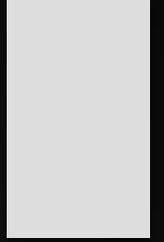


Une nouvelle approche
pour la gestion de la
mémoire avec CUDA

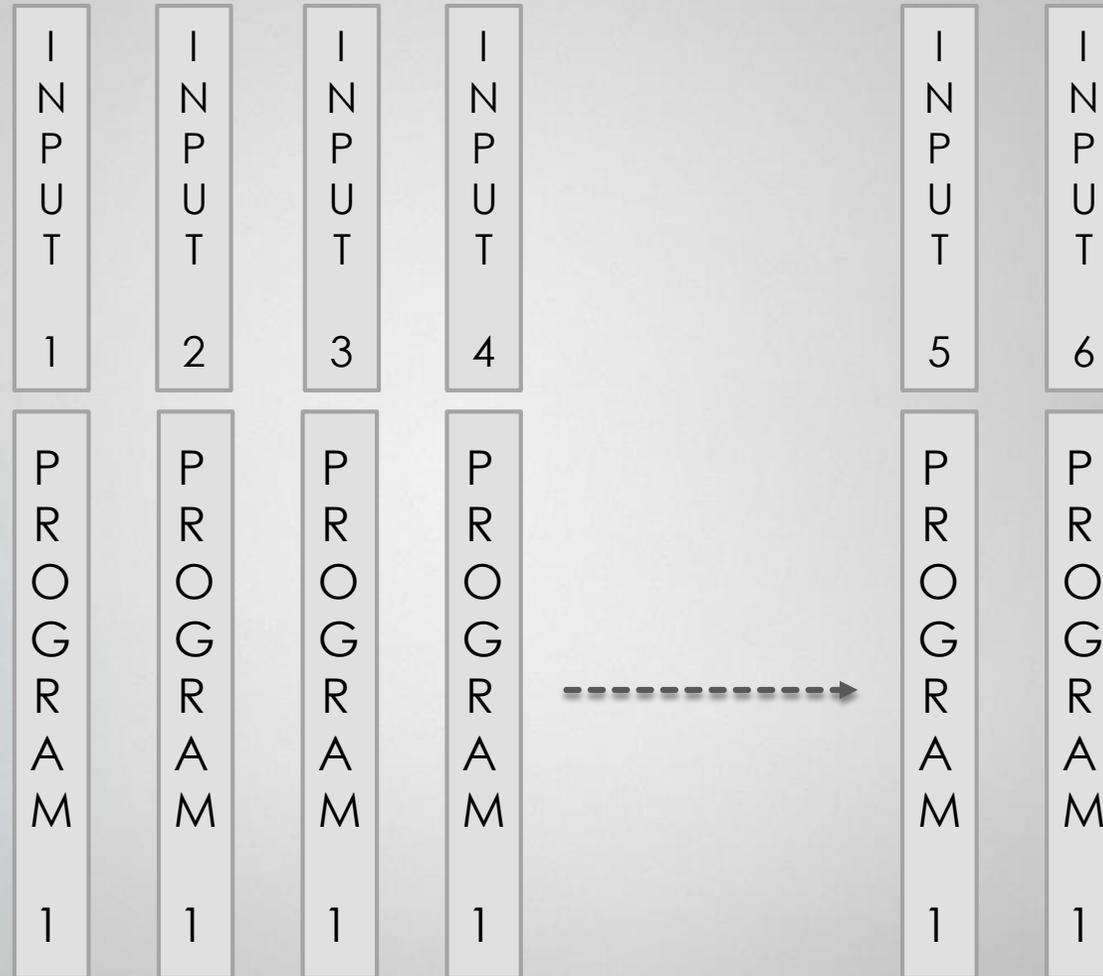
Une nouvelle approche pour la gestion de la mémoire avec CUDA

- ▶ Concepts de base
- ▶ Gérer la mémoire efficacement avec CUDA
- ▶ Qu'est ce que UVA et UVM ?
- ▶ Utiliser UVM dans une application

Architecture d'une carte graphique



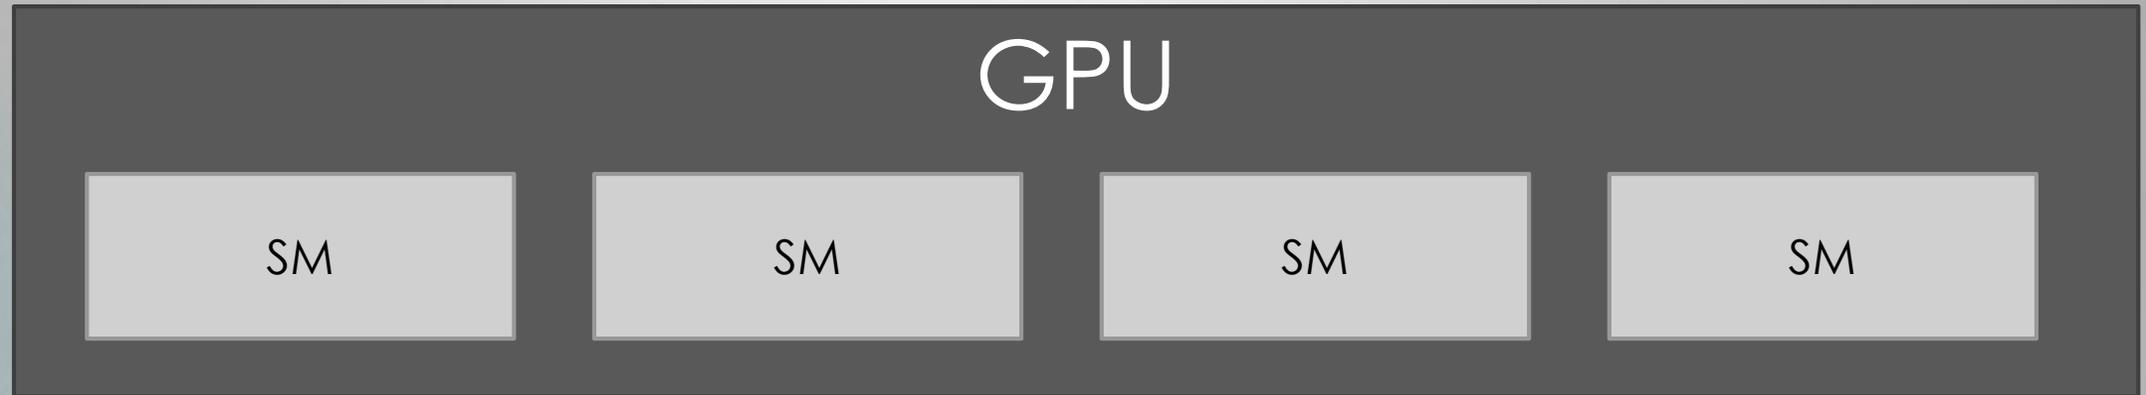
Architecture d'une carte graphique



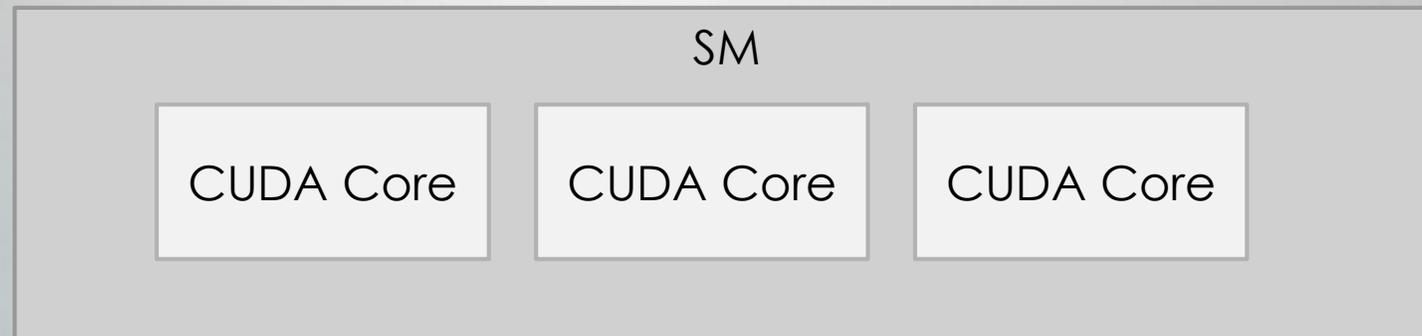
Architecture d'une carte graphique

```
MyCudaFunction<<<Block, Thread>>>(...);
```

