



## Formations CISM/CÉCI

**Pour une meilleure exploitation des architectures Multi-CPU/Multi-GPU**

**Application au traitement d'objets multimédia**

Sidi Ahmed Mahmoudi

14 Mars 2013

# PLAN

## Introduction

- I.** Présentation des GPU
- II.** Programmation des GPU
- III.** Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU
- IV.** Application au traitement d'objets multimédias
  - 1.** Traitement d'images sur architectures Multi-CPU/Multi-GPU
  - 2.** Traitement Multi-GPU de vidéos HD/Full HD en temps réel
- V.** Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes
- VI.** Résultats Expérimentaux: cas d'utilisations du modèle

## Conclusion

# PLAN

## Introduction

- I. Présentation des GPU
- II. Programmation des GPU
- III. Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU
- IV. Application au traitement d'objets multimédias
  1. Traitement d'images sur architectures Multi-CPU/Multi-GPU
  2. Traitement Multi-GPU de vidéos HD/Full HD en temps réel
- V. Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes
- VI. Résultats Expérimentaux: cas d'utilisations du modèle

## Conclusion

# Introduction

## Loi de Moore : 1968

Le nombre de transistors composant un circuit électronique à prix constant double tous les 2 ans



Loi bien vérifiée : puissance des CPU doublée tous les 18 mois



Fréquence des CPU plafonnée à 4 GHz : la loi n'est plus vérifiée

# Introduction

- Multiplication d'unités de calcul : **Multi-CPU, Multi-core, GPU**
- GPU : initialement utilisés pour le rendu 2D/3D et jeux vidéos

CPU Intel Core i7 3770K (2012)



4 cores/8 threads

**320 Euros**

GPU GeForce GTX 580 (2011)



512 CUDA cores

**350 Euros**

Naissance du GPGPU : General Purpose Graphic Processing Unit

# PLAN

Introduction

- I. Présentation des GPU**
- II. Programmation des GPU**
- III. Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU**
- IV. Application au traitement d'objets multimédias**
  - 1. Traitement d'images sur architectures Multi-CPU/Multi-GPU**
  - 2. Traitement Multi-GPU de vidéos HD/Full HD en temps réel**
- V. Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes**
- VI. Résultats Expérimentaux: cas d'utilisations du modèle**

Conclusion

# Présentation des GPU

- Unités de calcul graphiques



**NVIDIA**



**ATI**



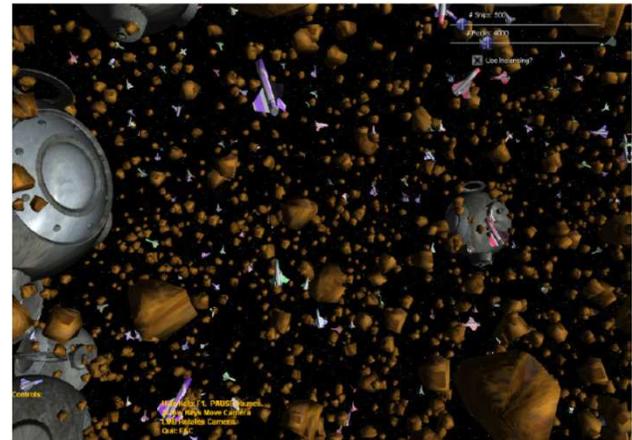
- Placés dans des cartes graphiques



**GeForce GTX 580**



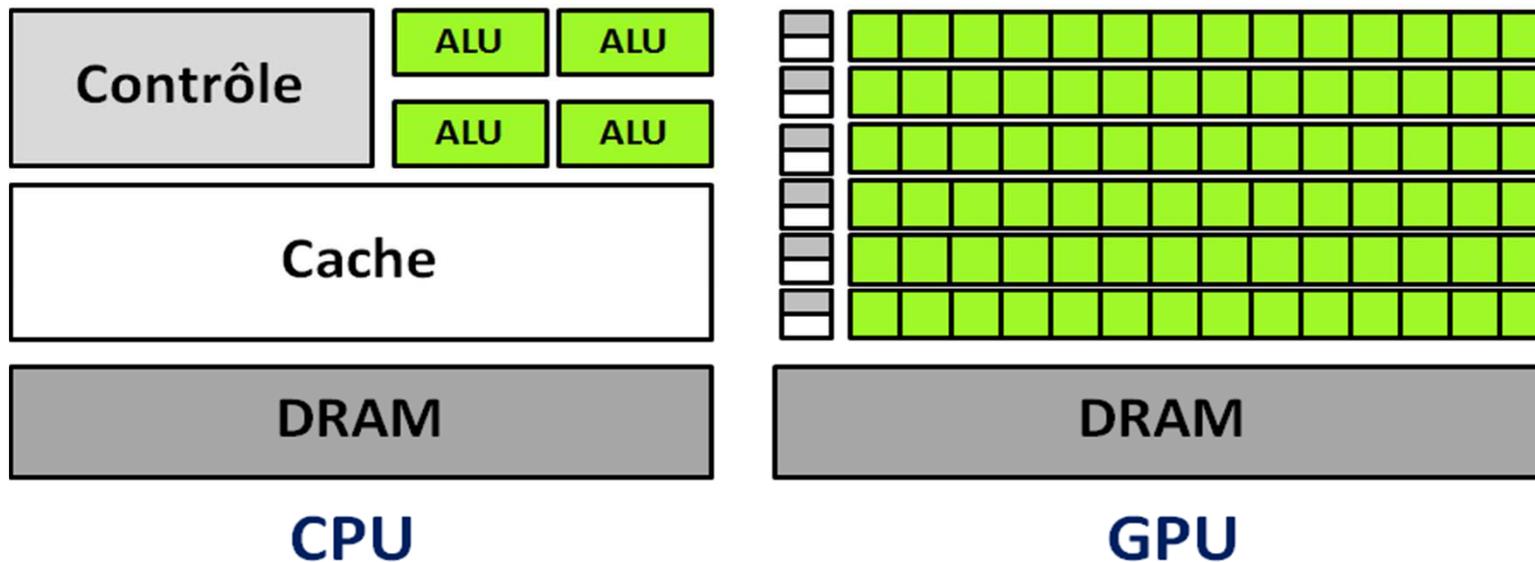
**Radeon HD4870**



- Initialement utilisés pour les applications 3D et jeux vidéos

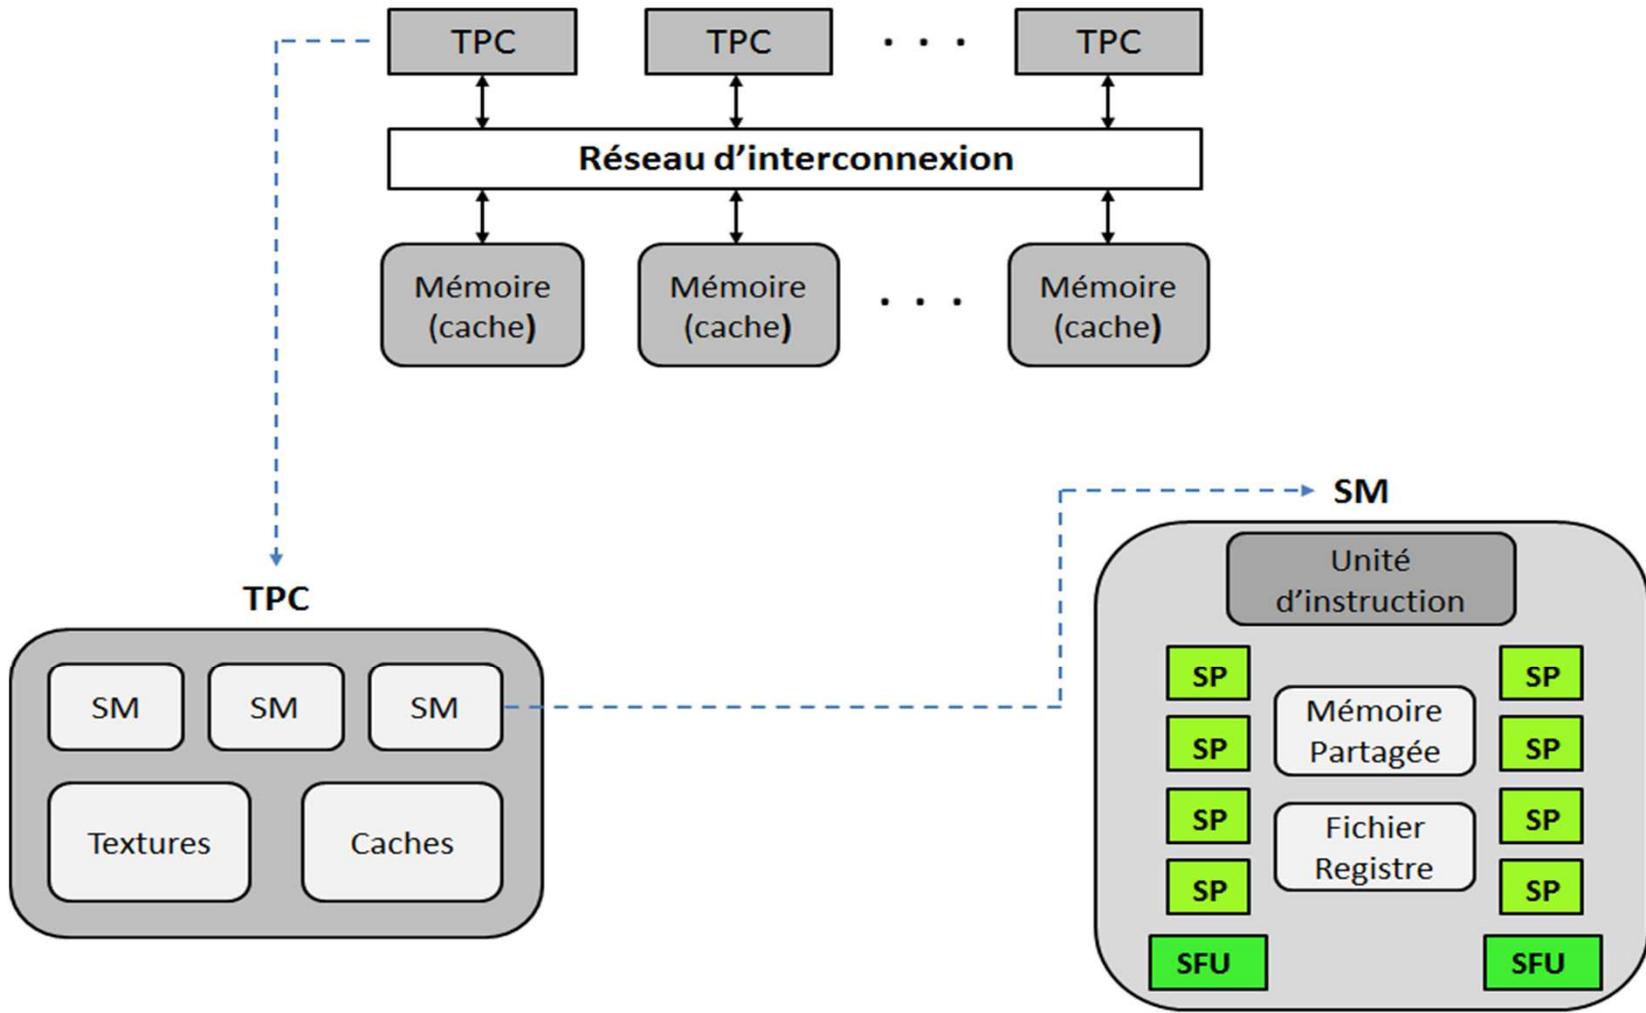
# Présentation des GPU

- GPU spécialisés pour les calculs massivement parallèles
- Plus de transistors dédiés aux unités de traitement
- Peu d'unités de contrôle et de cache

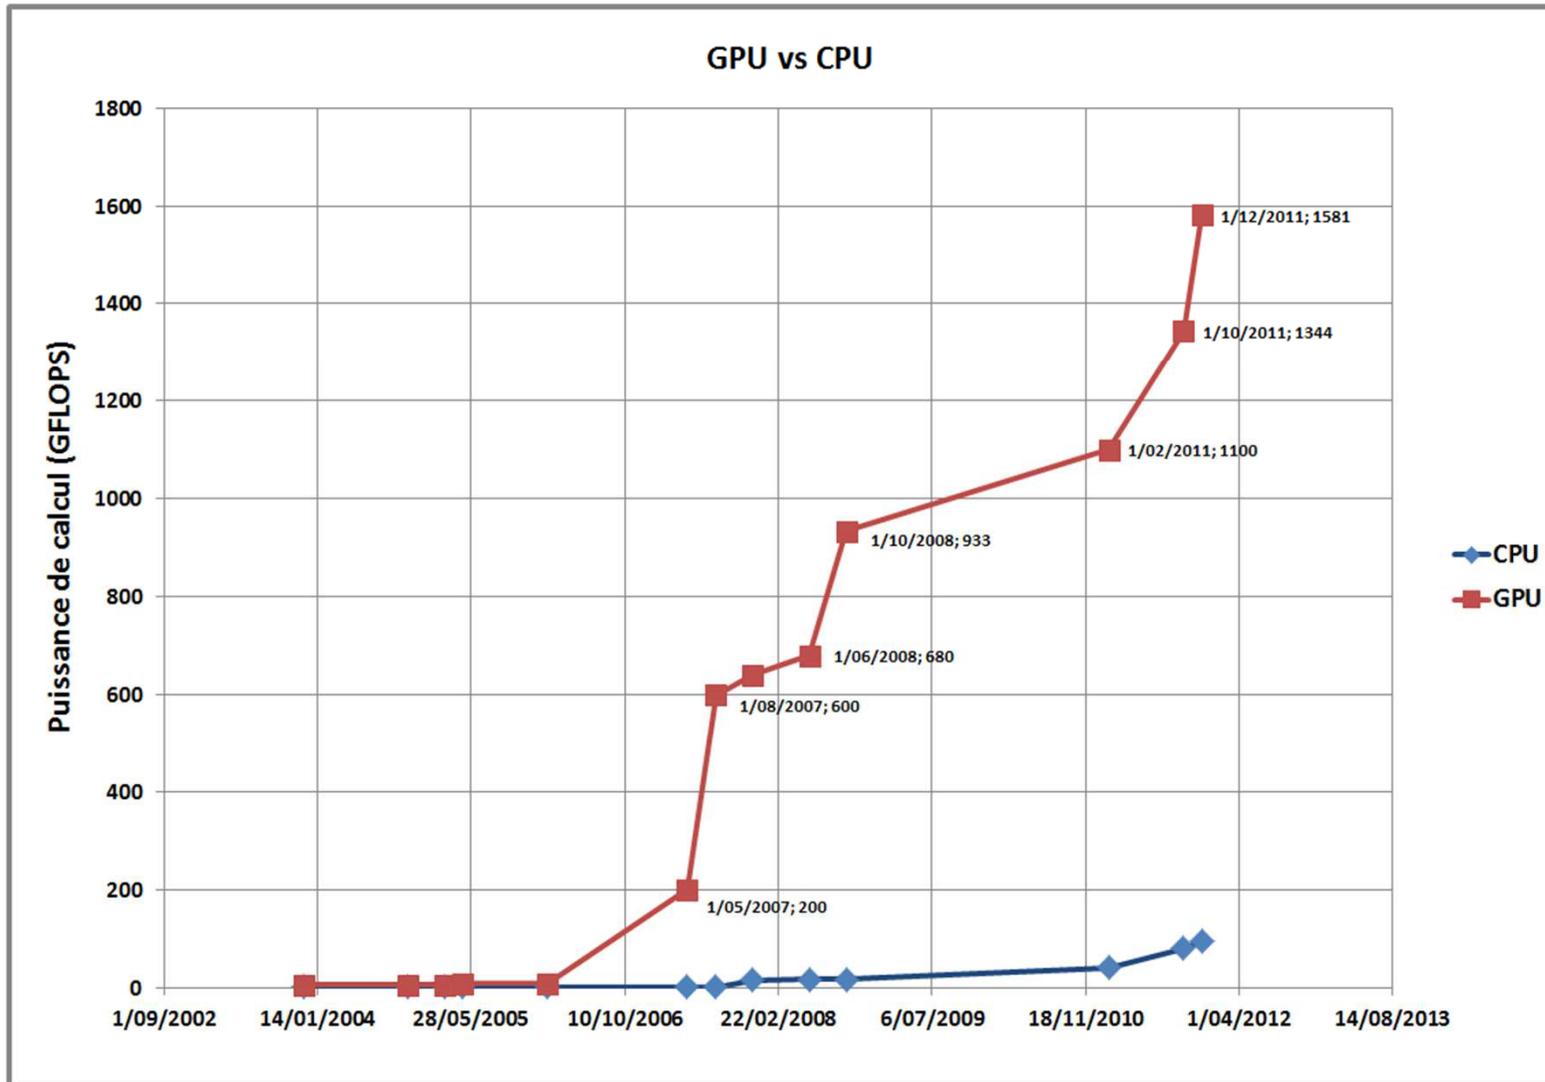


- **GPU:** Multiplication des unités de traitement

# Présentation des GPU

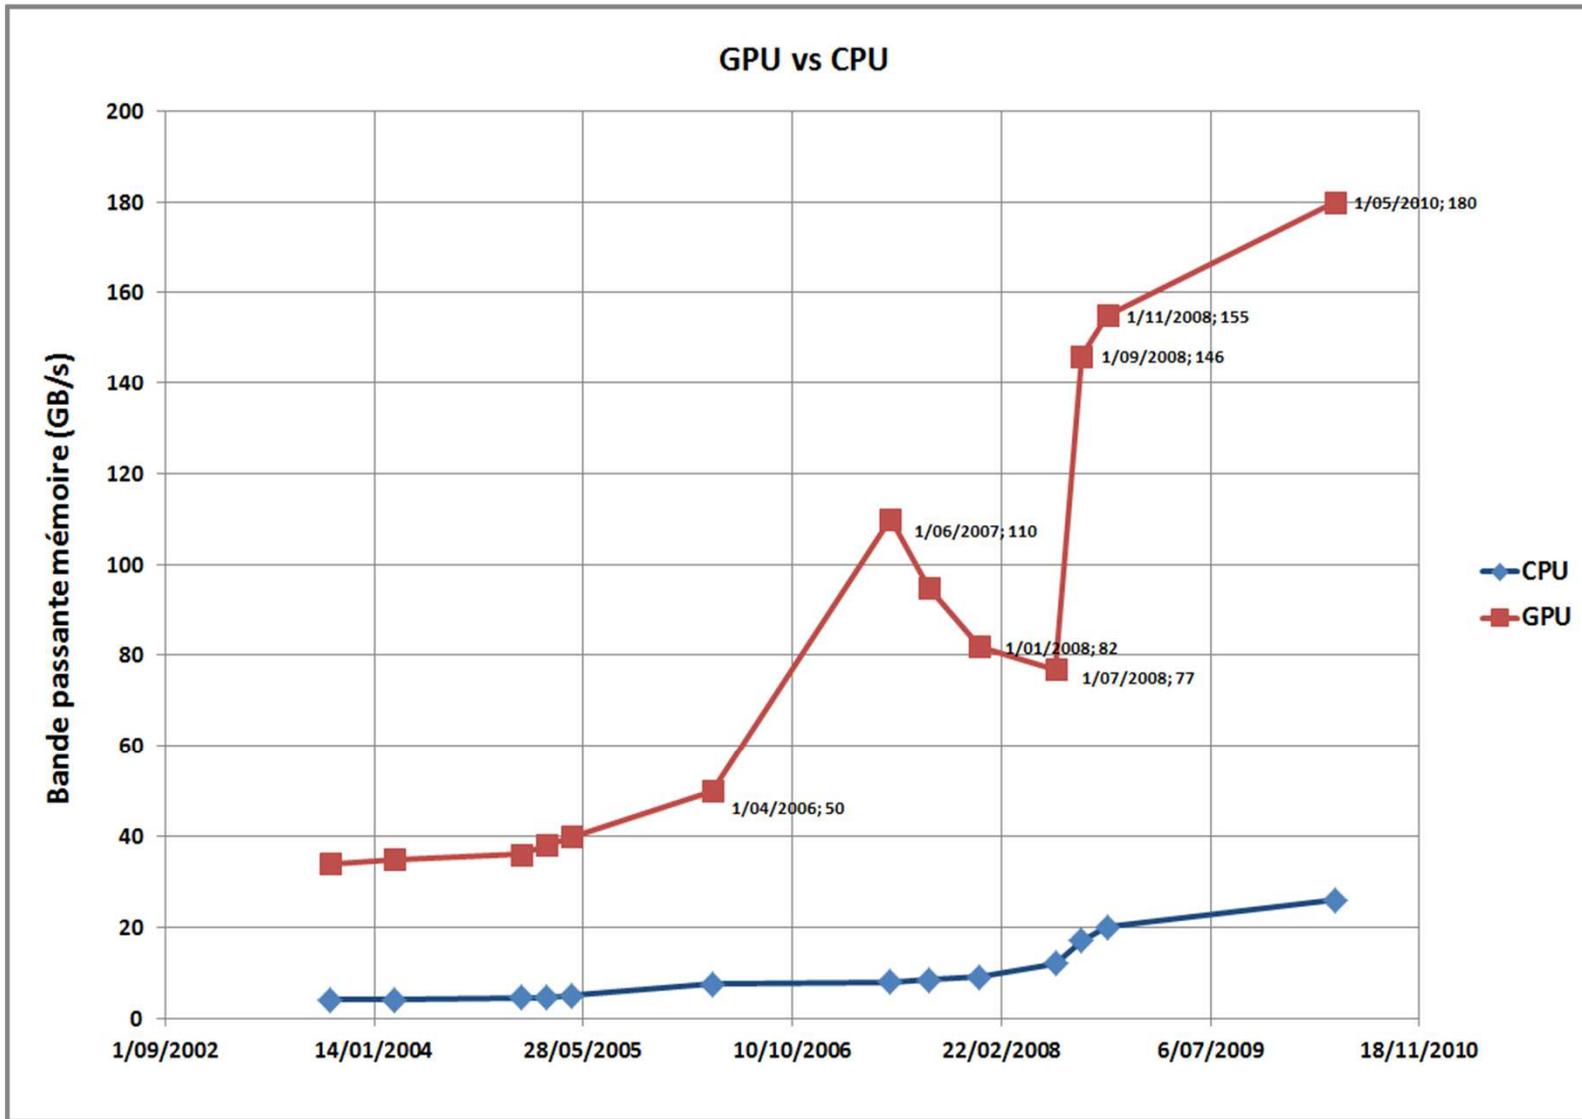


# Présentation des GPU



Evolution de la puissance de pointe des CPU Intel et GPU Nvidia

# Présentation des GPU



Evolution de la bande passante CPU vs. GPU

# PLAN

Introduction

I. Présentation des GPU

**II. Programmation des GPU**

III. Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU

IV. Application au traitement d'objets multimédias

**1.** Traitement d'images sur architectures Multi-CPU/Multi-GPU

**2.** Traitement Multi-GPU de vidéos HD/Full HD en temps réel

V. Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes

VI. Résultats Expérimentaux: cas d'utilisations du modèle

Conclusion

# Programmation des GPUs

- **Brook GPU** : Existe depuis 2004
- **ATI Stream** : Pour les cartes ATI
- **DirectX 11, OpenGL** : Shaders GPGPU
- **OpenCL** : Compatible avec tous types de cartes
- **CUDA** : Pour les cartes NVIDIA



