CentraleSupélec

Mineure CalHau2

CUDA : optimized programming

Stéphane Vialle

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

1

CentraleSupélec

CUDA : optimized programming

1 – Utilisation de la *shared memory*
- **Principes de la *shared memory***
- Ex 1: Moyenne glissante & blocs juxtaposés
- First generic scheme of a shM 2D kernel
- Ex 2: Moyenne glissante & blocs recouvrant
- Ex 3: Transposition de matrice
- Second generic scheme of a ShM 2D kernel

2 – Réduction optimisée
3 – Kernels auto-adaptatifs
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

2

Principe de la *shared memory*

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 global d'accès à la mémoire

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

CPU

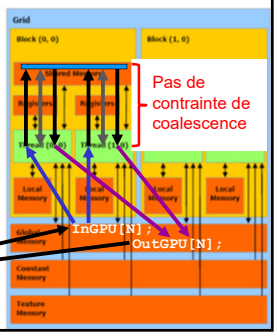

3

Principe de la *shared memory*

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 global d'accès à la mémoire

***Shared memory* d'un multiprocesseur :**
- 64KB/multiproc sur archi Pascal.
- 2x48KB sur archi Turing (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

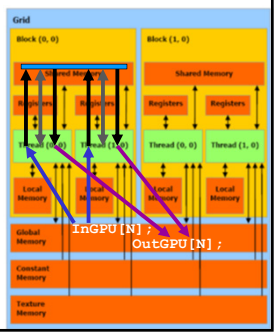

4

Principe de la *shared memory*

Kernel utilisant la mémoire *shared* … 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 « fait le cache » !

Les blocs sont juxtaposés

5

CentraleSupélec

CUDA : optimized programming

1 – Utilisation de la *shared memory*
- Principes de la *shared memory*
- **Ex 1: Moyenne glissante & blocs juxtaposés**
- First generic scheme of a shM 2D kernel
- Ex 2: Moyenne glissante & blocs recouvrant
- Ex 3: Transposition de matrice
- Second generic scheme of a ShM 2D kernel

2 – Réduction optimisée
3 – Kernels auto-adaptatifs
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

6

Utilisation de la *shared memory*

Ex 1: Moyenne glissante & blocs juxtaposés

Kernel utilisant la mémoire *shared* 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

```
__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

7

Utilisation de la *shared memory*

Ex 1: Moyenne glissante & blocs juxtaposés

Kernel utilisant la mémoire *shared* 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 »

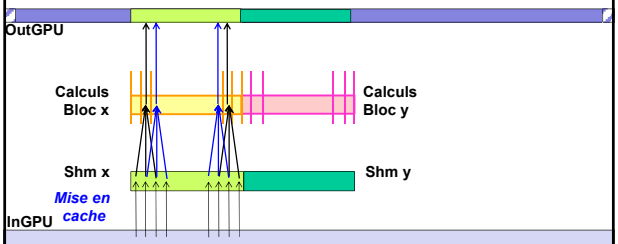

8

Utilisation de la *shared memory*

Ex 1: Moyenne glissante & blocs juxtaposés

Kernel utilisant la mémoire *shared* 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 »

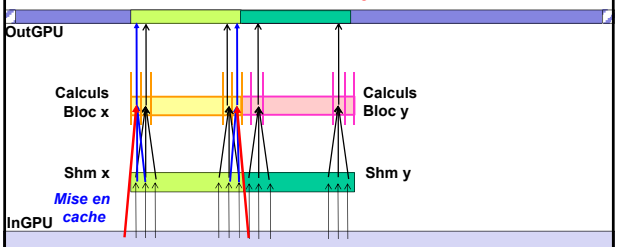

9

Utilisation de la *shared memory*

Ex 1: Moyenne glissante & blocs juxtaposés

Kernel utilisant la mémoire *shared* 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

On exploite les données en *shm*

Les blocs sont juxtaposés

10

Utilisation de la *shared memory*

Ex 1: Moyenne glissante & blocs juxtaposés

Kernel utilisant la mémoire *shared* 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