Architecture d'une carte graphique

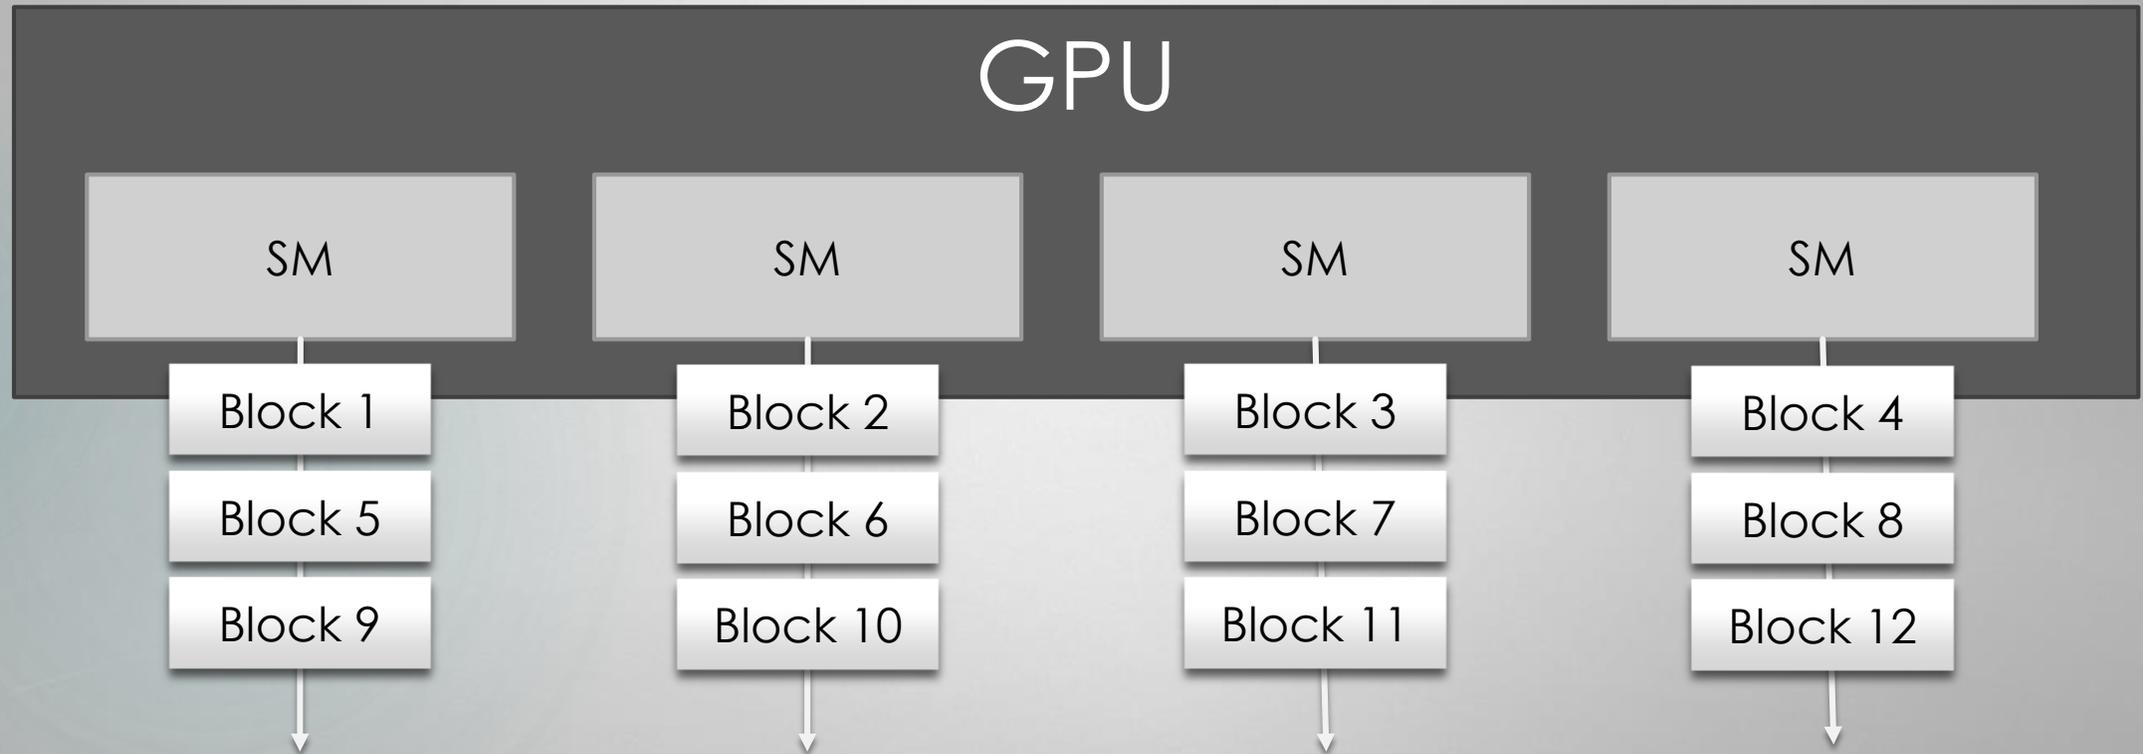


Architecture d'une carte graphique

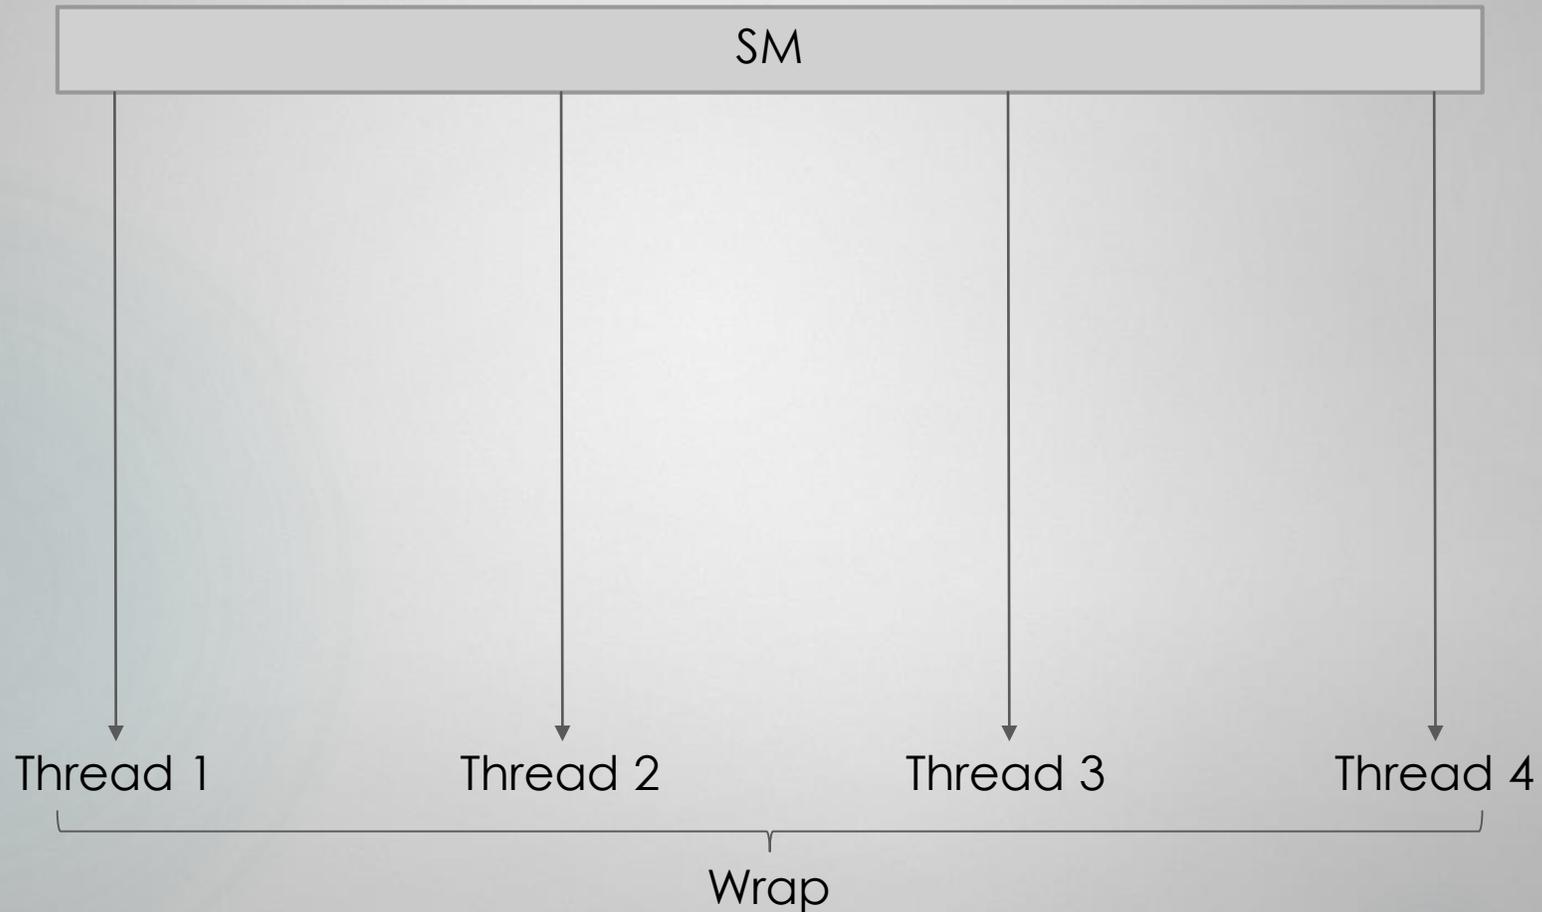


Architecture d'une carte graphique

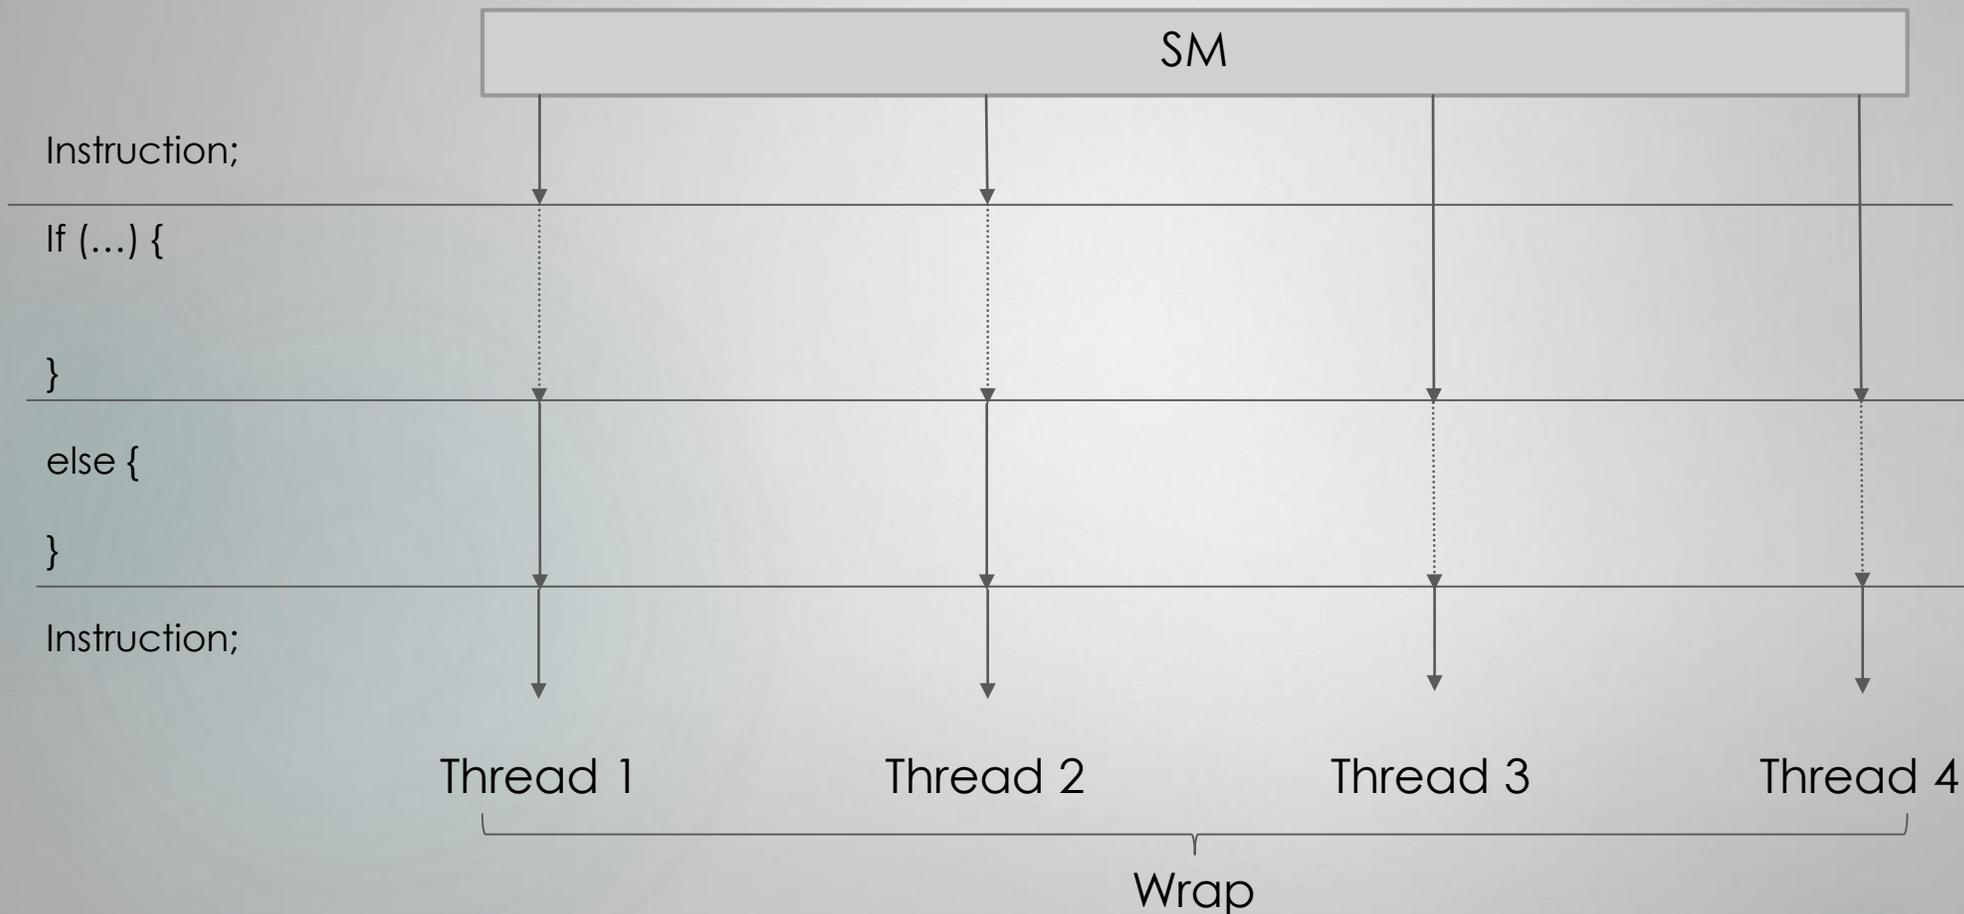
```
MyCudaFunction<<<12, ...>>>(...);
```



Architecture d'une carte graphique



Architecture d'une carte graphique



PTX: Parallel Thread Execution

setp.lt.s32 p | q, a, b

@p bra Else

instructionA

bra End

Else:

instructionB

End:

instructionC

setp.lt.s32 p | q, a, b