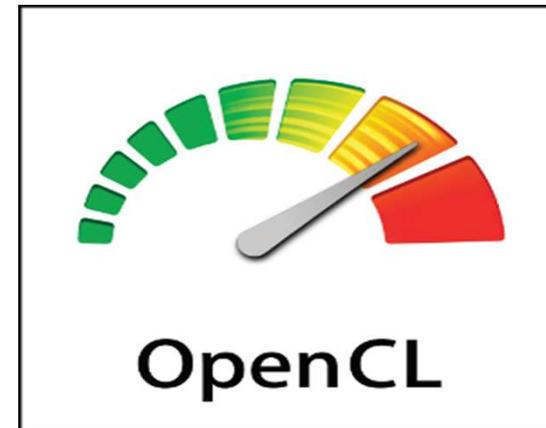
# Ati Stream

- Créé par AMD/ATI en 2008.
- En concurrence avec NVIDIA
- Pour les cartes ATI uniquement
- Distribution des charges entre les cœurs CPU et GPU
- Inclut différentes bibliothèques: FFT, LAPACK, BLAS



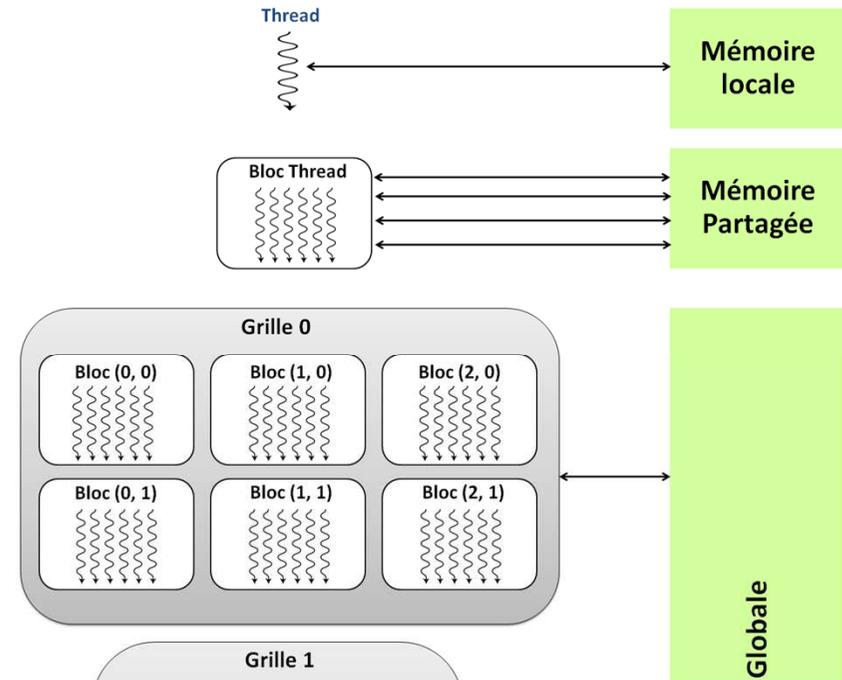
# OpenCL

- Lancé par Apple afin d'unifier l'utilisation des multicœurs et de GPU
- Rejoint par AMD/ATI et NVIDIA
- Première version en 2009
- Compatible avec les cartes NVIDIA et Ati
- Plus récent que CUDA : moins puissant !!
- Nouveau types de données (vecteur, image, etc.).



# CUDA

- Compatible avec les GPU NVIDIA.
- Syntaxe proche du C.
- Grille: ensemble de blocs.
- Bloc: ensemble de threads.
- Threads synchronisés à travers la



Type of Memory	Utility	Size	Latency ( horloge cycles)
Global	Principal Memory	1Go	400 to 600
Shared	Cooperation between threads	16 Ko	4
Registers	Local memory to each thread	100 byte per thread	1

# CUDA

- Exemple d'addition de vecteurs :

$$\begin{pmatrix} A[1] \\ A[2] \\ \vdots \\ A[N] \end{pmatrix} + \begin{pmatrix} B[1] \\ B[2] \\ \vdots \\ B[N] \end{pmatrix} = \begin{pmatrix} C[1] \\ C[2] \\ \vdots \\ C[N] \end{pmatrix}$$

```

__global__ void vecAdd(float* A, float* B, float* C)
{
    int i = threadIdx.x;
    C[i] = A[i] + B[i];
}

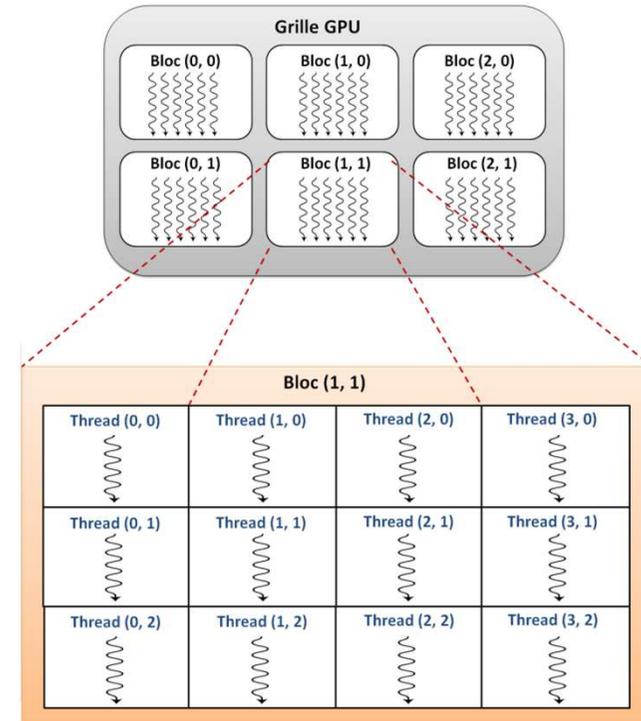
int main()
{
    // Kernel invocation
    vecAdd<<<1, N>>>(A, B, C);
}
    
```

**Kernel**

**Appel du Kernel**

# CUDA

$$\begin{pmatrix} A[1] \\ A[2] \\ \vdots \\ A[N] \end{pmatrix} + \begin{pmatrix} B[1] \\ B[2] \\ \vdots \\ B[N] \end{pmatrix} = \begin{pmatrix} C[1] \\ C[2] \\ \vdots \\ C[N] \end{pmatrix}$$



`vecAdd<<<1, N>>>(A, B, C);`

→ 1 Block de N threads

`vecAdd<<<2, N/2>>>(A, B, C);`

→ 2 Blocks de N/2 threads

`vecAdd<<<100, N/100>>>(A, B, C);`

→ 100 Blocks de N/100 threads

# CUDA

Un programme CUDA consiste en cinq étapes :

1. Allocation de mémoire sur GPU
2. Transfert des données depuis la mémoire CPU vers la mémoire GPU
3. Définition du nombre de threads
4. Lancement des fonctions CUDA en parallèle
5. Transfert des résultats depuis la mémoire GPU vers la mémoire CPU

# CUDA

## Exemple d'addition de matrices: allocation de mémoire

- Allocation de mémoire sur GPU
- La mémoire allouée recevra les données depuis la mémoire centrale

```
float *Ad, *Bd, *Cd;
const int size = N*N*sizeof(float);           // Taille de la matrice

cudaMalloc((void **)&A_d, size);           // Allouer la matrice A_d

cudaMalloc((void **)&B_d, size);           // Allouer la matrice B_d

cudaMalloc((void **)&C_d, size);           // Allouer la matrice C_d
```

# CUDA

## Exemple d'addition de matrices: transfert des données (CPU vers GPU)

- Transfert des données depuis la mémoire CPU vers la mémoire GPU
- Données initialisées sur la mémoire centrale
- Préciser le type de transfert : **HostToDevice**

```
cudaMemcpy(A_d, A, size, cudaMemcpyHostToDevice);  
cudaMemcpy(B_d, B, size, cudaMemcpyHostToDevice);  
  
// A and B représentent les matrices provenant de la mémoire CPU
```

# CUDA

## Exemple d'addition de matrices : définir le nombre de threads

- Définir le nombre de threads sur GPU:
  - Définir la taille de la grille
  - Définir la taille des blocs
- Le nombre de threads dépend de la taille des données à traiter

```
dim3 dimBlock( blocksize, blocksize );           // Taille du bloc
dim3 dimGrid( N/dimBlock.x, N/dimBlock.y);      // Taille de la grille
```

# CUDA

## Exemple d'addition de matrices : lancement des kernels CUDA

- Définir la fonction CUDA (kernel)
- Appeler et exécuter la fonction CUDA
- Spécifier le nombre de threads déjà défini

```
__global__ void add_matrix( float* a, float *b, float *c, int N )
{
    int i = blockIdx.x * blockDim.x + threadIdx.x;
    int j = blockIdx.y * blockDim.y + threadIdx.y;
    int index = i + j*N;
    if ( i < N && j < N )
        c[index] = a[index] + b[index];
}

add_matrix<<<dimGrid, dimBlock>>>( A_d, B_d, C_d, N );
```

# CUDA

## Exemple d'addition de matrices: transfert des résultats (GPU vers CPU)

- Résultats transférés vers la mémoire CPU une fois le traitement fini
- Préciser le type de transfert : **DeviceToHost**
- Libérer les espaces alloués sur la mémoire GPU

```
cudaMemcpy( C, C_d, size, cudaMemcpyDeviceToHost );  
  
cudaFree( A_d );  
  
cudaFree( B_d );  
  
cudaFree( C_d );  
  
// Les résultats seront sauvegardés sur la mémoire CPU « C ».
```

# PLAN

## Introduction

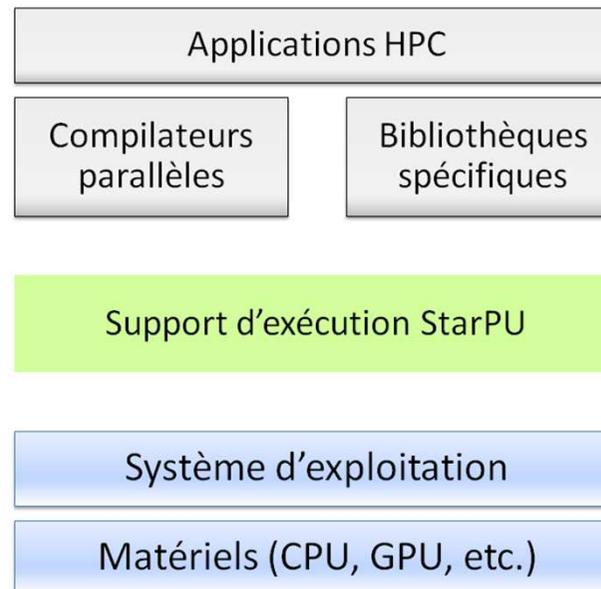
- I. Présentation des GPU
- II. Programmation des GPU
- III. Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU**
- IV. Application au traitement d'objets multimédias
  - 1. Traitement d'images sur architectures Multi-CPU/Multi-GPU
  - 2. Traitement Multi-GPU de vidéos HD/Full HD en temps réel
- V. Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes
- VI. Résultats Expérimentaux: cas d'utilisations du modèle

## Conclusion

# Exploitation des architectures hétérogènes

## StarPU

- Développé aux laboratoires LABRI et INRIA Bordeaux SO
- Exploitation simultanée des cœurs CPUs et GPUs multiples
- Fonctions implémentées en C, CUDA ou OpenCL
- Stratégies d'ordonnancement efficaces



### Aperçu de StarPU

# Exploitation des architectures hétérogènes

## StarSS

- Développé à l'université de Catalonia (Barcelone)
- Modèle de programmation flexible pour les multi- cœurs
- Basé essentiellement sur:
  - CellSS: programmation des processeurs Cell
  - SPMs: programmation des processeurs SPMs
  - ClearSpeedS: programmation des processeurs ClearSpeed
  - GPUSS: programmation Multi-GPU
  - ClusterSs: programmation des clusters
  - GridSs: programmes des ressources d'une grille

# Exploitation des architectures hétérogènes

## OpenACC

- API de haut niveau
- Supporté par CAPS entreprise, CRAY Inc, The Portland Group Inc (PGI) et nvidia
- Une collection de directives de compilation: boucle, etc.
- Prise en charge des tâches d'initialisation, lancement et arrêt d'accélérateurs
- Le lancement et l'arrêt d'accélérateurs est assuré par OpenACC
- Permet de fournir l'information aux compilateurs

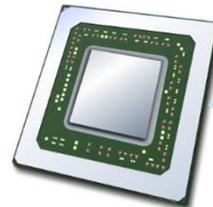
# PLAN

## Introduction

- I. Présentation des GPU
- II. Programmation des GPU
- III. Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU
- IV. Application au traitement d'objets multimédias**
  1. Traitement d'images sur architectures Multi-CPU/Multi-GPU
  2. Traitement Multi-GPU de vidéos HD/Full HD en temps réel
- V. Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes
- VI. Résultats Expérimentaux: cas d'utilisations du modèle

## Conclusion

Traitements intensifs  
Gros volumes  
HD, Full HD, 4K, etc.



**Multi-CPU**

Temps de calcul ?  
Temps réel ?  
Coût ?



Traitement d'images  
Traitement de vidéos  
Imagerie médicale



**Traitement d'objets multimédia**



**GPU ou Multi-GPU**

Accélération  
Calcul parallèle  
Calcul hétérogène  
CPU ou/et GPU ?

# Contexte et objectifs

## Matériel

- Haute puissance de calcul des GPUs
- Architectures hétérogènes (Multi-CPU/Multi-GPU)



GPU



# Contexte et objectifs

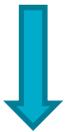
## Matériel

- Haute puissance de calcul des GPUs
- Architectures hétérogènes (Multi-CPU/Multi-GPU)

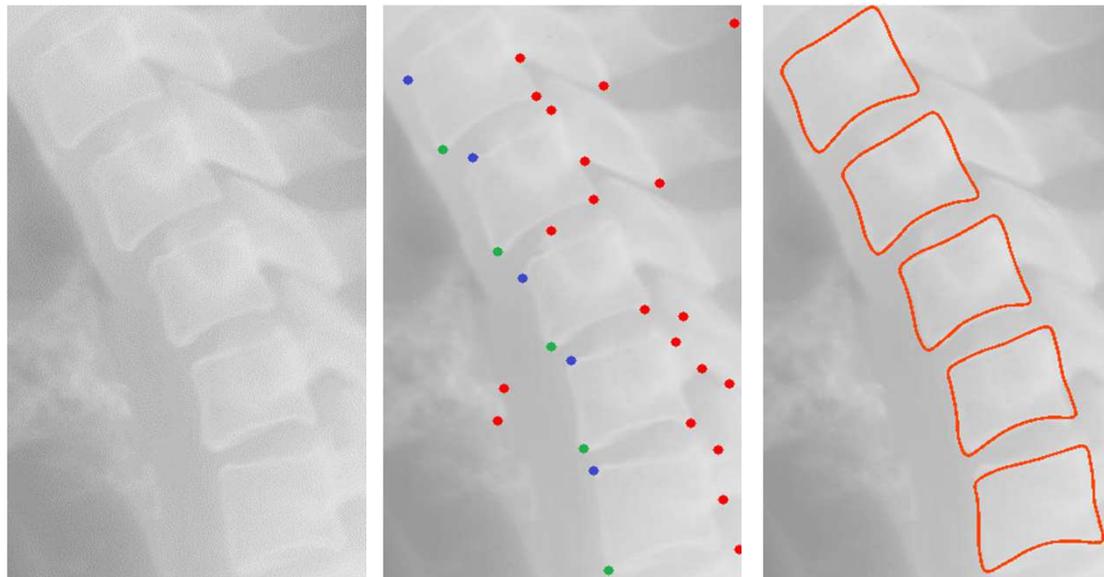
## Applications

- Traitements intensifs d'objets multimédias (images, vidéos, etc.)
- Forte intensité : Volumes importants d'objets multimédias (HD, Full HD)

200 images



Environ 05 minutes



Application médicale [Lecron2011]

# Contexte et objectifs

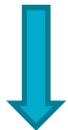
## Matériel

- Haute puissance de calcul des GPUs
- Architectures hétérogènes (Multi-CPU/Multi-GPU)

## Applications

- Traitements intensifs d'objets multimédias (images, vidéos, etc.)
- Forte intensité : Volumes importants d'objets multimédias (HD, Full HD)

2000 images



Environ 10 minutes



Indexation d'images :MediaCycle [Siebert2009]

# Contexte et objectifs

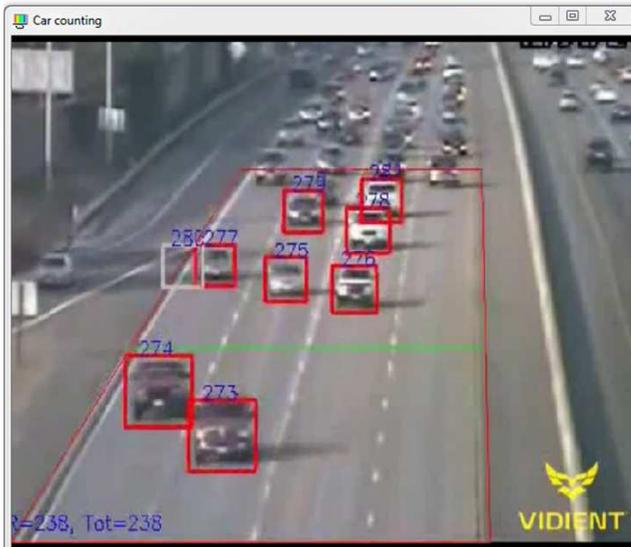
## Matériel

- Haute puissance de calcul des GPUs
- Architectures hétérogènes (Multi-CPU/Multi-GPU)

## Applications

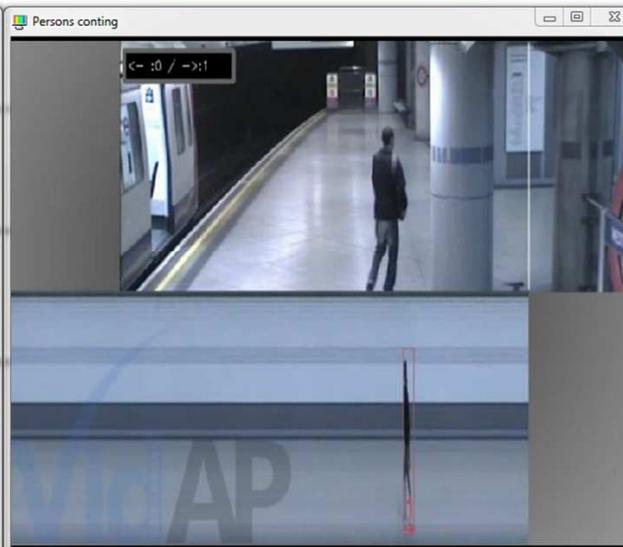
- Traitements intensifs d'objets multimédias (images, vidéos, etc.)
- Forte intensité : Volumes importants d'objets multimédias (HD, Full HD)

Car counting



Vidéo : 720x640 → 19 FPS

Persons counting



Vidéo : 640x376 → 20 FPS

High density crowd tracking



Vidéo : 720x640 → 8 FPS

# Contexte et objectifs

## Matériel

- Haute puissance de calcul des GPUs
- Architectures hétérogènes (Multi-CPU/Multi-GPU)

## Applications

- Traitements intensifs d'objets multimédias (images, vidéos, etc.)
- Forte intensité : Volumes importants d'objets multimédias (HD, Full HD)

## Contraintes

- Transferts coûteux entre mémoire CPU et mémoire GPU
- Choix adapté des ressources (CPU ou/et GPU)
- Ordonnancement efficace des tâches au sein des multiples CPU et GPU

## Objectifs

- Gestion efficace des mémoires : réduction maximale des transferts
- Choix des ressources selon la nature des données et de méthodes
- Traitement rapide d'objets multimédias sur plateformes hétérogènes

