CentraleSupélec

Mineure CalHau2

CUDA : Fast transfers & overlapping

Stéphane Vialle

CentraleSupélec université PARIS-SACLAY ÉCOLE DOCTORALE Sciences et technologies de l'information et de la communication (STIC) RISEGrid Région lorraine Grand Est ALSACE CHAMPAGNE-ARDENNE LORRAINE

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

1

CentraleSupélec

CUDA : Fast transfers & overlapping

1 – Verrouillage de pages mémoires CPU
2 – Transfert asynchrone CPU/GPU
3 – *Streams* & recouvrements

2

Transfert rapide entre mémoires CPU et GPU

1 – Allocation de mémoire CPU *pinned*

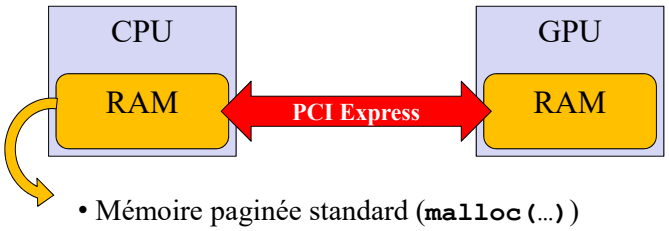

- Mémoire paginée standard (`malloc(…)`)
- **Mémoire « *pinned* » (ou « *locked* ») → transferts + rapides**
- *Mémoire « mapped » dans l'espace CUDA du GPU*
- *Mémoire « write – combined »*

La mémoire paginée peut être envoyée sur disque, alors que la mémoire verrouillée (« *pinned* ») reste en RAM

→ Il ne faut pas verrouiller trop de gros volumes de données ! (sinon il n'y a plus de RAM disponible)

3

Transfert rapide entre mémoires CPU et GPU

1 – Allocation de mémoire CPU *pinned*

Le transfert CPU/GPU nécessite des pages mémoires verrouillées

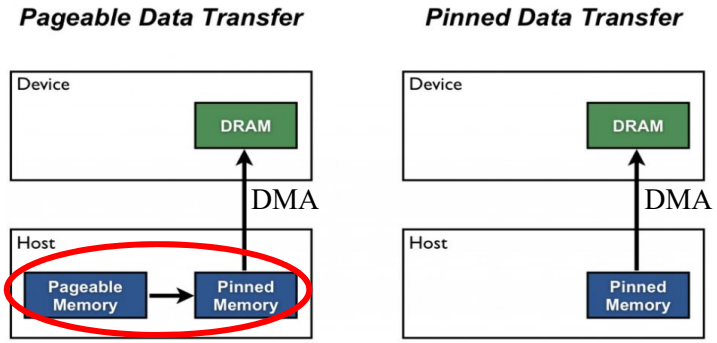

Allocation de mémoire verrouillée et recopie page par page : op longue avec synchronisations

Pour les données CPU à transférer :

→ allouer dès le début de l'espace mémoire verrouillé

4

1 – Allocation de mémoire CPU *pinned*

Allocation de mémoire « *pinned* » (ou « *locked* »)

Allocation de mémoire verrouillée sur le CPU pour une application :

```
cudaMallocHost(AdrPtHost, size)
```
... deprecated

ou bien

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

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

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

Libération de mémoire 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

1 – Convertion paginée ↔*pinned*

Convertion dynamique de mémoire paginée en mémoire « *pinned* »

- On transforme en mémoire « *pinned* » un zone mémoire standard :

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

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

```
cudaHostUnregister(PtHost)
```

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

→ **Facilite la récupération/transformation de *legacy codes* !**

Inutile de modifier un code CPU récupéré et complexe

6

CentraleSupélec

CUDA :
Fast transfers & overlapping

1 – Verrouillage de pages mémoires CPU
2 – Transfert asynchrone CPU/GPU
3 – *Streams* & recouvrements

7

CentraleSupélec

1 – Exploitation de mémoire CPU *pinned*

3 exploitations possibles d'une zone mémoire CPU « *pinned* » :

1 – Continuer à réaliser des transferts synchrones … mais plus rapides

```
cudaMemcpy(PtDst, PtSrc, size, cudaMemcpyHostToDevice)
cudaMemcpy(PtDst, PtSrc, size, cudaMemcpyDeviceToHost)
```