@p InstructionA

@q InstructionB

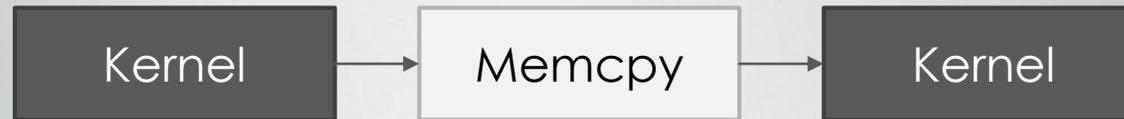
InstructionC

CUDA Stream

```
MyCudaFunction<<<Block, Thread, Stream>>>(...);
```

CUDA Stream

```
MyCudaFunction<<<Block, Thread>>>(...);  
Cumemcpy(...)  
MyCudaFunction<<<Block, Thread>>>(...);
```

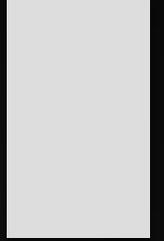


CUDA Stream

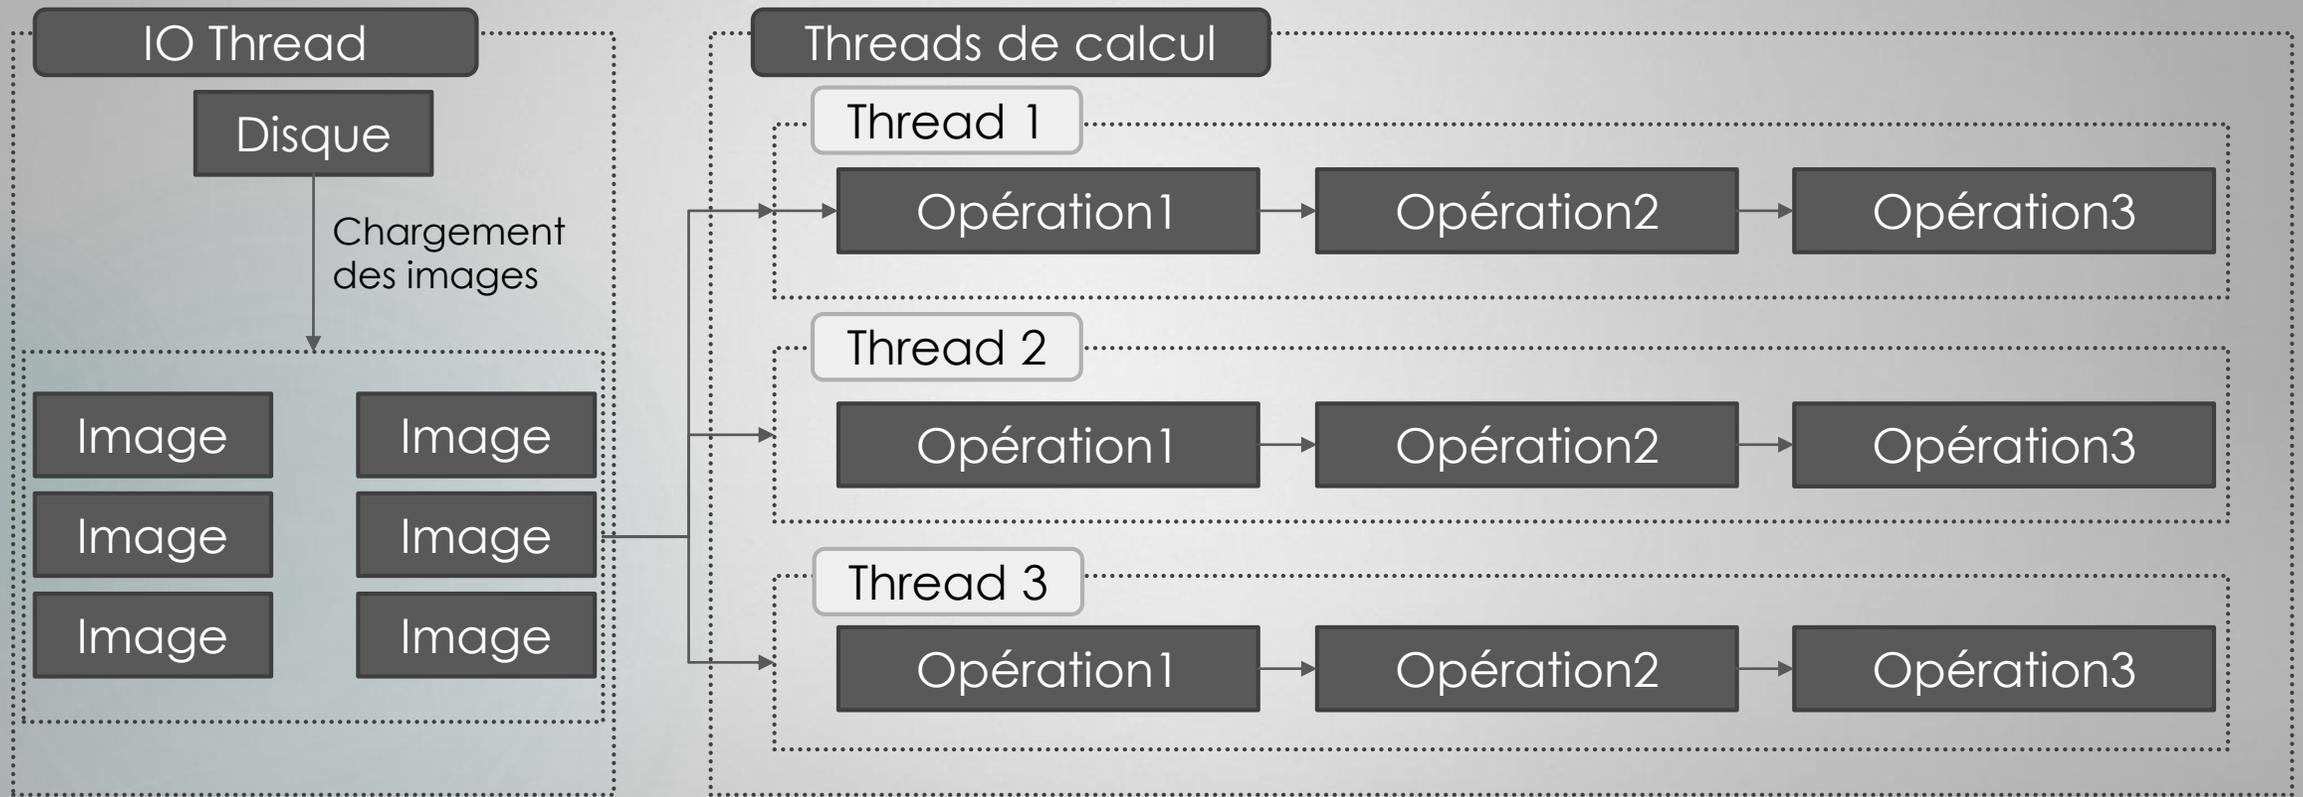
```
MyCudaFunction<<<Block, Thread, Stream1>>>(...);  
Cumemcpy(..., Stream2)  
MyCudaFunction<<<Block, Thread, Stream2>>>(...);
```