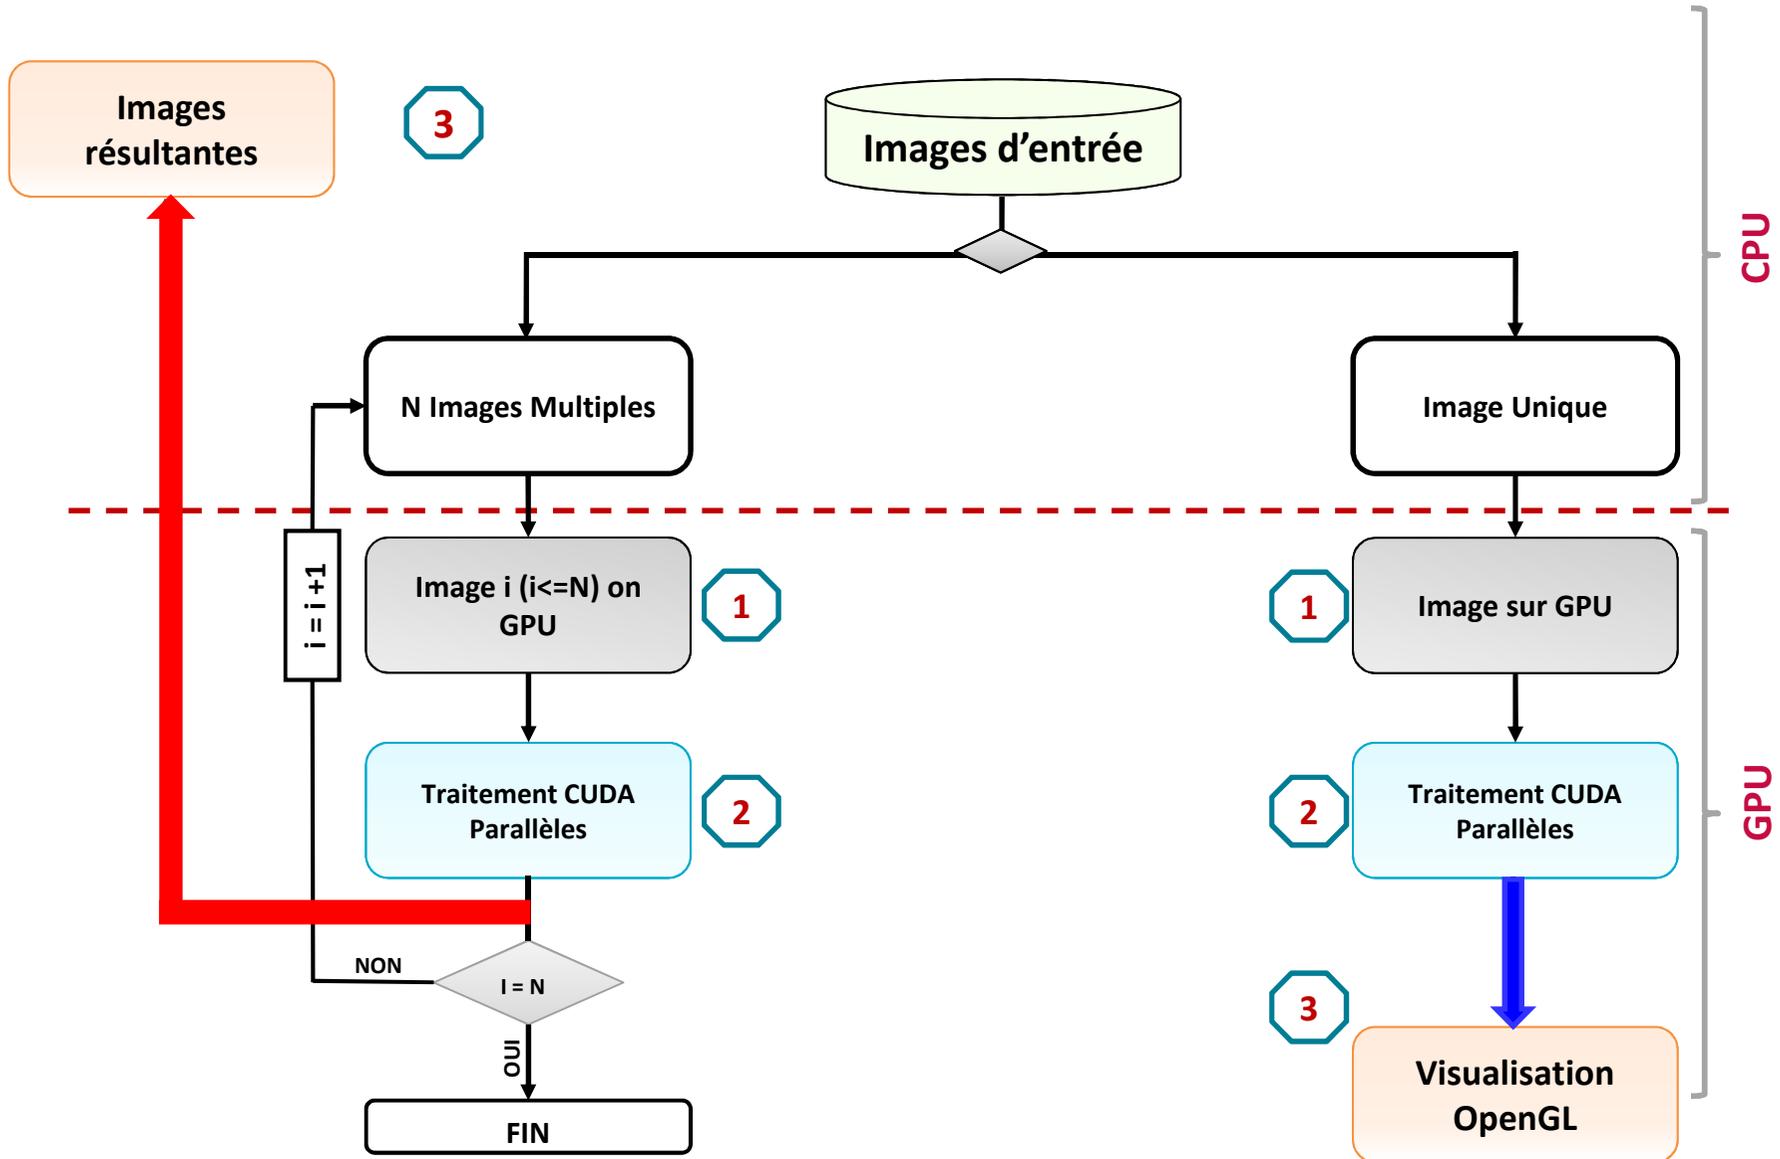
# PLAN

## Introduction

- I.** Présentation des GPU
- II.** Programmation des GPU
- III.** Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU
- IV.** Application au traitement d'objets multimédias
  - 1.** Traitement d'images sur architectures Multi-CPU/Multi-GPU
  - 2.** Traitement Multi-GPU de vidéos HD/Full HD en temps réel
- V.** Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes
- VI.** Résultats Expérimentaux: cas d'utilisations du modèle

## Conclusion

# Schéma de développement proposé



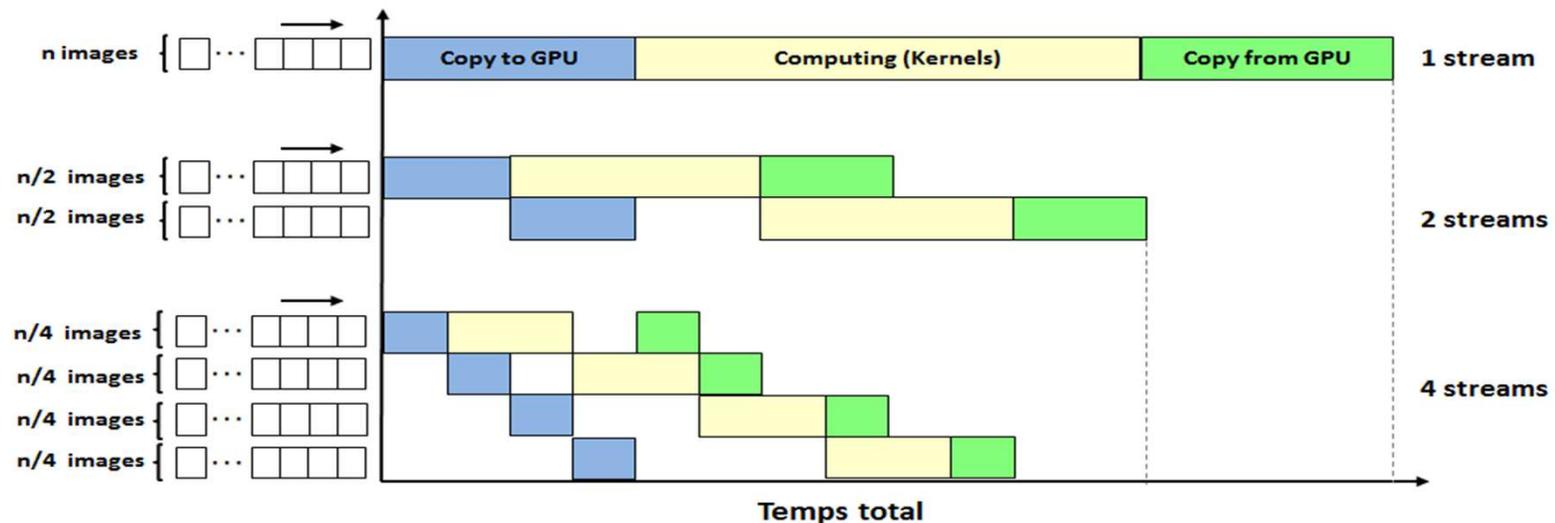
# Optimisations GPU employées

## Traitement d'image individuelle

- Mémoire texture : accès plus rapide au pixels
- Mémoire partagée : accès rapide au voisinage

## Traitement d'images multiples

- Mémoires texture et partagée
- Recouvrement des transferts par les exécutions sur GPU : CUDA streams



# Algorithmes implémentés sur GPU

## Méthodes classiques de traitement d'images :

- Transformations géométriques :
  - rotation, translation, homographie
- Traitement parallèle entre pixels de l'image
- Accélération GPU: de **10x** à **100x**



Homographie sur GPU

## Extraction de points d'intérêts sur GPU:

- Etape préliminaire à de nombreux processus de vision par ordinateur
- Implémentation GPU basée sur le principe de Harris
- Efficacité: invariance à la rotation, à la luminosité, à l'échelle, etc.



Détection des coins sur GPU

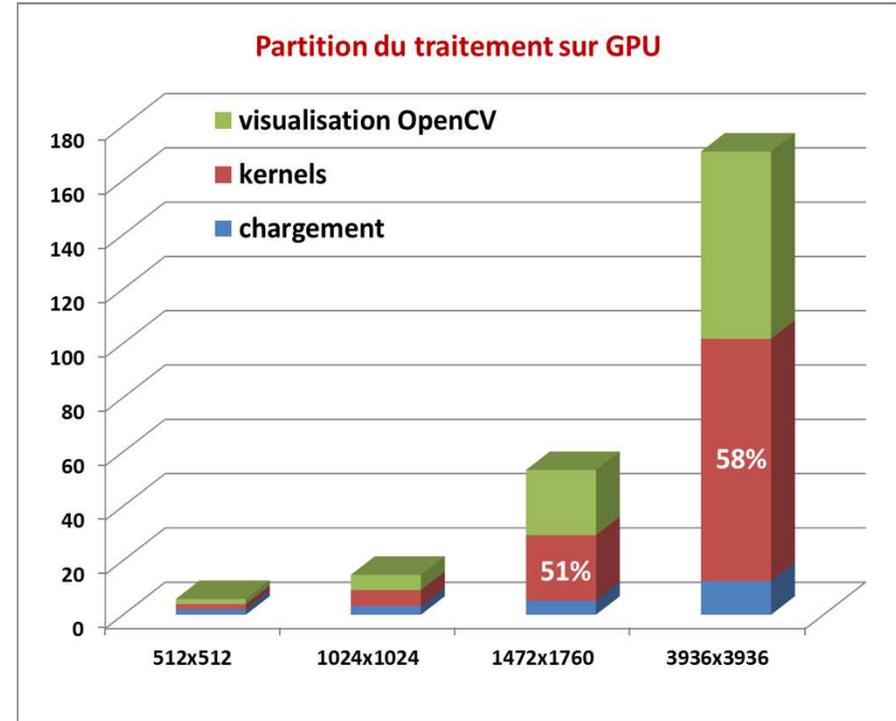
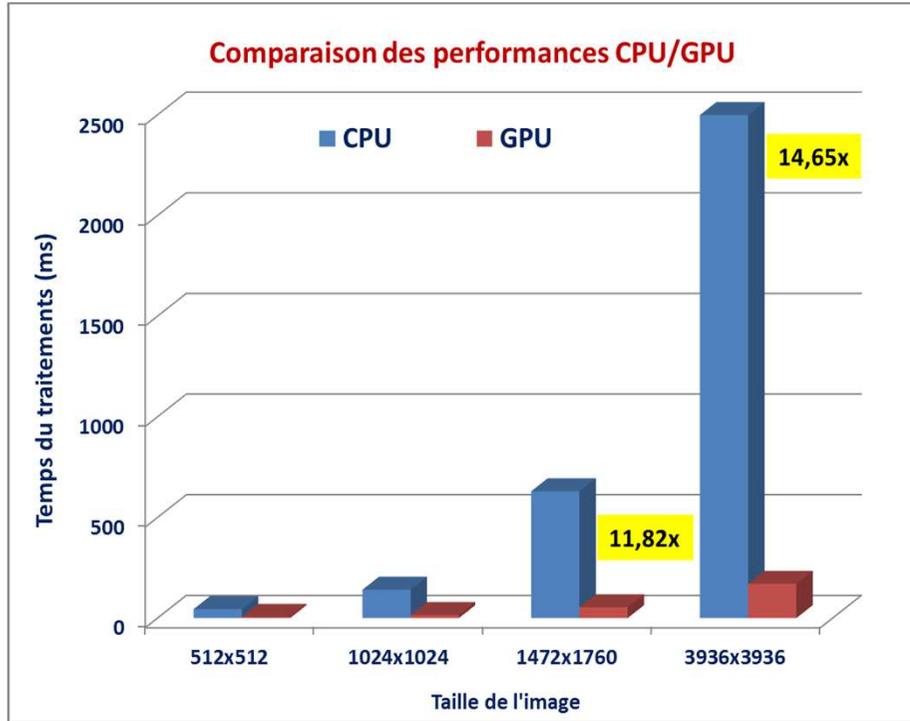
## Détection des contours sur GPU:

- Implémentation GPU basée sur le principe de Deriche-Canny
- Efficacité: robustesse aux bruits, nombre réduit d'opérations
- Bonne qualité des contours extraits



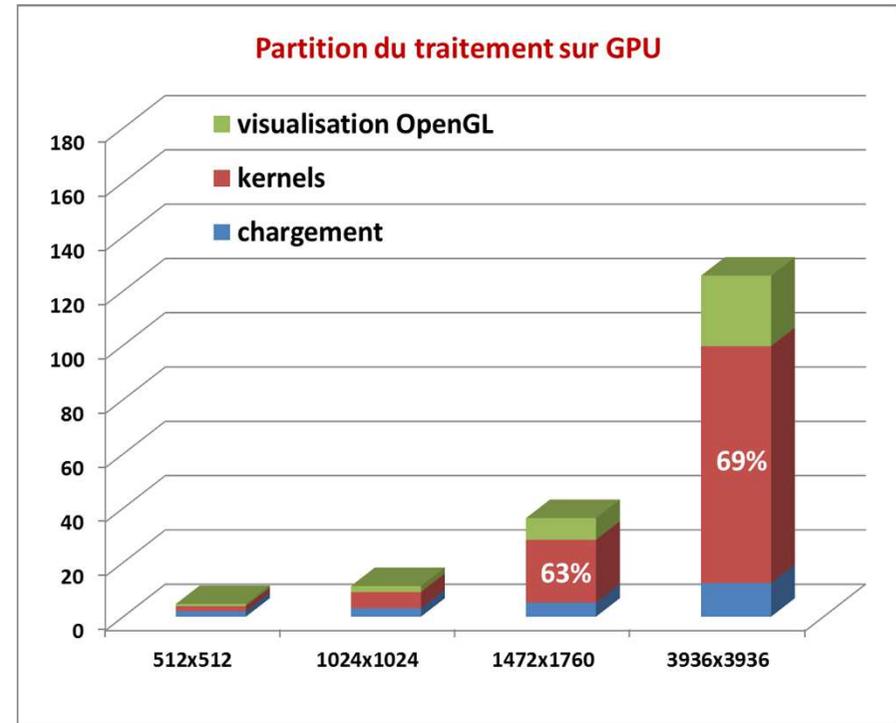
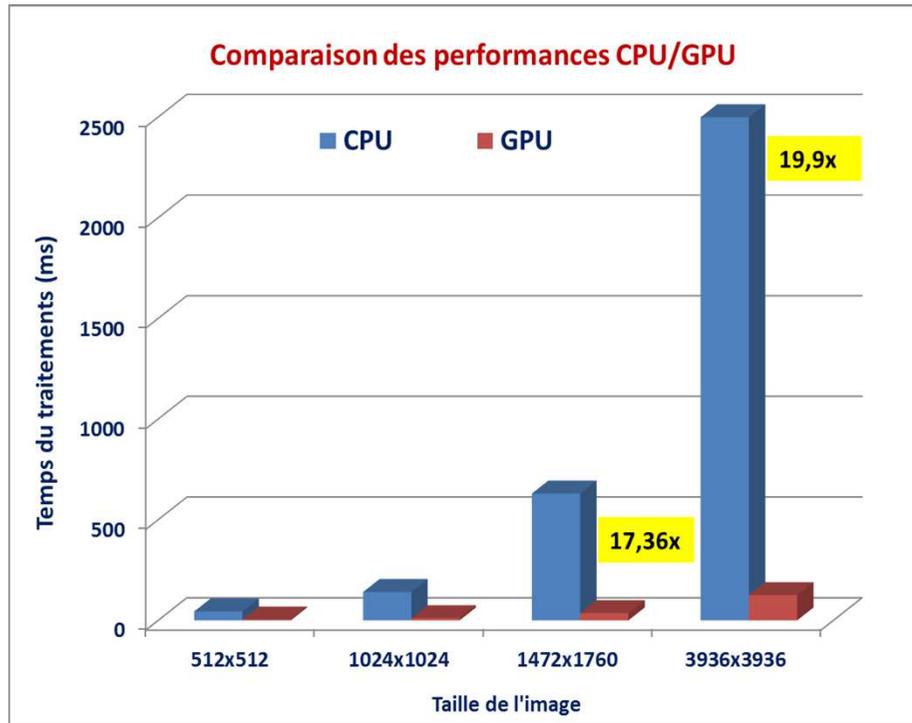
Détection des contours sur GPU

# Résultats : traitement GPU d'image unique



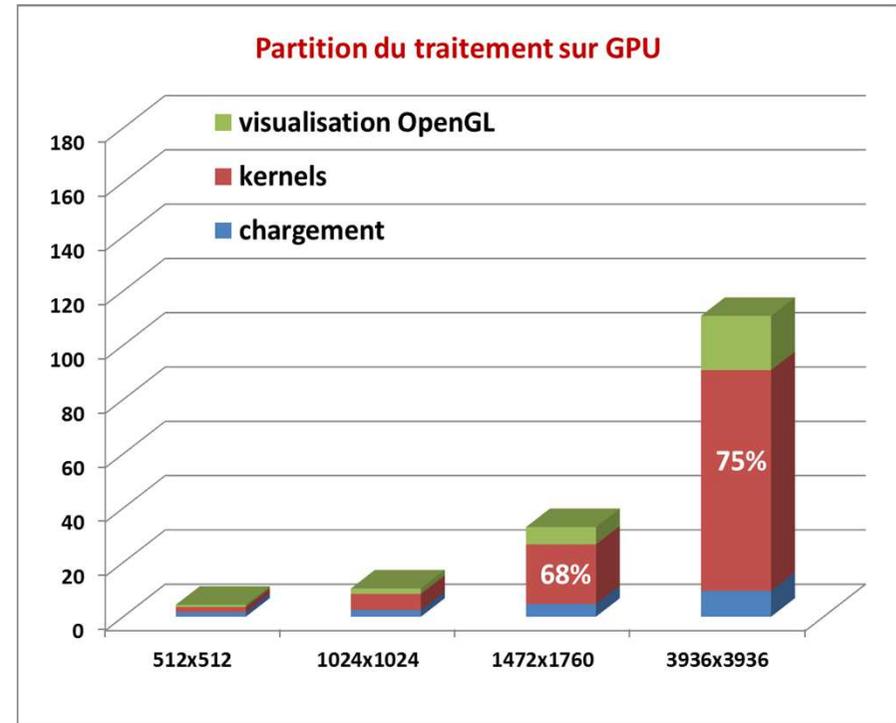
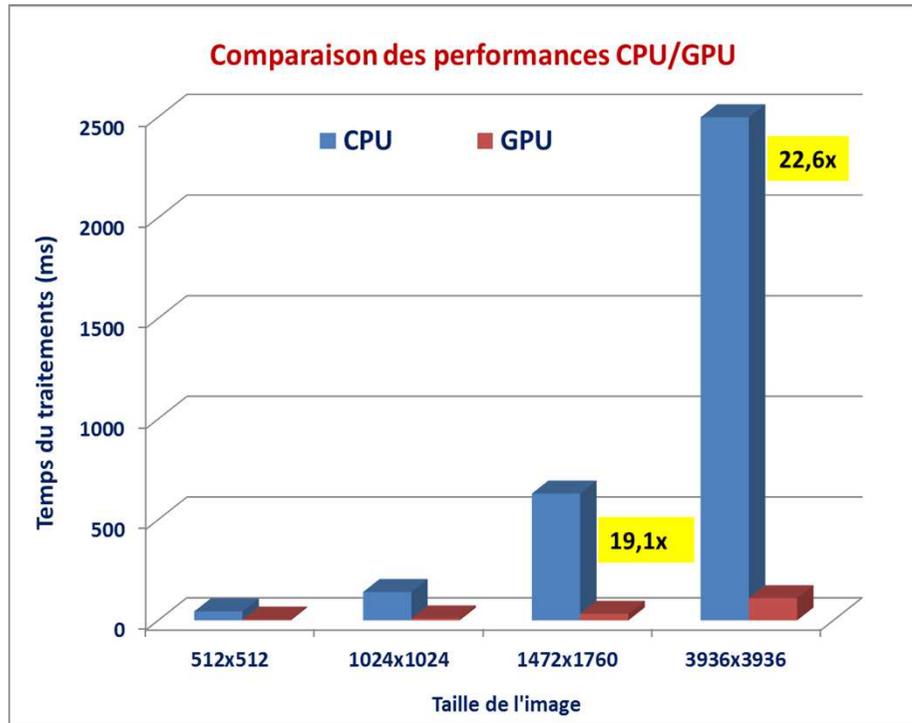
Détection des coins et de contours sur GPU : **Mémoire Globale**

