POLYTECH PARIS-SACLAY

GP-GPU

CUDA: Fast transfers and overlap

Stéphane Vialle

université PARIS-SACLAY — Sciences et technologies de l'information et de la communication (STIC) — LISN

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

1

POLYTECH PARIS-SACLAY

CUDA : Transferts rapides et recouvrements

1 – Utilisation de pages mémoires CPU verrouillées
- **Principes de la mémoire verrouillée**
- **Allocation et conversion de mémoire verrouillée**
- **Accélération des transferts CPU/GPU**

2 – Transferts asynchrones CPU/GPU

3 – Utilisation de multiples *Streams*

2

Principes de la mémoire verrouillée

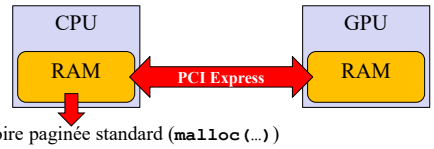

• Mémoire paginée standard (`malloc(…)`)

Ou bien :

• **Mémoire verrouillée (« *pinned* », « *locked* ») :**
- La mémoire paginée peut être envoyée sur disque, alors que la mémoire verrouillée reste en RAM
- Il ne faut pas verrouiller trop de gros volumes de données sinon il n'y a plus de RAM disponible !
- **Les transferts CPU/GPU seront + rapides**
- **Les transferts CPU/GPU pourront être asynchrones (voir plus loin)**

3

Principes de la mémoire verrouillée

Le transfert CPU/GPU nécessite des pages mémoires verrouillées

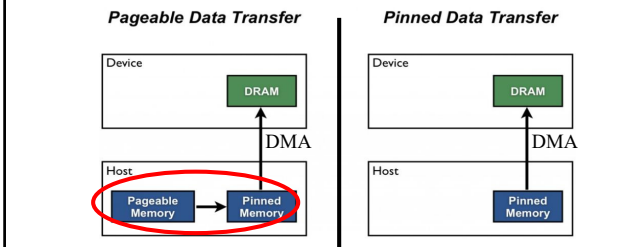

1. Allocation de mémoire verrouillée
2. Recopie des données à transférer
3. Puis transfert des données
→ op longue avec synchronisations

1. Transfert des données
→ allouer dès le début de l'espace mémoire verrouillé !

4

Allocation de mémoire verrouillée

Allocation de mémoire verrouillée

Allocation de mémoire verrouillée sur le CPU pour une application :

```
cudaHostAlloc(AdrPtHost, size, cudaHostAllocDefault)
```

Allocation de mémoire verrouillée accessible à plusieurs applications (plusieurs contextes CUDA) :

```
cudaHostAlloc(AdrPtHost, size, cudaHostAllocPortable)
```

Libération de la mémoire verrouillée allouée dans la RAM du CPU

```
cudaFreeHost(PtHost)
```

Rmq : on peut allouer de la mémoire verrouillée avec les bibliothèques systèmes CPU…mais avec CUDA c'est très simple à faire !

5

Conversion de mémoire verrouillée

Conversion dynamique de mémoire paginée en mémoire verrouillée

- On transforme une zone mémoire standard en mémoire verrouillée :

```
cudaHostRegister(PtHost,size,cudaHostRegisterDefault)
```

ou

```
cudaHostRegister(PtHost,size,cudaHostRegisterPortable)
```

- On retransforme une zone mémoire verrouillée en mémoire paginée dès qu'on n'a plus besoin de la transférer vers/depuis le GPU:

```
cudaHostUnregister(PtHost)
```

évite de garder trop d'espace mémoire verrouillé et de manquer de RAM!

→ La *conversion dynamique* facilite la transformation de *legacy codes*
Inutile de modifier la totalité d'un ancien code CPU complexe !

6

Accélération des transferts CPU/GPU

Possibilité d'accélération sans autres changemement dans le code

```
cudaMemcpy(PtDst,PtSrc,size,cudaMemcpyHostToDevice)
MyKernel<<< Dg, Db >>>(……)
cudaMemcpy(PtDst,PtSrc,size,cudaMemcpyDeviceToHost)
```

Les transferts CPU/GPU depuis/vers de la mémoire CPU verrouillée doivent être plus rapides …

… mais on n'observe pas toujours de différence!