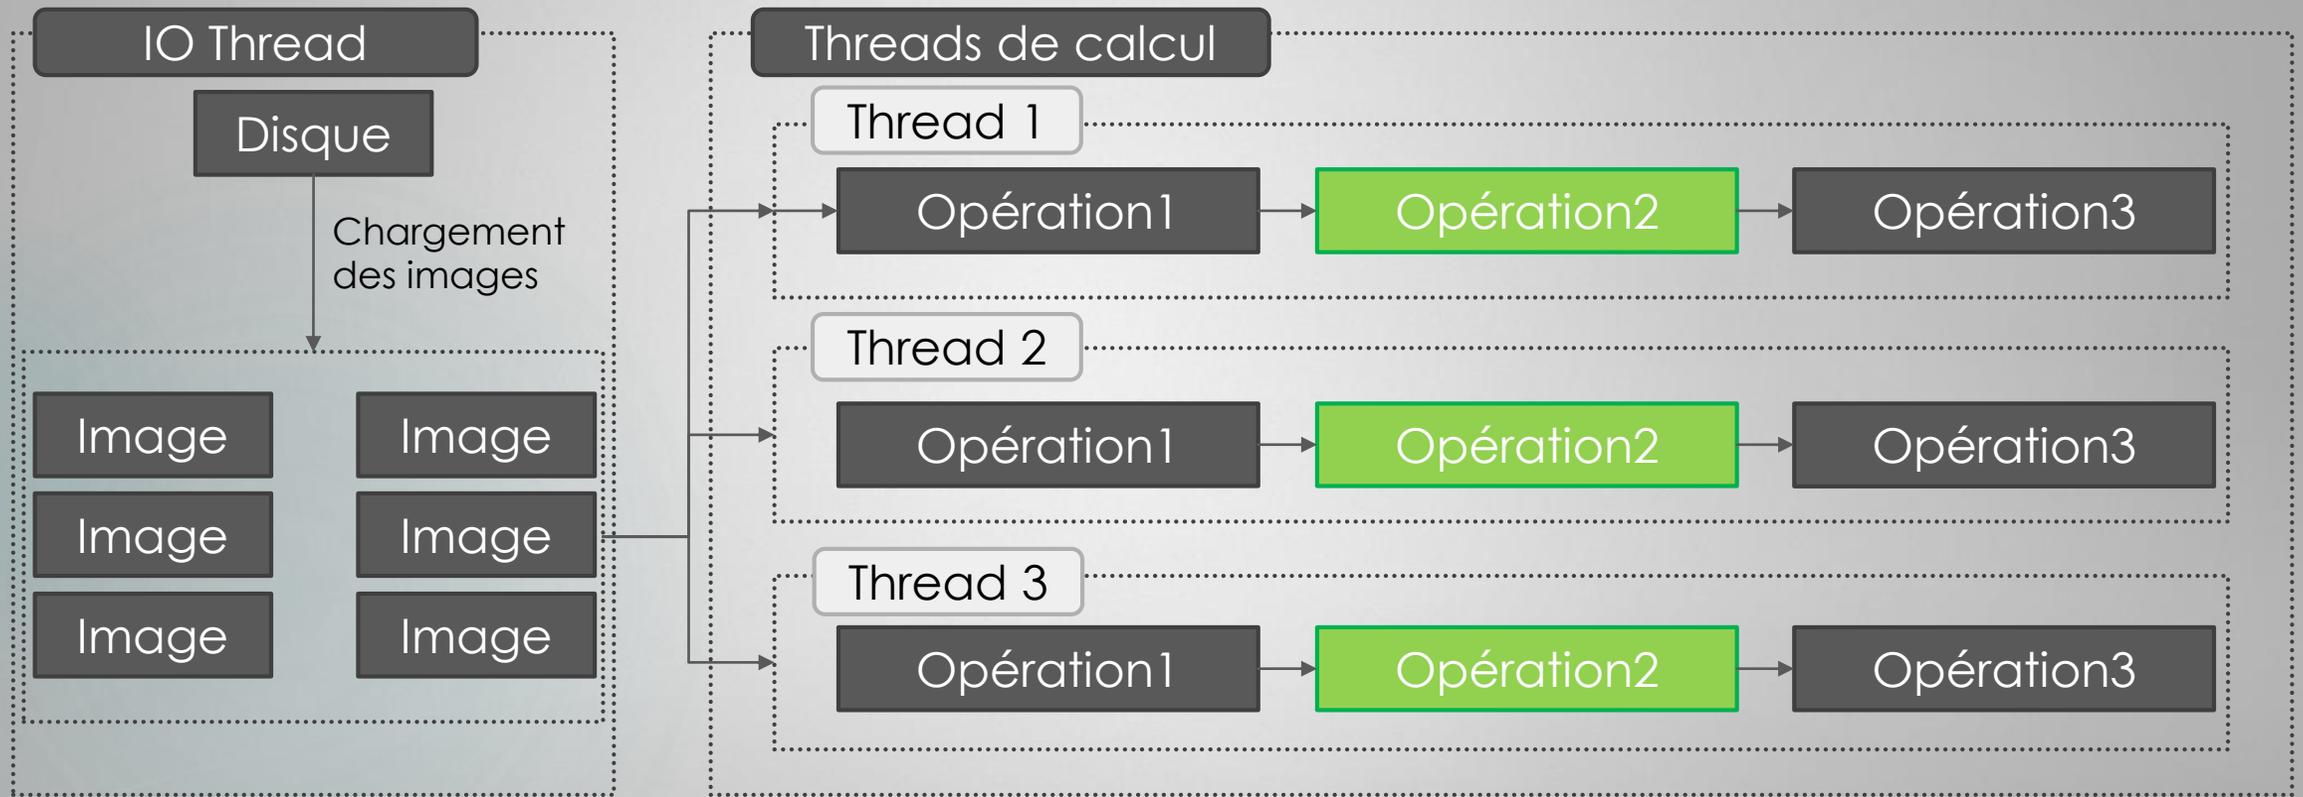
Gérer la mémoire efficacement avec CUDA



Gérer la mémoire efficacement avec CUDA



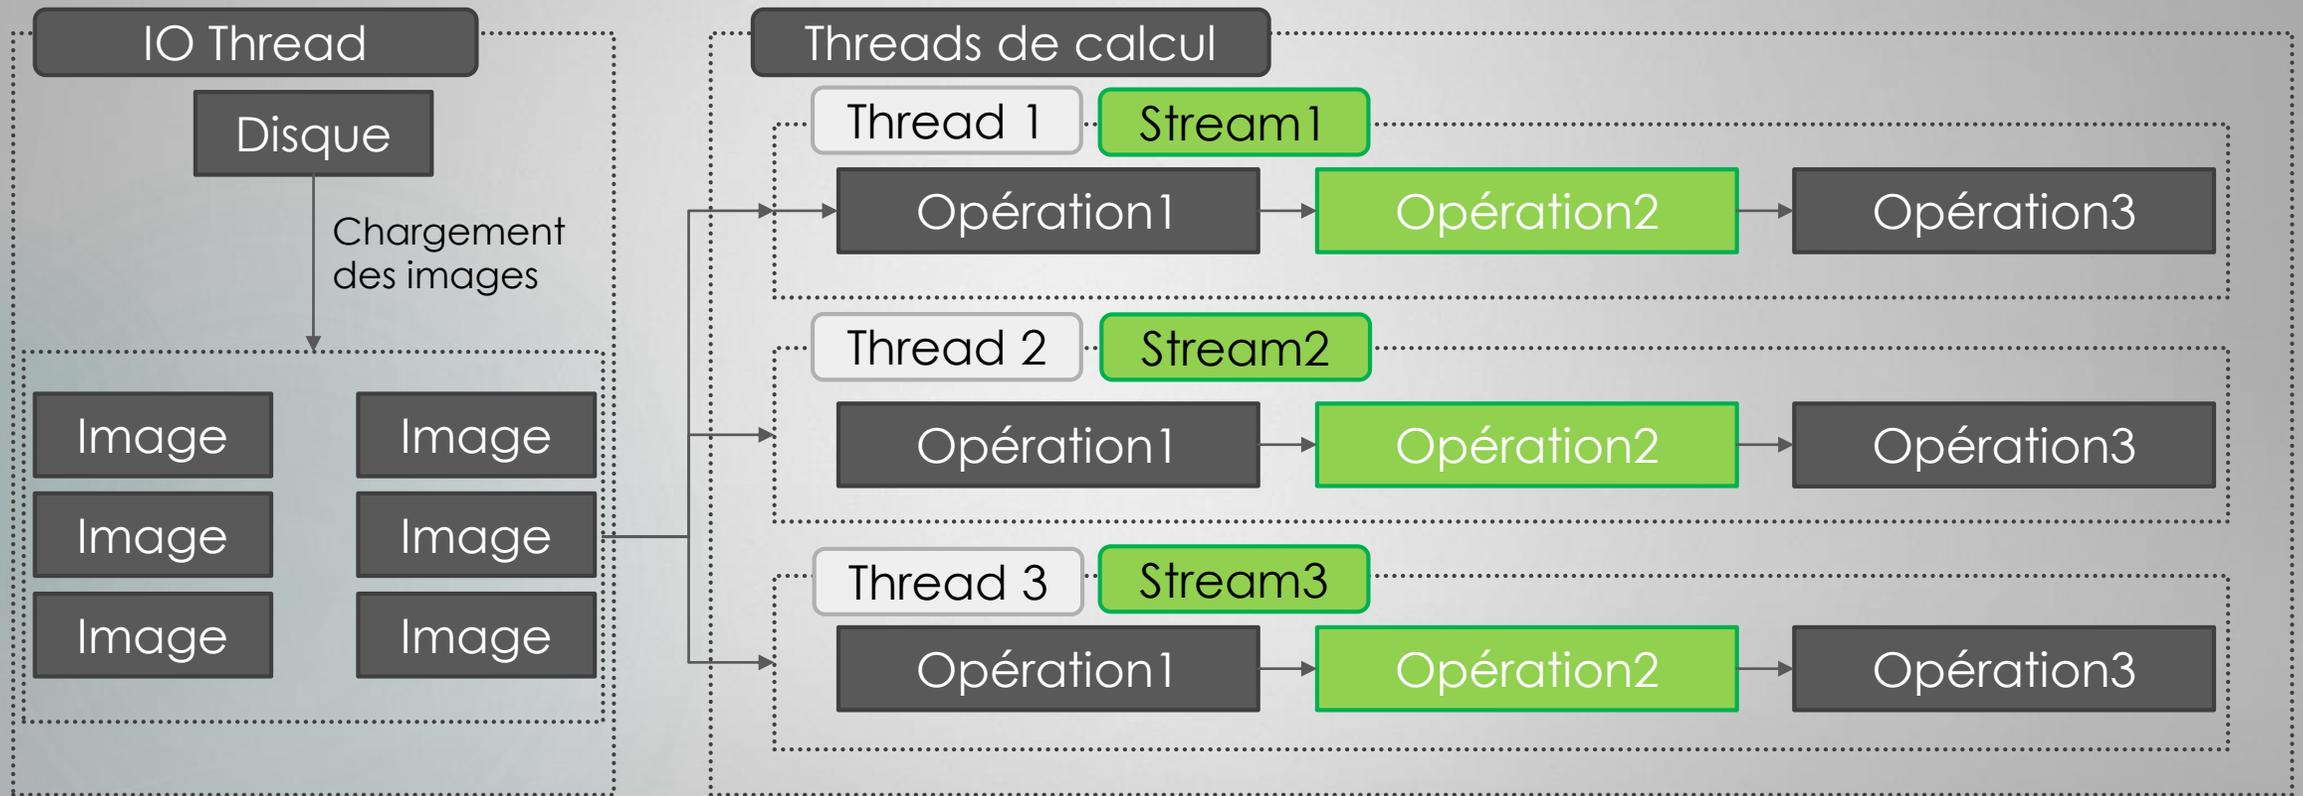
Gérer la mémoire efficacement avec CUDA