```
__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 !!
 .....
```

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

Les blocs sont juxtaposés
mais le dernier bloc déborde

11

Utilisation de la *shared memory*

Ex 1: Moyenne glissante & blocs juxtaposés

Kernel utilisant la mémoire *shared* 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

12

CUDA : optimized programming

1 – Utilisation de la *shared memory*
- Principes de la *shared memory*
- Ex 1: Moyenne glissante & blocs juxtaposés
- **First generic scheme of a shM 2D kernel**
- Ex 2: Moyenne glissante & blocs recouvrant
- Ex 3: Transposition de matrice
- Second generic scheme of a ShM 2D kernel

2 – Réduction optimisée
3 – Kernels auto-adaptatifs
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

13

First generic scheme of a 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 some boundaries
 // on indexes in global memory
 if (…) {                                   Ensure coalescence
   shdata[threadIdx.y][threadIdx.x] = Input[idxY][idxX];
 }
 __syncthreads(); // REQUIRED: wait for all data loaded in ShM
 // Computations using any data into the shared memory,
 // respecting others boundaries
 if (…) {    No constraint
   res = … shdata[…][…] … ;
   Output[idxY][idxX] = res;
 }        Ensure coalescence
```

14

CUDA : optimized programming

1 – Utilisation de la *shared memory*
- Principes de la *shared memory*
- Ex 1: Moyenne glissante & blocs juxtaposés
- First generic scheme of a shM 2D kernel
- **Ex 2: Moyenne glissante & blocs recouvrant**
- Ex 3: Transposition de matrice
- Second generic scheme of a ShM 2D kernel

2 – Réduction optimisée
3 – Kernels auto-adaptatifs
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

15

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données cachées en *shared memory*.

→ 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;
  }
}
```

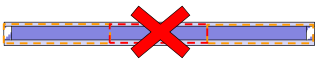

→ Des blocs juxtaposés ne suffisent plus

16

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données cachées en *shared memory*.

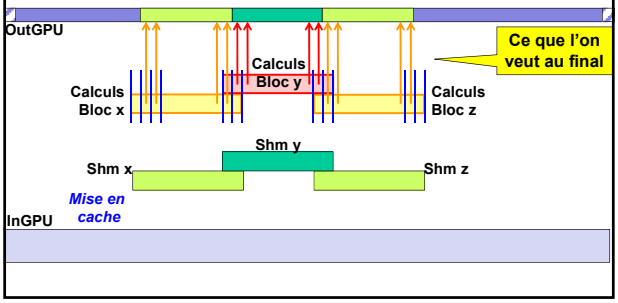

17

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données cachées en *shared memory*.

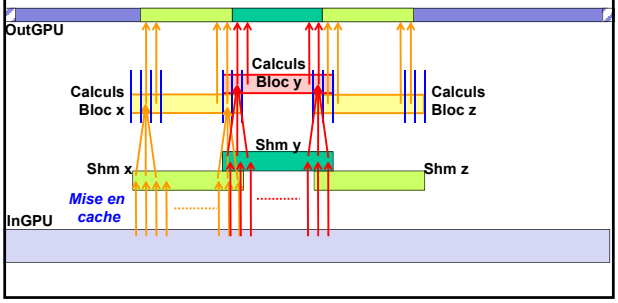

18

Utilisation de la *shared memory*

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données cachées en *shared memory.*

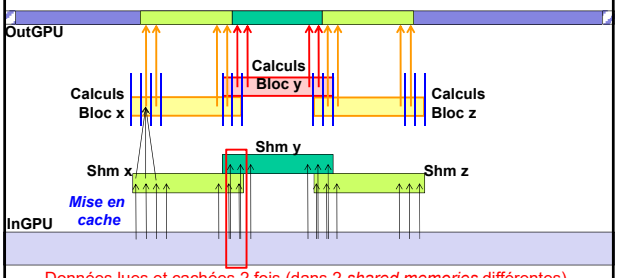

Données lues et cachées 2 fois (dans 2 *shared memories* différentes)

19

Utilisation de la *shared memory*

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données cachées en *shared memory.*

Les blocs sont **juxtaposés pour l'écriture** dans OutGPU

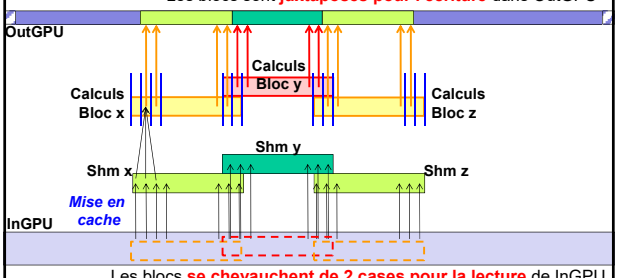

Les blocs **se chevauchent de 2 cases pour la lecture** de InGPU

20

Utilisation de la *shared memory*

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données cachées en *shared memory.*

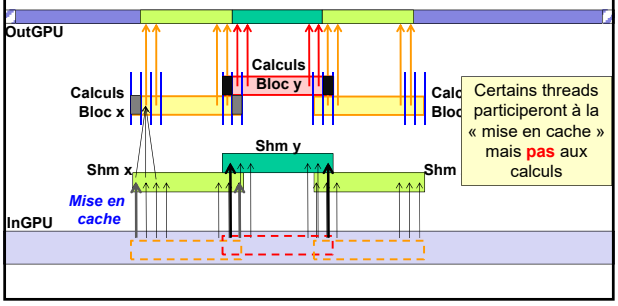

21

Utilisation de la *shared memory*

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données des calculs d'un bloc cachées en *shm*

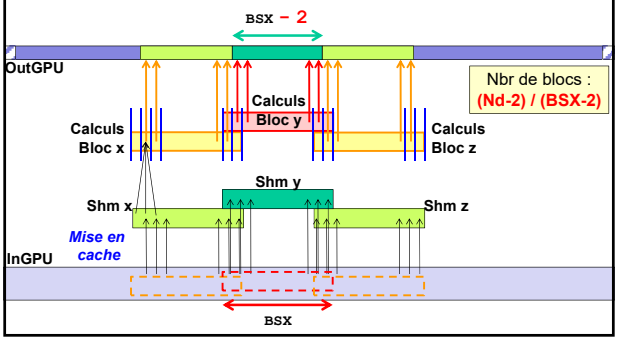

22

Utilisation de la *shared memory*

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données cachées en *shared memory*

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),1,1}

