

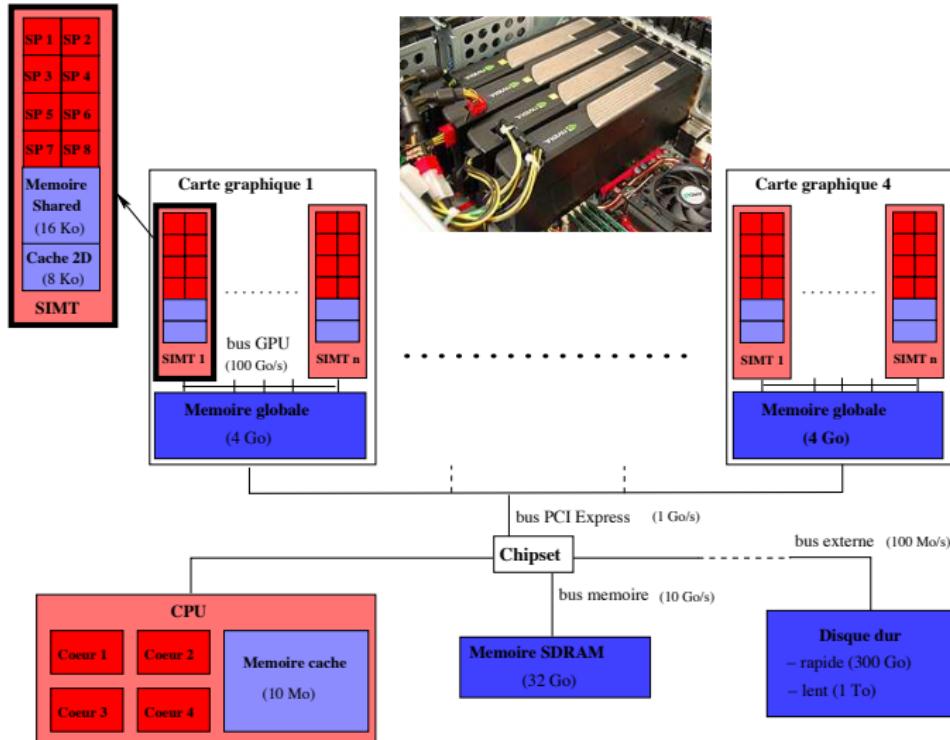
# Parallélisation des calculs sur serveur multi-GPUs pour la résolution de problèmes inverses

Nicolas GAC, MCF Université Paris Sud  
Groupe Problèmes Inverses (GPI)  
Pôle Signaux  
L2S (CentraleSupélec/CNRS/Univ Paris Sud)

NVIDIA/CDS/UPSAclay meeting, LAL, 30 Mars 2015



# Serveur de calcul multi GPU

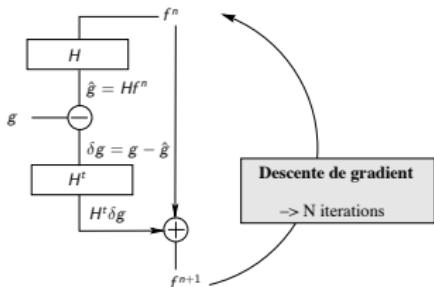


1 Résolution de problème inverse

2 Applications/Projects

- [Deconv1D] Déconvolutions
- [Astro] Méthode d'apprentissage en astronomie
- [Tomo3D] Reconstruction tomographique