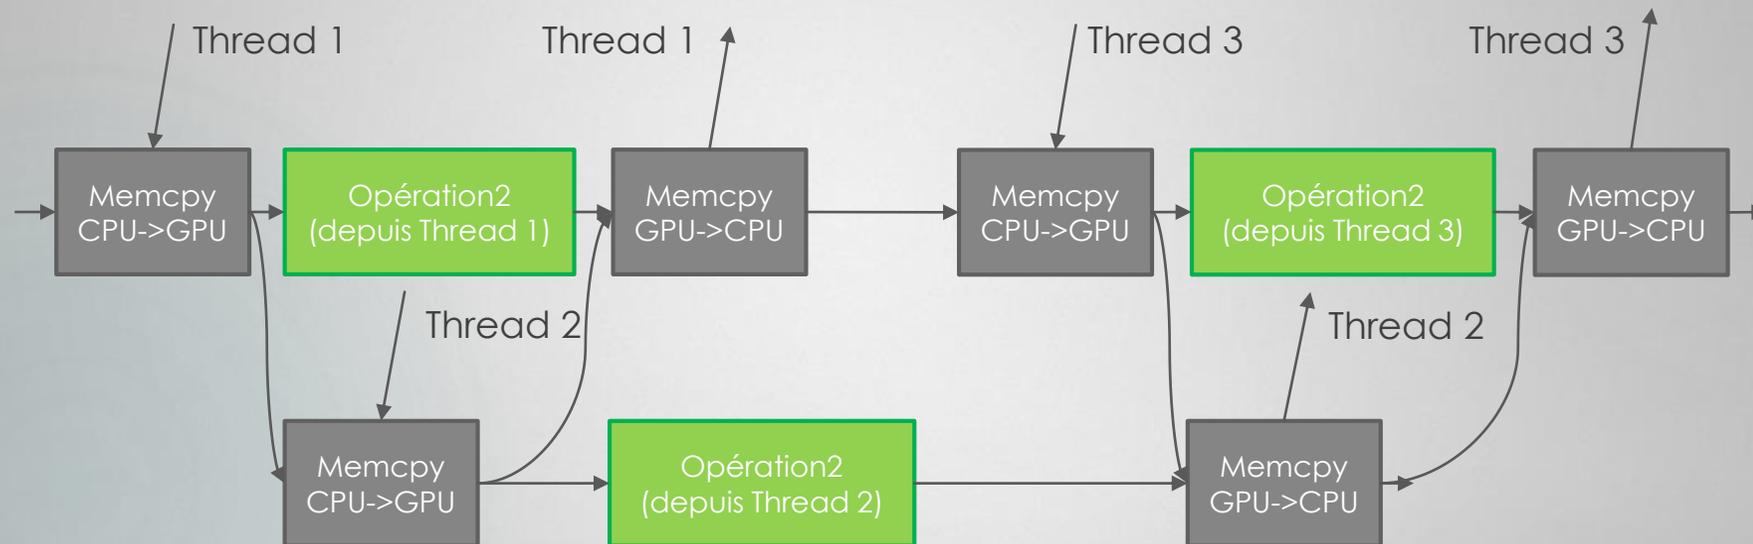
Gérer la mémoire efficacement avec CUDA



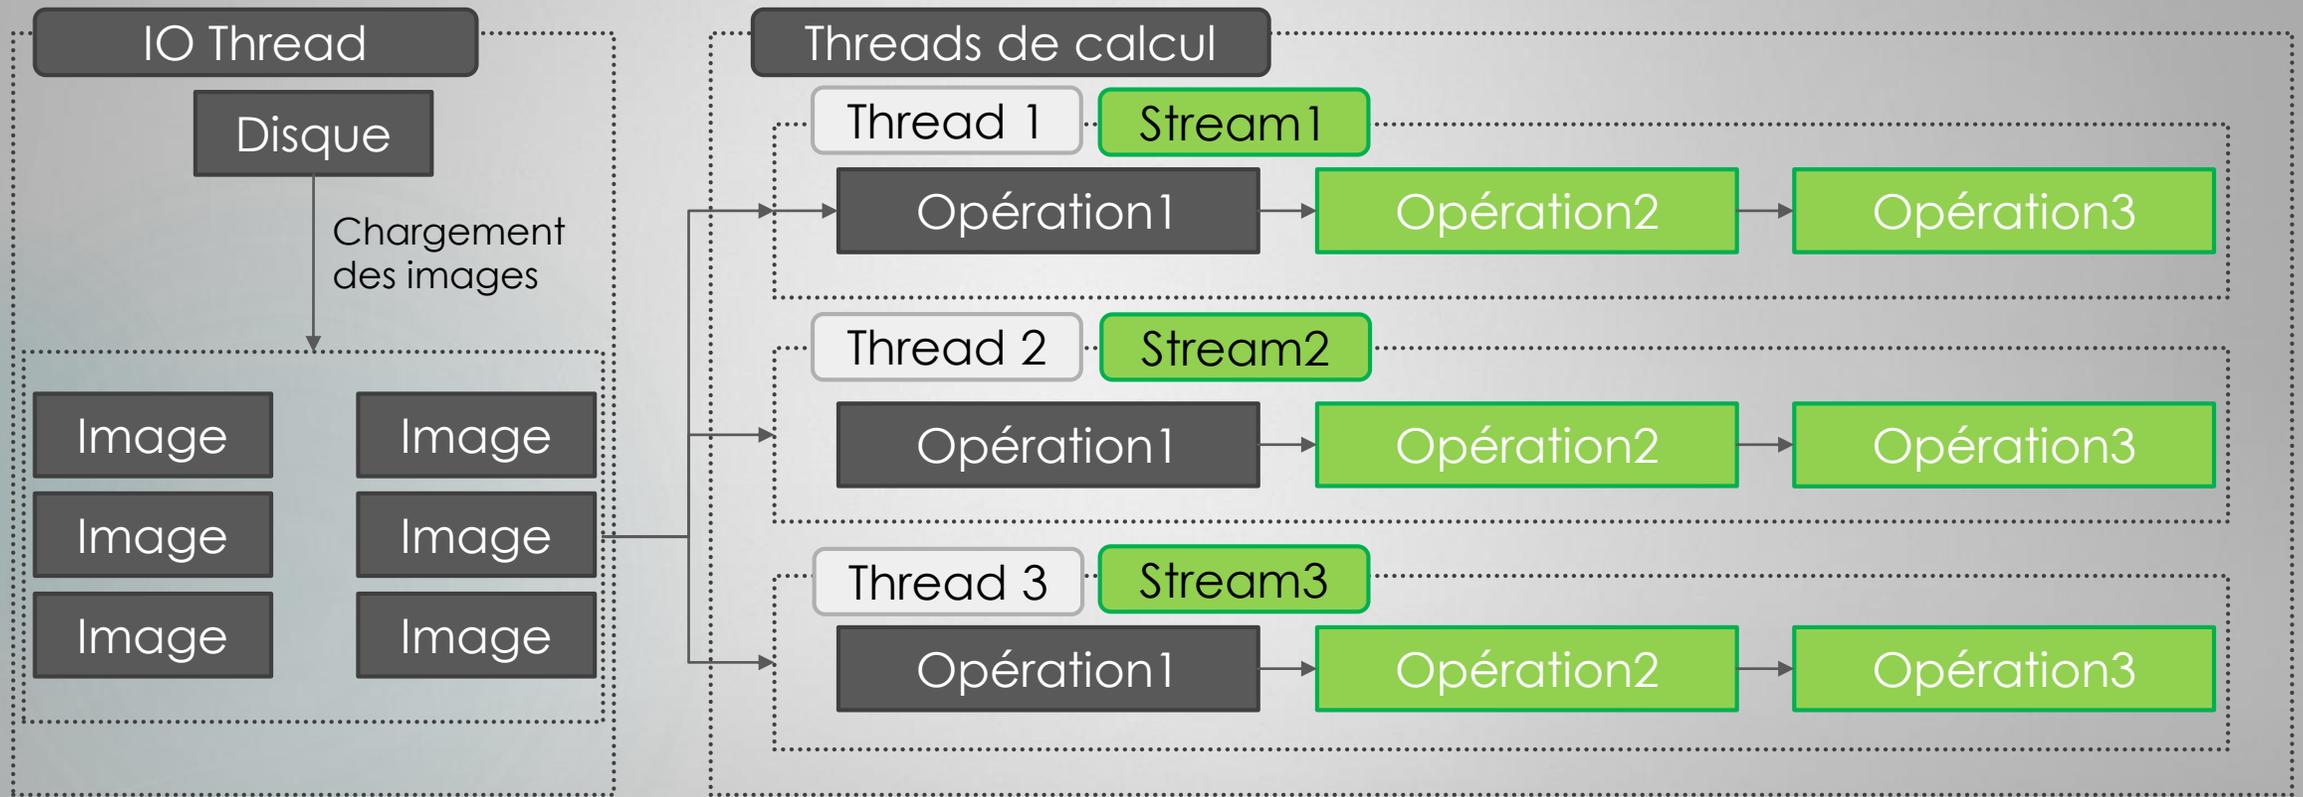
Gérer la mémoire efficacement avec CUDA



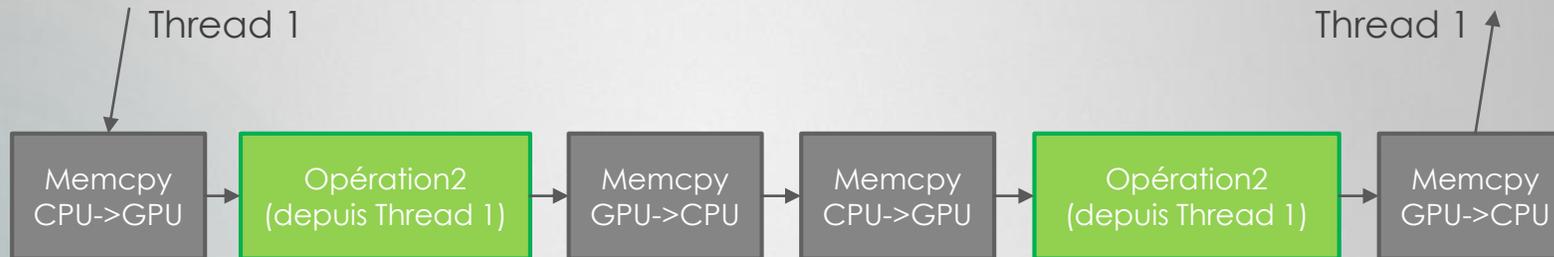
Gérer la mémoire efficacement avec CUDA