```
__global__ void k1D(void)
{
  // Collective definition of table in the shared memory
    __shared__ float shdata[BSX];
  // Local computation result
  float res;
  // 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 !!
  if (threadIdx.x > 0 && threadIdx.x < BSX-1
      /* && idx > 0 && idx < Nd-1 */) {
    // 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;
  }
}
```

Les blocs **doivent** se chevaucher

23

Utilisation de la *shared memory*

Ex 2: Moyenne glissante & blocs recouvrant

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

Objectif : toutes les données cachées en *shared memory*

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}

```
__global__ void f1(void)
{
  // Collective definition of table
    __shared__ float shdata[BSX];
  // Local computation result
  float res;
  // 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 !!
  if (threadIdx.x > 0 && threadIdx.x < BSX-1
      /* && idx > 0 */ && idx < Nd-1) {
    // 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;
  }
}
```

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

24

CUDA : optimized programming

1 – Utilisation de la *shared memory*
- Principes de la *shared memory*
- Ex 1: Moyenne glissante & blocs juxtaposés
- First generic scheme of a shM 2D kernel
- Ex 2: Moyenne glissante & blocs recouvrant
- **Ex 3: Transposition de matrice**
- Second generic scheme of a ShM 2D kernel

2 – Réduction optimisée
3 – Kernels auto-adaptatifs
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

25

Ex 3: Transposition de matrice

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];
}
```