Les principaux intérêts à utiliser de la mémoire verrouillée sont :

- l'exploitation de routines de transferts asynchrones
- le recouvrement entre les calculs CPU, les calculs GPU et les transferts CPU/GPU.

7

CUDA : Transferts rapides et recouvrements

8

Routines CUDA

La mémoire CPU verrouillée autorise les transferts asynchrones

```
1 cudaMemcpyAsync(PtGPU, PtCPU, size, cudaMemcpy…To…);
2 kernel<<<Dg,Db>>>(…);
3 cudaMemcpyAsync(PtCPU, PtGPU, size, cudaMemcpy…To…);
4 …… // next instructions of the CPU
```

- Les trois opérations 1, 2, et 3 sont **non bloquantes** pour le CPU qui fait ces appels : elles sont réalisées en asynchrone vis-à-vis du CPU
- Le CPU se retrouve instantanément à l'instruction 4 et peut entamer d'autres calculs pendant que le GPU travaille (voir plus loin)
- Mais les instructions 1, 2 et 3 sont bien exécutées dans l'ordre par le GPU, sur le *stream par défaut* (ou *stream 0*)

9

Fonctionnement d'un *stream* CUDA

Un *stream* fonctionne comme une file d'attente FIFO

On peut préciser explicitement le *stream* à utiliser (0 = *stream* par défaut) :

```
1 cudaMemcpyAsync(PtGPU, PtCPU, size, cudaMemcpy…To…, 0);
2 kernel<<<Dg,Db,0,0>>>(…);
3 cudaMemcpyAsync(PtCPU, PtGPU, size, cudaMemcpy…To…, 0);
```

Le *stream* séquentialise (dans l'ordre) les opérations qui lui sont envoyées :

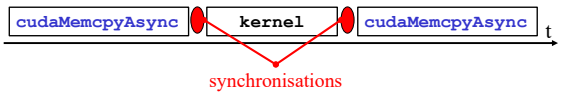

→ Il y a sérialisation et synchronisation implicites des opérations lancées sur un même *stream*

10

Recouvrement de calculs CPU et GPU

Mémoire verrouillée + Asynchronisme + Synchronisation :

```
1  cudaHostRegister(PtInCPU,…);
2  cudaHostRegister(PtOutCPU,…);
3  cudaMemcpyAsync(PtInGPU,PtInCPU,size,
                   cudaMemcpyHostToDevice);
4  k1_GPU<<< Dg, Db >>>(…);
5  cudaMemcpyAsync(PtOutCPU,PtOutGPU,size,
                   cudaMemcpyDeviceToHost);
6  k2_CPU(…);
7  cudaDeviceSynchronize();
8  k3_CPU(PtOutCPU);
9  cudaFreeHost(PtInCPU);
10 cudaFreeHost(PtOutCPU);
```

Attend la fin de toutes les ops. sur le GPU

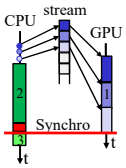

→ Calculs sur CPU en parallèle des transferts et des calculs sur GPU

→ Besoin d'une synchro. explicite avant d'exploiter les résultats du GPU

11

Recouvrement de calculs CPU et GPU

Mémoire verrouillée + Asynchronisme + Synchronisation :

```
1  cudaHostRegister(PtInCPU,…);
2  cudaHostRegister(PtOutCPU,…);
3  cudaMemcpyAsync(PtInGPU,PtInCPU,size,
                   cudaMemcpyHostToDevice);
4  k1_GPU<<< Dg, Db >>>(…);
5  cudaMemcpyAsync(PtOutCPU,PtOutGPU,size,
                   cudaMemcpyDeviceToHost);
6  k2_CPU(…);
7  cudaStreamSynchronize(0);
8  k3_CPU(PtOutCPU);
9  cudaFreeHost(PtInCPU);
10 cudaFreeHost(PtOutCPU);
```