Gérer la mémoire efficacement avec CUDA



Gérer la mémoire efficacement avec CUDA



Gérer la mémoire efficacement avec CUDA

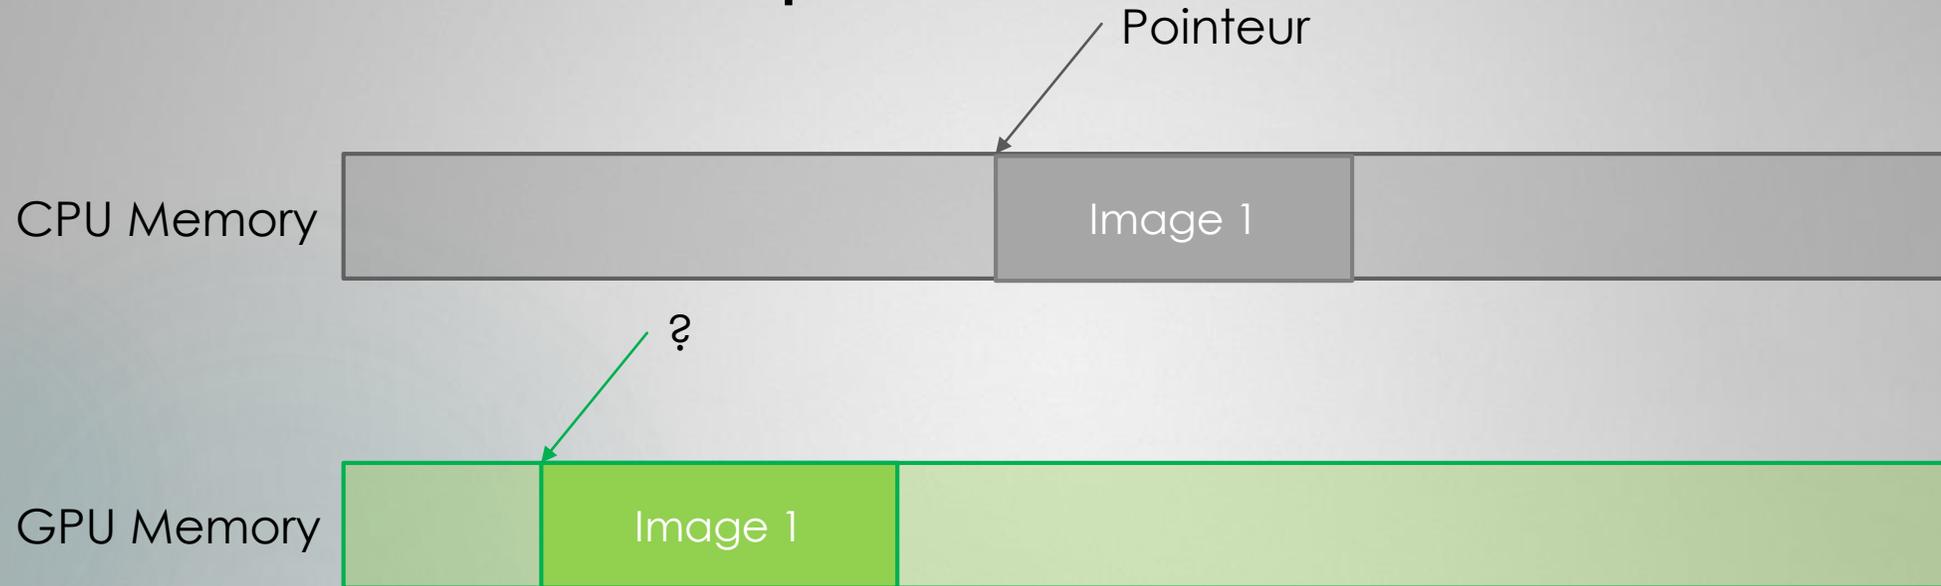


Que faire si les opérations sont dans des bibliothèques ?