# Résultats : traitement GPU d'image unique



Détection des coins et de contours sur GPU : **Visualisation OpenGL**

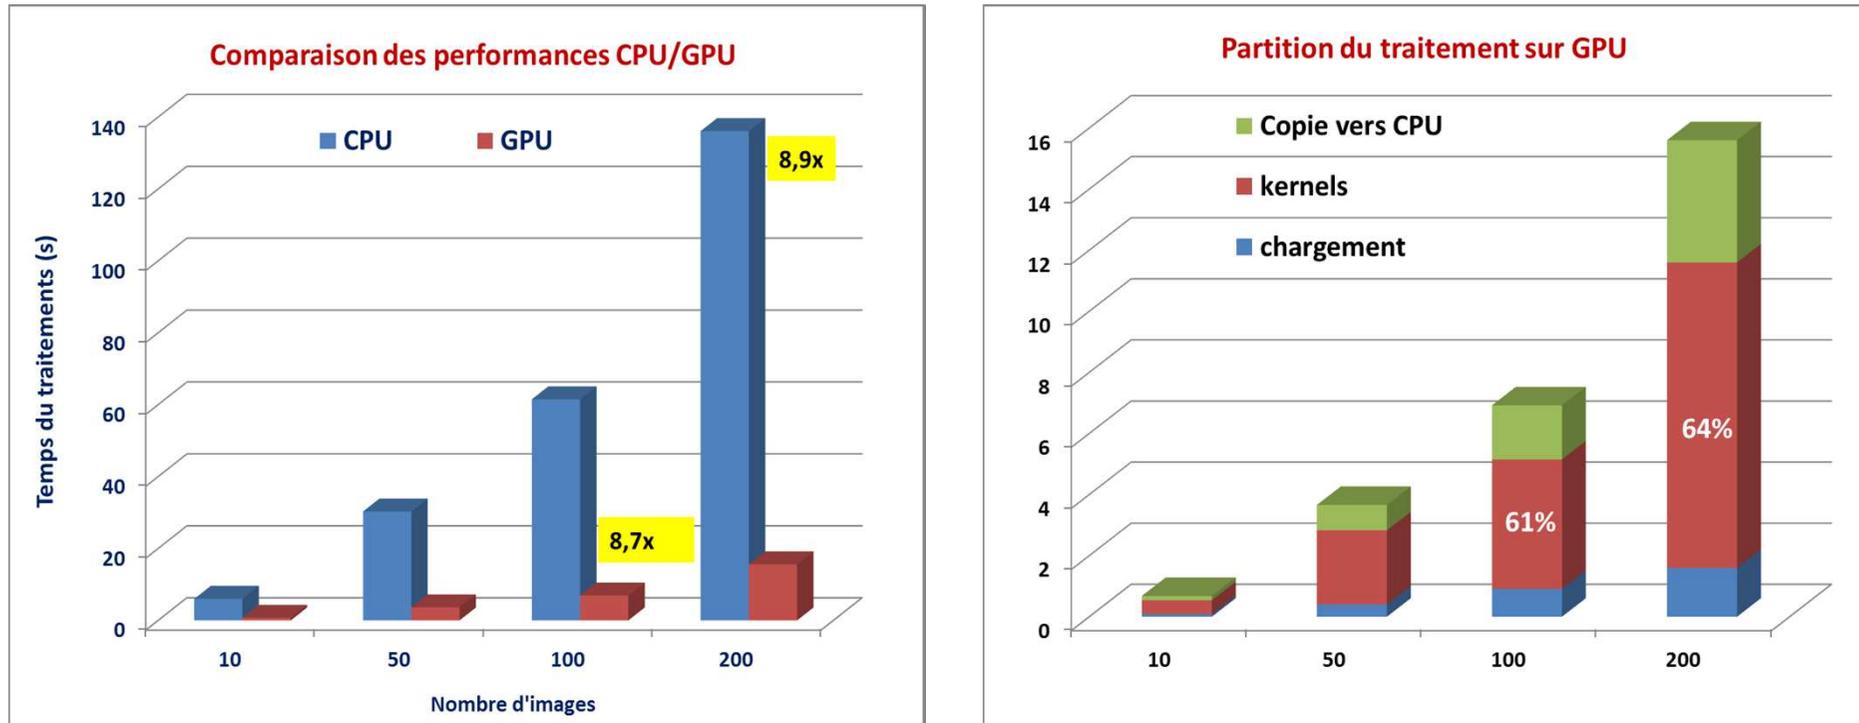
# Résultats : traitement GPU d'image unique



Détection des coins et de contours sur GPU : **Mémoires « texture et partagée »**

# Résultats : traitement GPU d'images multiples

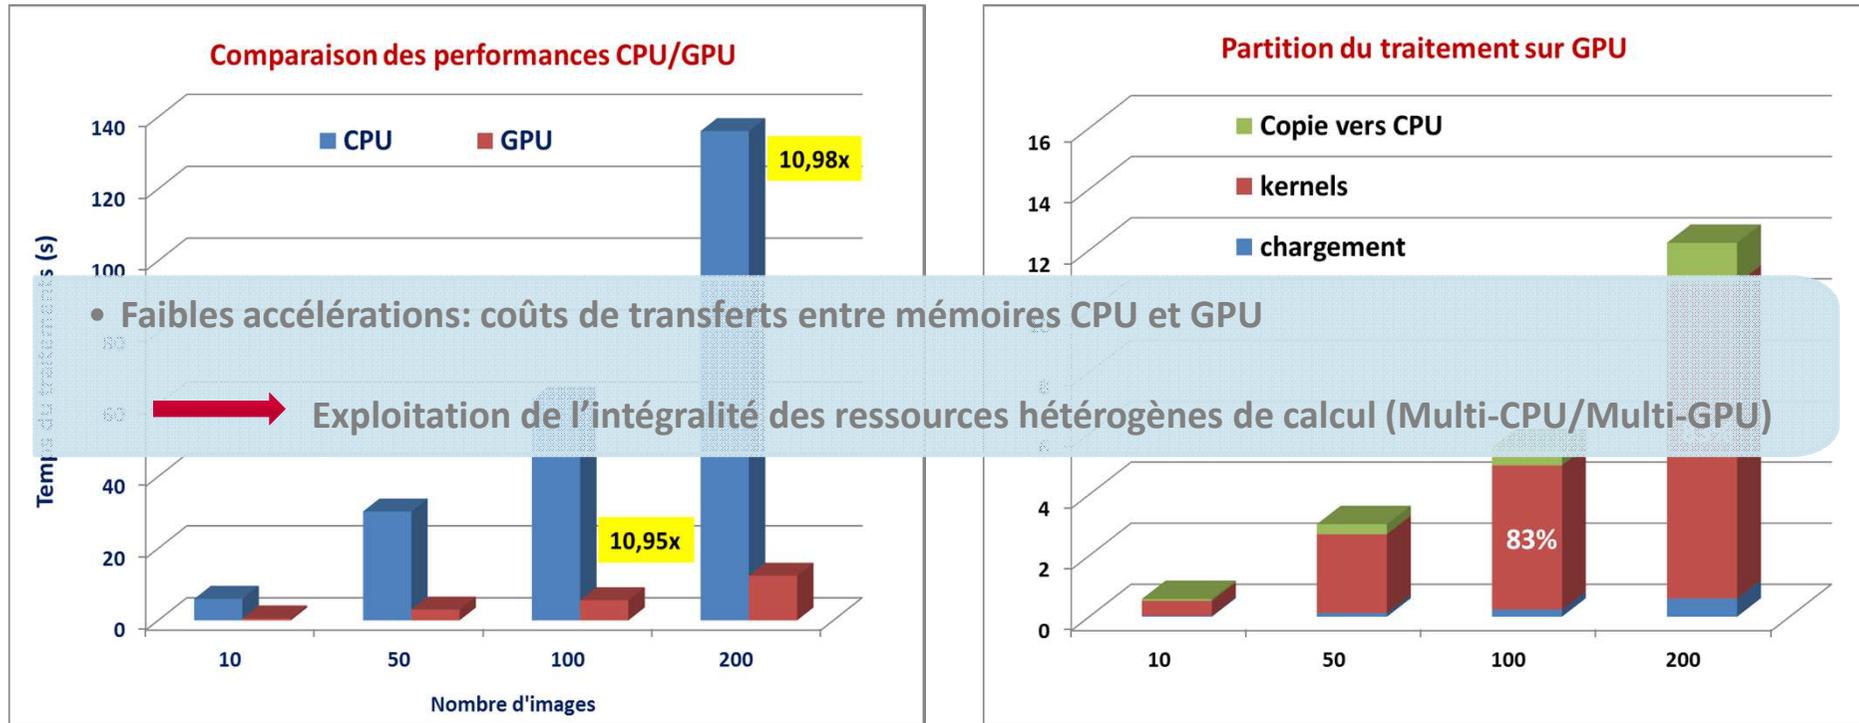
Résolution d'images : 2048x2048



Détection des coins et de contours sur GPU : Mémoires « texture et partagée »

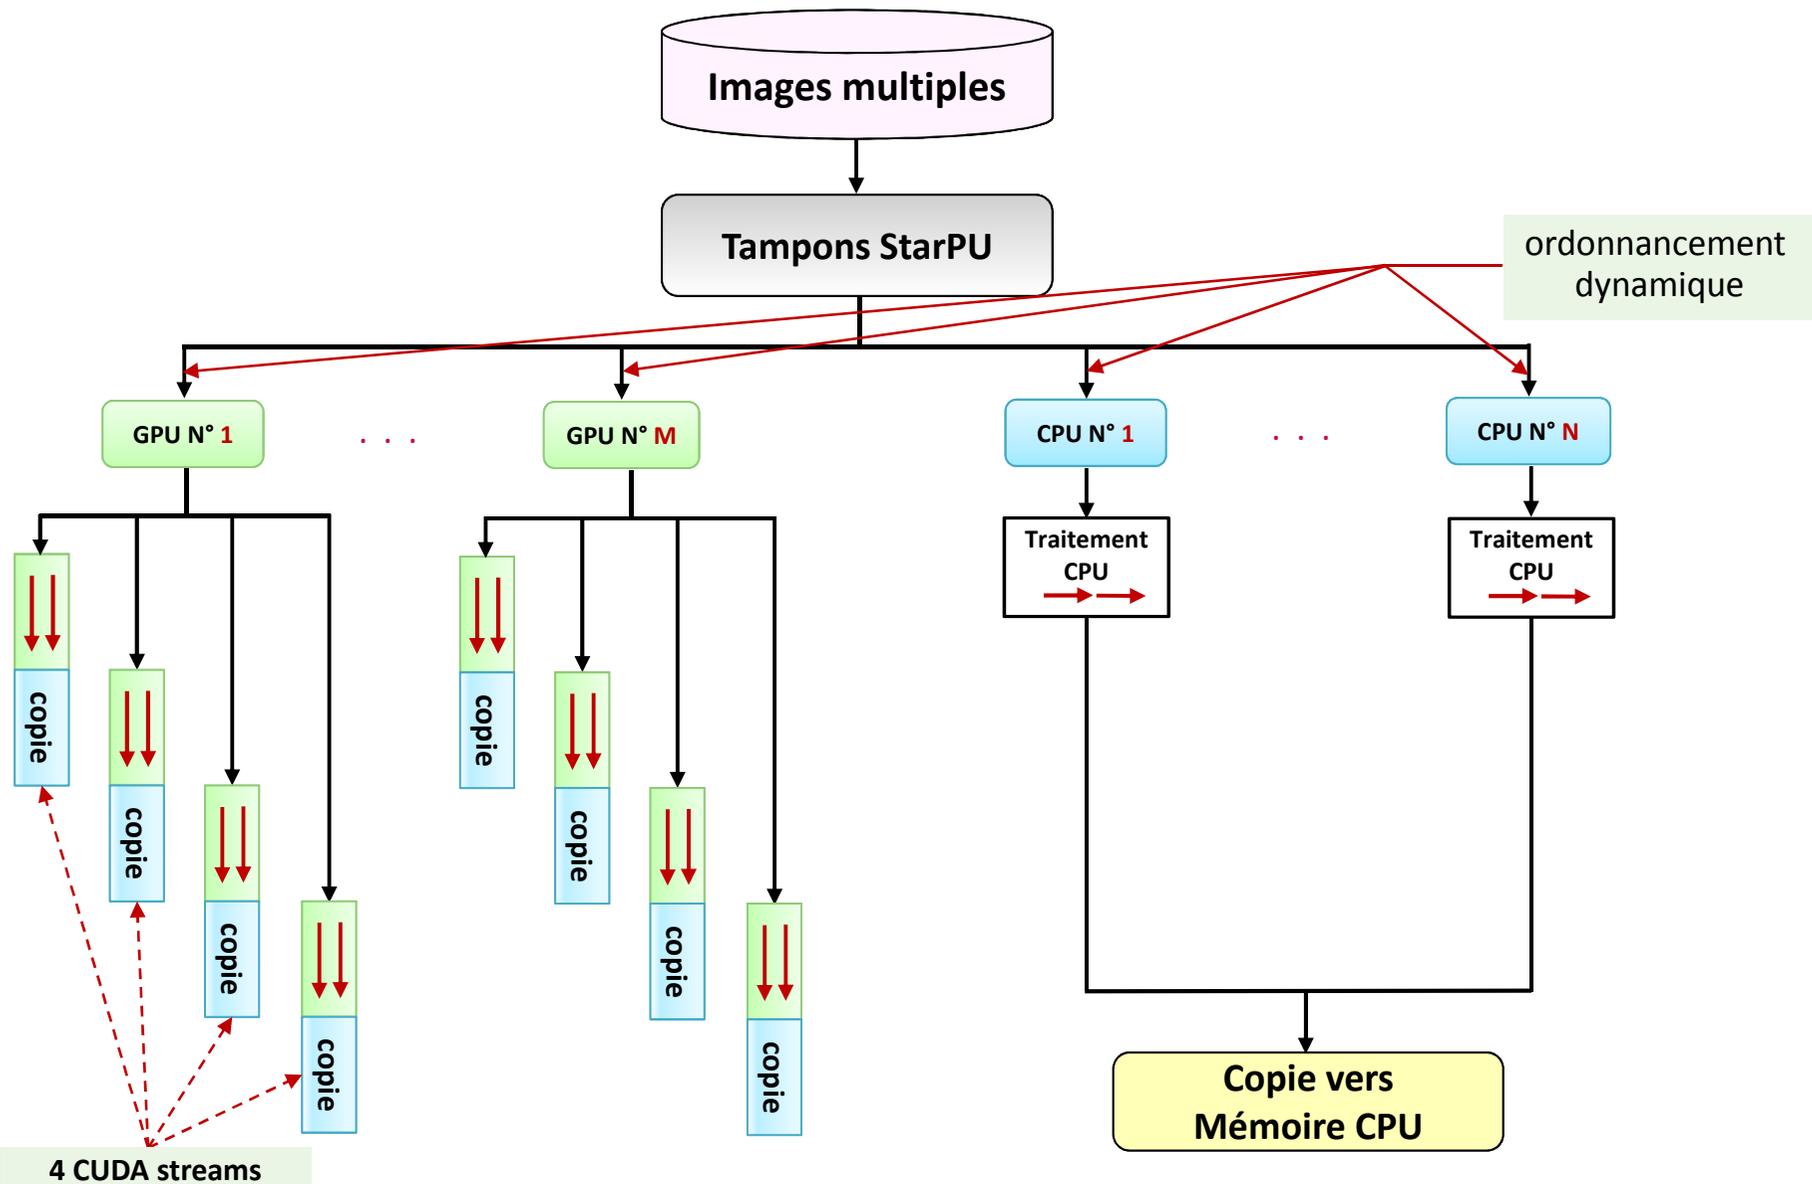
# Résultats : traitement GPU d'images multiples

Résolution d'images : 2048x2048



Détection des coins et de contours sur GPU : **CUDA streaming**

# Schéma 2 : traitement hétérogène d'images multiples



# Traitement hétérogène: Optimisations employées

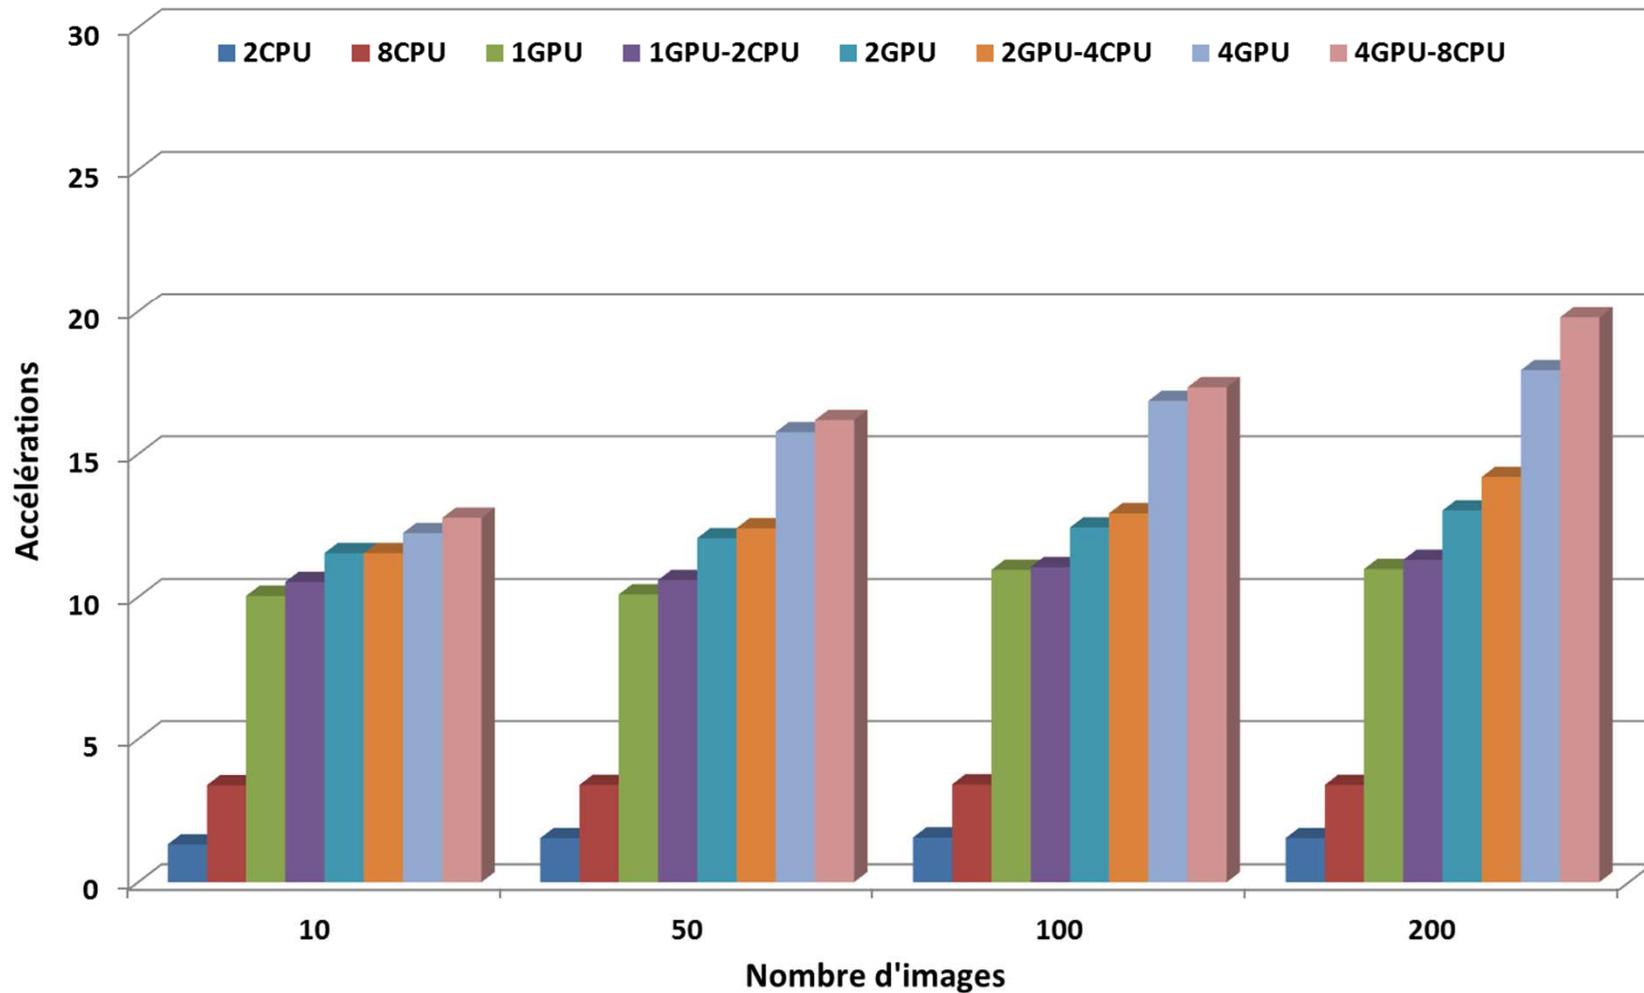
## Ordonnancement des tâches:

