POLYTECH
PARIS-SACLAY

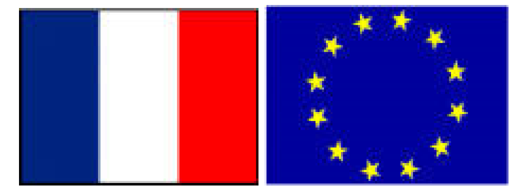

GP-GPU

Advanced CUDA programming
Part 1

Stéphane Vialle

université
PARIS-SACLAY

ÉCOLE DOCTORALE
Sciences et technologies
de l'information
et de la communication (STIC)

Stephane.Vialle@centralesupelec.fr
http://www.metz.supelec.fr/~vialle

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

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

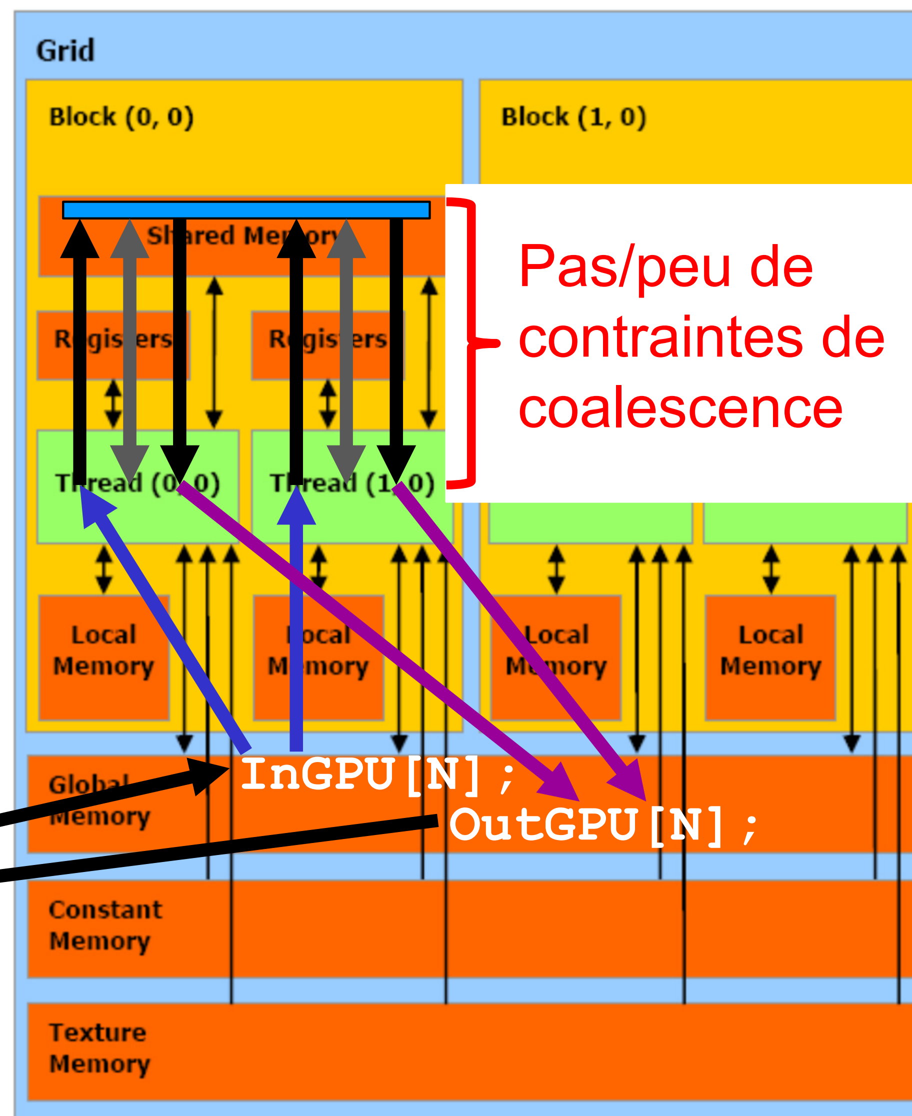

Principles of the *shared memory*

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

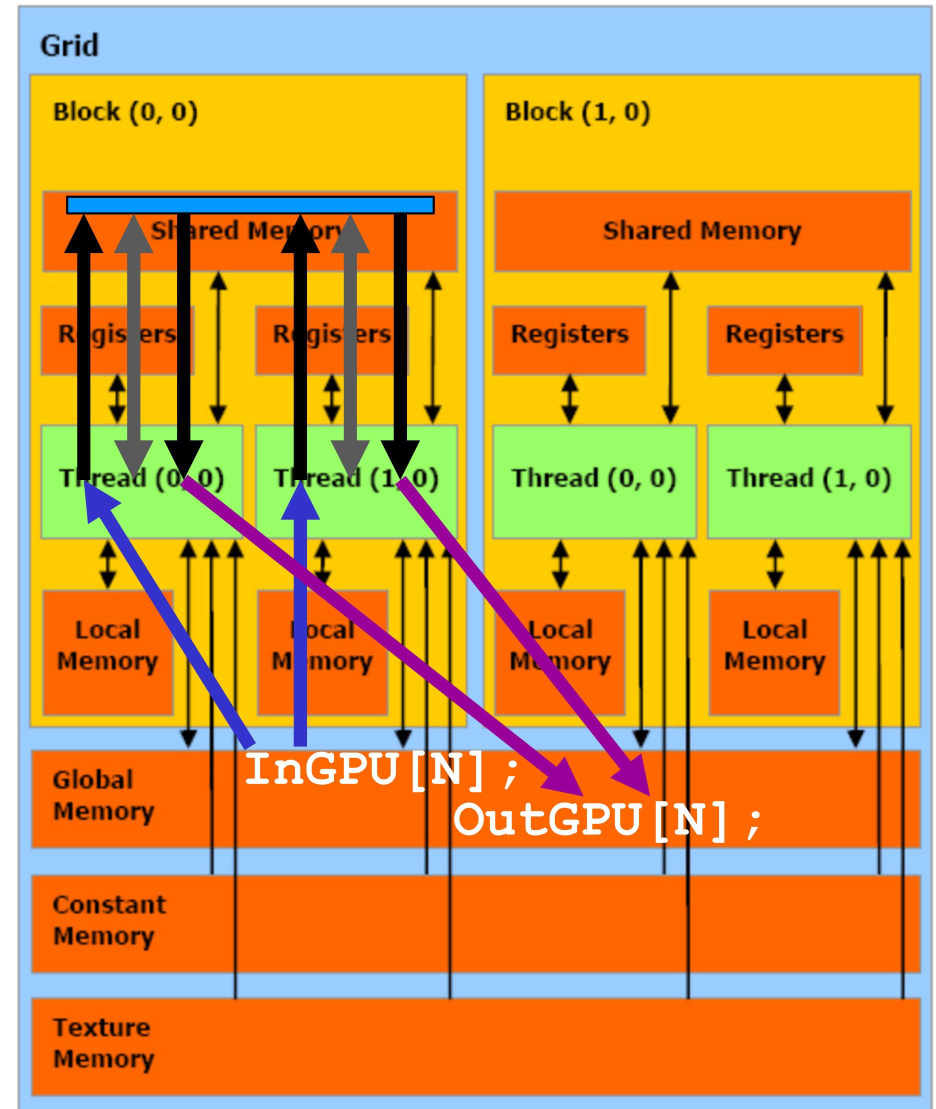

Basic concepts

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.BLOCK_SIZE_X

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

```
__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;
}
```

Le programmeur « remplace l'algo de cache » !

Les blocs sont juxtaposés

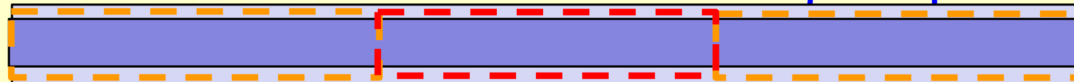

POLYTECH PARIS-SACLAY

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

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
```

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

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;
 }
}
```

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
  }
  .........
```

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

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*BLOCK_SIZE_X

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