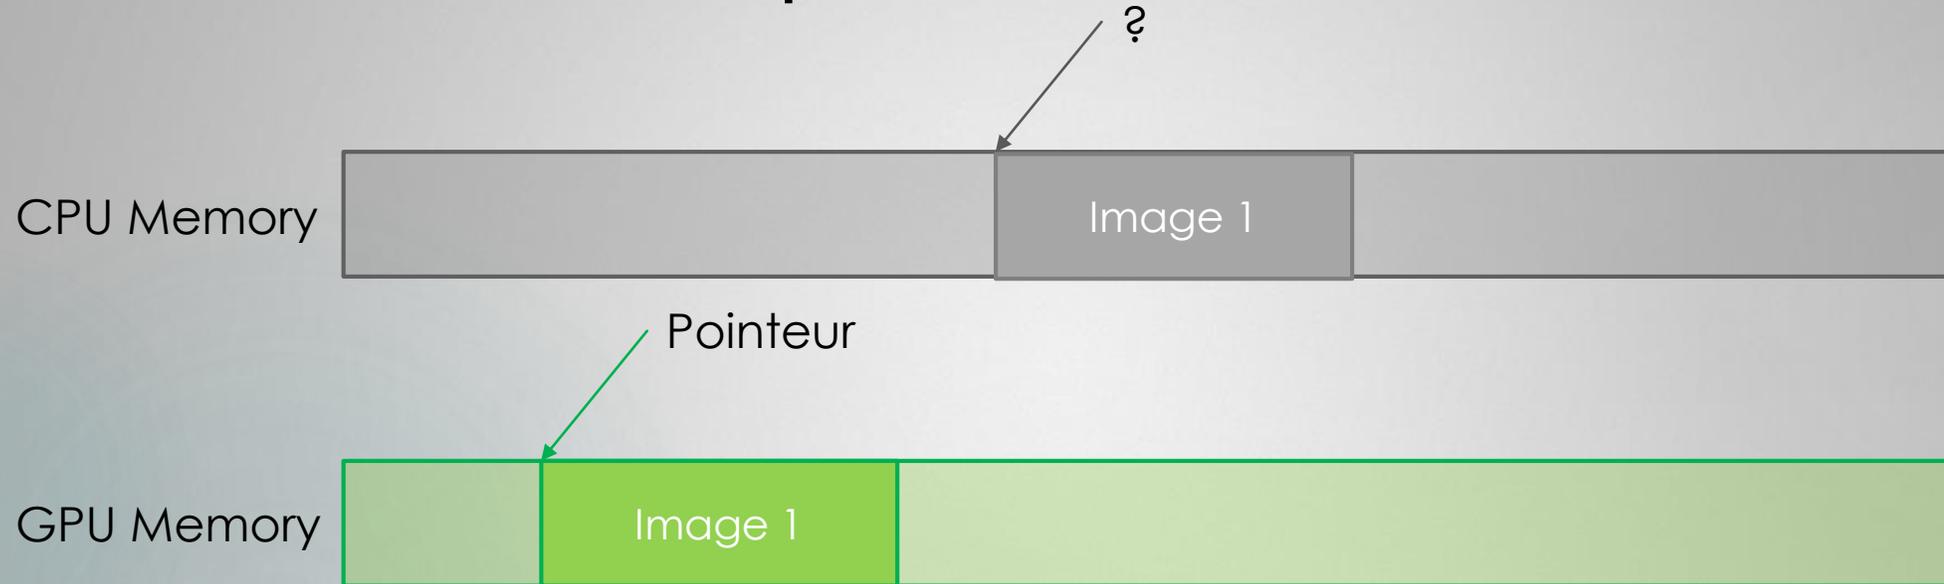
Que faire si les opérations sont dans des bibliothèques ?



Que faire si les opérations sont dans des bibliothèques ?

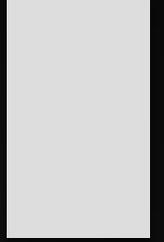


Que faire si les opérations sont dans des bibliothèques ?



Que faire si les opérations sont dans des bibliothèques ?

Qu'est ce que UVA et UVM ?



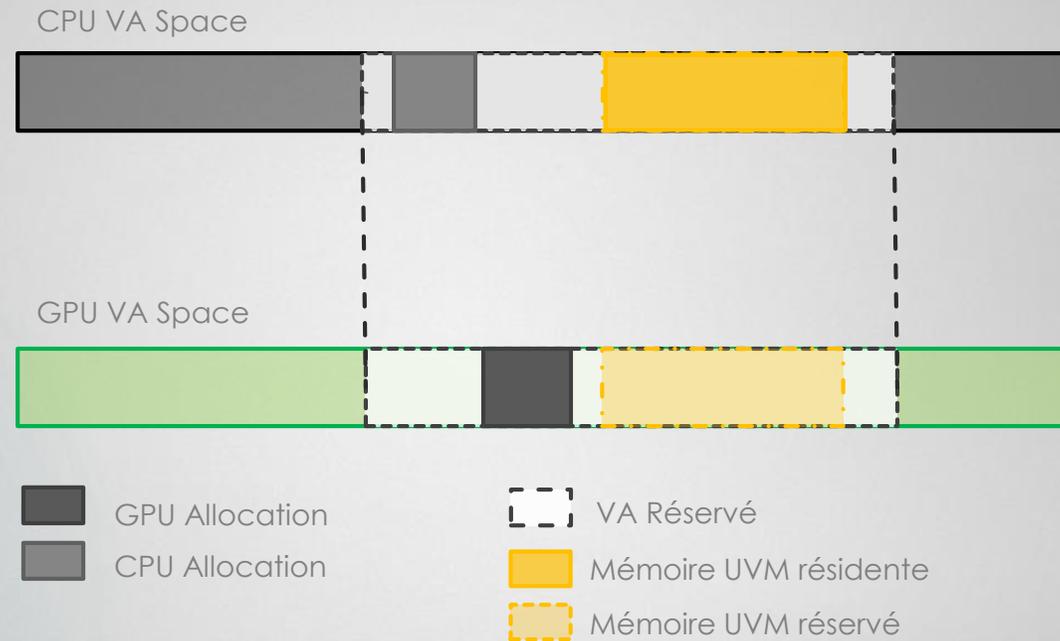
Qu'est ce que UVA?



Description de UVA (Unified Virtual Address)

Qu'est ce que UVA et UVM ?

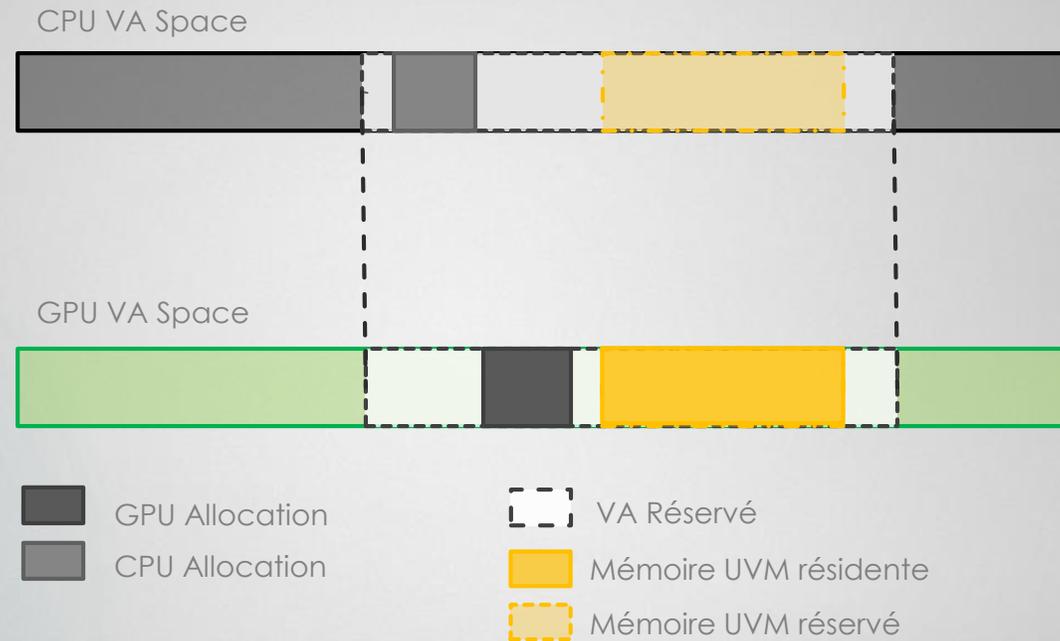
Qu'est ce que UVM?



Description de UVM (Unified Virtual Memory)

Qu'est ce que UVA et UVM ?