Accès NON coalescent

Accès coalescent

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

26

Ex 3: Transposition de matrice

Kernel optimisé de transposition d'une matrice

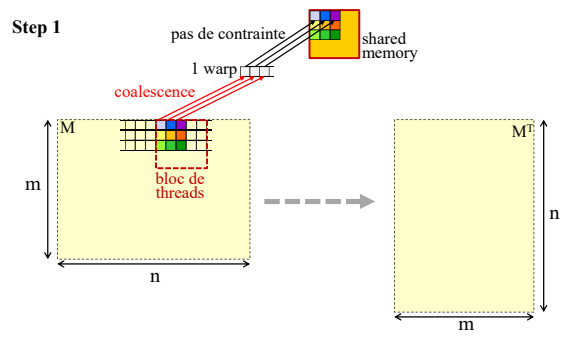

27

Ex 3: Transposition de matrice

Kernel optimisé de transposition d'une matrice

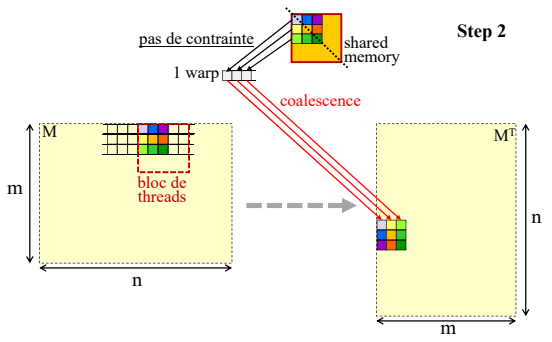

28

Ex 3: Transposition de matrice

Kernel optimisé de transposition d'une matrice

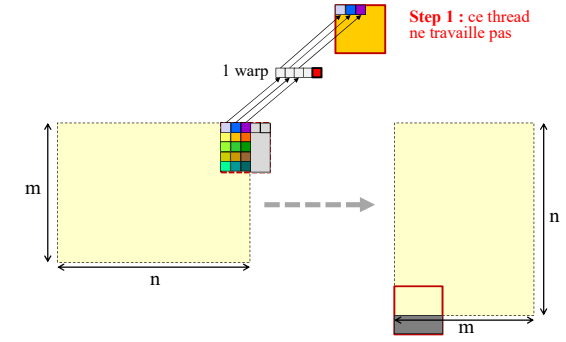

29

Ex 3: Transposition de matrice

Kernel optimisé de transposition d'une matrice

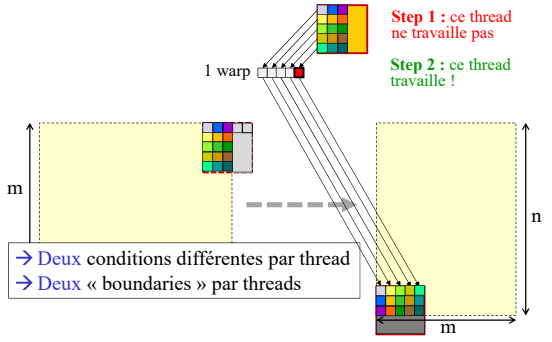

30

Ex 3: Transposition de matrice

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];
}
```

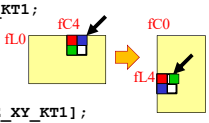

31

Second generic scheme of a 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);
 for (int step = 0; step < …; step++) {
   // shared memory update
   …
   __syncthreads();
   // local computation
   res += …
   __syncthreads();
 }
 if (…) {
   Output[idxY][idxX] = res;
 }
}
```

32

Second generic scheme of a ShM 2D kernel

```
__global__ void k2D(void)
{
 ……
 for (int step = 0; step < …; step++) {
   // Loading input data into the ShM,
   if (…) {
     shdata[threadIdx.y][threadIdx.x] =
                          Input[gg(idxY,step)][ff(idxX,step)];
   }
   __syncthreads(); // REQUIRED: wait for ShM has been updated
   // Computations using any data into the shared memory,
   if (…) {
     res += … shdata[…][…] … ;
   }
   __syncthreads(); // REQUIRED: wait for all ShM has been read
 }
 ……
```

33

CUDA : optimized programming

1 – Utilisation de la *shared memory*
2 – Réduction optimisée
- **Optimisation du schéma de réduction**
- Implantation coalescente et peu divergente
- Implantation en *shared memory*

3 – Kernels auto-adaptatifs
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

34

Optimisation du schéma de réduction

Schéma de base :

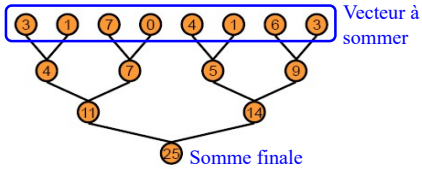

Une « réduction » contient du parallélisme difficile à exploiter :

- plus les calculs progressent et moins il y a de parallélisme,
- il y a bcp d'accès aux données et peu de calculs,
- et risque de *divergence* et de *non-coalescence*

Voir : *Optimizing Parallel Reduction in CUDA*, Mark Harris (NVIDIA)

35

Optimisation du schéma de réduction

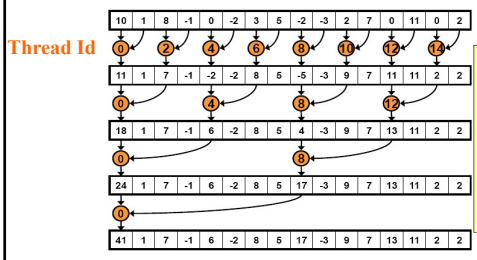

Forte divergence, et **pas de coalescence**. Très mauvaise stratégie sur GPU !

Données à réduire de + en + dispersées
→ Accès mémoire de moins en moins « coalescents » !

Thread actifs de + en + dispersées
→ Activations de « warps » très pauvres en threads actifs

36

Optimisation du schéma de réduction

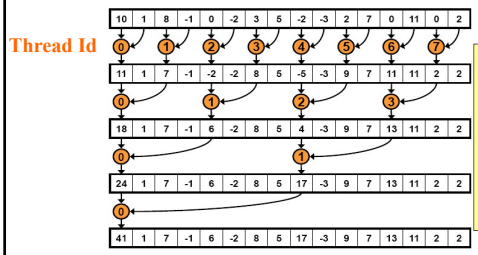

Divergence maîtrisée, mais **pas de coalescence**. Mauvaise stratégie sur GPU !