```
__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

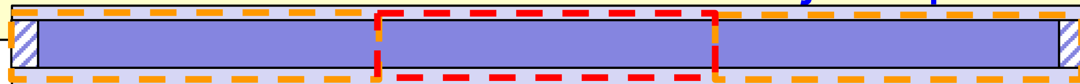

Ex 1: Filtering & juxtaposed blocks

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

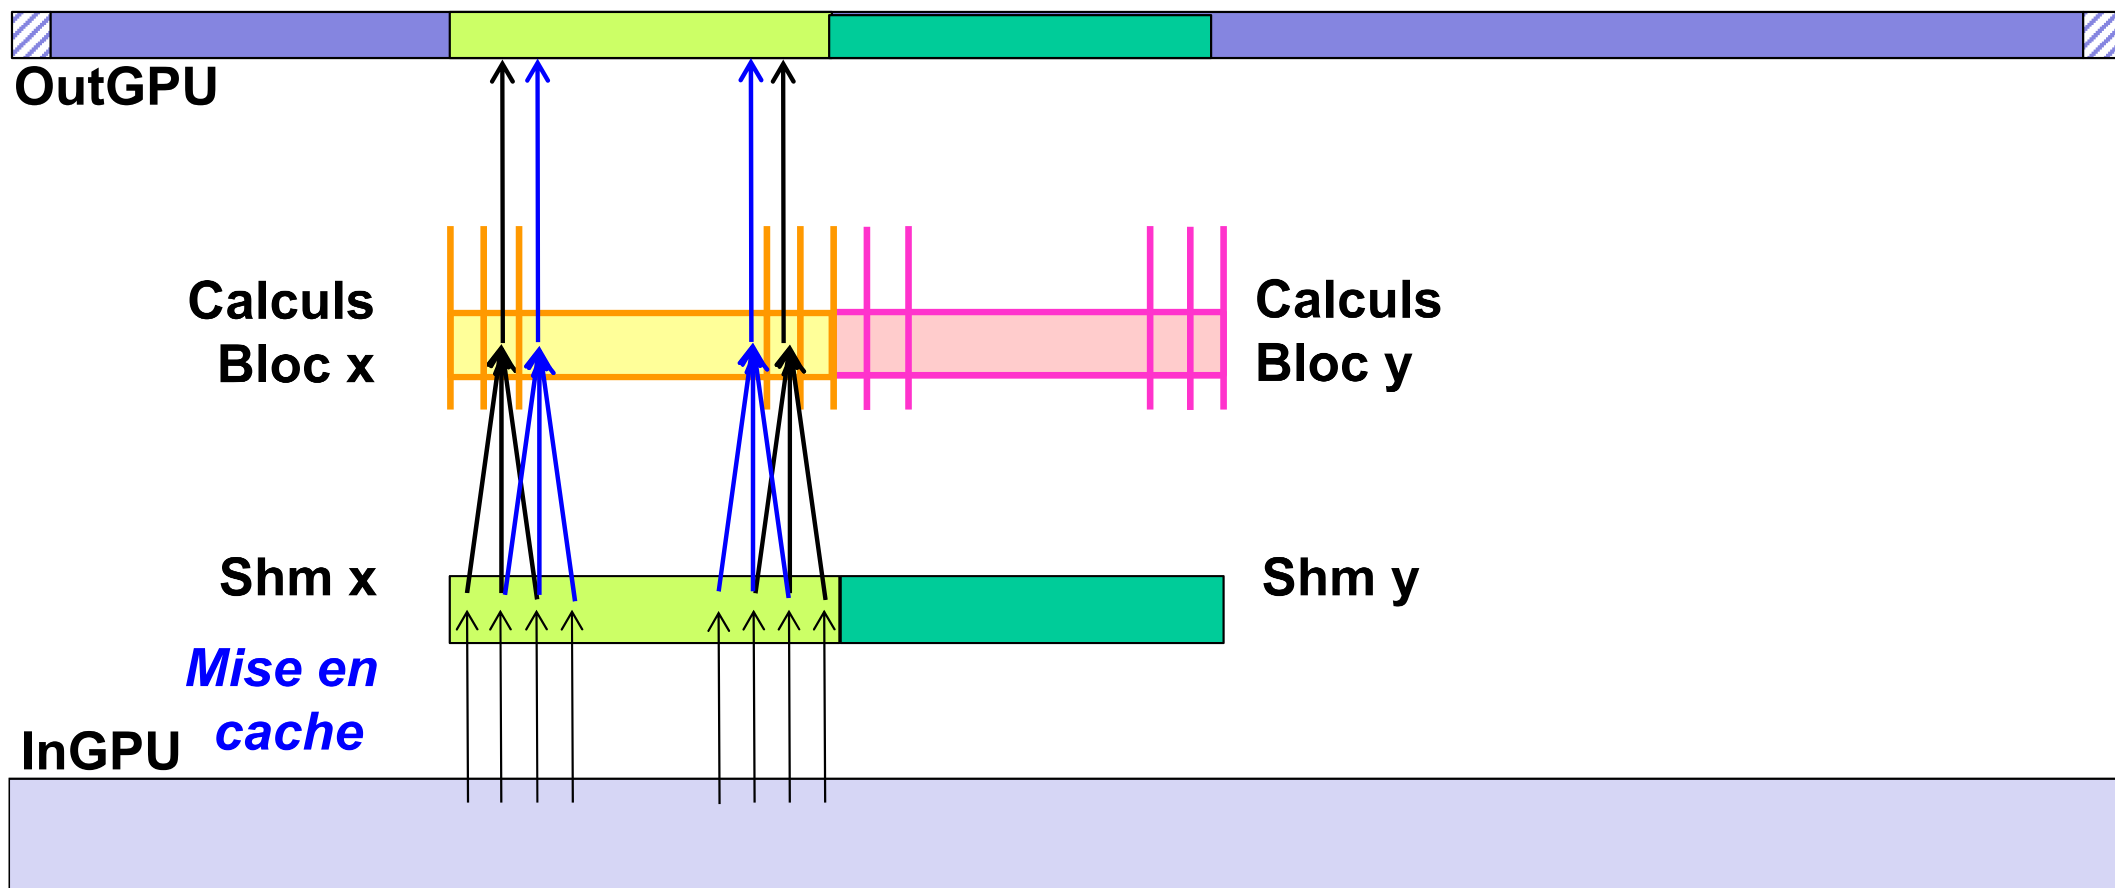

Ex 1: Filtering & juxtaposed blocks

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

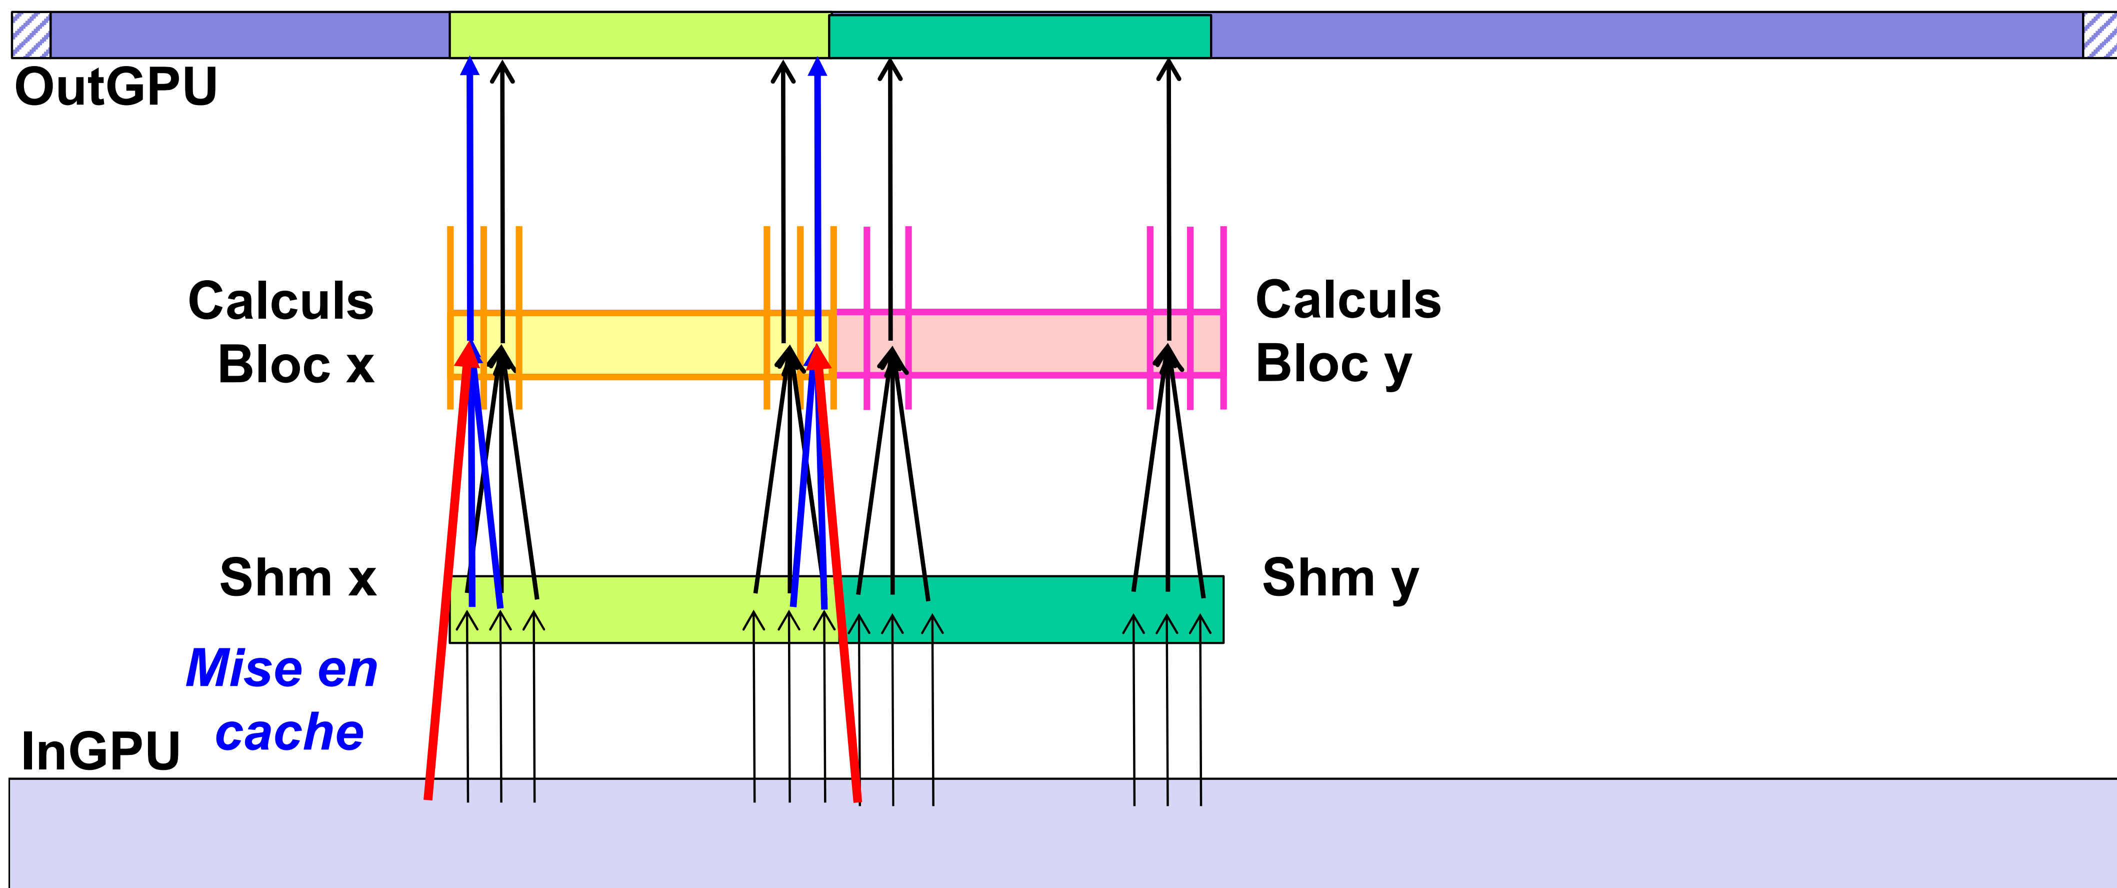

Ex 1: Filtering & juxtaposed blocks

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*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;
 }
}
```

Accès à des données non chargées dans la *shm* par les *threads* du bloc (→ `left = InGPU[idx-1];`)

Exploitation de données dans la *shm* (→ `left = shdata[threadIdx.x-1];`)

Les blocs sont juxtaposés

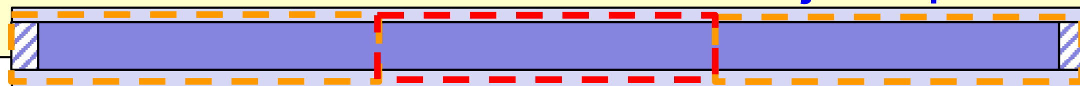

Ex 1: Filtering & juxtaposed blocks

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 ≠ k*BLOCK_SIZE_X

```
Db = {BLOCK_SIZE_X,1,1}
Dg = {Nd/(BLOCK_SIZE_X)+
      (Nd%BLOCK_SIZE_X ? 1 : 0),1,1}
```

```
__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

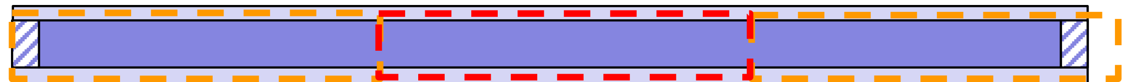

Ex 1: Filtering & juxtaposed blocks

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 ≠ k*BLOCK_SIZE_X

```
Db = {BLOCK_SIZE_X,1,1}
Dg = {Nd/(BLOCK_SIZE_X)+
      (Nd%BLOCK_SIZE_X ? 1 : 0),1,1}
```

```
.........
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

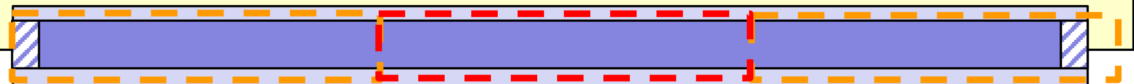

POLYTECH PARIS-SACLAY

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

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;
   }
}
```