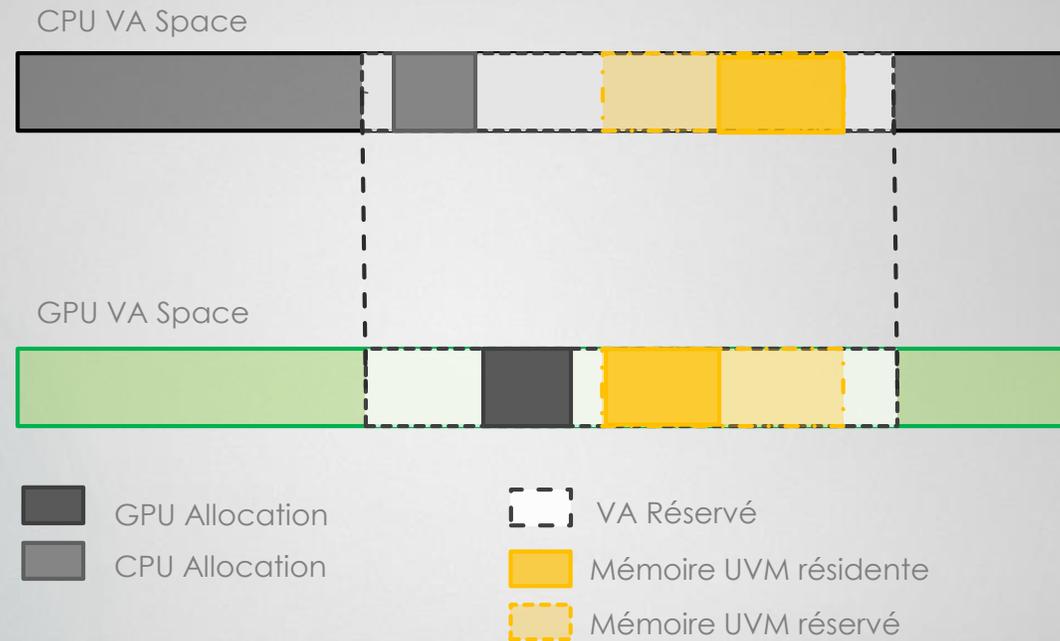
Qu'est ce que UVM?



Description de UVM (Unified Virtual Memory)

Qu'est ce que UVA et UVM ?

Qu'est ce que UVM?



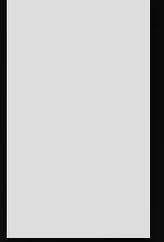
Description de UVM (Unified Virtual Memory)

Qu'est ce que UVA et UVM ?

Qu'est ce que UVA et UVM ?

Qu'est ce que UVA et UVM ?

Utiliser UVM dans une application



Utiliser UVM dans une application

CPU Memory



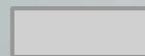
GPU Memory



Allocation d'un bloc de mémoire avec UVM et création d'un stream pour le contenir.



Block mémoire réservé



Block mémoire résident

Utiliser UVM dans une application

CPU Memory



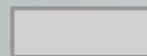
GPU Memory



Chargement de l'image dans le bloc mémoire.



Block mémoire réservé



Block mémoire résident

Utiliser UVM dans une application

CPU Memory



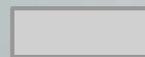
GPU Memory



Binarization d'un bloc de l'image dans UVM



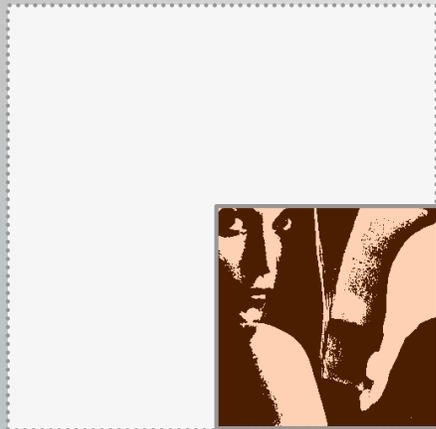
Block mémoire réservé




Block mémoire résident

Utiliser UVM dans une application

CPU Memory



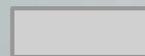
GPU Memory



Migration GPU -> CPU lorsque l'utilisateur accède au données depuis le CPU.



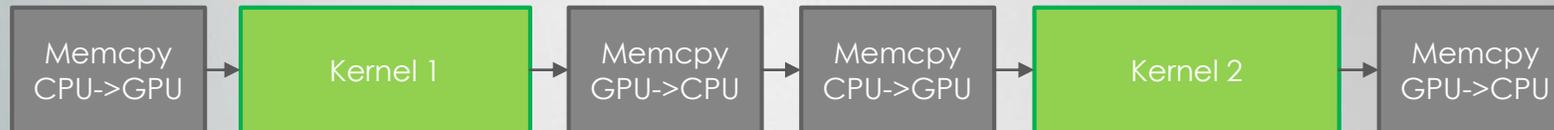
Block mémoire réservé



Block mémoire résident

Avantages

Elimination des memcpy inutile automatique



Utiliser UVM dans une application

Avantages

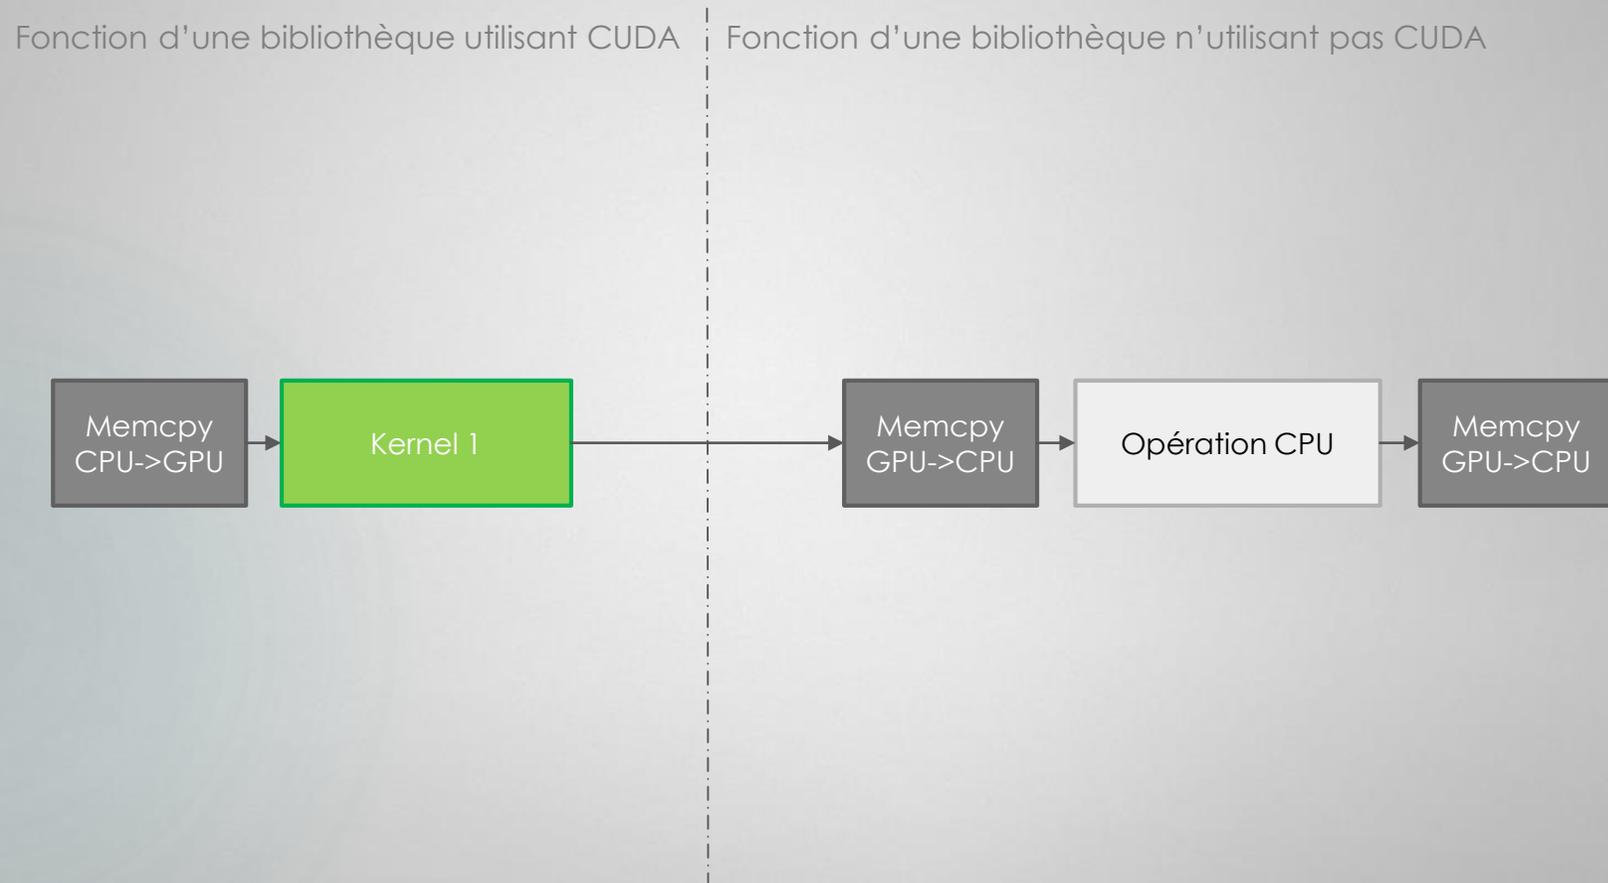
Elimination des memcpy inutile automatique



Utiliser UVM dans une application

Avantages

Cohabitation entre bibliothèques utilisant CUDA et bibliothèques conventionnelles



Utiliser UVM dans une application

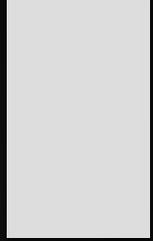
Inconvénients

Plus lent qu'une optimisation manuelle des memcpy

Moins de contrôle sur les déplacement de mémoire

Utilisable sur des cartes Nvidia récentes uniquement

Conclusion



Questions ?