Sous-ensembles de threads actifs « contiguës depuis le thread 0 ».

Mais données à réduire de + en + dispersées

→ Accès mémoire toujours de moins en moins « coalescents » !

37

Optimisation du schéma de réduction

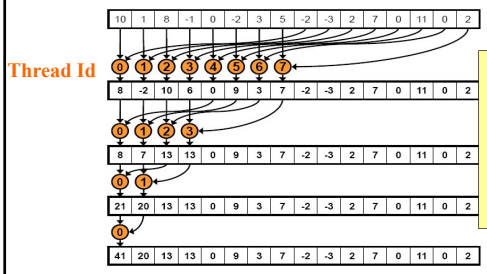

Pas de divergence et accès coalescents. **Bonne stratégie sur GPU** !

Sous-ensembles de threads actifs « contiguës depuis le thread 0 ».

Accès mémoires qui restent coalescents.

→ Stratégie efficace sur GPU … … **comment l'implanter ?**

38

CUDA : optimized programming

1 – Utilisation de la *shared memory*
2 – Réduction optimisée
- Optimisation du schéma de réduction
- **Implantation coalescente et peu divergente**
- Implantation en *shared memory*

3 – Kernels auto-adaptatifs
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

39

Implantation coalescente et peu divergente

On garde actif un sous-ensemble [0;n] de threads

```
int idx = …;
// 1ère partie du kernel: tous les th actifs
A[idx] = …

// 2nd partie du kernel: la moitié des th actifs
if (idx%2 == 0) {
  A[idx] = A[idx] + A[idx+1];
}
if (idx%4 == 0) { // Puis le quart des th actifs
  ……
}
…
```

Mauvais

```
int idx = …;
// 1ère partie du kernel: tous les th actifs
A[idx] = …

// 2nd partie du kernel: la moitié des th actifs
if (threadIdx.x < BLOCKSIZE_X/2) {
  A[idx] = A[idx] + A[idx + BLOCKSIZE_X/2];
}
if (threadIdx.x < BLOCKSIZE_X/4) ……
……
```

40

Implantation coalescente et peu divergente

On peut même terminer explicitement les threads inutiles

```
int idx = …;
// 1ère partie du kernel: tous les th actifs
A[idx] = …

// 2nd partie du kernel: la moitié des th actifs
if (threadIdx.x < BLOCKSIZE_X/2) {
  A[idx] = A[idx] + A[idx + BLOCKSIZE_X/2];
} else {
  return;
}
// Puis le quart des th actifs
if (threadIdx.x < BLOCKSIZE_X/4) {
  A[idx] = A[idx] + A[idx + BLOCKSIZE_X/4];
} else {
  return;
}
……
```

- Moins de « warps » activés en 2nd partie de kernels
- Moins d'accès en mémoire globale (hyp : accès coalescents par warp)

41

CUDA : optimized programming

1 – Utilisation de la *shared memory*
2 – Réduction optimisée
- Optimisation du schéma de réduction
- Implantation coalescente et peu divergente
- **Implantation en *shared memory***

3 – Kernels auto-adaptatifs
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

42

Réduction optimisée

Implantation en *shared memory*

```
__global__ void Reduce_kernel(float gtab[N], int l, float *AdrGRes)
{
  __shared__ float buff[BLOCK_SIZE];  // BLOCK_SIZE must be a power of 2
  int useful = BLOCK_SIZE;            // Nb of useful threads
  int idx = threadIdx.x + blockIdx.x*BLOCK_SIZE;

  // Coalescent global memory reading (all threads are active)
  if (idx < N)
    buff[threadIdx.x] = gtab[idx];    // load global data
  else
    buff[threadIdx.x] = 0.0;          // padding when necessary
  __syncthreads();                    // Required synchronization barrier

  // Reduction loop
  useful >>= 1;       // Only half of threads are now useful
  while (useful > 0) {
    if (threadIdx.x < useful) // Useful threads reduce data
      buff[threadIdx.x] += buff[threadIdx.x + useful];
    else
      return;         // Useless threads terminate
    useful >>= 1;     // Half of threads won't be useful at the next iter
    __syncthreads();// Required synchronization barrier
  }

  // Accumulation in global memory by th 0 of the block
  atomicAdd(AdrGRes,buff[0]);     // expensive op: not the only solution
}
```