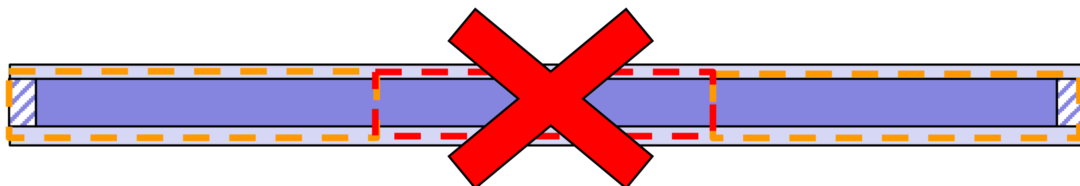

→ Des blocs juxtaposés ne suffisent plus

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*

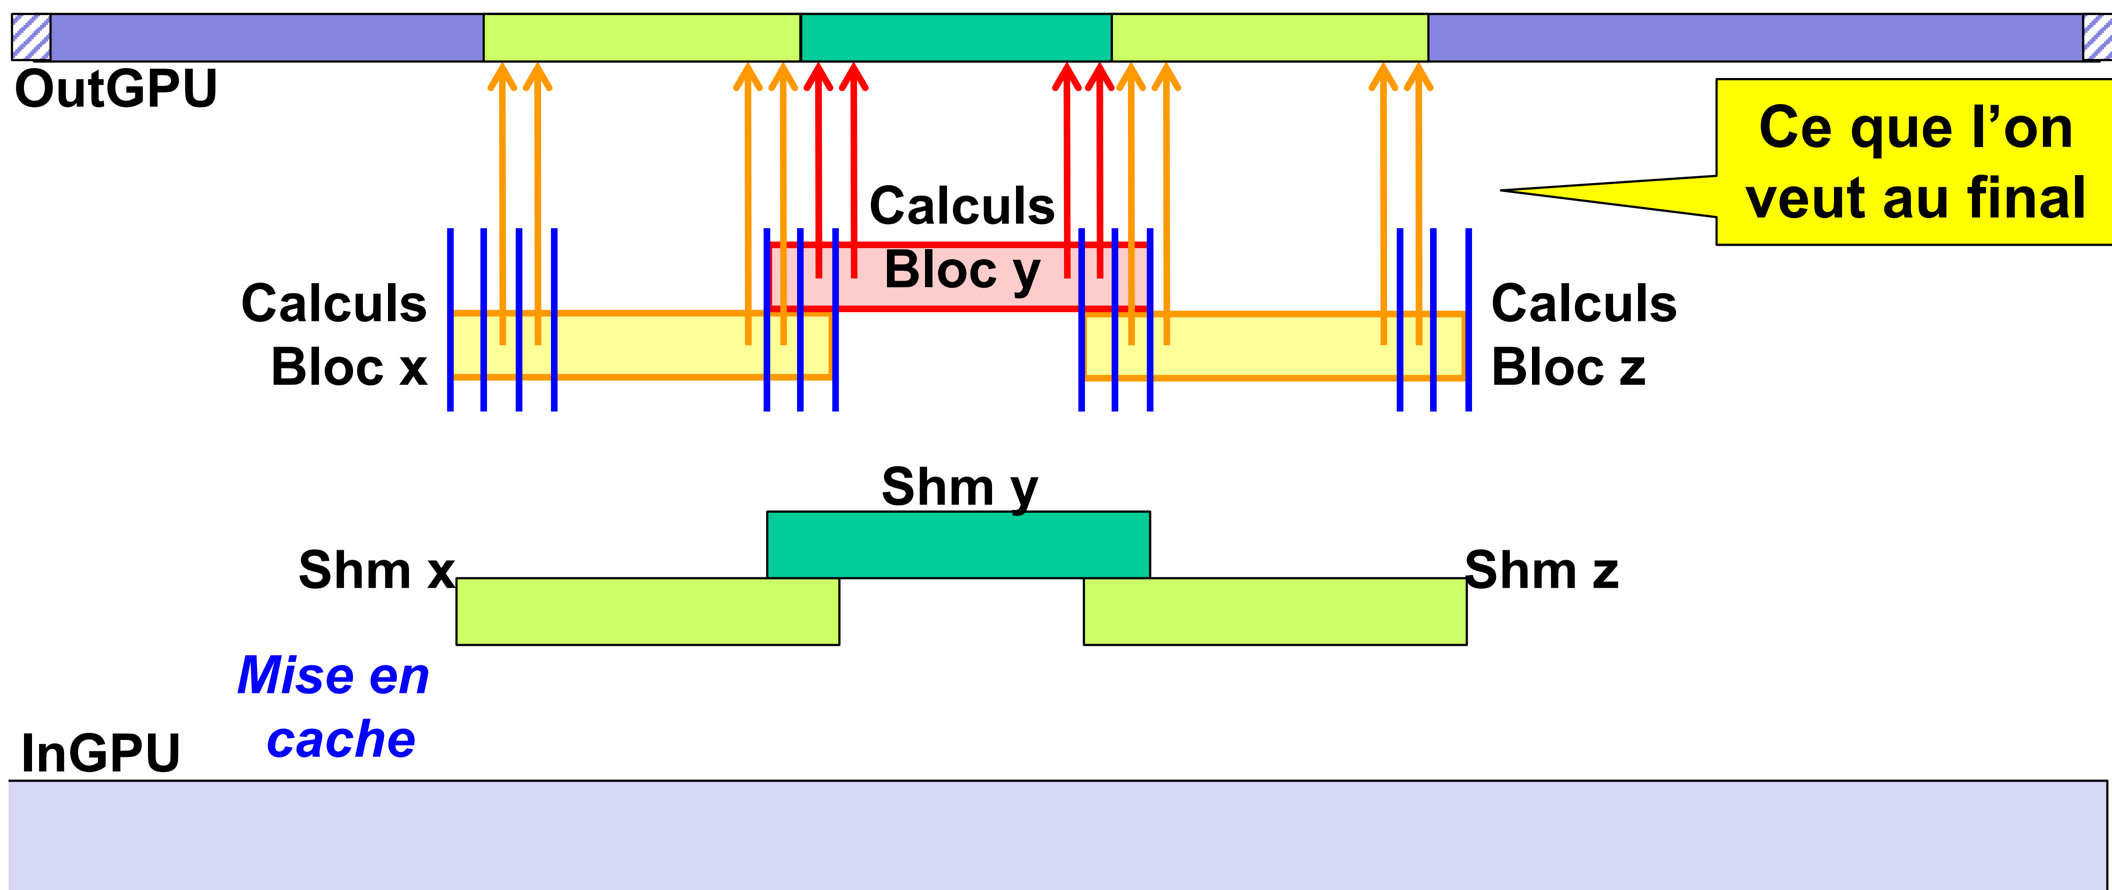

Ex 2: Filtering & overlapping blocks

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

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

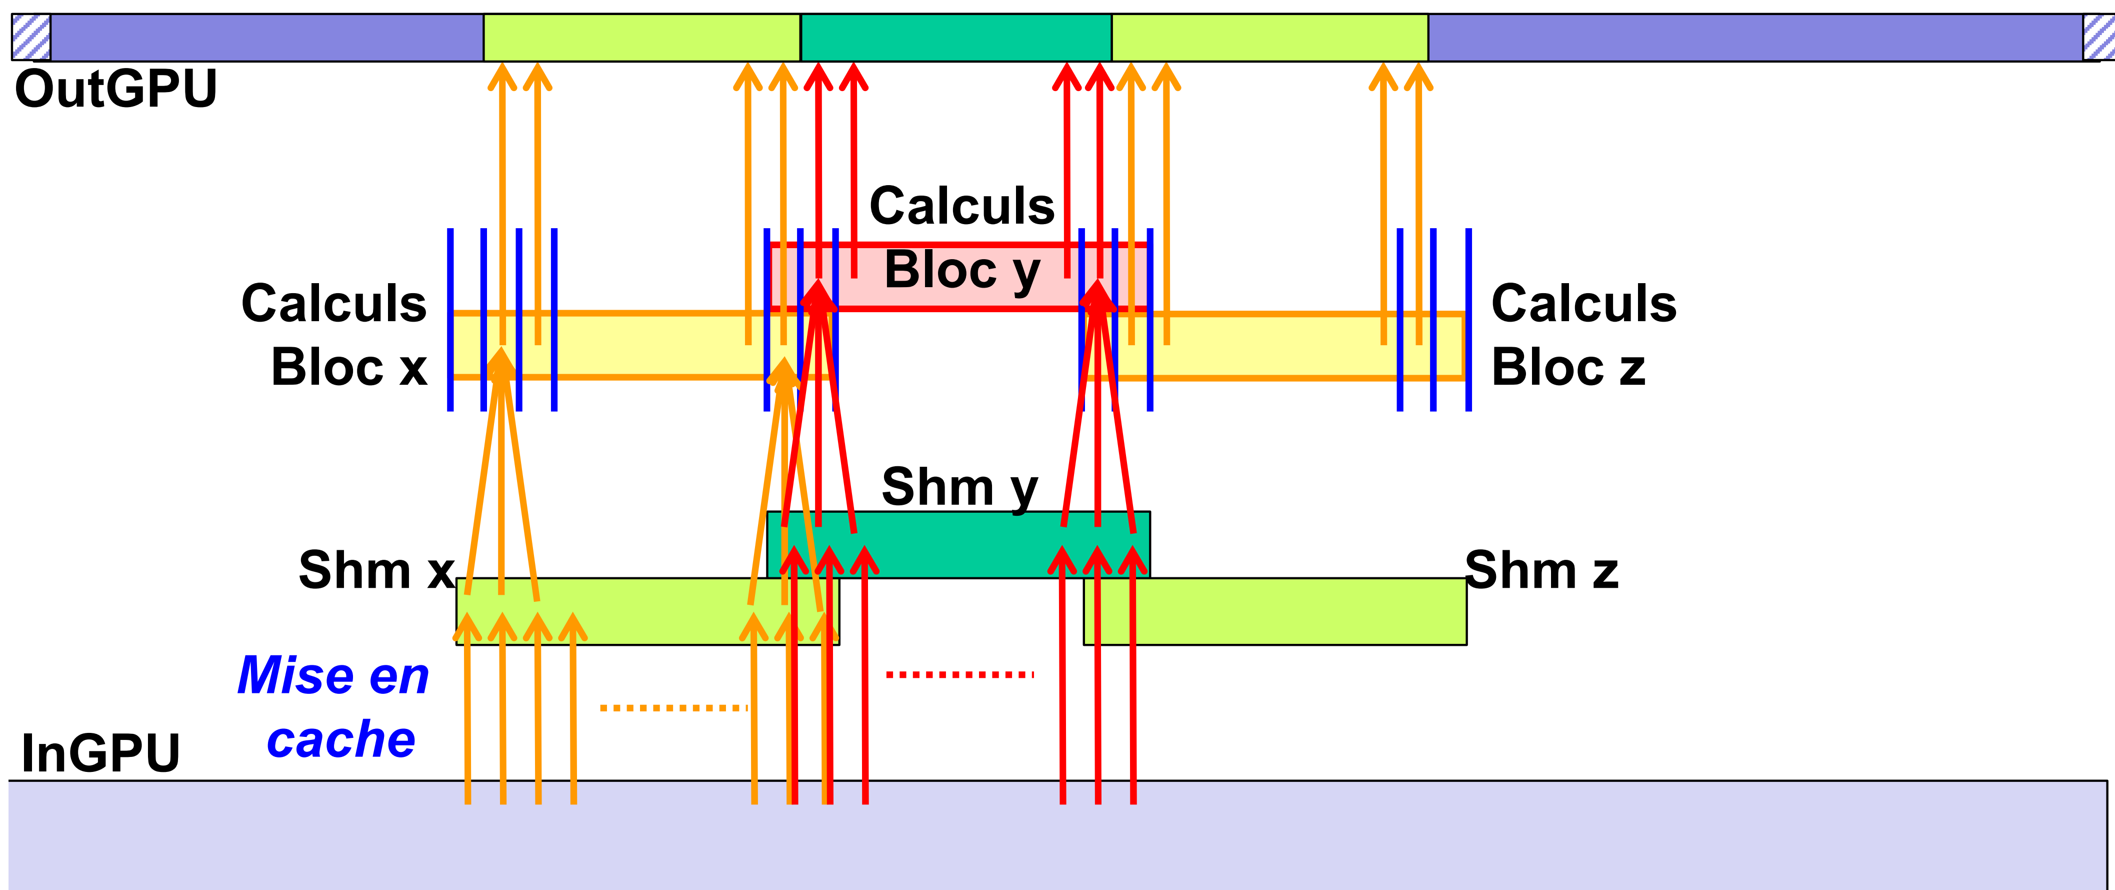

Ex 2: Filtering & overlapping blocks

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

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

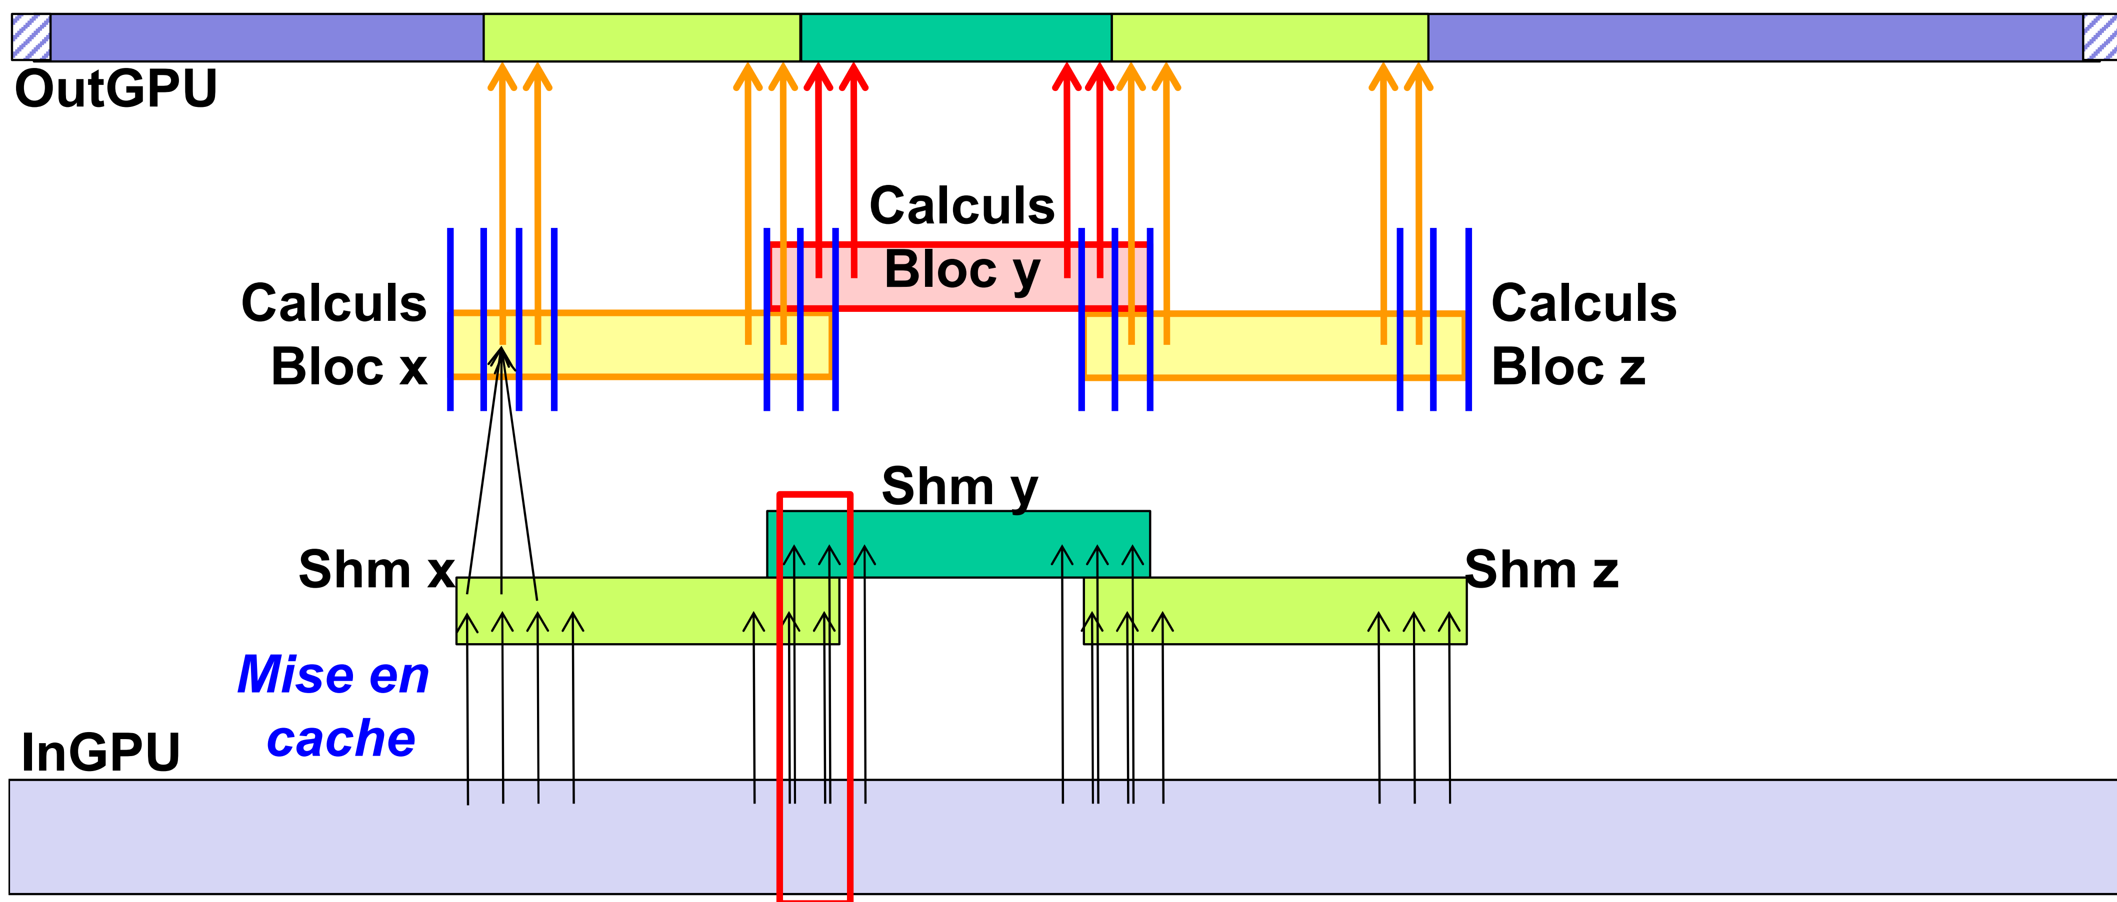

Données lues et cachées 2 fois (dans 2 *shared memories* différentes)