- Appliqué au sein des cœurs hétérogènes (Multi-CPU/Multi-GPU)
- Estimation préliminaire de durée de tâches sur base de l'historique (tâches précédentes)
- Ordonnancement prenant en compte:
  - ✓ durées estimées des tâches
  - ✓ estimation du temps de transfert de données

## CUDA streaming

- Appliqué au sein des GPUs multiples
- recouvrement des transferts par les exécutions
- Chaque GPU traite un sous-ensemble d'images utilisant 4 streams CUDA
- Le choix de quatre streams CUDA offre de meilleures performances

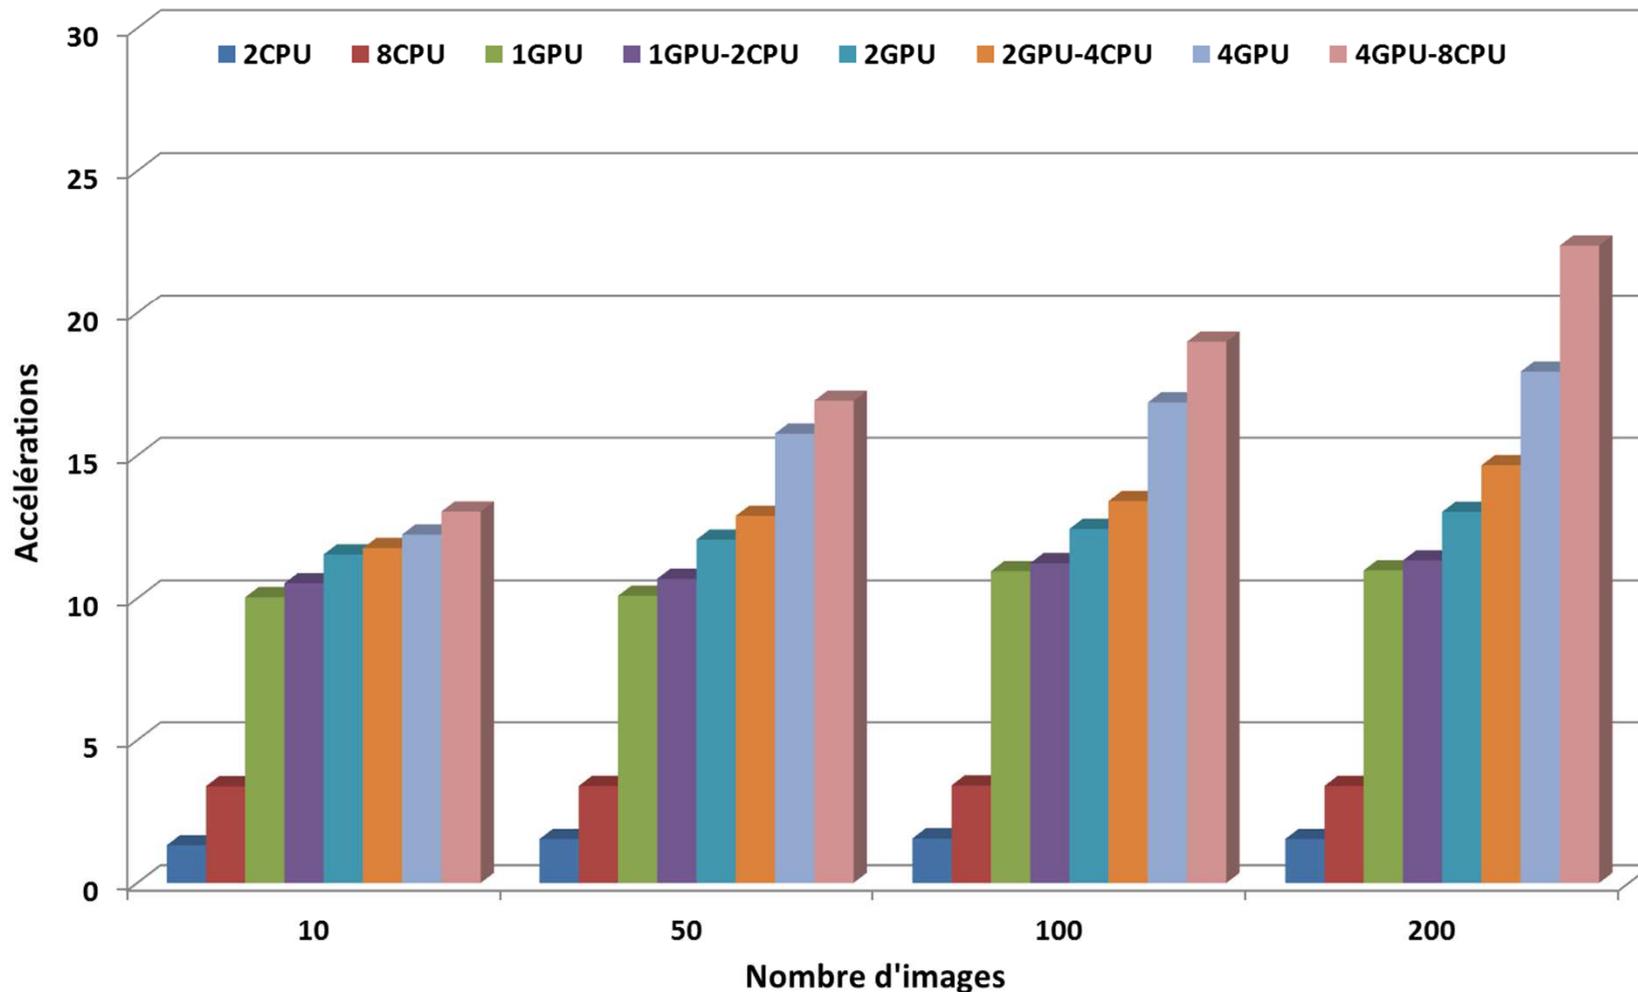
# Traitement hétérogène : résultats



Résolution d'images : 512x512, 1024x1024, 2048x2048, 3936x3936

Détection hétérogène des coins et contours d'images multiples

# Traitement hétérogène : résultats

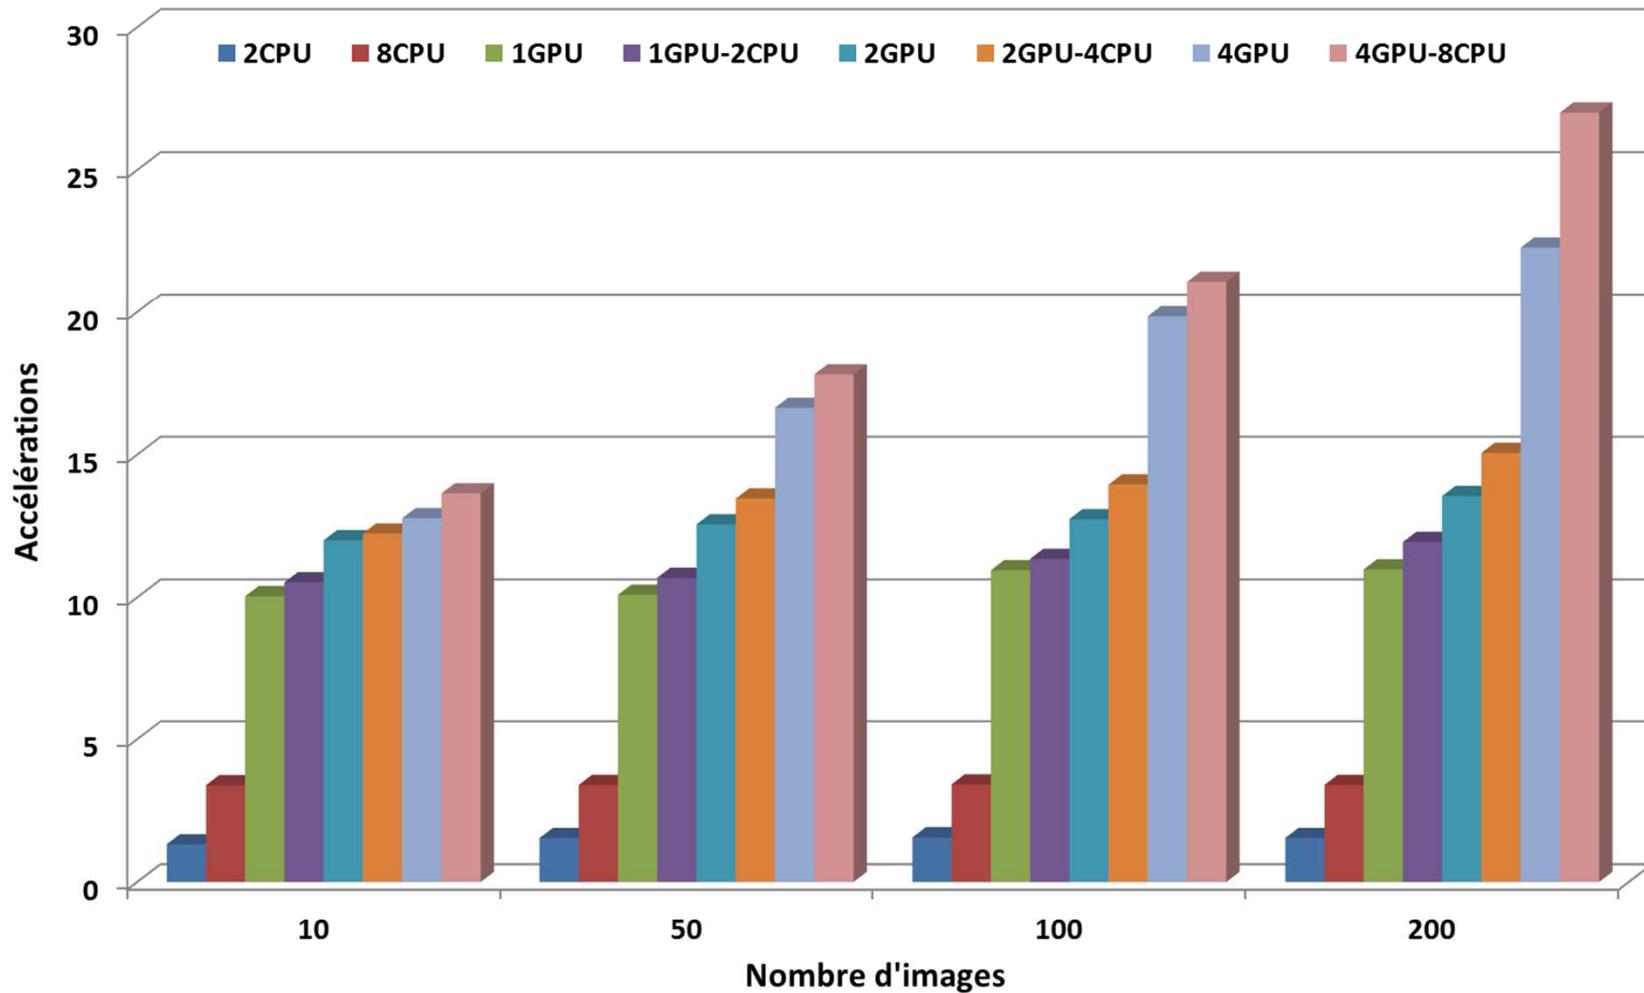


Résolution d'images : 512x512, 1024x1024, 2048x2048, 3936x3936

Détection hétérogène des coins et contours d'images multiples

**Ordonnancement dynamique**

# Traitement hétérogène : résultats



Résolution d'images : 512x512, 1024x1024, 2048x2048, 3936x3936

Détection hétérogène des coins et contours d'images multiples

**Ordonnancement dynamique + CUDA streaming**

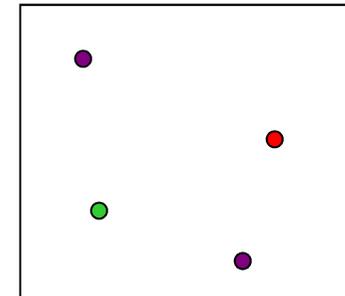
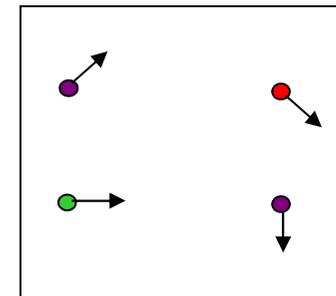
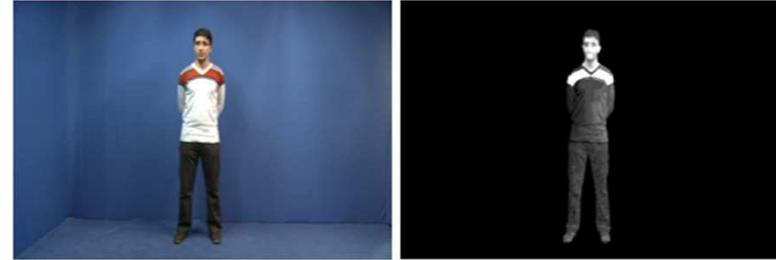
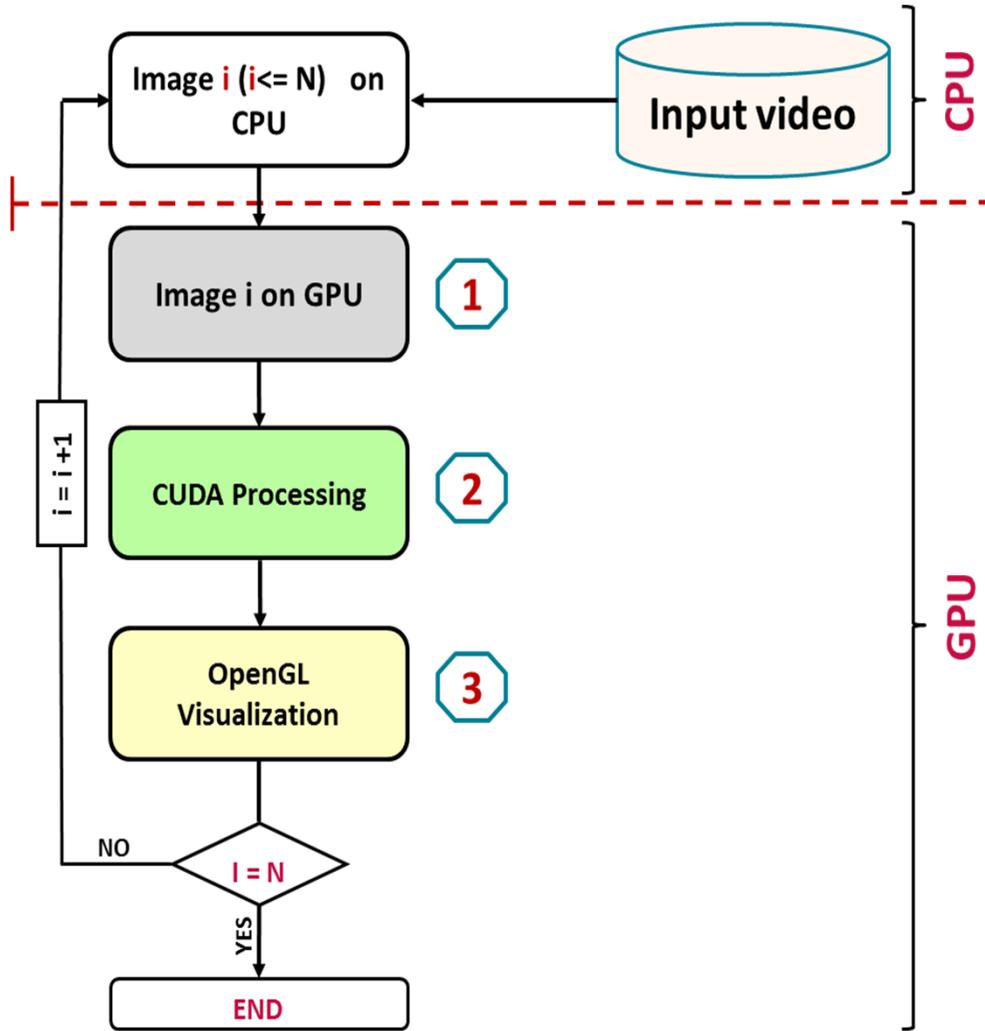
# PLAN

## Introduction

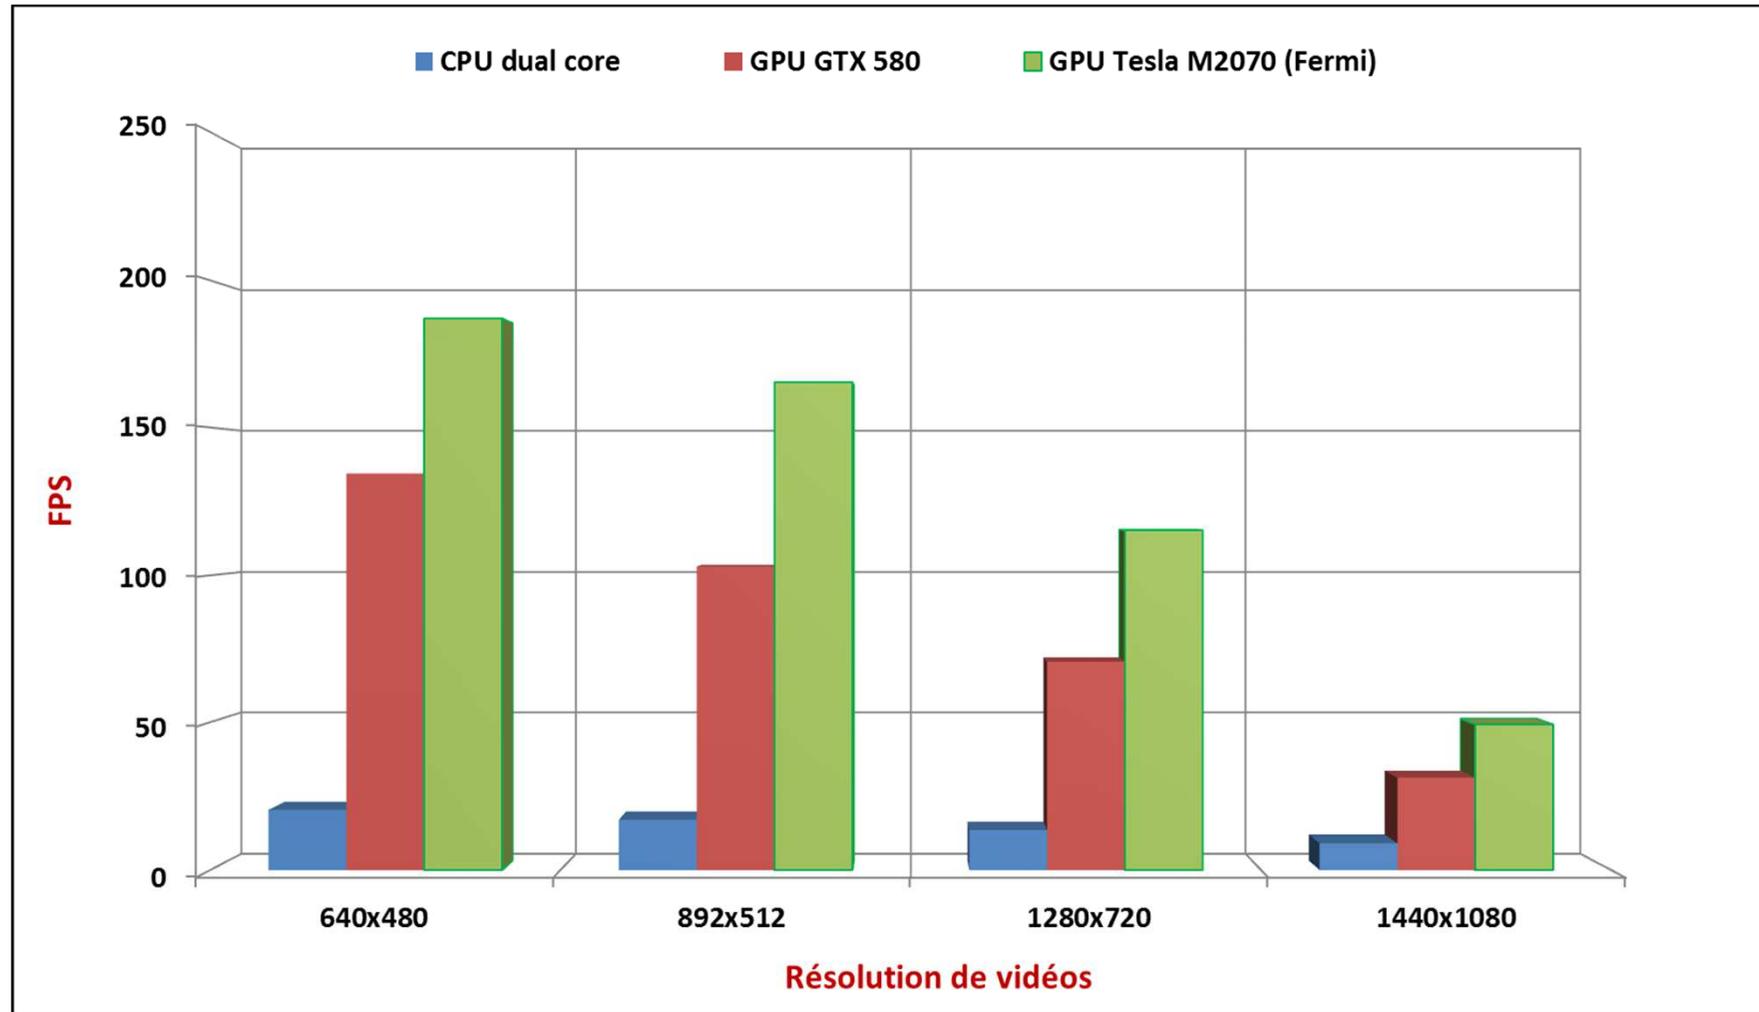
- I.** Présentation des GPU
- II.** Programmation des GPU
- III.** Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU
- IV.** Application au traitement d'objets multimédias
  - 1.** Traitement d'images sur architectures Multi-CPU/Multi-GPU
  - 2. Traitement Multi-GPU de vidéos HD/Full HD en temps réel**
- V.** Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes
- VI.** Résultats Expérimentaux: cas d'utilisations du modèle