43

Réduction optimisée

Implantation en *shared memory*

```
__global__ void Reduce_kernel(float gtab[N], int l, float *AdrGRes)
{
  __shared__ float buff[BLOCK_SIZE];  // BLOCK_SIZE must be a power of 2
  int useful = BLOCK_SIZE;            // Nb of useful threads
  int idx = threadIdx.x + blockIdx.x*BLOCK_SIZE;

  // Coalescent global memory reading (all threads are active)
  if (idx < N)
    buff[threadIdx.x] = gtab[idx];  // load global data
  else
    buff[threadIdx.x] = 0.0;        // padding when necessary

  // Reduction loop
  useful >>= 1;       // Only half of threads are now useful
  while (useful > 0) {
    __syncthreads();// Required synchronization barrier
    if (threadIdx.x < useful) // Useful threads reduce data
      buff[threadIdx.x] += buff[threadIdx.x + useful];
    else
      return;         // Useless threads terminate
    useful >>= 1;     // Half of threads won't be useful at
  }

  // Accumulation in global memory by th 0 of the block
  atomicAdd(AdrGRes,buff[0]);     // expensive op: not the only solution
}
```

Avec 1 barrière de synchro. de moins ☺

44

CUDA : optimized programming

1 – Utilisation de la *shared memory*
2 – Réduction optimisée
3 – Déroulement de boucle auto-adaptatif
- **Auto-adaptation à la compilation**
- Optimisation SIMD de la boucle déroulée
- Implantation en template C++

4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

45

Déroulement de boucle auto-adaptatif

Auto-adaptation à la compilation

Principe :
- Implanter un kernel sans limite de taille (générique) : BLOCK_SIZE_X = 1, 2, 4, 8, …512, 1024
- Mais ne compiler que les parties correspondant à sa taille
  → Compiler le strict minimum d'instruction à exécuter

Solution :
- Dérouler la boucle de réduction
- Éliminer à la compilation les étapes inutiles

46

Déroulement de boucle auto-adaptatif

Auto-adaptation à la compilation

```
__global__ void Reduce_kernel(float gtab[N], int l, float *AdrGRes)
{
  __shared__ float buff[BLOCK_SIZE];  // BLOCK_SIZE must be a power of 2
  int idx = threadIdx.x + blockIdx.x*BLOCK_SIZE;

  // Coalescent global memory reading (all threads are active)
  if (idx < N)
    buff[threadIdx.x] = gtab[idx];  // load global data (coalescent)
  else
    buff[threadIdx.x] = 0.0;        // padding when necessary

  // Reduction loop
  #if BLOCK_SIZE > 512
  __syncthreads();              // Barrière de synchro NECESSAIRE
  if (threadIdx.x < 512)        // Useful threads reduce data
    buff[threadIdx.x] += buff[threadIdx.x + 512];
  else
    return;                     // Useless threads terminate
  #endif

  #if BLOCK_SIZE > 256
  __syncthreads();              // Barrière de synchro NECESSAIRE
  if (threadIdx.x < 256)        // Useful threads reduce data
    buff[threadIdx.x] += buff[threadIdx.x + 256];
  else
    return;                     // Useless threads terminate
  #endif
```

47

Déroulement de boucle auto-adaptatif

Auto-adaptation à la compilation

```
  #if BLOCK_SIZE > 128
  __syncthreads();              // Barrière de synchro NECESSAIRE
  if (threadIdx.x < 128)        // Useful threads reduce data
    buff[threadIdx.x] += buff[threadIdx.x + 128];
  else
    return;                     // Useless threads terminate
  #endif

  #if BLOCK_SIZE > 64
  __syncthreads();              // Barrière de synchro NECESSAIRE
  if (threadIdx.x < 64)         // Useful threads reduce data
    buff[threadIdx.x] += buff[threadIdx.x + 64];
  else
    return;                     // Useless threads terminate
  #endif

  #if BLOCK_SIZE > 32
  __syncthreads();              // Barrière de synchro NECESSAIRE
  if (threadIdx.x < 32)         // Useful threads reduce data
    buff[threadIdx.x] += buff[threadIdx.x + 32];
  else
    return;                     // Useless threads terminate
  #endif
```

48

Auto-adaptation à la compilation

```
#if BLOCK_SIZE > 16
__syncthreads();            // Barrière de synchro NECESSAIRE
if (threadIdx.x < 16)       // Useful threads reduce data
  buff[threadIdx.x] += buff[threadIdx.x + 16];
else
  return;                   // Useless threads terminate
#endif

#if BLOCK_SIZE > 8
__syncthreads();            // Barrière de synchro NECESSAIRE
if (threadIdx.x < 8)        // Useful threads reduce data
  buff[threadIdx.x] += buff[threadIdx.x + 8];
else
  return;                   // Useless threads terminate
#endif

.....

#if BLOCK_SIZE > 1
__syncthreads();            // Barrière de synchro NECESSAIRE
if (threadIdx.x  < 1)       // Useful threads reduce data
  buff[threadIdx.x] += buff[threadIdx.x + 1];
else
  return;                   // Useless threads terminate
#endif

// Accumulation in global memory by th 0 (the only survivor !)
atomicAdd(AdrGRes,buff[0]);
}
```