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*

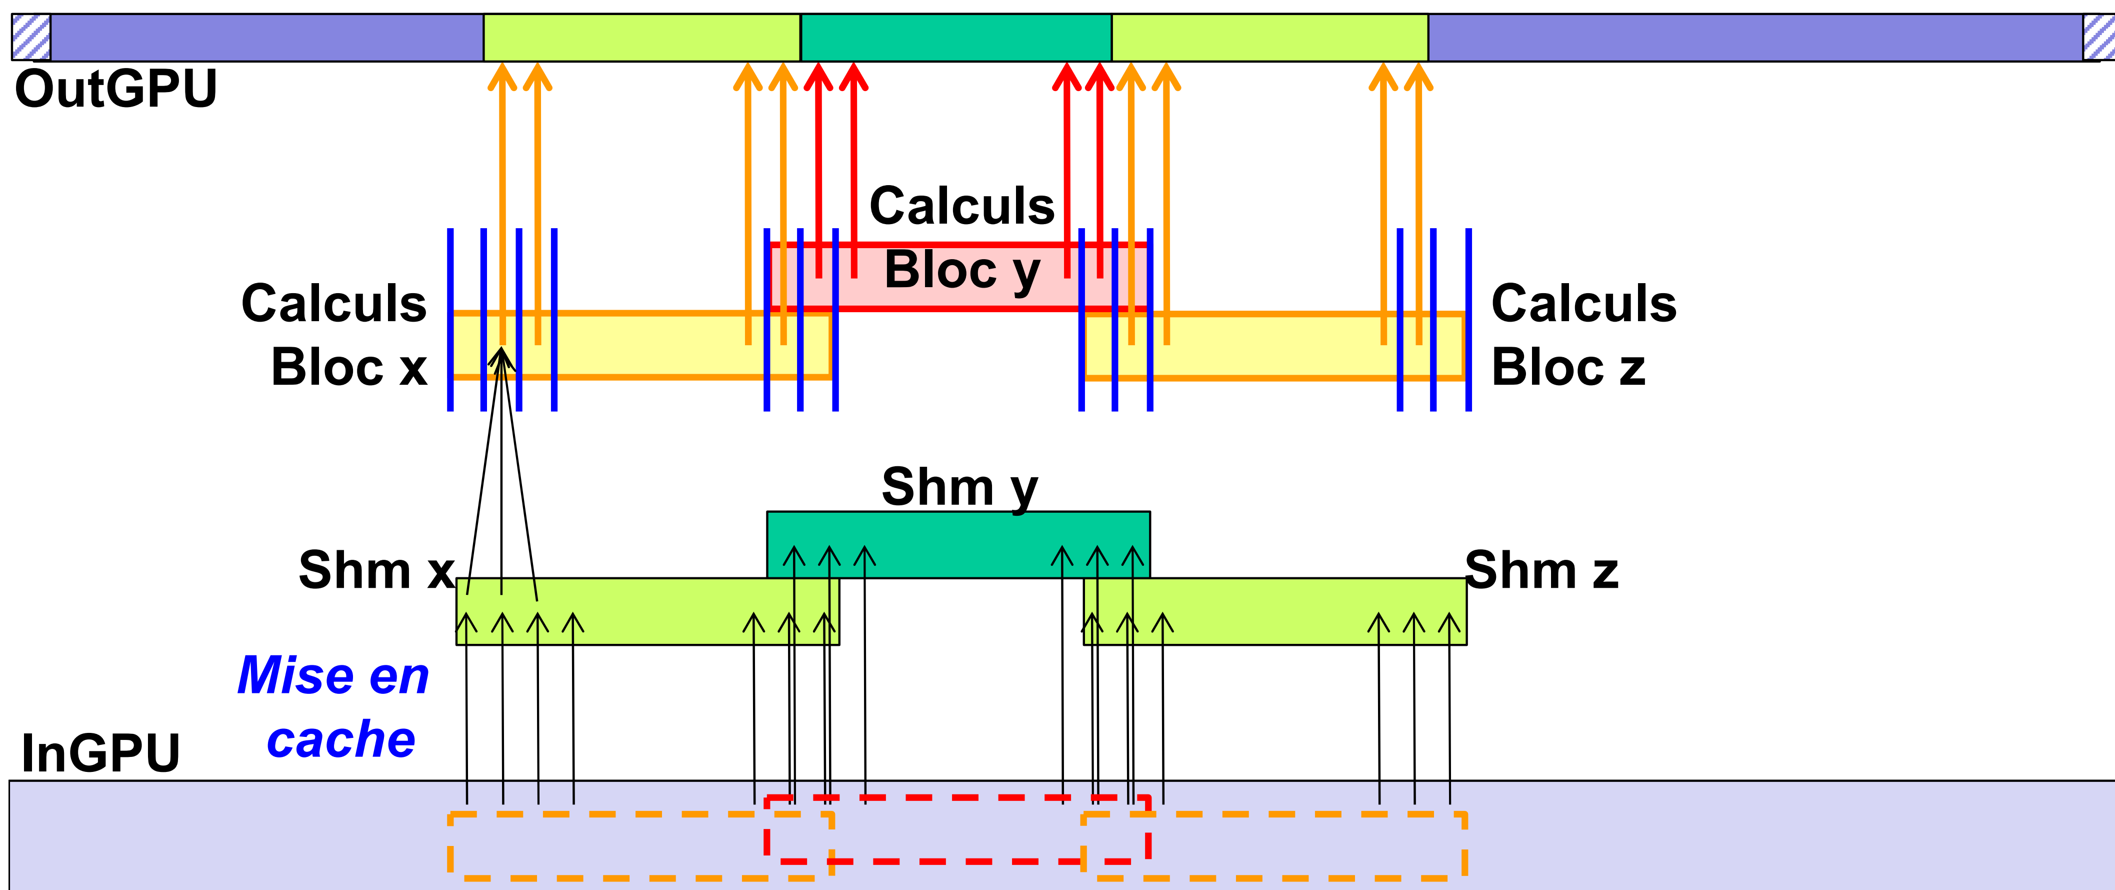

POLYTECH PARIS-SACLAY

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*

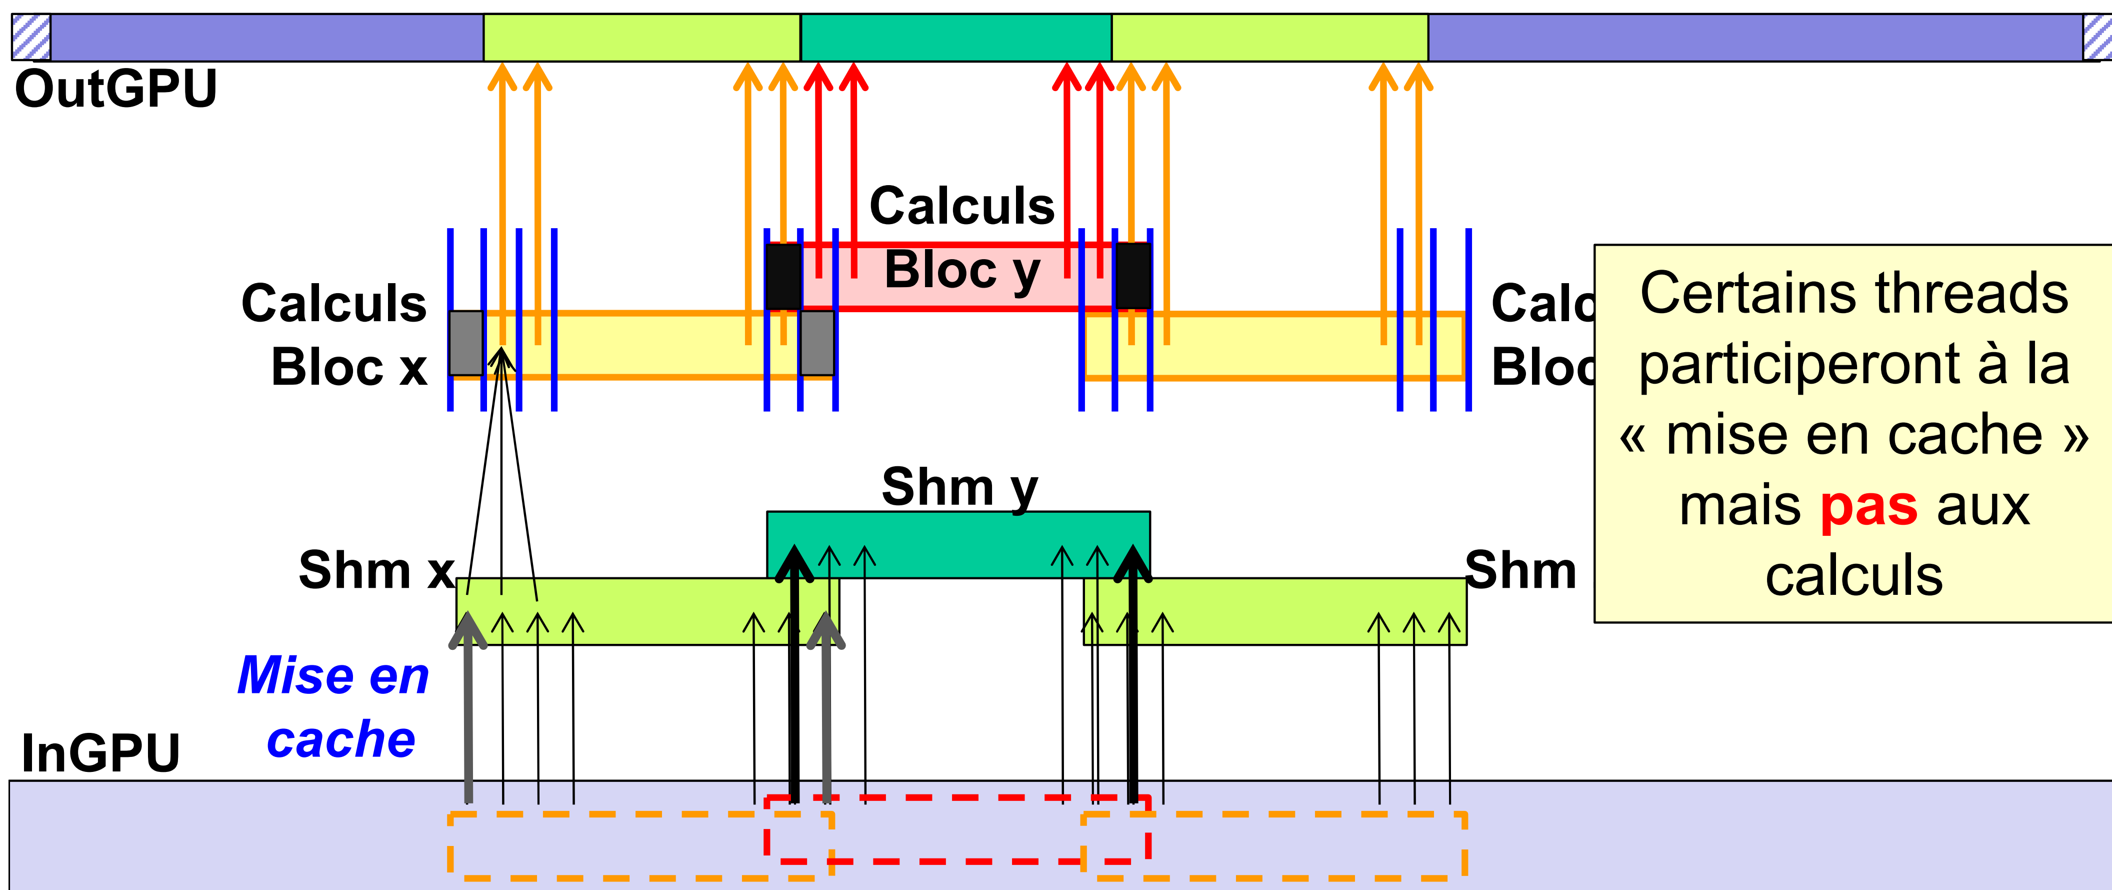

Ex 2: Filtering & overlapping blocks

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

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

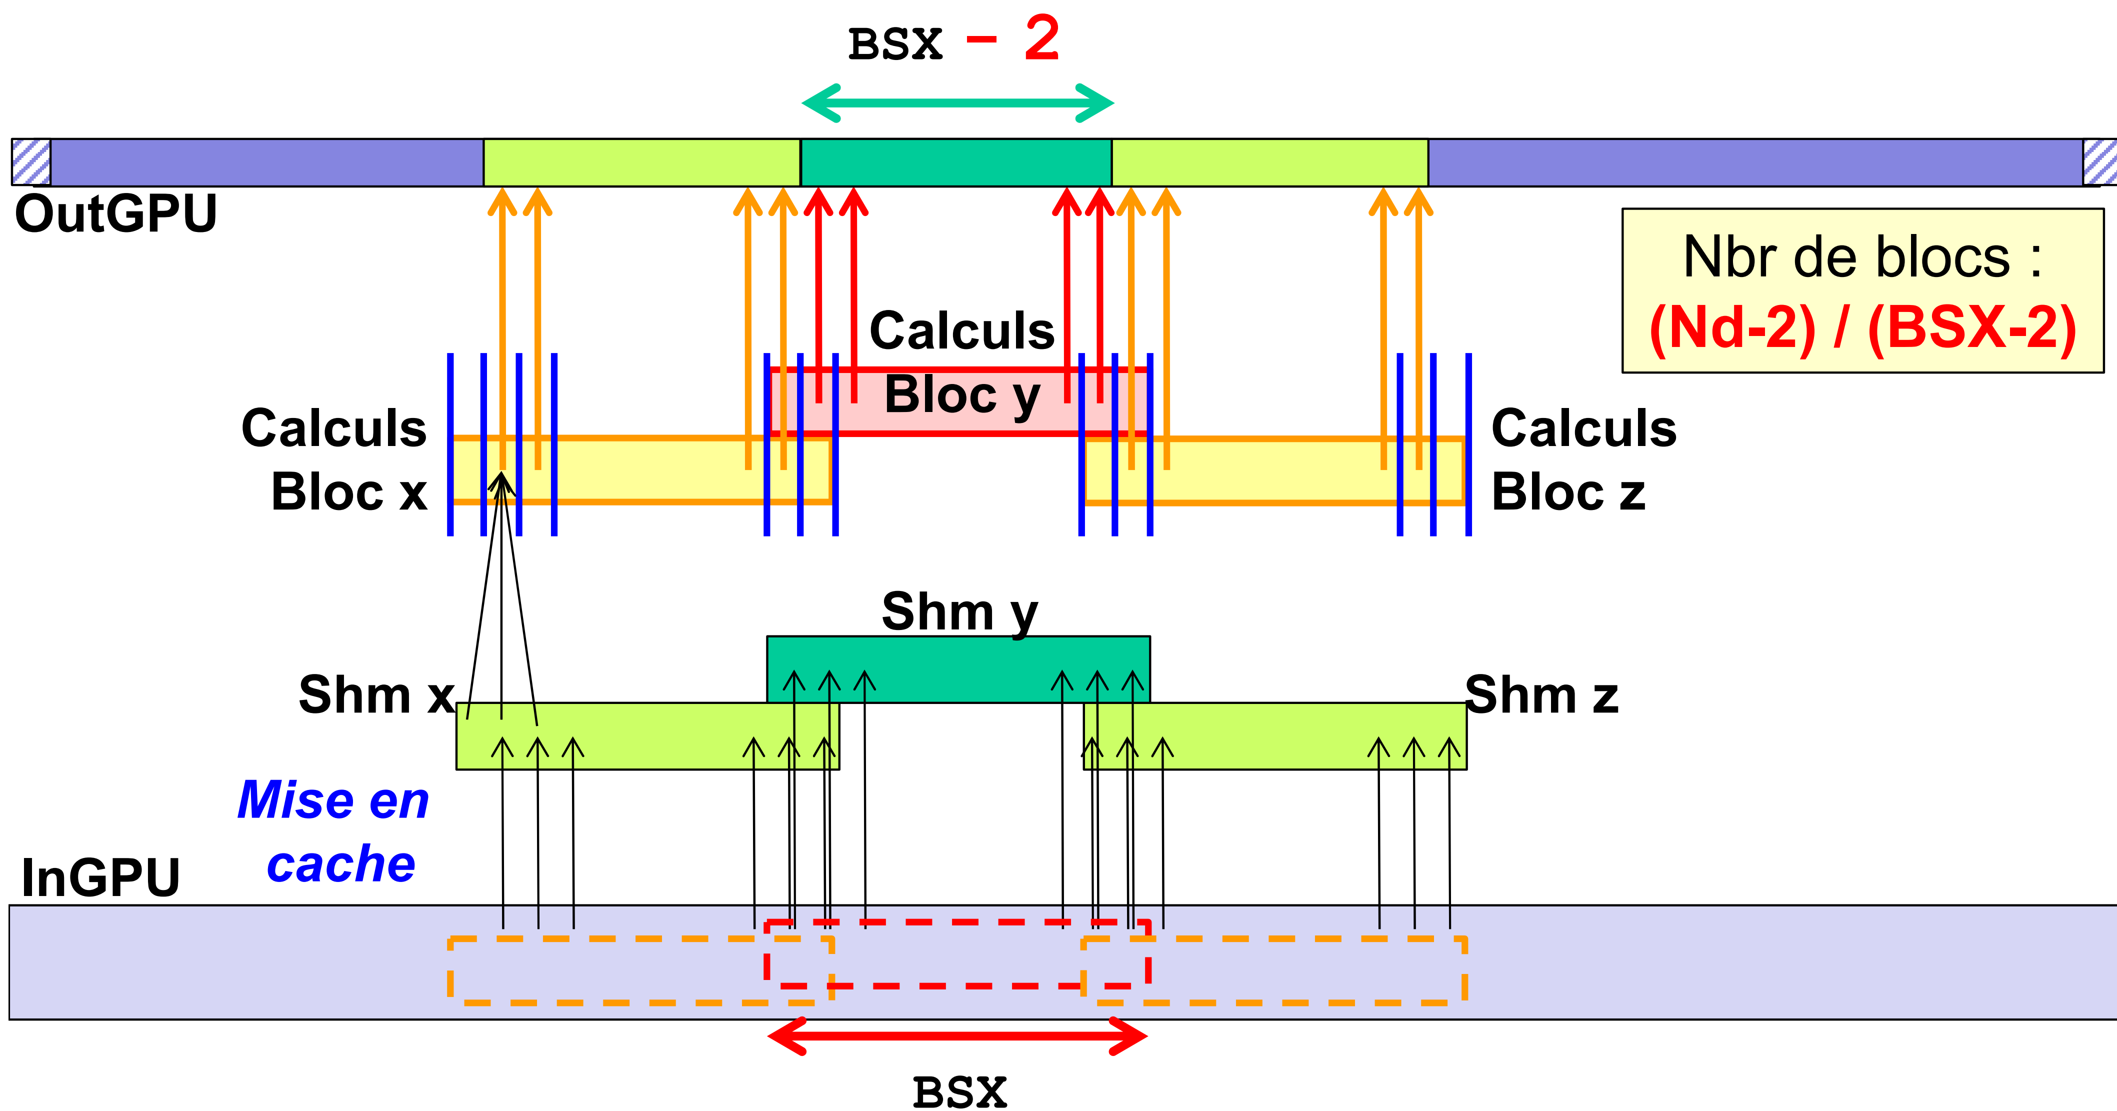

Ex 2: Filtering & overlapping blocks

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*(BSX – 2)

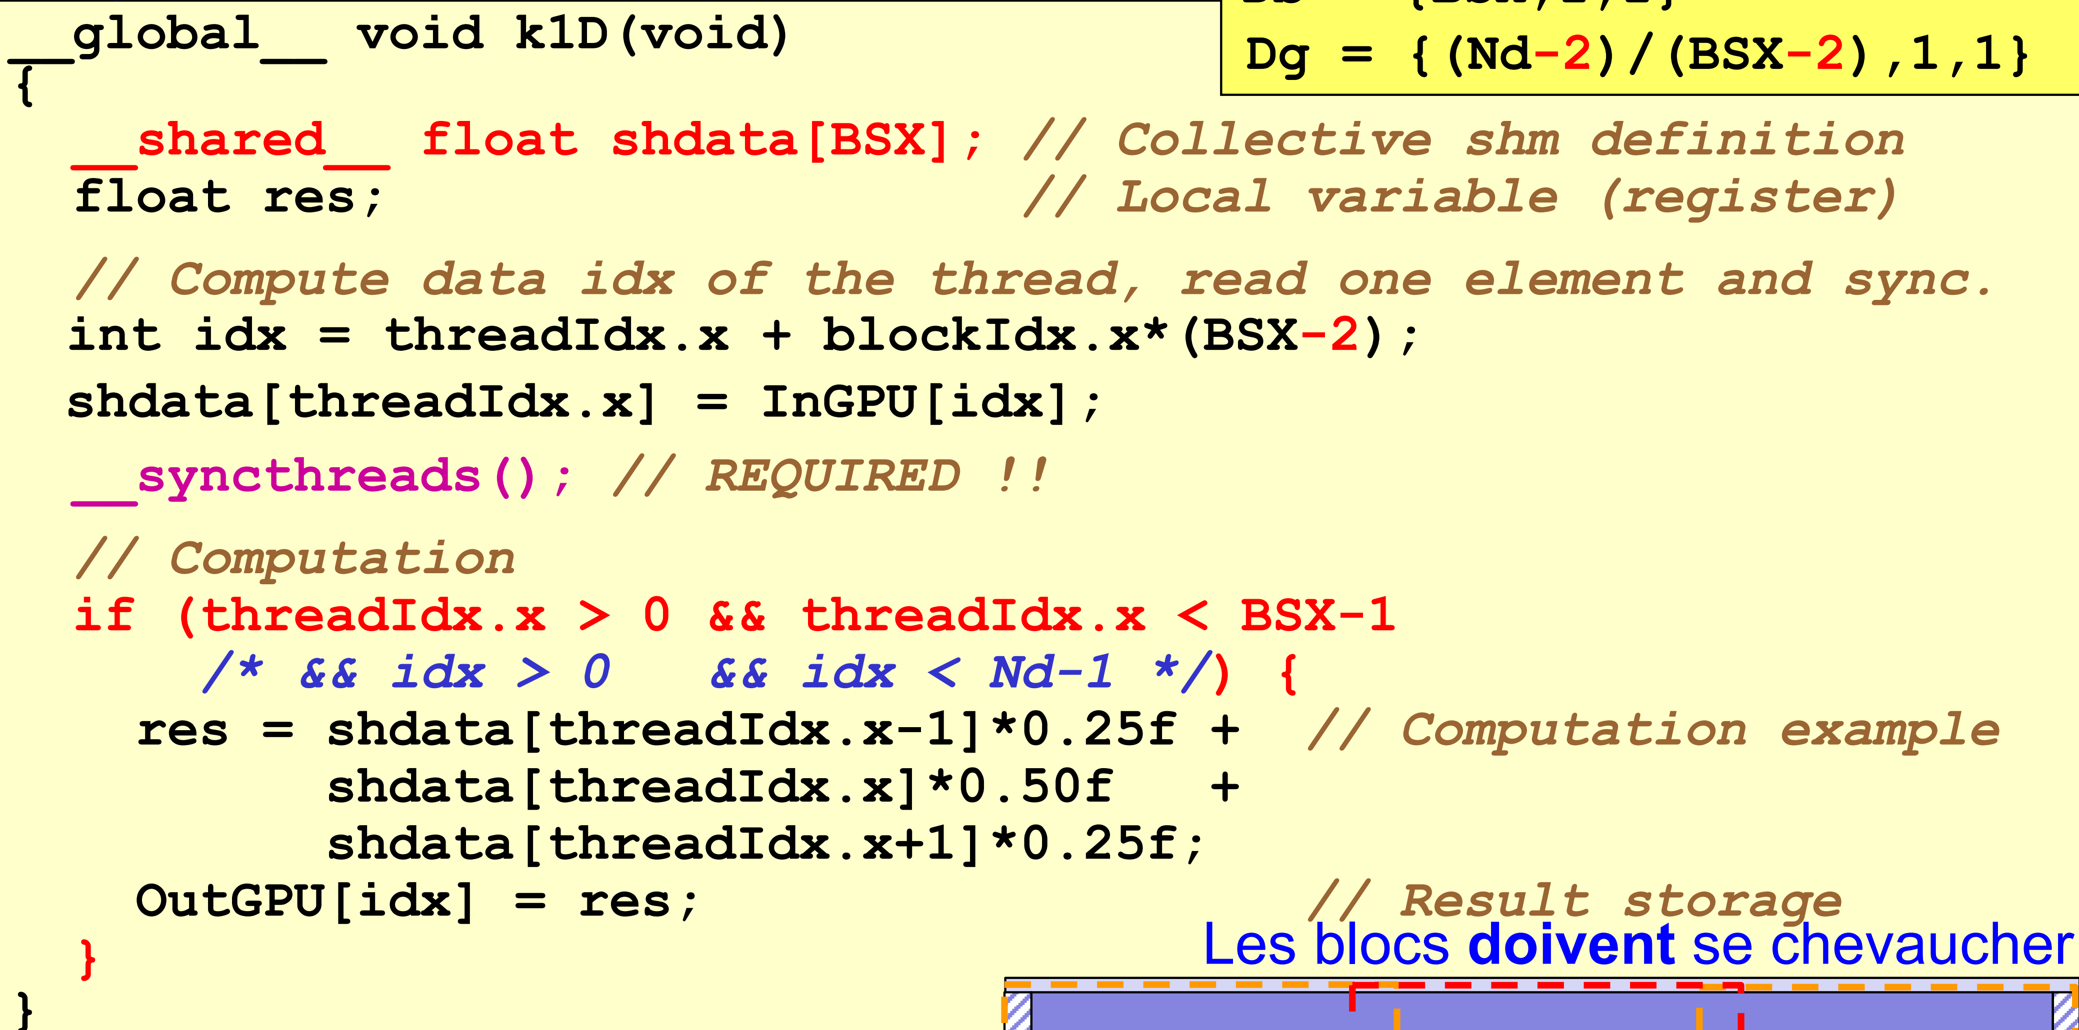

Ex 2: Filtering & overlapping blocks

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 ≠ k*(BSX – 2)

```
Db = {BSX,1,1}
Dg = {(Nd-2)/(BSX-2) +
        ((Nd-2)%(BSX-2)?1:0),1,1}
```

new !

```
__global__ void k1D(void)
{
  __shared__ float shdata[BSX]; //
  float res;                      // Local variable (register)

  // 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];}
  __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;
  }
}
```

new !

new !

Les blocs **doivent** se chevaucher, et le dernier déborde

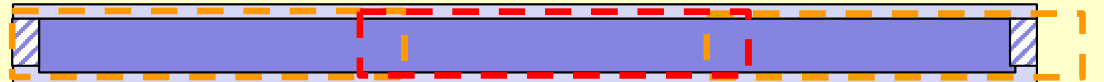

POLYTECH PARIS-SACLAY

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

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 (MT[colM*nbLigM + ligM])

Accès coalescent (M[ligM*nbColM + colM])