## Conclusion

# Traitement de vidéos HD sur GPU

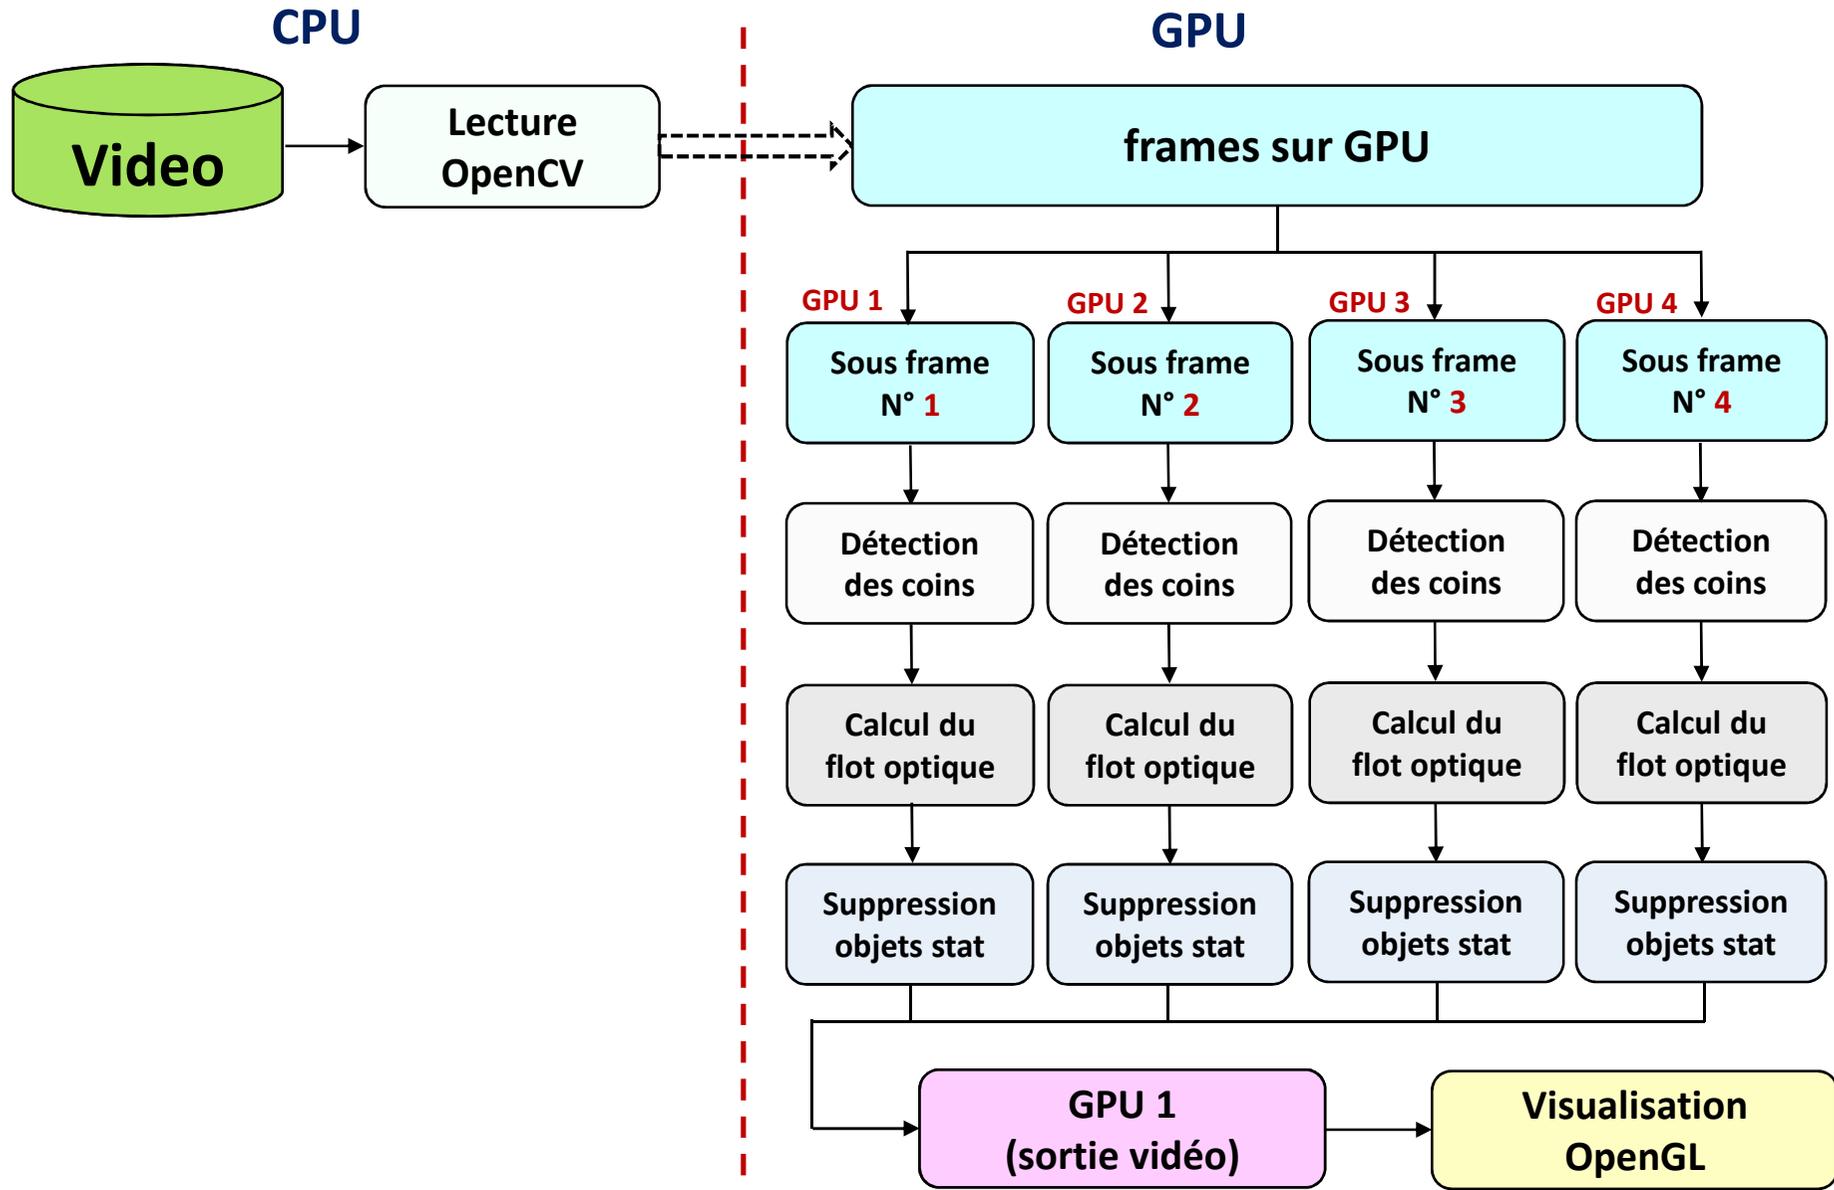


# Extraction de silhouettes sur GPU

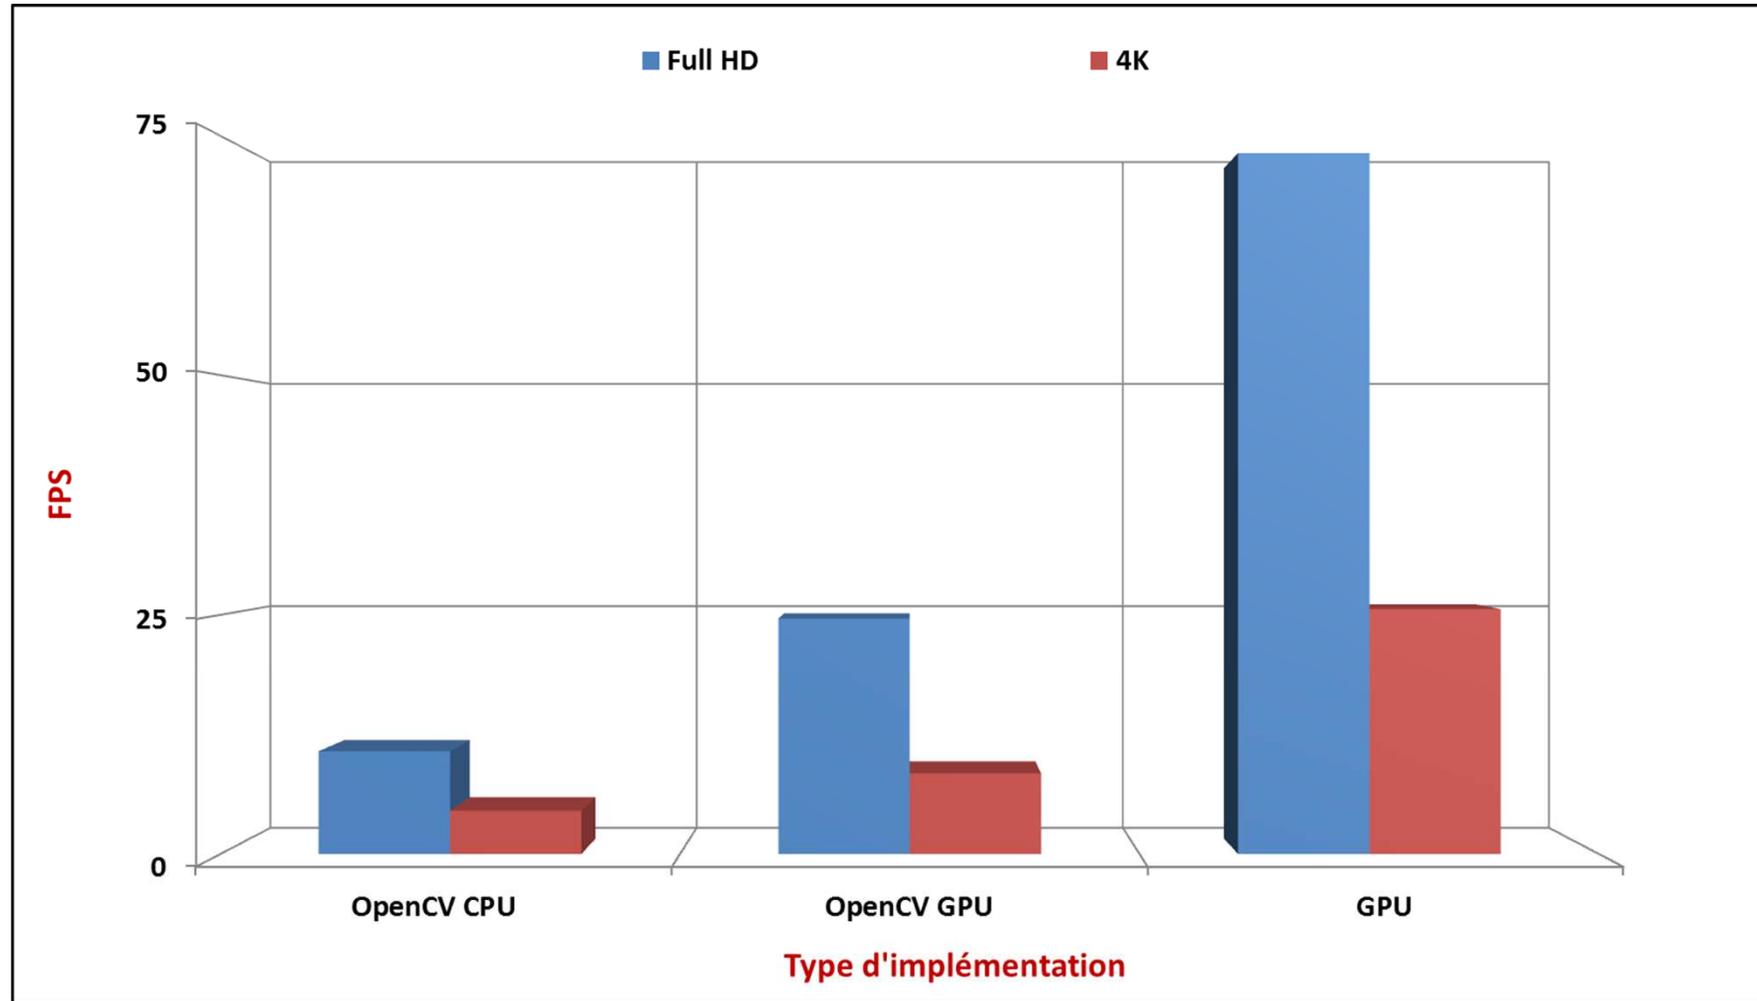


Performances d'extraction de silhouette sur GPU

# Suivi de mouvements sur GPU multiples



# Suivi de mouvements sur un GPU



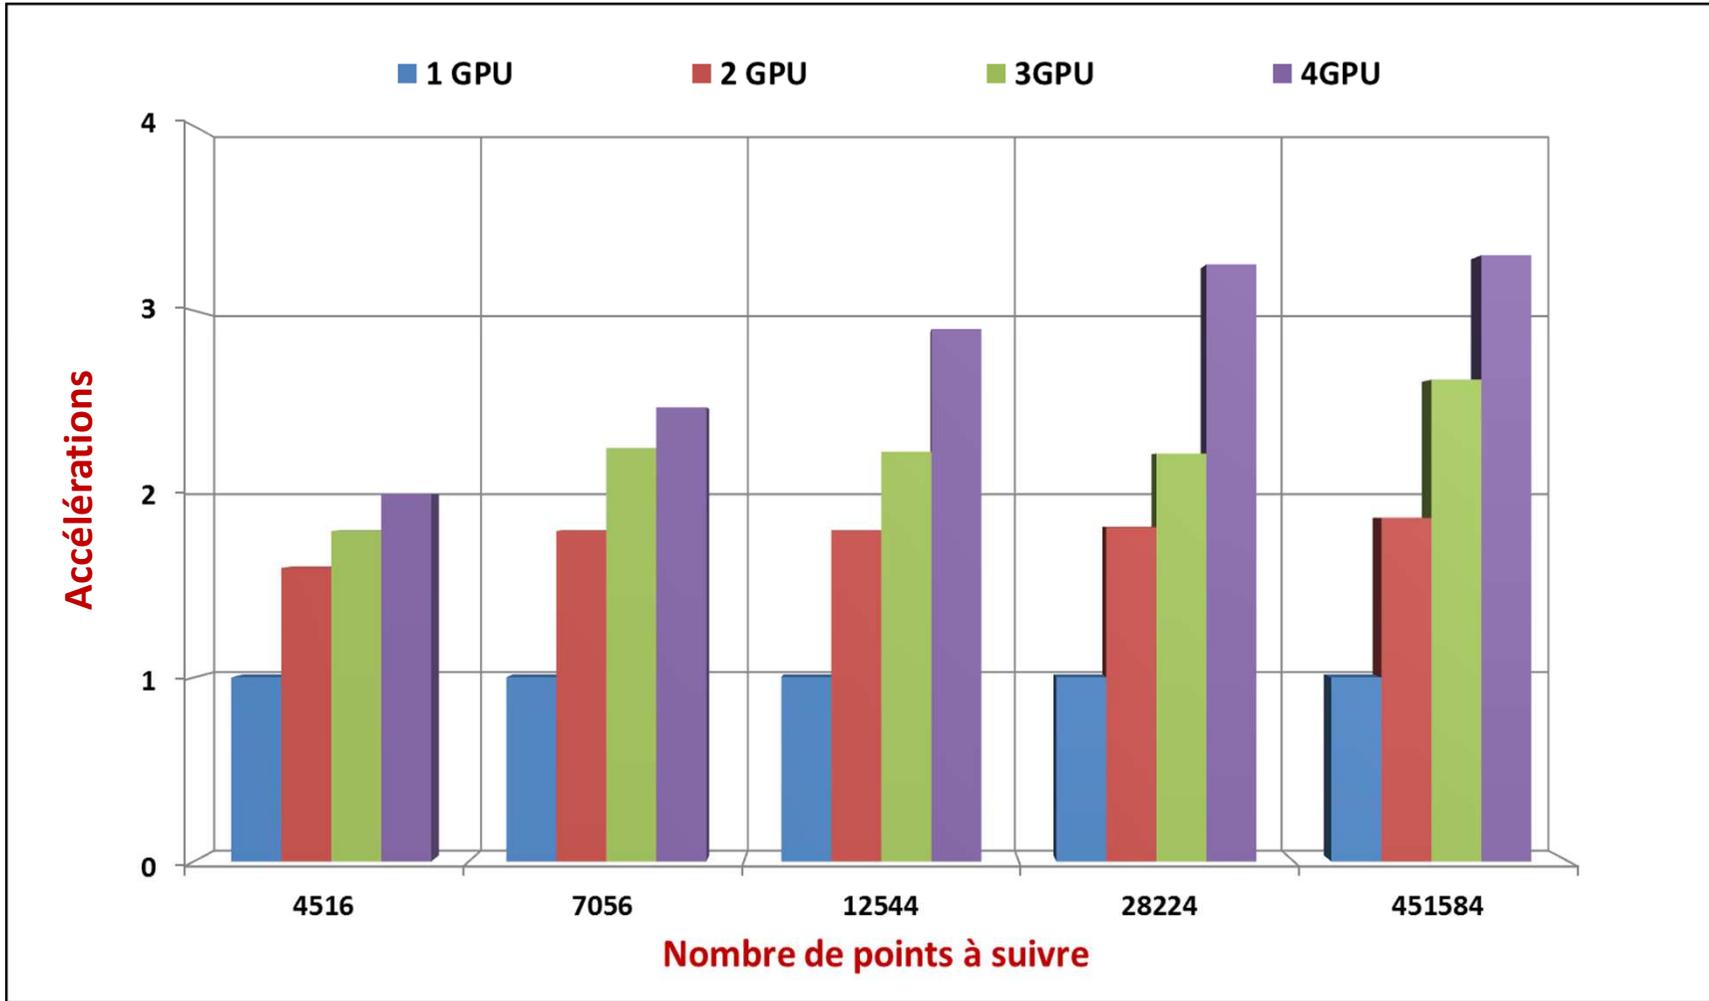
Performances de suivi de mouvements sur un GPU

HD : 1280x720

Full HD : 1920x1080

4K : 3840x2160

# Suivi de mouvements sur GPU multiples



Performances de suivi de mouvements sur GPU multiples

# Suivi de mouvements sur GPU multiples



Suivi de mouvements dans une vidéo Full HD (1920x1080)

# Suivi de mouvements sur GPU multiples



The image shows an aerial view of a multi-lane highway in winter, with snow on the ground and trees. Several vehicles, including trucks and cars, are visible on the road. Black arrows of varying lengths are overlaid on the scene, indicating the direction and speed of movement for various objects. The scene is annotated with several callouts and labels:

- On the left side, a yellow vertical bar contains the text "OpenCV GPU".
- Two light blue speech bubble callouts, one on the left and one on the right, both contain the word "Bruits" in red text.
- On the right side, a green vertical bar contains the text "19 FPS" in black.
- Another light blue speech bubble callout on the right side contains the word "Bruits" in red text.

Suivi de mouvements dans une vidéo Full HD (1920x1080)

# Suivi de mouvements sur GPU multiples



The image shows an aerial view of a snowy road with several cars. Black arrows are drawn on the image to track the movement of the cars. The scene is surrounded by snow-covered trees and streetlights. The image is framed by a yellow vertical bar on the left and a green vertical bar on the right. There are four callout boxes: two on the left and two on the right, each containing the text 'Suppr Bruits'. A central callout box on the right contains the text '62 FPS'. The word 'GPU' is written vertically on the yellow bar.