49

CUDA : optimized programming

50

Optimisation SIMD

Principe :

- Profiter des propriétés SIMD des *warps* lorsqu'il ne reste plus qu'un *warp* actif dans le bloc
- On peut alors supprimer les opérations de synchronisation entre threads (**`__syncthreads()`**) !

Solution :

- Simplifier le code quand le nombre de threads actifs devient inférieur à 32

51

Optimisation SIMD

```
__global__ void Reduce_kernel(float gtab[N], int l, float *AdrGRes)
{
 __shared__ float buff[BLOCK_SIZE > 64 ? BLOCK_SIZE :64];//power of 2
 int idx = threadIdx.x + blockIdx.x*BLOCK_SIZE;

 // Coalescent global memory reading (all threads are active)
 if (idx < N)
   buff[threadIdx.x] = gtab[idx];  // load global data (coalescent)
 else
   buff[threadIdx.x] = 0.0;        // padding when necessary

 // Reduction loop
 #if BLOCK_SIZE > 512
 __syncthreads();            // Barrière de synchro NECESSAIRE
 if (threadIdx.x < 512)      // Useful threads reduce data
   buff[threadIdx.x] += buff[threadIdx.x + 512];
 else
   return;                   // Useless threads terminate
 #endif

 #if BLOCK_SIZE > 256
 __syncthreads();            // Barrière de synchro NECESSAIRE
 if (threadIdx.x < 256)      // Useful threads reduce data
   buff[threadIdx.x] += buff[threadIdx.x + 256];
 else
   return;                   // Useless threads terminate
 #endif
 ..............................
```

52

Optimisation SIMD

```
#if BLOCK_SIZE > 16
__syncthreads();            // Barrière de synchro NEC
if (threadIdx.x < 16)       // Useful threads reduce d
  buff[threadIdx.x] += buff[threadIdx.x + 16];
else
  return;                   // Useless threads termina
#endif

#if BLOCK_SIZE > 8
__syncthreads();            // Barrière de synchro NECESSAIRE
if (threadIdx.x < 8)        // Useful threads reduce d
  buff[threadIdx.x] += buff[threadIdx.x + 8];
else
  return;                   // Useless threads termina
#endif

.....

#if BLOCK_SIZE > 1
__syncthreads();            // Barrière de synchro NECESSAIRE
if (threadIdx.x < 1)        // Useful threads reduce d
  buff[threadIdx.x] += buff[threadIdx.x + 1];
else
  return;                   // Useless threads termina
#endif

// Accumulation in global memory by th0 (warning 32
if (threadIdx.x == 0) atomicAdd(AdrGRes,buff[0]);
}
```

32 th vivants seulement dans 1 seul warp
→ **SIMD pur**

Attention, on n'a pas tuer les threads [1;31] du warp
→ **Ne faire écrire que le dernier**

Ecriture atomique pour éviter les conflits avec les threads 0 des autres blocs !

53

Optimisation SIMD

Simple ré-écriture sans les lignes supprimées :

```
#if BLOCK_SIZE > 32
__syncthreads();            // Barrière de synchro NECESSAIRE
if (threadIdx.x < 32)       // Useful threads reduce data
  buff[threadIdx.x] += buff[threadIdx.x + 32];
else
  return;                   // Useless threads terminate
#endif

#if BLOCK_SIZE > 16
buff[threadIdx.x] += buff[threadIdx.x + 16];
#endif

#if BLOCK_SIZE > 8
buff[threadIdx.x] += buff[threadIdx.x + 8];
#endif

.....

#if BLOCK_SIZE > 1
buff[threadIdx.x] += buff[threadIdx.x + 1];
#endif

// Accumulation in global memory by th0 (warning 32 threads still alive)
if (threadIdx.x == 0) atomicAdd(AdrGRes,buff[0]);
}
```

Les 32 th survivants sont dans 1 seul warp
→ **SIMD pur**

54

CUDA : optimized programming

1 – Utilisation de la *shared memory*
2 – Réduction optimisée
3 – Déroulement de boucle auto-adaptatif
- Auto-adaptation à la compilation
- Optimisation SIMD de la boucle déroulée
- **Implantation en template C++**