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

Ex 3: Matrix transposition & juxtaposed blocks

Kernel optimisé de transposition d’une matrice

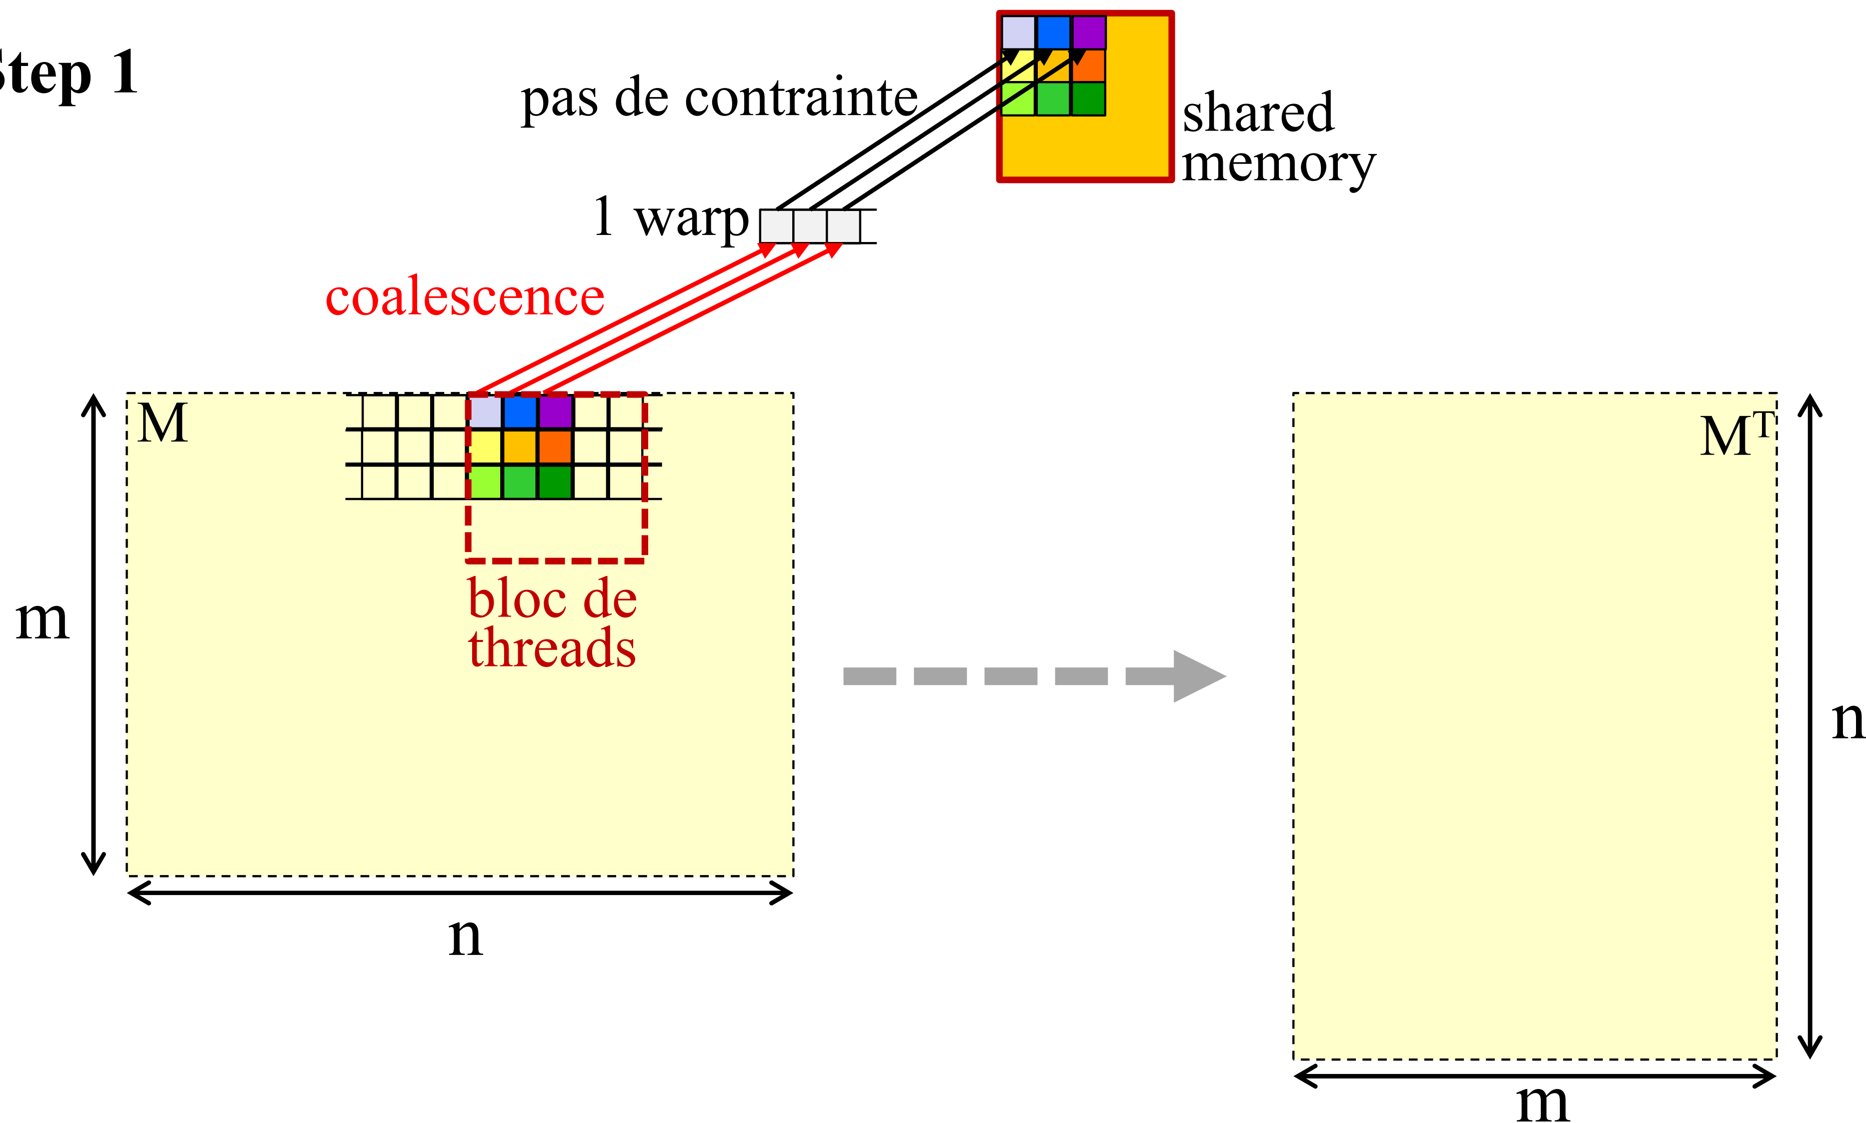

Ex 3: Matrix transposition & juxtaposed blocks

Kernel optimisé de transposition d'une matrice

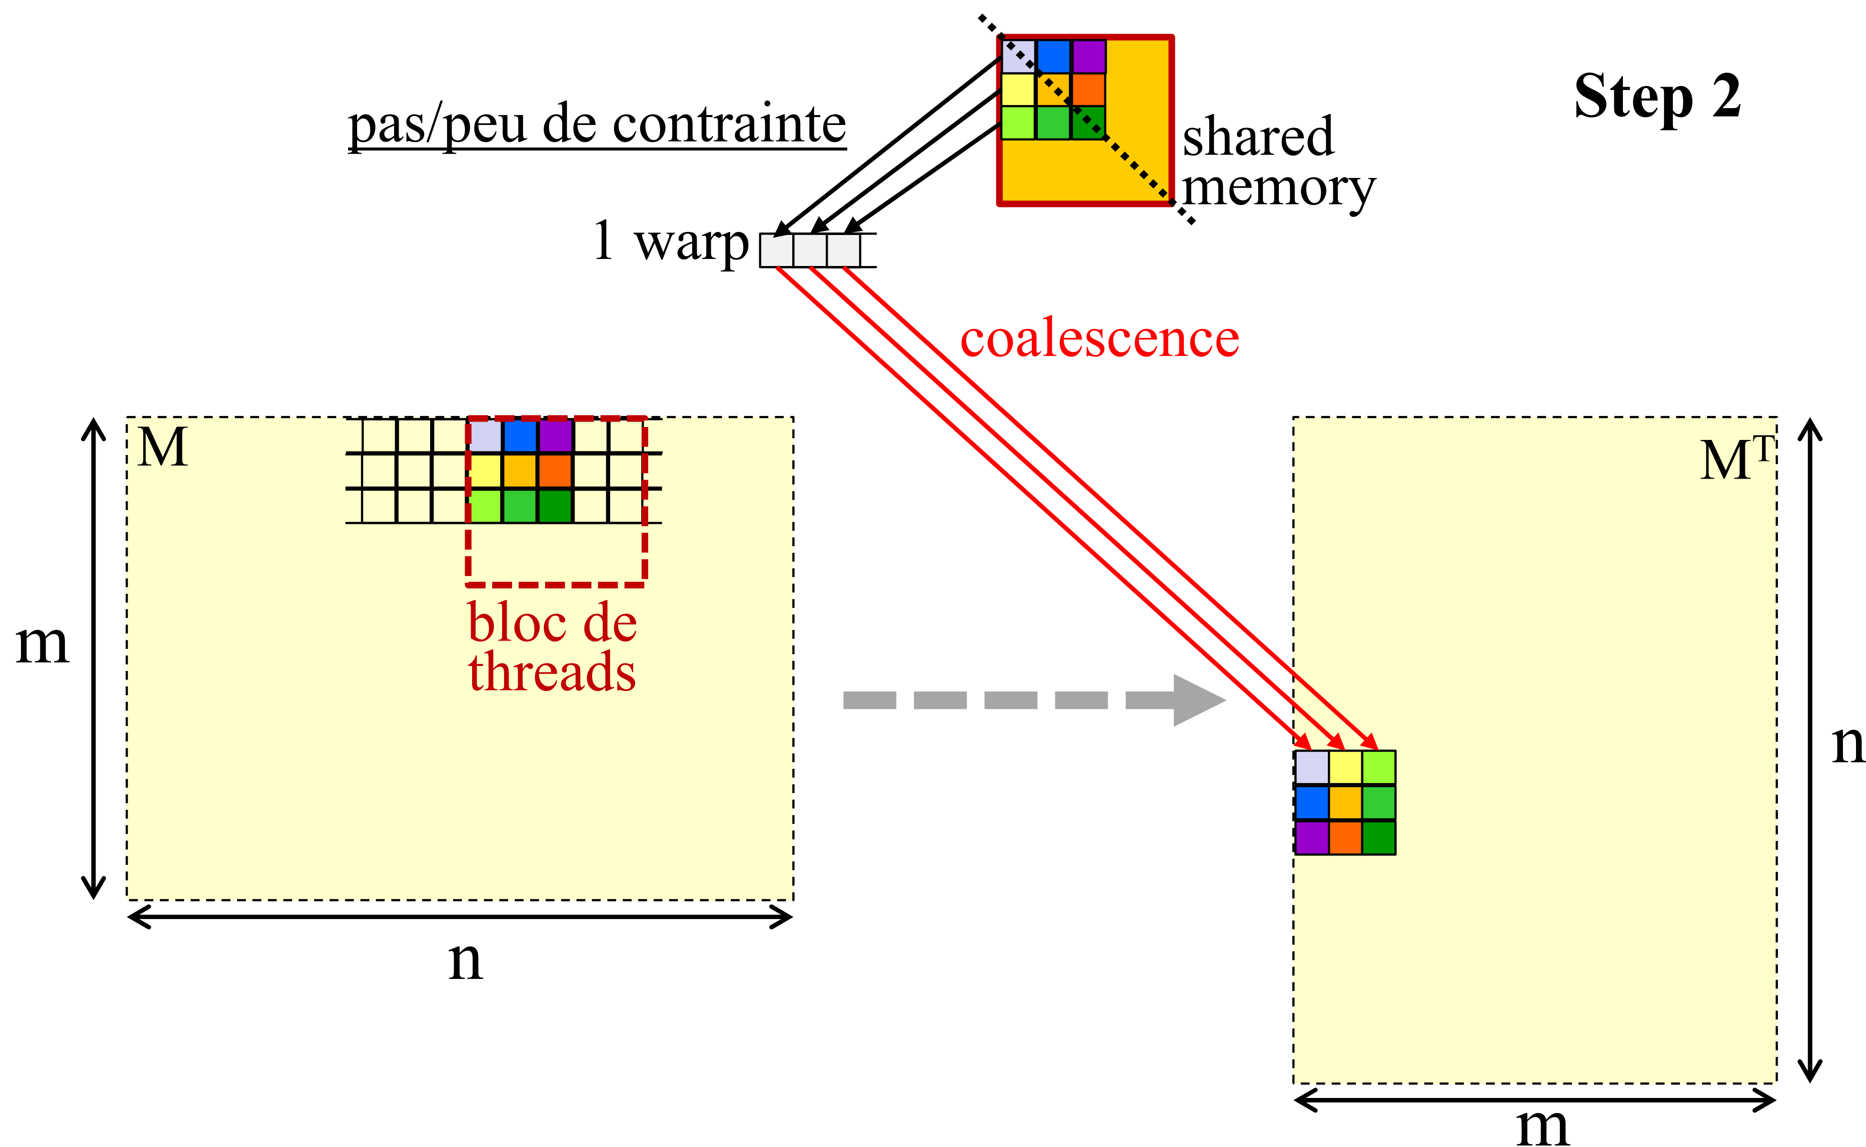

Ex 3: Matrix transposition & juxtaposed blocks

Kernel optimisé de transposition d'une matrice

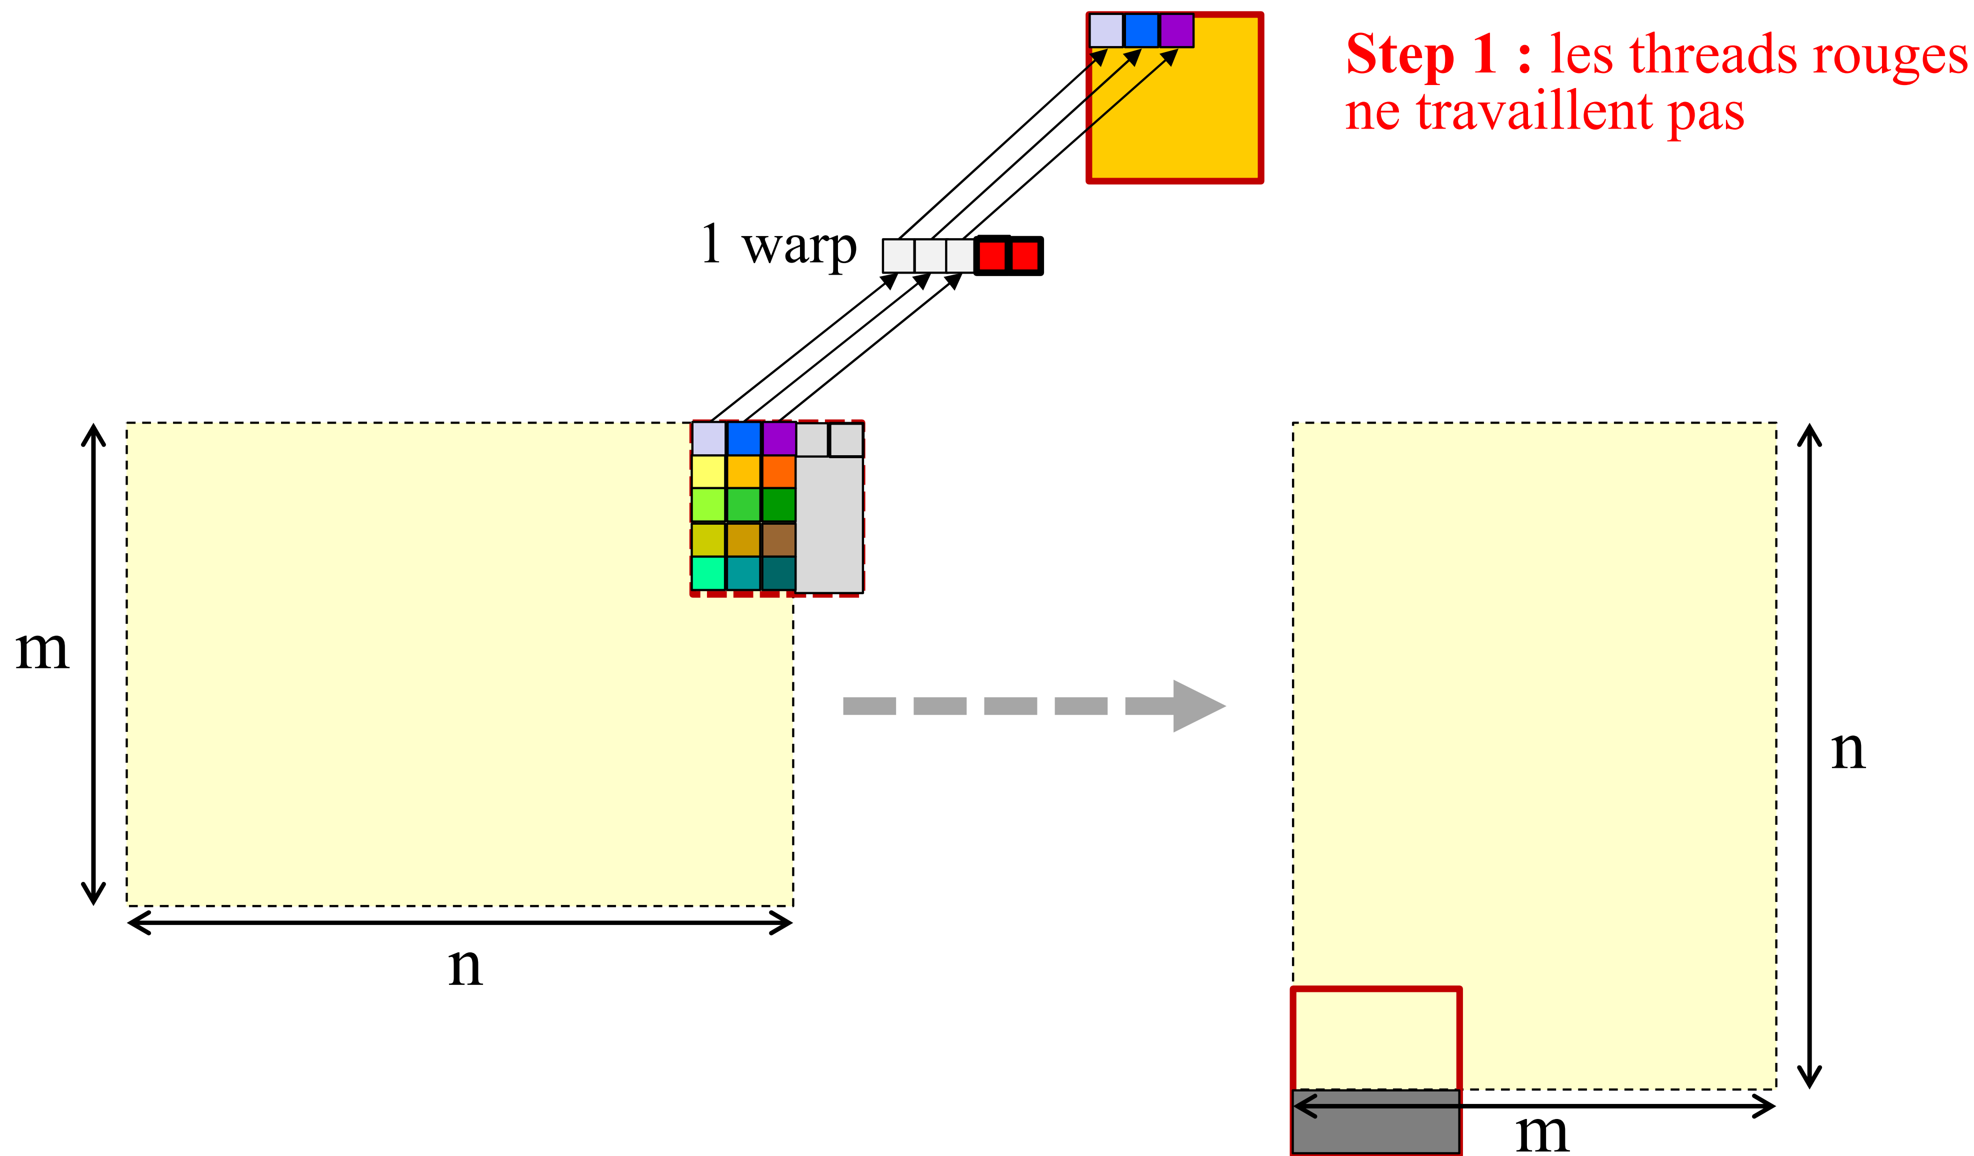

Ex 3: Matrix transposition & juxtaposed blocks

Kernel optimisé de transposition d'une matrice

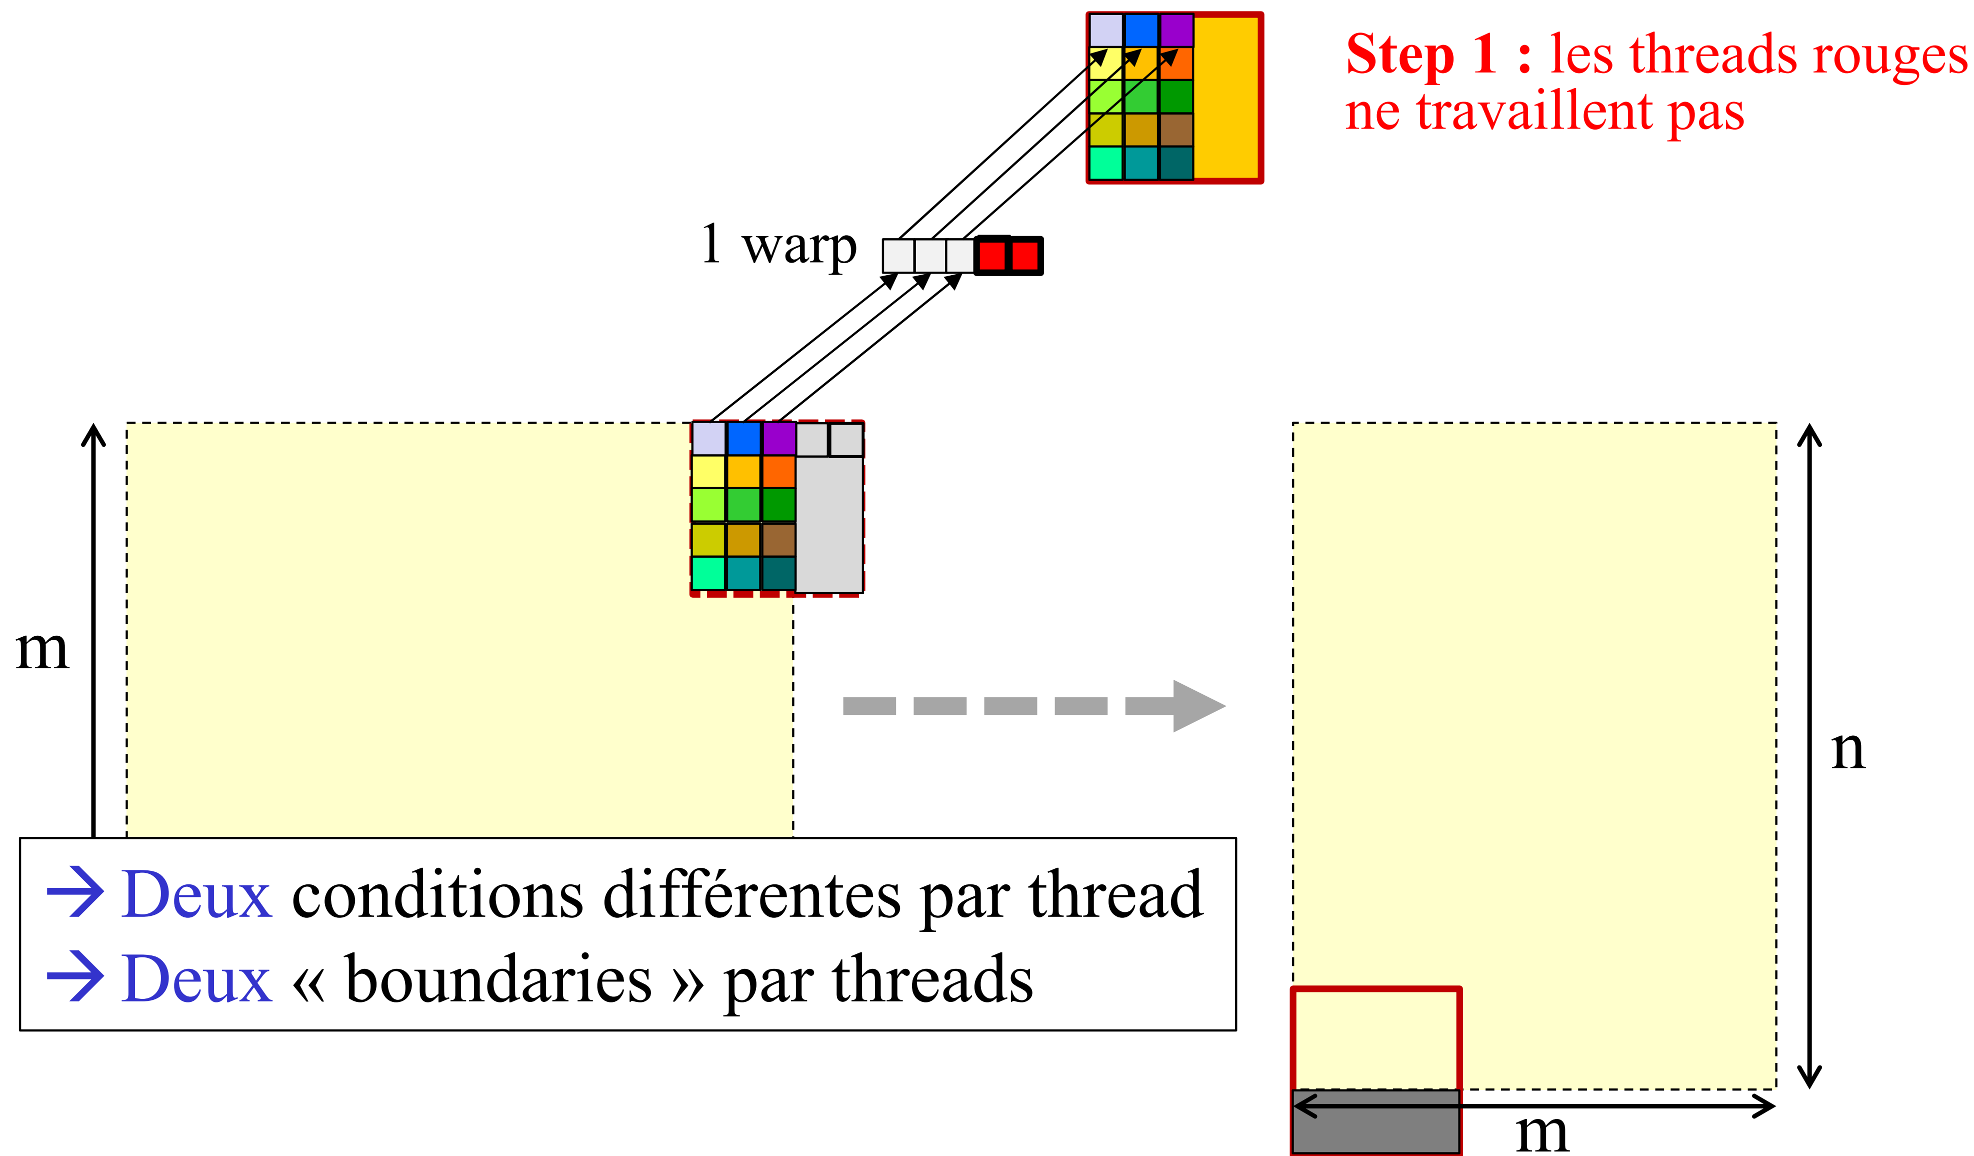

Ex 3: Matrix transposition & juxtaposed blocks

Kernel optimisé de transposition d’une matrice

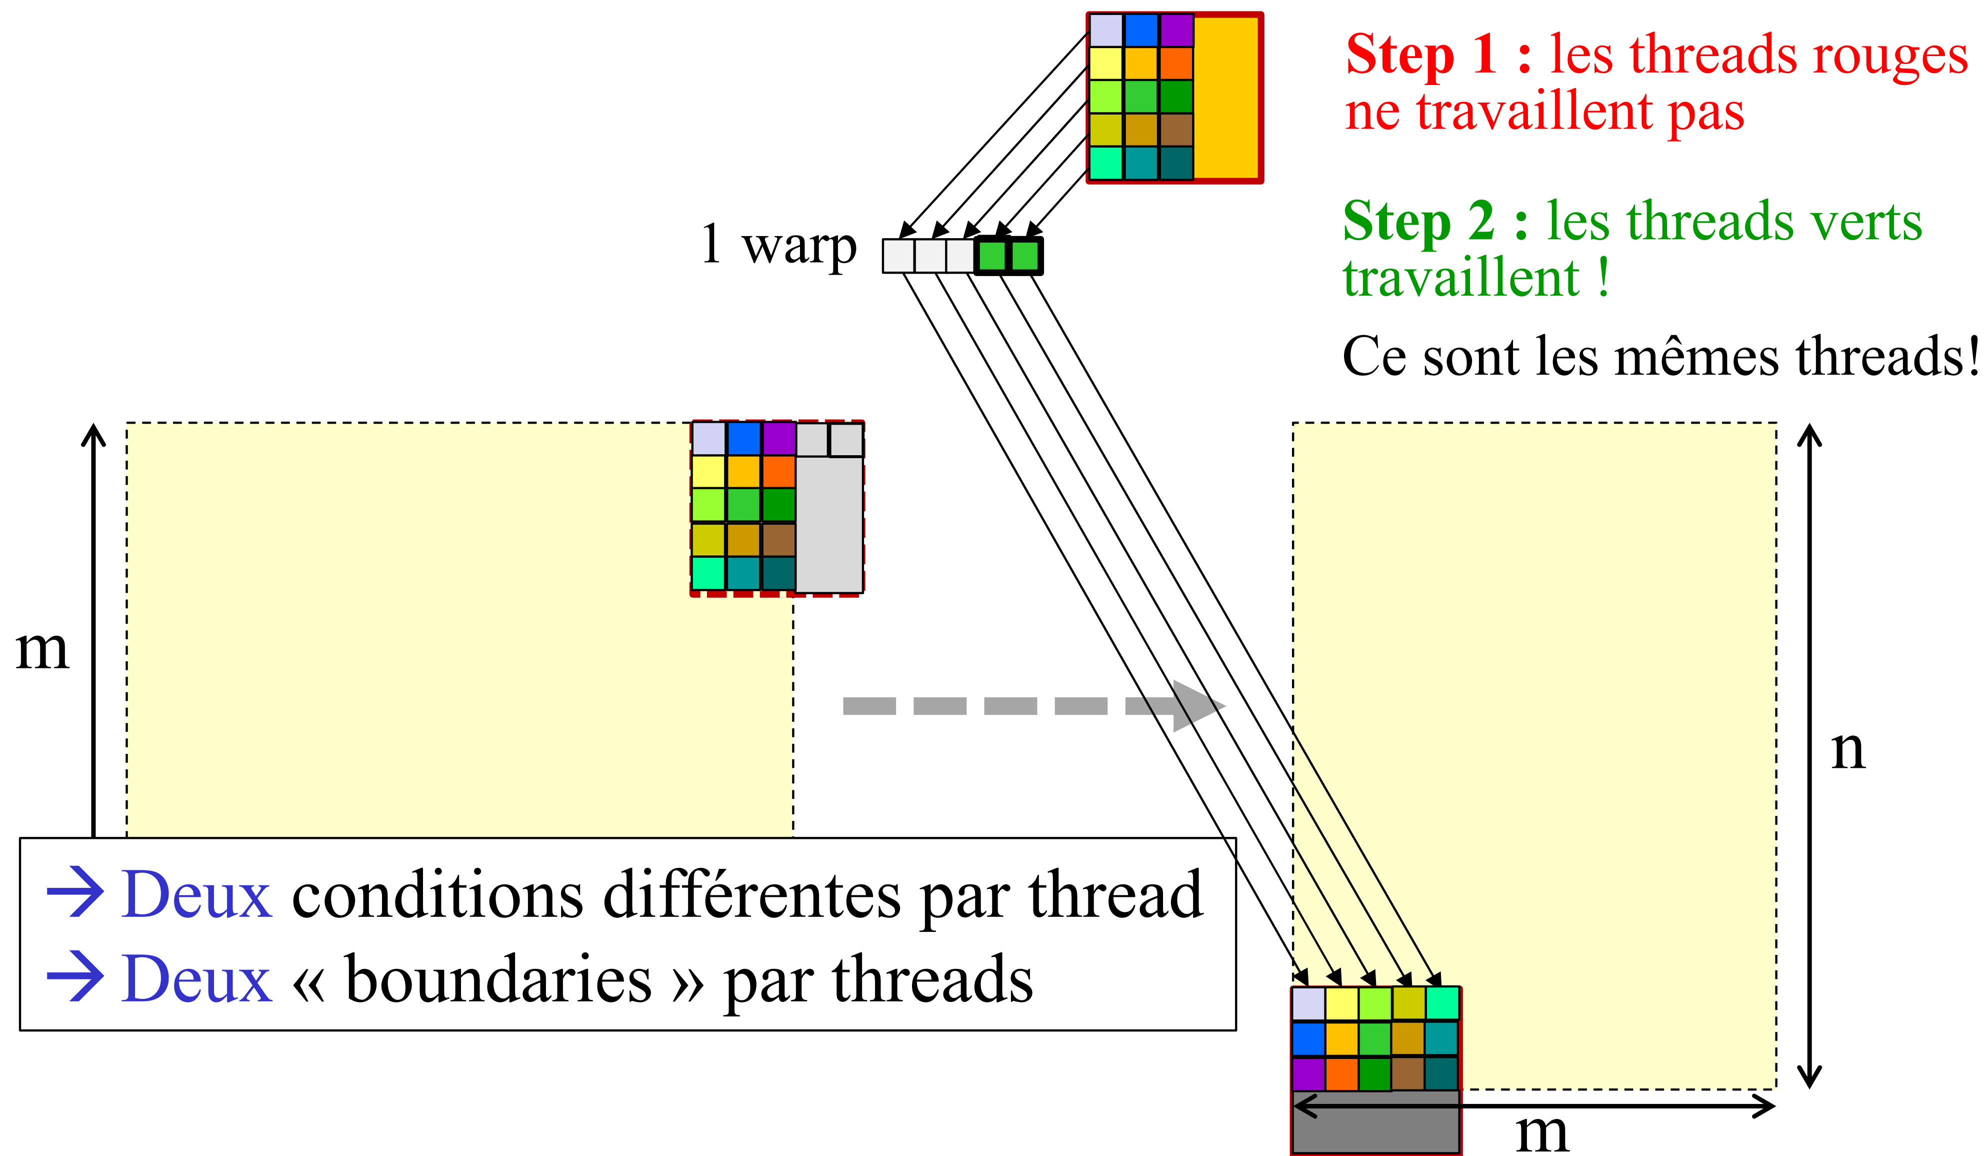

Ex 3: Matrix transposition & juxtaposed blocks

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;
int colM = firstColBlock + threadIdx.x;
int ligMT = firstColBlock + threadIdx.y;
int colMT = firstLigBlock + threadIdx.x;
__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];
}
```

thIdx(0,1)
fC4
fL0
fC0
thIdx(0,1)
fL4

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

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