Suppr  
Bruits

GPU

Suppr  
Bruits

62 FPS

Suppr  
Bruits

Suivi de mouvements dans une vidéo Full HD (1920x1080)

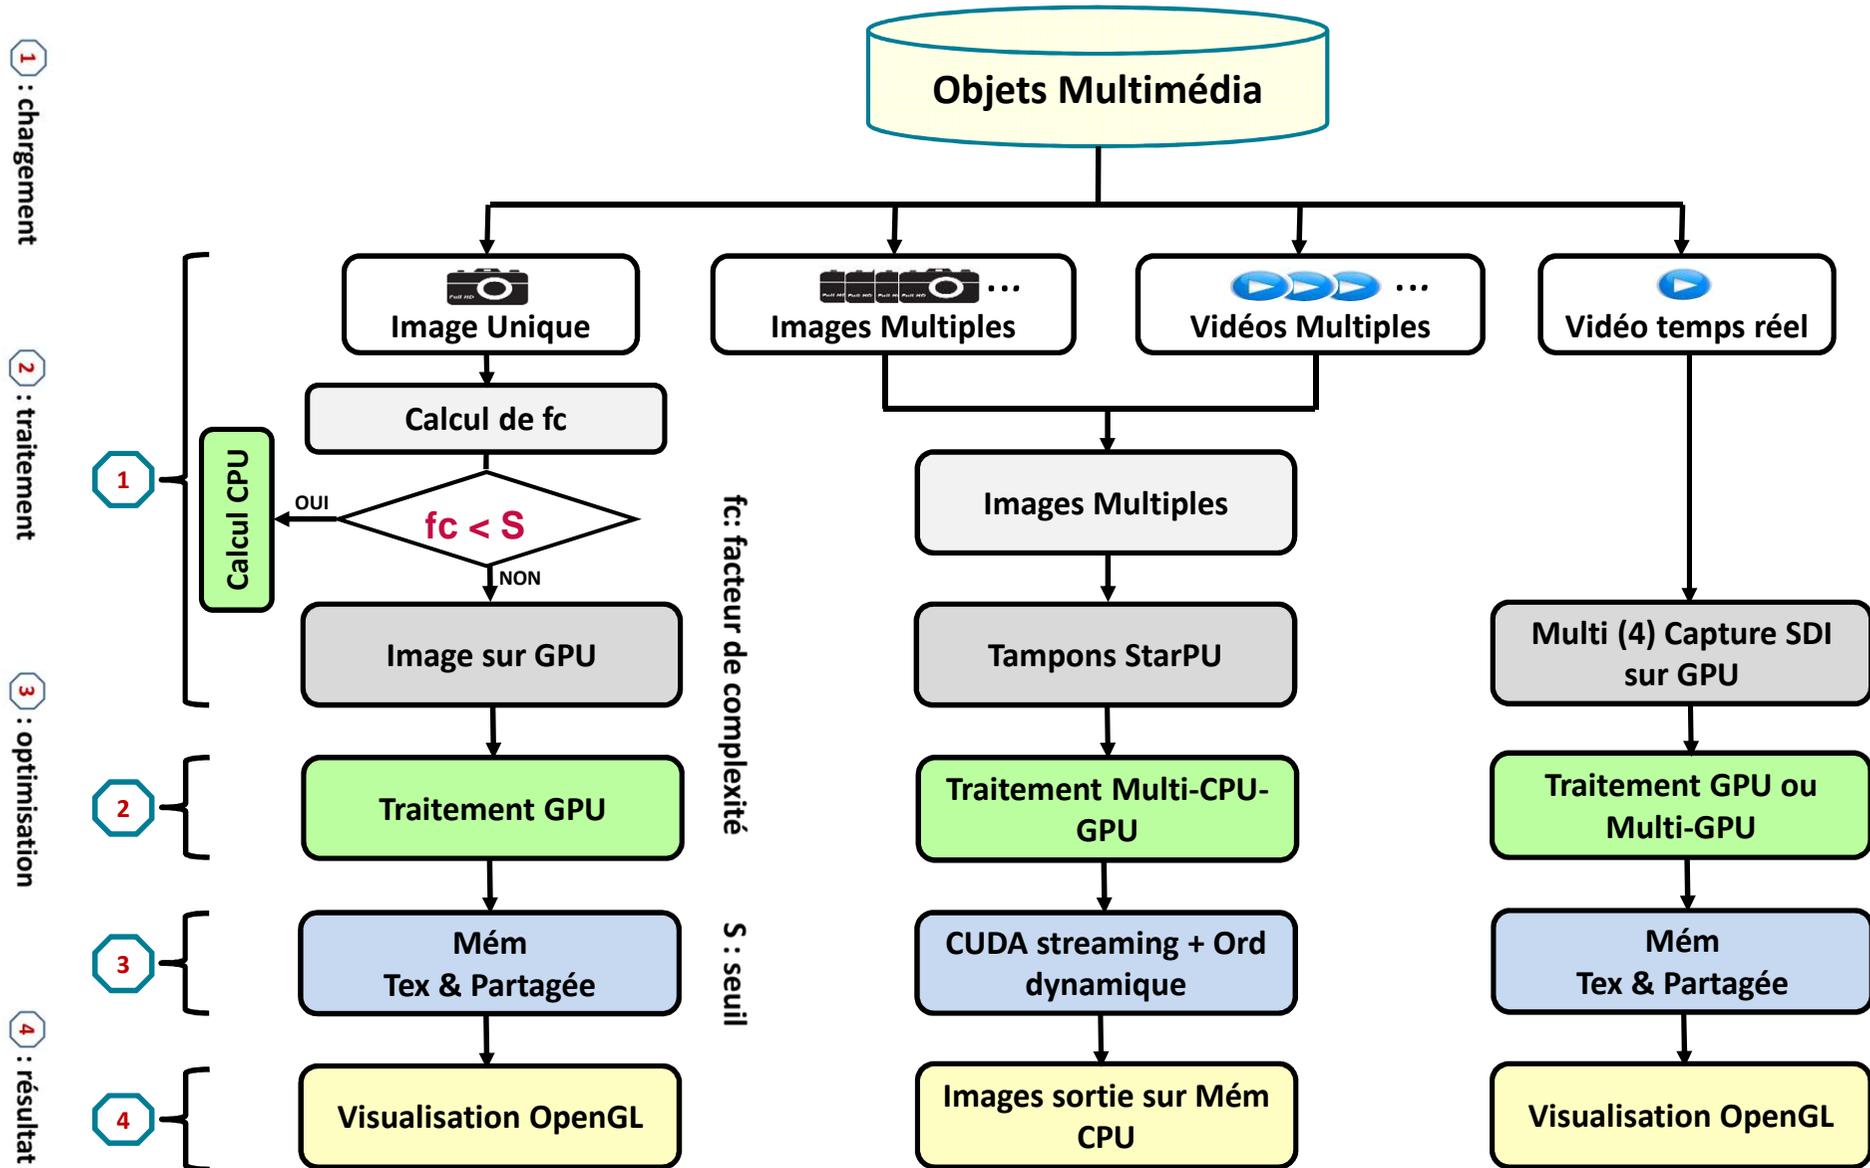
# PLAN

## Introduction

- I.** Présentation des GPU
- II.** Programmation des GPU
- III.** Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU
- IV.** Application au traitement d'objets multimédias
  - 1.** Traitement d'images sur architectures Multi-CPU/Multi-GPU
  - 2.** Traitement Multi-GPU de vidéos HD/Full HD en temps réel
- V.** **Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes**
- VI.** Résultats Expérimentaux: cas d'utilisations du modèle

## Conclusion

# Modèle de traitement d'objet multimédias



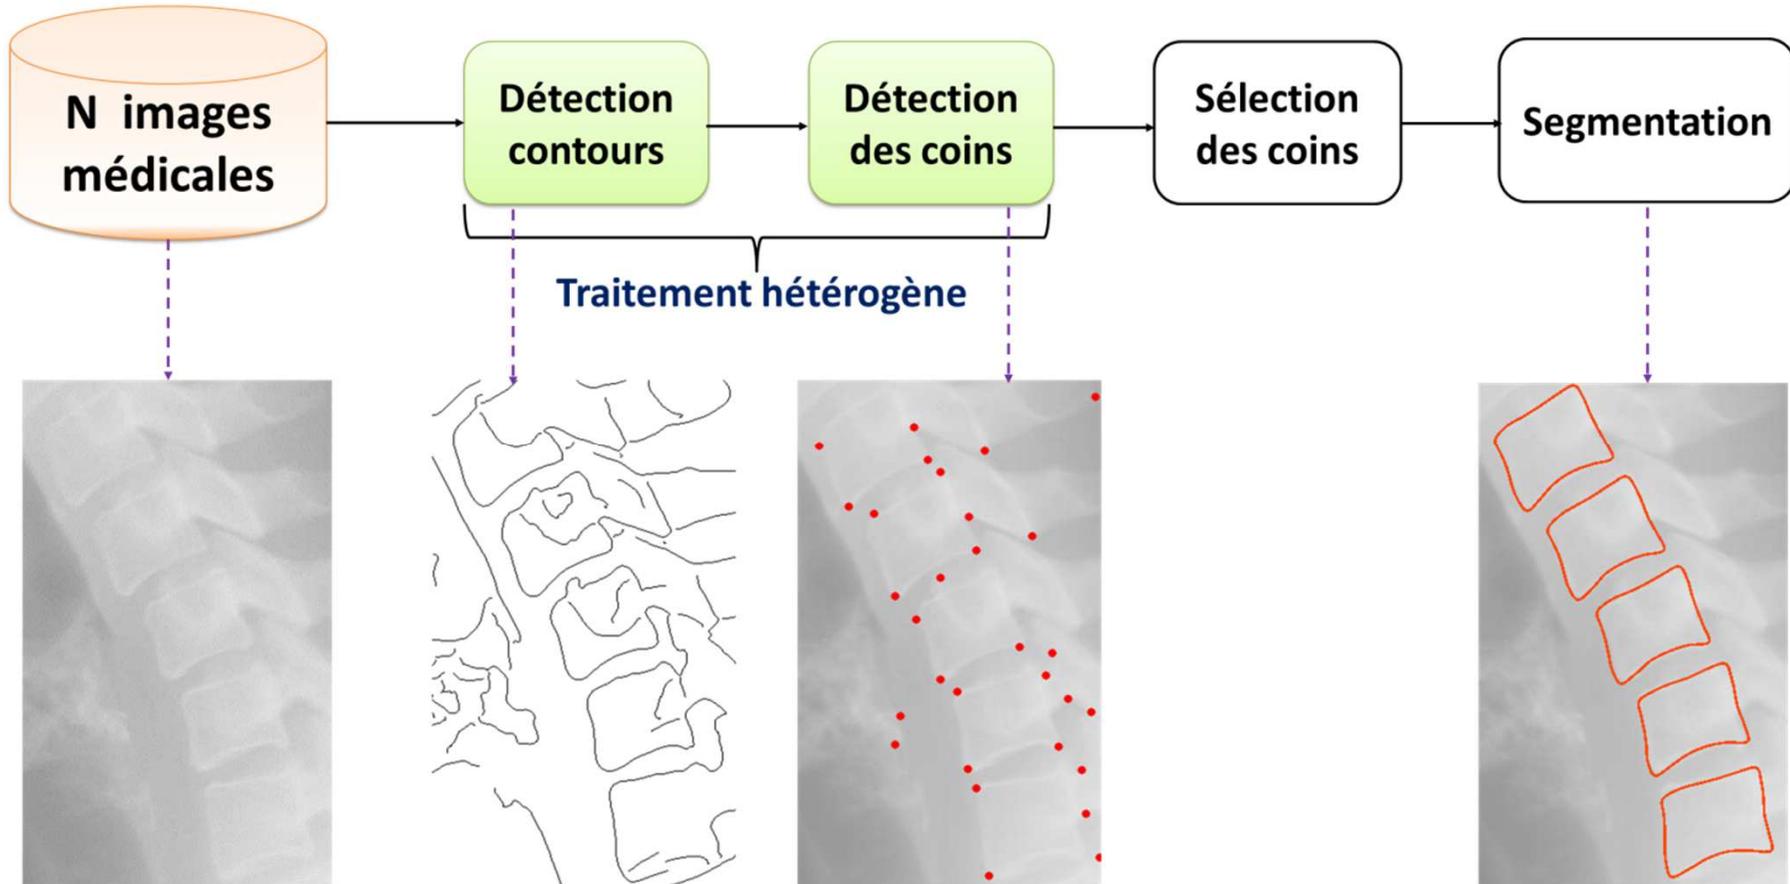
# PLAN

## Introduction

- I.** Présentation des GPU
- II.** Programmation des GPU
- III.** Exploitation des architectures hétérogènes Multi-CPU/Multi-GPU
- IV.** Application au traitement d'objets multimédias
  - 1.** Traitement d'images sur architectures Multi-CPU/Multi-GPU
  - 2.** Traitement Multi-GPU de vidéos HD/Full HD en temps réel
- V.** Modèle de traitement d'images et de vidéos sur architectures parallèles et hétérogènes
- VI.** Résultats Expérimentaux: cas d'utilisations du modèle

## Conclusion

## 1<sup>er</sup> cas : segmentation des vertèbres



Traitement hétérogènes d'images médicales : segmentation des vertèbres

# 1<sup>er</sup> cas : segmentation des vertèbres

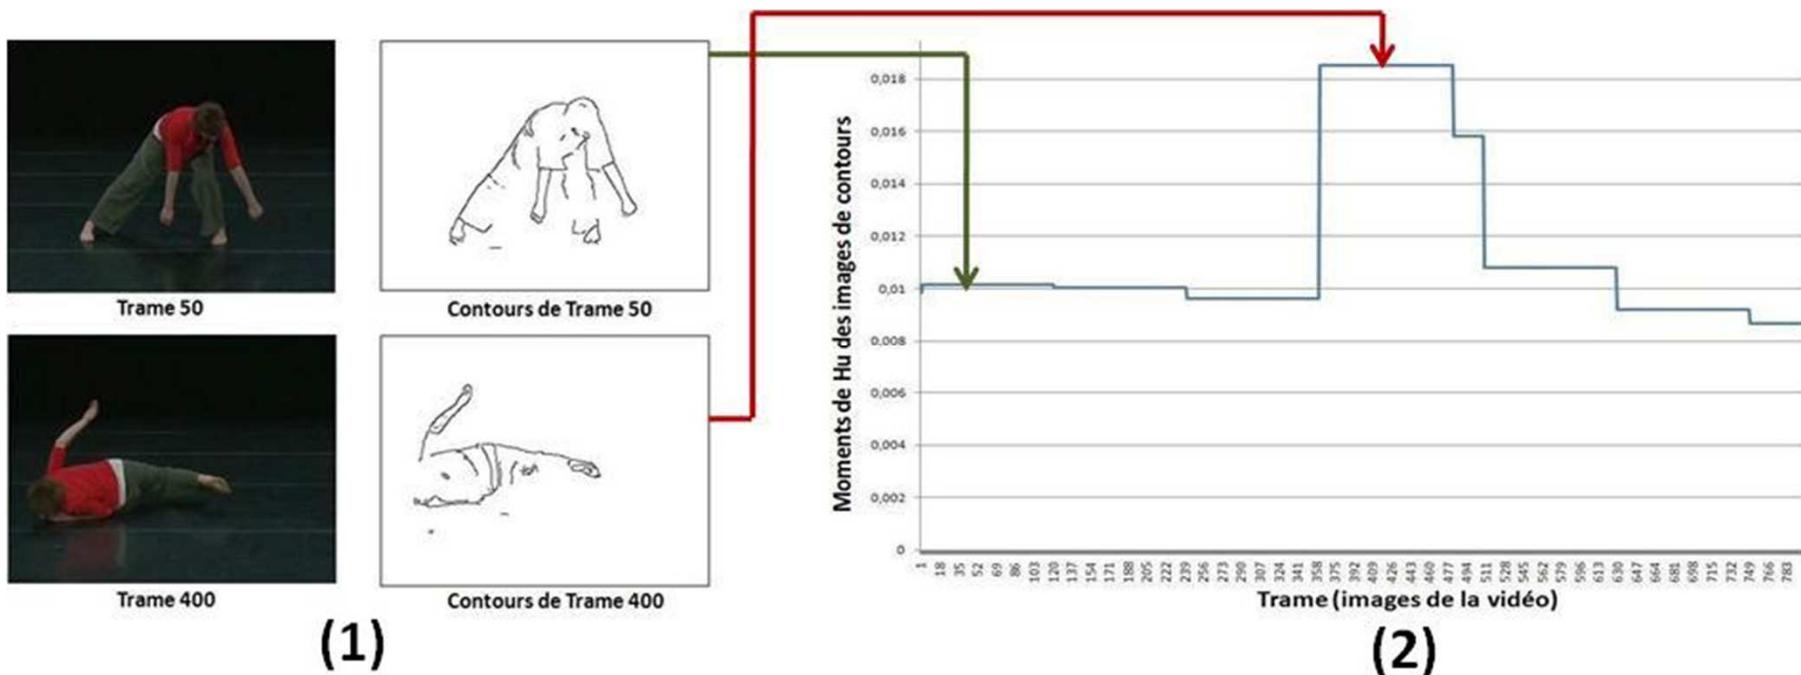
Étapes	1CPU	8CPU		1GPU/8CPU				4GPU/8CPU			
	Temps(T)	T	Acc	1GPU		8CPU		8CPU		4GPU/8CPU	
		T	Acc	T	Acc	T	Acc	T	Acc	T	Acc
Egalisation histogramme	62.10 s	15.44 s	4.02×	/	15.44 s	4.02×	15.44 s	4.02×	/		
Détection contours	135.8 s	39.06 s	3.48×	15.80 s	08.60×	/	/	/	4.84 s	28.06×	
Détection coins (poly)	46.12 s	11.51 s	4.01×	/	11.51 s	4.01×	11.51 s	4.01×	/		
<b>Temps total</b>	<b>T</b> 244.02 s	<b>T</b> 66.01 s	<b>Acc</b> 3.70 x	<b>T</b> 42.75 s	<b>Acc</b> 5.71 x	<b>T</b> 31.79 s	<b>Acc</b> 7.68 x				

Performances de détection hétérogène de vertèbres de 200 images (1476x1680)