4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

55

Implantation en template C++

NVCC est un compilateur C++…

→ On peut se servir du mécanisme des « **templates** » pour spécialiser le code à la compilation

56

Implantation en template C++

```
template <int BLOCK_SIZE>
__global__ void Reduce_kernel(float gtab[N], int l, float *AdrGRes)
{
 __shared__ float buff[BLOCK_SIZE > 64 ? BLOCK_SIZE :64]; // a power of 2
 int idx = threadIdx.x + blockIdx.x*BLOCK_SIZE;

 // Coalescent global memory reading (all threads are active)
 if (idx < N)
   buff[threadIdx.x] = gtab[idx];  // load global data (coalescent)
 else
   buff[threadIdx.x] = 0.0;        // padding when necessary
 // Reduction loop
 if (BLOCK_SIZE > 512) {
    __syncthreads();  // Barrière de synchro NECESSAIRE
   if (idx < 512)     // Useful threads reduce data
     buff[threadIdx.x] += buff[threadIdx.x + 512];
   else
     return;         // Useless threads terminate
 }
 if (BLOCK_SIZE > 256) {
    __syncthreads();  // Barrière de synchro NECESSAIRE
   if (idx < 256)     // Useful threads reduce data
     buff[threadIdx.x] += buff[threadIdx.x + 256];
   else
     return;         // Useless threads terminate
 }
 .........
```

57

Implantation en template C++

```
if (BLOCK_SIZE > 32) {
   __syncthreads(); // Barrière de synchro NECESSAIRE
   if (idx < 32)    // Useful threads reduce data
     buff[threadIdx.x] += buff[threadIdx.x + 32];
   else
     return;        // Useless threads terminate
 }

 if (BLOCK_SIZE > 16) {
   buff[threadIdx.x] += buff[threadIdx.x + 16];
 }
 if (BLOCK_SIZE > 8) {
   buff[threadIdx.x] += buff[threadIdx.x + 8];
 }
 .....
 if (BLOCK_SIZE > 1) {
   buff[threadIdx.x] += buff[threadIdx.x + 1];
 }
 // Accumulation in global memory by th0 (warning 32 threads still alive)
 if (threadIdx.x == 0) atomicAdd(AdrGRes,buff[0]);
}
```

Les 32 th survivants sont dans 1 seul warp
→ **SIMD pur**

58

CUDA : optimized programming

1 – Utilisation de la *shared memory*
2 – Réduction optimisée
3 – Déroulement de boucle auto-adaptatif
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

59

Parallélisme dynamique

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

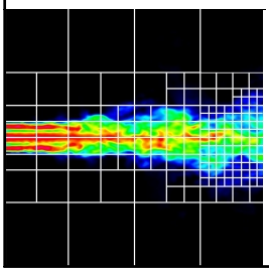

```
__global__ ChildKernel(void* data){
  //Operate on data
}

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

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

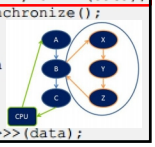

60

CUDA : optimized programming

1 – Utilisation de la *shared memory*
2 – Réduction optimisée
3 – Déroulement de boucle auto-adaptatif
4 – Parallélisme dynamique sur GPU
5 – Bilan de la programmation CUDA

61

Bilan de la programmation CUDA

Une nouvelle façon de programmer (ou que l'on redécouvre) :

- Demande une période d'apprentissage (!) debug difficile…
- Arriver à identifier rapidement si un algorithme est adapté au GPU
- Apprendre les optimisations principales : voir le « *CUDA C Best Practices Guide* ».

Performances :

- Annonces de gains *spectaculaires* vis-à-vis d'un coeur CPU
- Souvent un gain de 2 à 10 seulement vis-à-vis d'un code parallèle et optimisé sur dual-CPU (serveur standard) !
- Codes hybrides CPU+GPU efficaces mais restent plus complexes.

62

Bilan de la programmation CUDA

Les bonnes pratiques :

- Ecrire des kernels coalescents et non-divergents
- Utiliser la *shared memory* avec un « algo de cache dédié au pb »
- Terminer les threads devenues inutiles, et éliminer des *warps* entiers
- Ne pas oublier de resynchroniser les threads !
- Mais éliminer les synchros quand il ne reste qu'un seul *warp* actif!
- Écrire des kernels génériques avec des constantes (connues à la compilation), afin que le compilateur :
  - élimine les lignes de code inutiles
    (par « `#define` » ou « template functions »)
  - spécialise le kernel pour le problème.

63

CUDA : optimized programming

End

64