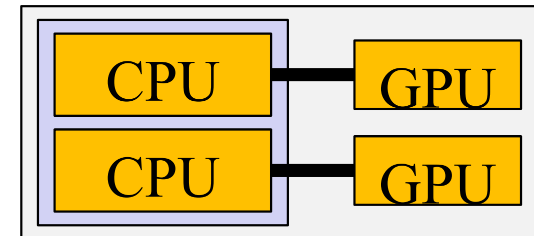

- **`atomicXxx(…)`** : exclusion avec tous les threads CUDA du même programme sur le même GPU

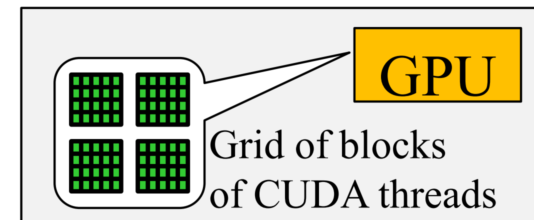

- **`atomicXxx_block(…)`** : exclusion avec tous les threads CUDA du même bloc de threads

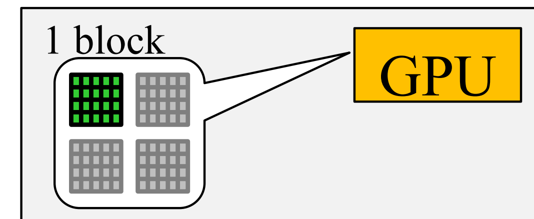

Classical atomic functions

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);
```

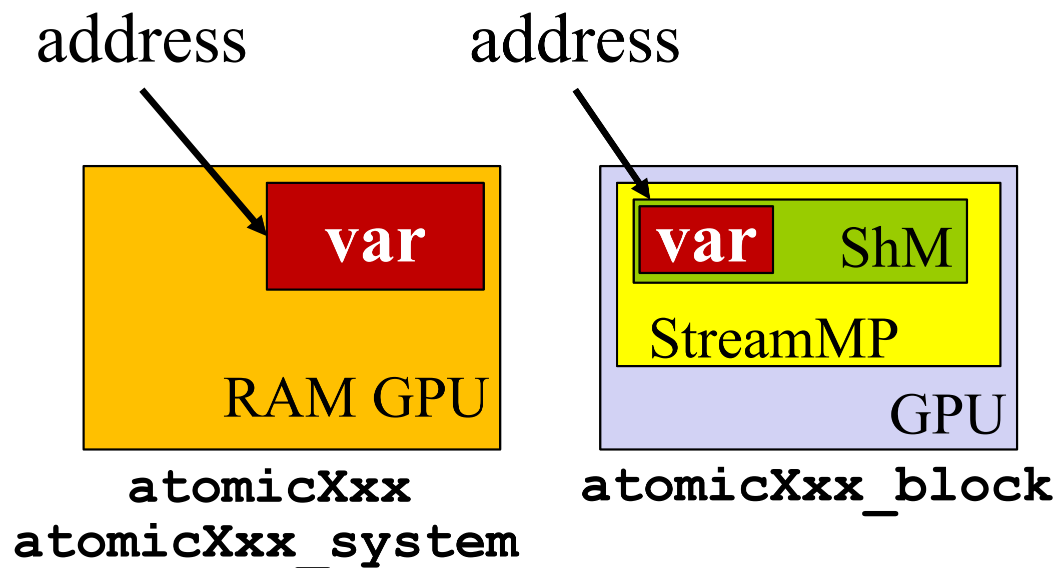

Entrée en mutex

Lecture de *var (old_var)*
Ajout de *val à old_var*
Ecritute dans *var*

Sortie de mutex

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

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*)

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);
```

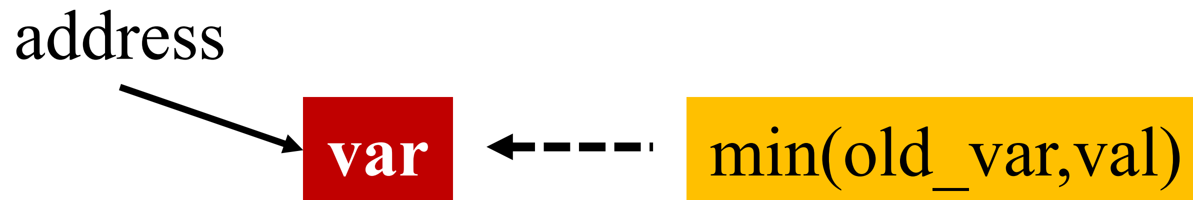

Les `atomicMax` :

```
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*)

Classical atomic functions

Les `atomicInc` :

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

address

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

Les `atomicDec` :

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

address

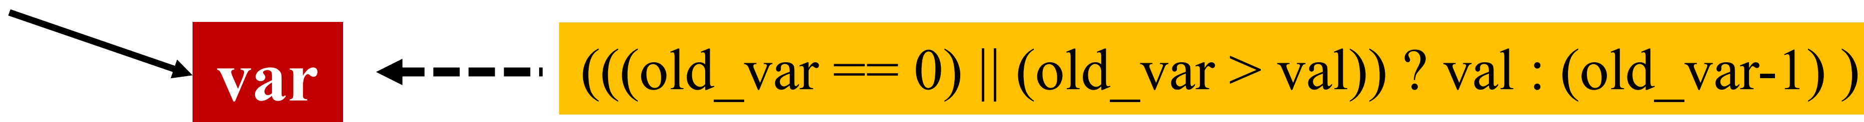

Décrémente *var* et retour à *val* s'il avait atteint *0*