2 – Réaliser des transferts asynchrones (non bloquants) sur le « *stream par défaut* », et réaliser une autre tâche en parallèle sur le CPU

```
cudaMemcpyAsync(PtDst, PtSrc, size, cudaMemcpy…To…)
```
ou
```
cudaMemcpyAsync(PtDst, PtSrc, size, cudaMemcpy…To…,
                /* stream = */ 0)
kernel<<<Dg,Db>>>(…)
```
ou
```
kernel<<<Dg,Db,0,/* stream = */ 0>>>(…)
```

Sérialisation et synchro implicite des op lancées sur un même *stream*
→ il y aura bien transfert asynchrone PUIS lancement d'un kernel

8

1 – Exploitation de mémoire CPU *pinned*

3 exploitations possibles d'une zone mémoire CPU « *pinned* » :

3 – Utiliser de « *multiples streams* » pour exploiter au maximum le recouvrement des transferts et des calculs sur GPU

On peut créer puis utiliser jusqu'à 16 *streams*

sérialisation ↓

```
cudaStream_t Stream[Ns];

cudaStreamCreate(&Stream[i])

cudaMemcpyAsync(PtGPU,PtCPU,size,
                cudaMemcpyHostToDevice,Stream[i]);
kernel<<<Dg,Db,0,Stream[i]>>>(…);
cudaMemcpyAsync(PtCPU,PtGPU,size,
                cudaMemcpyHostToDevice,Stream[i]);

cudaStreamDestroy(Stream[i]);
```

9

CUDA : Fast transfers & overlapping

1 – Verrouillage de pages mémoires CPU
2 – Transfert asynchrones CPU/GPU
3 – *Streams* & recouvrements

10

2 – Streaming

```
cudaMemcpy(a_d, a_h, N*sizeof(float), dir);
kernel<<< N/nThreads, nThreads >>>(a_d);
```

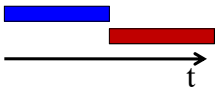


```
size = N*sizeof(float)/nStreams;
for (i = 0; i < nStreams; i++) {
  offset = i * N/nStreams;
  cudaMemcpyAsync(a_d + offset,
                  a_h + offset,
                  size, dir,
                  stream[i]);
}
for (i = 0; i < nStreams; i++) {
  offset = i * N/nStreams;
  kernel<<< {N/nStreams/BlkSizeX,1,1},
            {BlkSizeX,1,1}, 0,
            stream[i] >>>(a_d+offset);
}
```

CUDA C Best Practices Guide

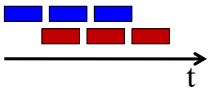

Les ops. sur un même *stream* sont sérialisées automatiquement

16 *streams* sont utilisables

- `cudaStreamCreate(…)`
- `cudaStreamDestroy(…)`
- `cudaStreamSynchronize`
- …

11

2 – Streaming

```
size = N*sizeof(float)/nStreams;
for (i = 0; i < nStreams; i++) {
  offset = i * N/nStreams;
  cudaMemcpyAsync(…,stream[i]);
}
for (i = 0; i < nStreams; i++) {
  offset = i * N/nStreams;
  kernel<<< …,stream[i]>>>(…);
}
```

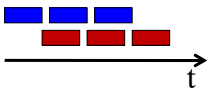

Les ops. sur un même *stream* sont sérialisées automatiquement

```
// Wait for all ops on all streams are
// completed
for (i = 0; i < nStreams; i++)
   cudaStreamSynchronize(stream[i]);
// Get global results on CPU
cudaMemcpy(CPU_res,GPU_res,size,
           cudaMemcpyDeviceToHost);
```

Mais pas les ops sur d'autres stream:

→ 1ère sol : synchro explicite sur chaque *stream*

12

2 – *Streaming*

```
size = N*sizeof(float)/nStreams;
for (i = 0; i < nStreams; i++) {
  offset = i * N/nStreams;
  cudaMemcpyAsync(…,stream[i]);
}
for (i = 0; i < nStreams; i++) {
  offset = i * N/nStreams;
  kernel<<< …,stream[i]>>>(…);
}
```

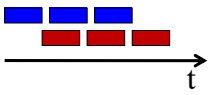

Les ops. sur un même *stream* sont sérialisées automatiquement

```
// Wait for all GPU ops are completed
cudaDeviceSynchronize();
// Get global results on CPU
cudaMemcpy(CPU_res,GPU_res,size,
           cudaMemcpyDeviceToHost);
```

Mais pas les ops sur d'autres stream:

→ 2ème sol : synchro explicite avec tout le GPU

13

CUDA : Fast transfers & overlapping

Fin

14