## 2<sup>ème</sup> cas : indexation de vidéos

**VideoCycle:** Indexation de séquences vidéo à partir de caractéristiques d'images

- Silhouette
- Zones de mouvements
- Contours
- Moments de Hu

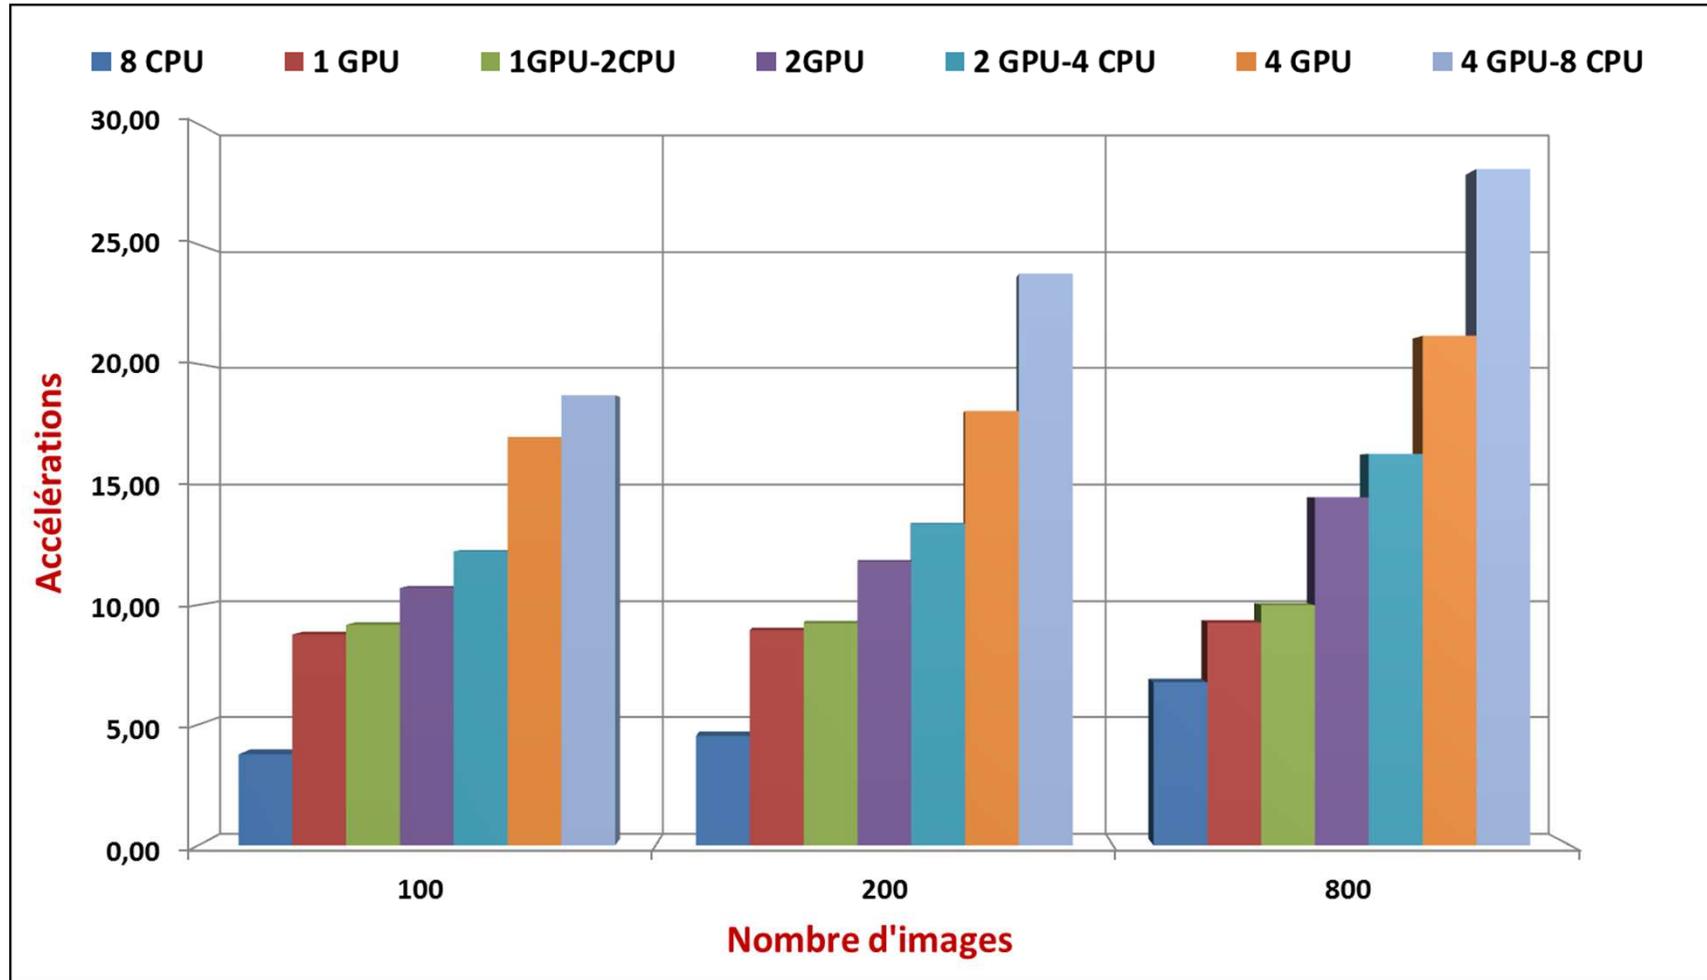


**Détection hétérogène des contours**

**Moments de Hu extraits à partir des contours**

**Traitement hétérogène de vidéos multiples : indexation de vidéos**

## 2<sup>ème</sup> cas : indexation de vidéos

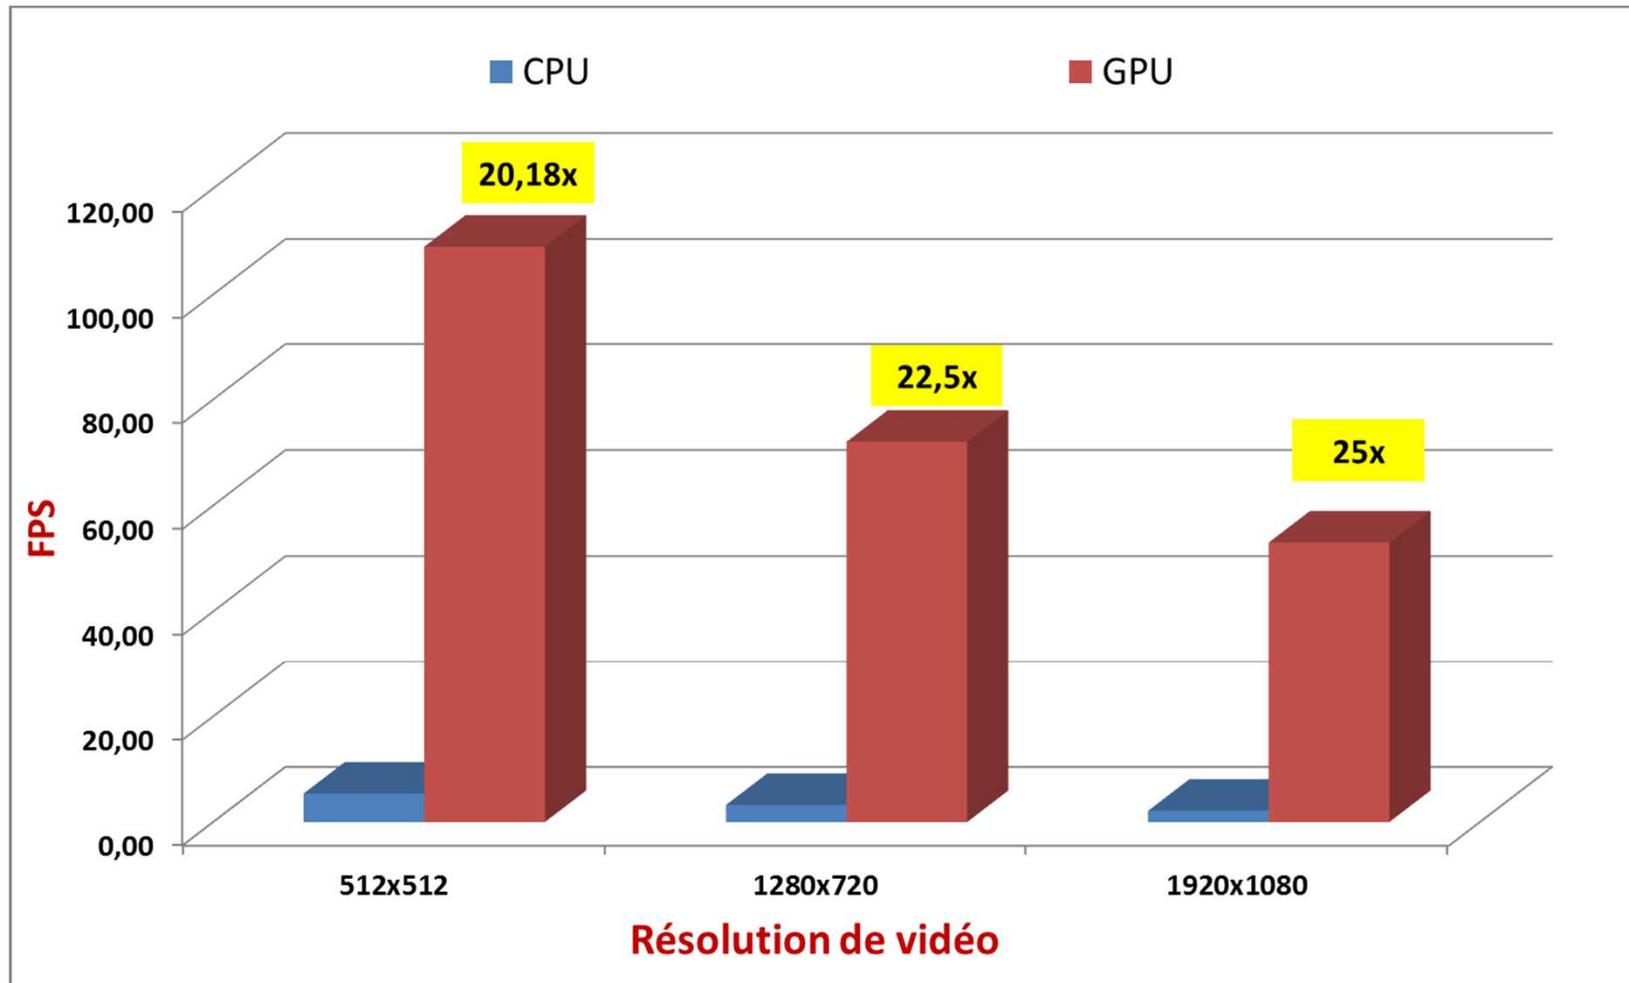


Performances du calcul hétérogène d'extraction de caractéristiques

## 3<sup>ème</sup> cas: Détection de mouvements avec caméra mobile

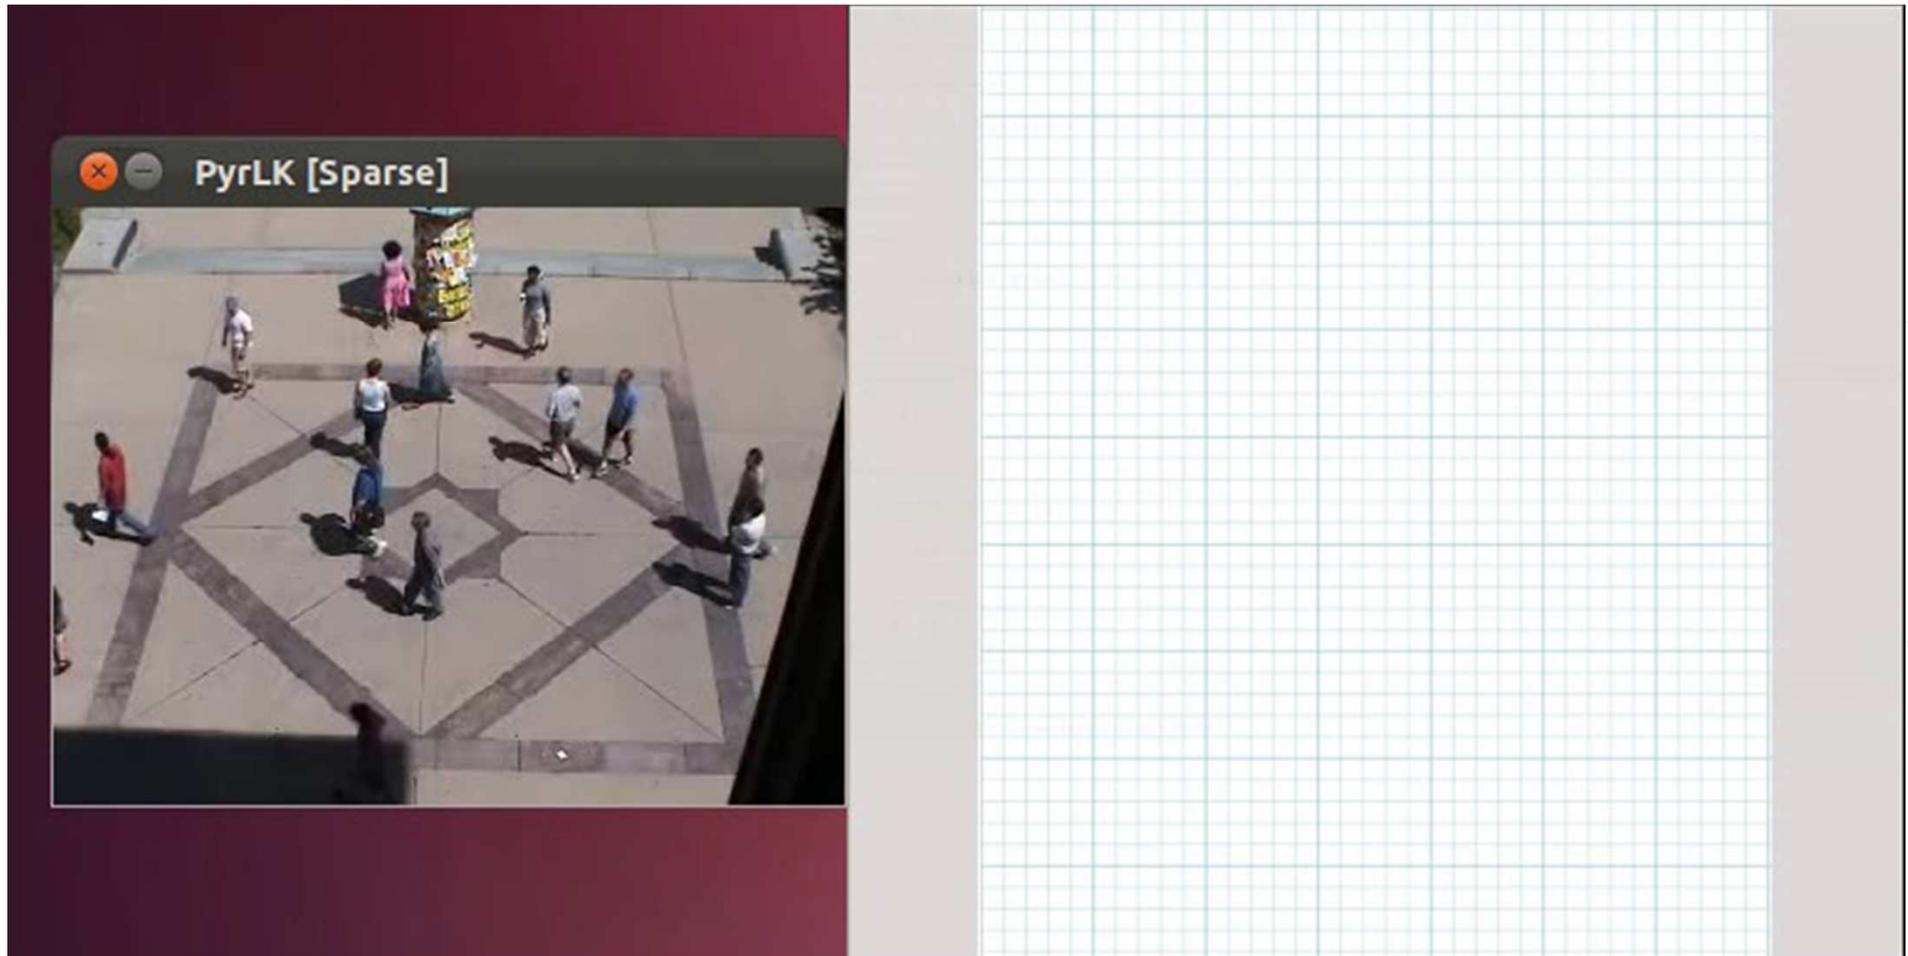


## 3<sup>ème</sup> cas: Détection de mouvements avec caméra mobile



Performances du traitement GPU appliqué à la détection de mouvements

## 4<sup>ème</sup> cas: Détection d'évènement anormaux en temps réel



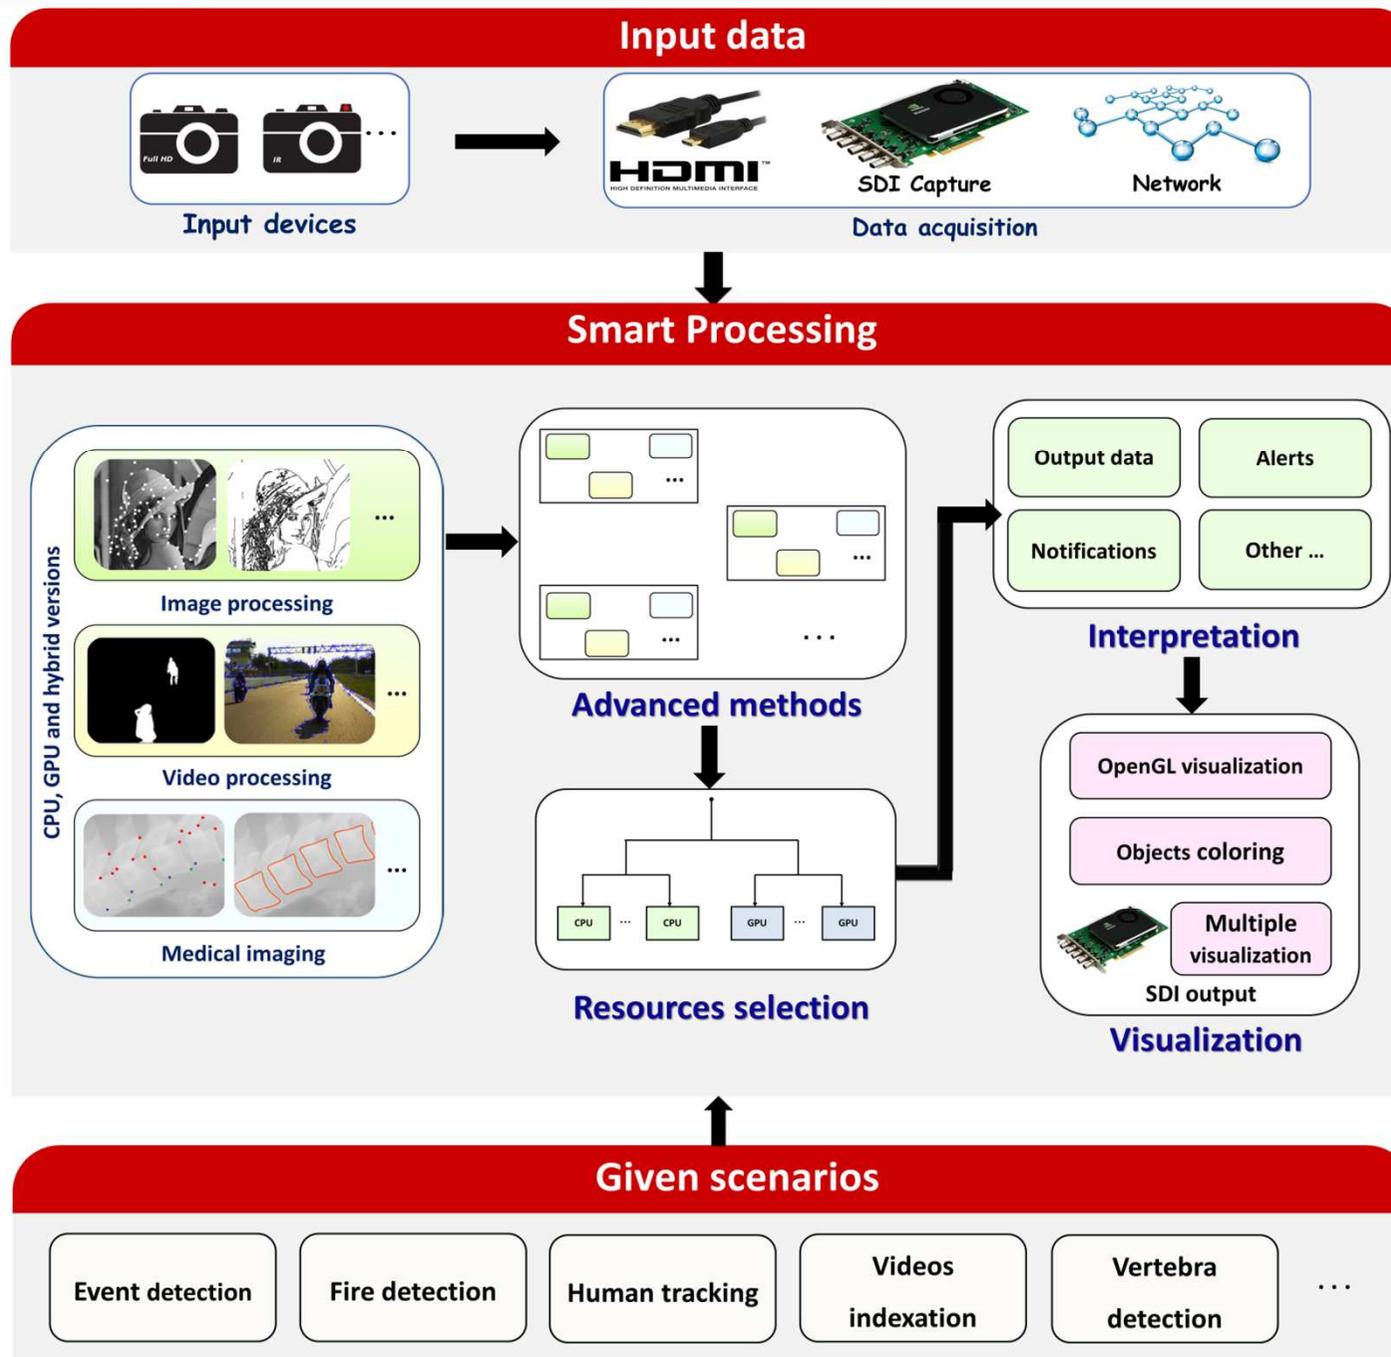
Détection d'évènement anormaux dans la foule (en temps réel)

# Conclusion

- **Traitement parallèle intra et inter-images**
  - Traitement parallèle des pixels sous CUDA et visualisation rapide via OpenGL
  - Exploitation des cœurs CPUs et GPUs multiples
  - Ordonnancement de tâches basé sur l'historique
- **Gestion efficace des mémoires sur GPU multiples**
  - Exploitation adaptée des mémoires partagée et de textures
  - Recouvrement des transferts par les kernels d'exécutions: CUDA streams
- **Traitement GPU/Multi-GPU de vidéos Full HD/4K en temps réel**
  - Méthode de détection, analyse et suivi de mouvements sous CUDA
  - Traitements appliqués en temps réel sur des vidéos HD, Full HD et 4K
- **Choix efficace des ressources**
  - Estimation de complexité (facteur de parallélisation, nombre d'opérations, etc.)
  - Choix de ressource (CPU ou GPU) à partir de ce facteur

# Perspectives

- Estimation de complexité améliorée: ratio calcul/accès mémoire, graphe de dépendances, etc.
- Ordonnancement de tâches prenant en compte plus de paramètres
- Choix automatique du nombre de ressources à exploiter
- Analyse de consommation d'énergie
- Système intelligent de suivi de mouvements dans différents scénarios



## Revue internationale

- F. Lecron, **S. A. Mahmoudi**, M. Benjelloun, S. Mahmoudi and P. Manneback "Heterogeneous Computing for Vertebra Detection and Segmentation in X-Ray Images", *International Journal of Biomedical Imaging : Parallel Computation in Medical Imaging Applications*. Juin 2011.
- **S. A. Mahmoudi**, P. Manneback, C. Augonnet, S. Thibault « Traitement d'Images sur Architectures Parallèles et Hétérogènes », *Revue des sciences et technologies de l'information*. Article vol :31/8-10 – 2012, pp.1183-1203, doi:10.3166/tsi.31.1183-1203, Octobre 2012

## Conférences internationales

- P. D. Possa, **S. A. Mahmoudi**, N. Harb, C. Valderrama " A New Self-Adapting Architecture for Feature Detection ", FPL 2012 : 22nd International Conference on Field Programmable Logic and Applications, Oslo, Novège. Août 2012.
- **S. A. Mahmoudi**, P. Manneback, C. Augonnet, S. Thibault "Détection optimale des coins et contours dans des bases d'images volumineuses sur architectures multi-cœurs hétérogènes", *20eme Rencontres Francophones du Parallélisme, RenPar'20*, Saint-Malo, France. Mai 2011.
- **S. A. Mahmoudi**, S. Frémal, M. Bagein, P. Manneback, "Calcul intensif sur GPU : exemples en traitement d'images, en bio-informatique et en télécommunication", *CIAE 2011 : Colloque d'Informatique, Automatique et Electronique*, Casablanca, Maroc. Mars 2011.
- **S. A. Mahmoudi**, F. Lecron, P. Manneback, M. Benjelloun, S. Mahmoudi, "GPU-Based Segmentation of Cervical Vertebra in X-Ray Images", *Workshop HPCCE. IEEE International Conference on Cluster Computing*, Crete, Greece. Septembre 2010.
- **S. A. Mahmoudi**, P. Manneback, "Parallel Image Processing with CUDA and OpenGL", *Network for High-Performance Computing on Complex Environments*. Lisbon, Portugal. COST ACTION IC 805, WG Meeting. October 2009.
- **S. A. Mahmoudi**, P. Manneback, "Traitements d'images sur GPU sous CUDA et OpenGL : application a l'imagerie médicale", *Journées CIGIL : Calcul Intensif et Grilles Informatiques a Lille*. Lille, France. December 2009.
- **S. A. Mahmoudi**, Pierre Manneback, « Traitement d'objets multimédias sur gpu », Seconde journée scientifique du pôle hainuyer. Belgique, Mai 2010.

## Rapports techniques

- S. Dupont, C. Frisson, **S. A. Mahmoudi**, X. Siebert, J. Urbain, T. Ravet, "MediaBlender : Interactive Multimedia Segmentation and Annotation", *QPSR of the numediart research program*, volume 3, December 2010.
- M. Mancas, R. B. Madkhour, **S. A. Mahmoudi**, T. Ravet, "VirTrack: Tracking for Virtual Studios", *QPSR of the numediart research program*, volume 3, N° 2010
- M. Mancas, J. Tilmanne, R. Chessini, S. Hidot, C. Machy, **S. A. Mahmoudi**, T. Ravet, "MATRIX : Natural Interaction Between Real and Virtual Worlds", *QPRS of the numediart research program*, vol. 1, N° 5, January 2009.
- M. Mancas, M. Bagein, N. Guichard, S. Hidot, C. Machy, **S. A. Mahmoudi**, X. Siebert, "AVS : Augmented Virtual Studio", *QPSR of the numediart*, 2008



**MERCI**