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

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

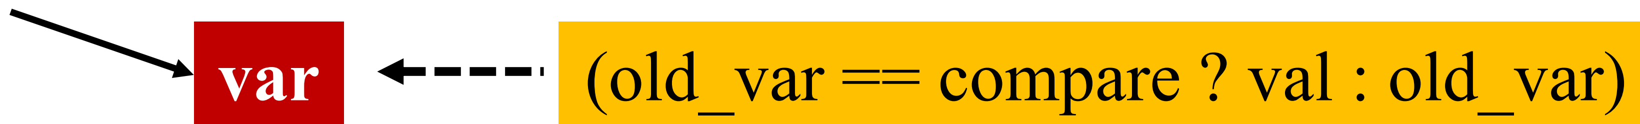

Change *var* s'il vaut une certaine valeur

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

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);
```

« System » and « block » atomic fucntions

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 <u>no</u> **`atomicXxx_system`** (system-wide)
- Autres restrictions sur les fct portant sur les doubles ou sur les half

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

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

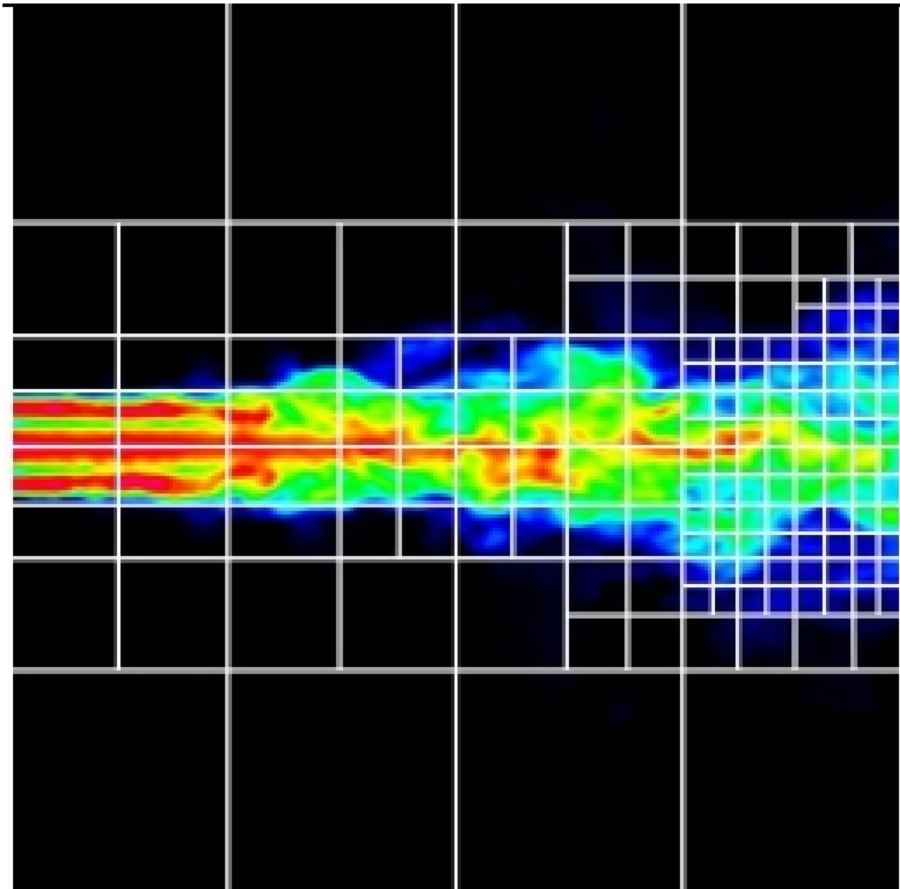

```
  global    ChildKernel(void* data){
    //Operate on data
}

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

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

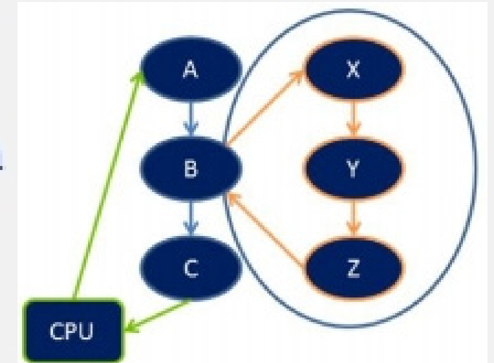

POLYTECH PARIS-SACLAY

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)

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**

POLYTECH PARIS-SACLAY

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

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) !

Advanced CUDA programming
Part 1

End