Attend la fin de toutes les ops. sur le *stream* par défaut

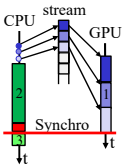

→ Calculs sur CPU en parallèle des transferts et des calculs sur GPU

→ Besoin d'une synchro. explicite avant d'exploiter les résultats du GPU

12

CUDA :
Transferts rapides et recouvrements

1 – Utilisation de pages mémoires CPU verrouillées
2 – Transferts asynchrones CPU/GPU
3 – Utilisation de multiples *Streams*
- **Création et suppression de *Streams***
- **Recouvrement de transferts et de calculs GPU**

13

Création et suppression de *Streams*

Routines CUDA

CUDA permet de créer un grand nombre de *streams* (sans limites)
Mais un nombre limité de *streams* peuvent fonctionner en parallèle (ex : 16 sur les anciennes architectures Fermi….)

```
1 cudaStream_t Stream[Ns];
2 for (int i = 0; i < Ns; i++)
    cudaStreamCreate(&Stream[i]);
3 …… // Transfers and computations on all streams
4 for (int i = 0; i < Ns; i++)
    cudaStreamDestroy(Stream[i]);
```

Chaque *stream* créé gère une file FIFO d'opérations, et sérialise et synchronise les opérations de sa file.

14

Recouvrement de transferts et de calculs GPU

Basic approach

```
  // Synchronous basic data transfer
1 cudaMemcpy(PtGPU, PtCPU, N*sizeof(float),
             cudaMemcpyHostToDevice);
  // Run a 1D Grid of 1D blocks of threads
2 kernel<<< {N/BSX,1,1}, {BSX,1,1} >>>(PtGPU);
```

Chronogramme de l'exécution :

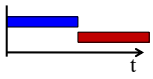

→ Le GPU et le bus PCIe ne travaillent pas en parallèle

On cherche à obtenir un **recouvrement des calculs et des transferts** :

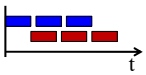

15

Recouvrement de transferts et de calculs GPU

Démarche NVIDIA : Lancer tous les transferts de données sur chaque *stream*
Puis, lancer toutes les petites grilles de blocs de threads

```
  …… // Create Nst streams
1 size = N*sizeof(float)/Nst; //Size processed on 1 stream
  // Insert a transfer op in each stream FIFO
2 for (i = 0; i < Nst; i++) {
3   offset = i * N/Nst;
4   cudaMemcpyAsync(PtGPU + offset, PtCPU + offset, size,
                    cudaMemcpyHostToDevice, Stream[i]);
  }
  // Insert a small grid launch op in each stream FIFO
5 for (i = 0; i < Nst; i++) {
6   offset = i * N/Nst;
7   kernel<<< {N/Nst/BSX),1,1}, {BSX,1,1},
              0, Stream[i] >>>(PtGPU + offset);
  }
```

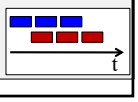

16

Recouvrement de transferts et de calculs GPU

Démarche NVIDIA : Puis, lancer tous les transferts de résultats
Puis, resynchroniser avec le CPU (si besoin) – v1

```
  // Insert a transfer op in each stream FIFO
8 for (i = 0; i < Nst; i++) {
9   offset = i * N/Nst;
10  cudaMemcpyAsync(PtResCPU+offset, PtResGPU+offset, size,
                    cudaMemcpyDeviceToHost, Stream[i]);
  }
  // Synchronize the CPU with end of ops. on each stream
11 for (i = 0; i < Nst; i++) {
12  cudaStreamSynchronize(Stream[i]);
  }
  …… // Destroy the Nst streams
```

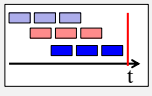

17

Recouvrement de transferts et de calculs GPU

Démarche NVIDIA : Puis, lancer tous les transferts de résultats
Puis, resynchroniser avec le CPU (si besoin) – v2

```
  // Insert a transfer op in each stream FIFO
8 for (i = 0; i < Nst; i++) {
9   offset = i * N/Nst;
10  cudaMemcpyAsync(PtResCPU+offset, PtResGPU+offset, size,
                    cudaMemcpyDeviceToHost, Stream[i]);
  }
  // Synchronize the CPU with end of ops. on the GPU
11 cudaDeviceSynchronize();
  …… // Destroy the Nst streams
```

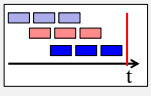

18

POLYTECH PARIS-SACLAY

CUDA: Fast transfers
and overlap

Fin

19