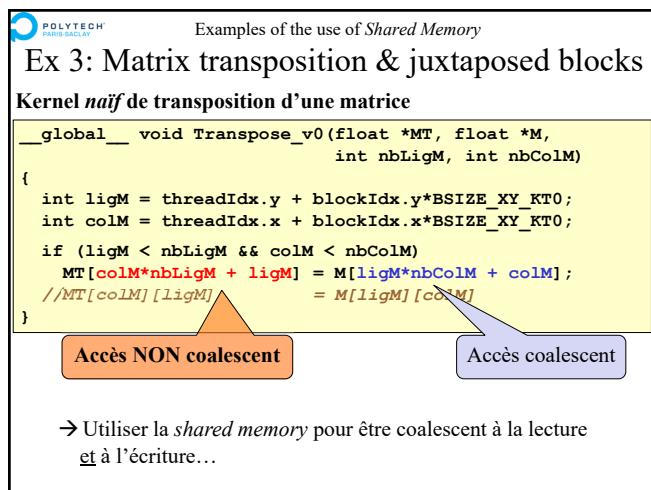


27

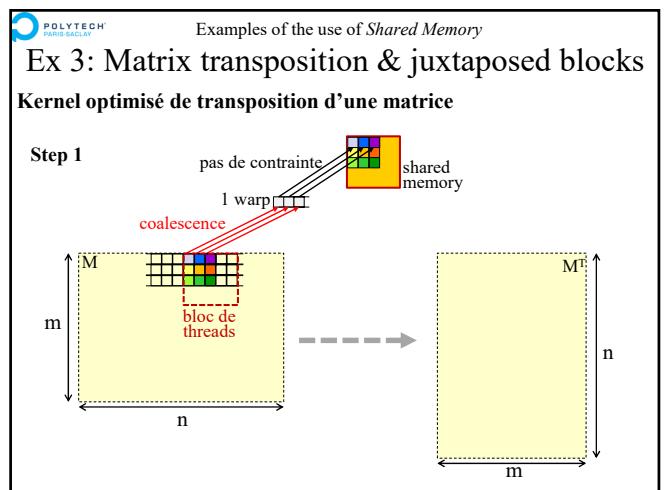
Advanced CUDA programming Part 1

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

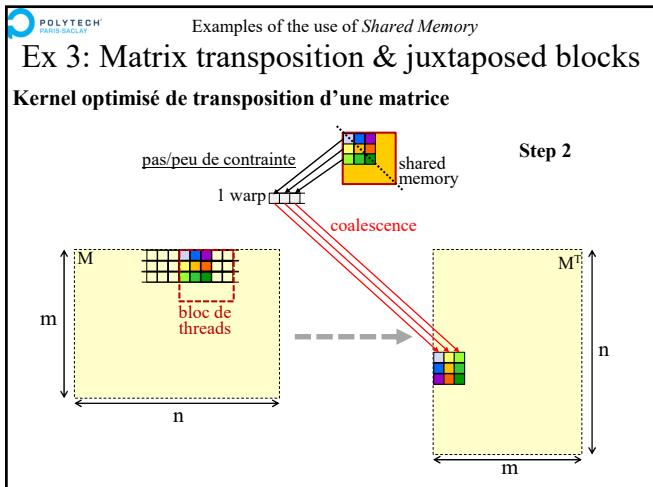
28



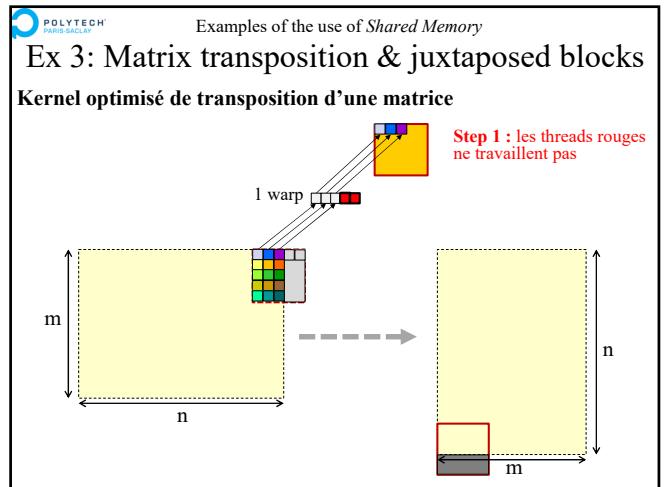
29



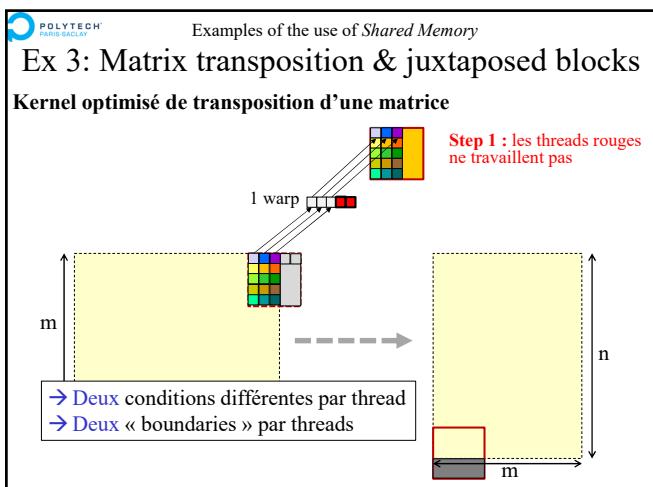
30



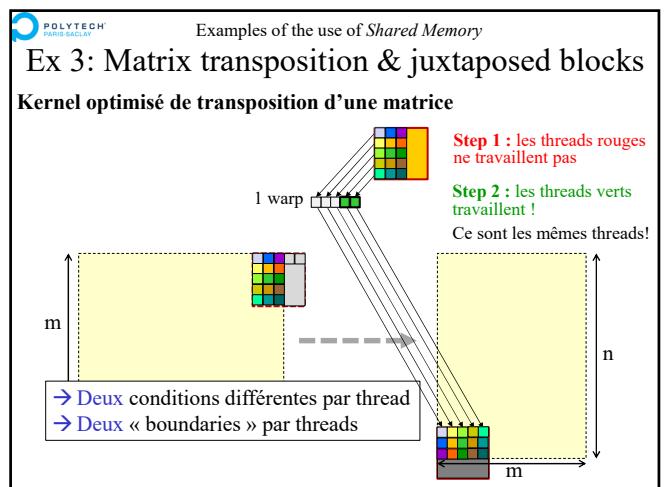
31



32



33



34

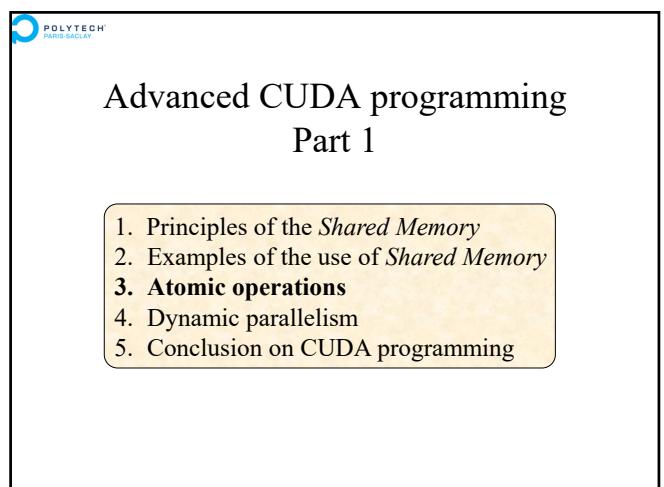
POLYTECH PARIS-SACLAY Examples of the use of Shared Memory

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; fL0
int colM = firstColBlock + threadIdx.x; fC0
int ligMT = firstColBlock + threadIdx.y; fL4
int colMT = firstLigBlock + threadIdx.x; fC4
__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



Atomic operations

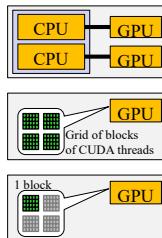
3 kinds of atomic functions

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



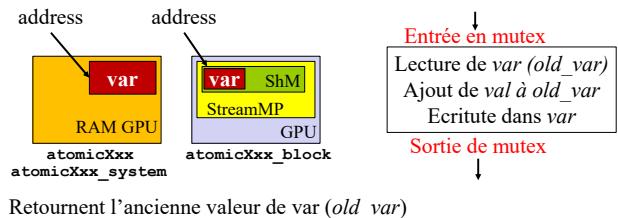
37

Atomic operations

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

Atomic operations

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);
```



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

39

Atomic operations

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);
```

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

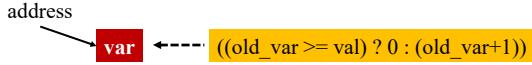
40

Atomic operations

Classical atomic functions

Les **atomicInc** :

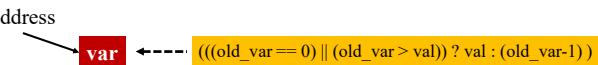
```
unsigned int atomicInc(unsigned int* address, unsigned int val);
```



Incrémente var et retour à 0 quand il a atteint val

Les **atomicDec** :

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



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

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

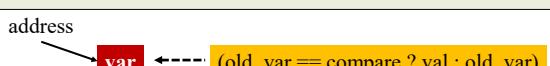
41

Atomic operations

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);
```



Change var s'il vaut une certaine valeur

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

POLYTECH
PARIS-SACLAY

Atomic operations

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

POLYTECH
PARIS-SACLAY

Atomic operations

« 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

POLYTECH
PARIS-SACLAY

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

POLYTECH
PARIS-SACLAY

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

```
global ChildKernel(void* data) {
    //Operate on data
}

global ParentKernel(void *data) {
    if (threadIdx.x == 0) {
        ChildKernel<<<1, 32>>>(data);
        cudaThreadSynchronize();
    }
    syncthreads();
    //Operate on data
}

// In Host Code
ParentKernel<<<8, 32>>>(data);
```

The diagram shows a heatmap representing a complex pattern being processed by a grid of threads. A specific thread (highlighted in red) is shown launching a child kernel (ChildKernel). The host code (ParentKernel) is shown launching the child kernel and synchronizing threads. A callout shows the relationship between the host code and the device code.

46

POLYTECH
PARIS-SACLAY

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

POLYTECH
PARIS-SACLAY

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 : implanter 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

51