# Algorithme itératif



$$\mathbf{g} = \mathbf{Hf} + \epsilon$$

$f$  : objet observé

$g$  : mesure de l'instrument

$H$  : modèle d'acquisition

$\epsilon$  : bruit

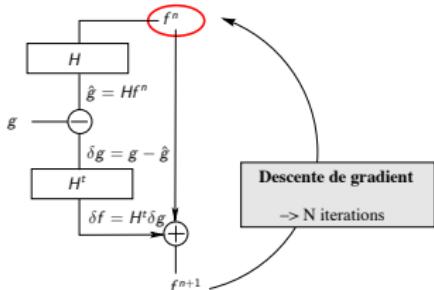
## Descente de gradient

$$J(f) = \|g - Hf\|^2$$

$$f^{n+1} = f^n - \alpha \cdot \nabla J(f^n)$$

$$\nabla J(f) = -2 \cdot H^t (g - Hf)$$

# Algorithme itératif



$f^n$  : Estimée du volume

$$\mathbf{g} = \mathbf{Hf} + \epsilon$$

$f$  : objet observé

$g$  : mesure de l'instrument

$H$  : modèle d'acquisition

$\epsilon$  : bruit

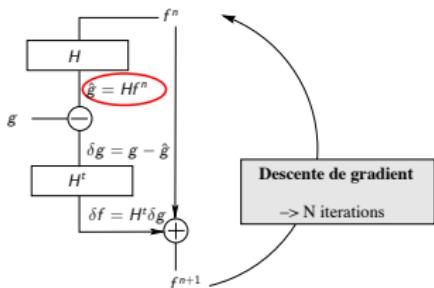
## Descente de gradient

$$J(f) = \|g - Hf\|^2$$

$$f^{n+1} = f^n - \alpha \cdot \nabla J(f^n)$$

$$\nabla J(f) = -2 \cdot H^t (g - Hf)$$

# Algorithme itératif



$\hat{g}$  : Estimée des données

$$\mathbf{g} = \mathbf{Hf} + \boldsymbol{\epsilon}$$

$f$  : objet observé

$g$  : mesure de l'instrument

$H$  : modèle d'acquisition

$\boldsymbol{\epsilon}$  : bruit

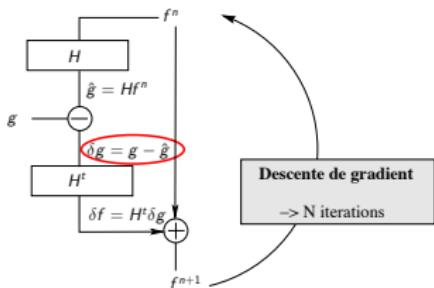
## Descente de gradient

$$J(f) = \|g - Hf\|^2$$

$$f^{n+1} = f^n - \alpha \cdot \nabla J(f^n)$$

$$\nabla J(f) = -2 \cdot H^t(g - Hf)$$

# Algorithme itératif



$\delta g$  : Correction des données

$$\mathbf{g} = \mathbf{Hf} + \epsilon$$

$f$  : objet observé

$g$  : mesure de l'instrument

$H$  : modèle d'acquisition

$\epsilon$  : bruit

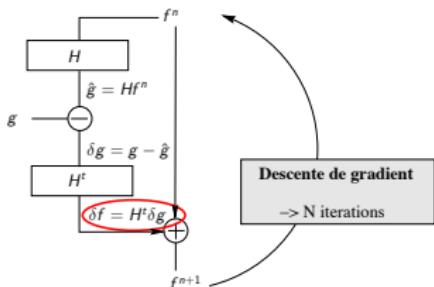
## Descente de gradient

$$J(f) = \|g - Hf\|^2$$

$$f^{n+1} = f^n - \alpha \cdot \nabla J(f^n)$$

$$\nabla J(f) = -2 \cdot H^t (g - Hf)$$

# Algorithme itératif



$\delta f$  : Correction du volume

$$\mathbf{g} = \mathbf{Hf} + \boldsymbol{\epsilon}$$

$f$  : objet observé

$g$  : mesure de l'instrument

$H$  : modèle d'acquisition

$\boldsymbol{\epsilon}$  : bruit

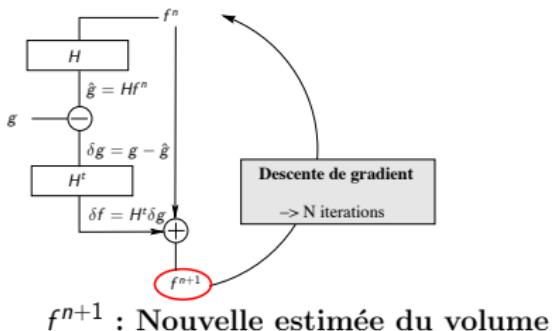
## Descente de gradient

$$J(f) = \|g - Hf\|^2$$

$$f^{n+1} = f^n - \alpha \cdot \nabla J(f^n)$$

$$\nabla J(f) = -2 \cdot H^t (g - Hf)$$

# Algorithme itératif



$f^{n+1}$  : Nouvelle estimée du volume

$$\mathbf{g} = \mathbf{Hf} + \epsilon$$

$f$  : objet observé

$g$  : mesure de l'instrument

$H$  : modèle d'acquisition

$\epsilon$  : bruit

## Descente de gradient

$$J(f) = \|g - Hf\|^2$$

$$f^{n+1} = f^n - \alpha \cdot \nabla J(f^n)$$

$$\nabla J(f) = -2 \cdot H^t(g - Hf)$$

# Correction de vibrations mécaniques par déconvolution 1D

Collaboration avec l'IDES de l'Univ. Paris-Sud (F. Schmidt)  
PhD fellowship financed by CDS (beginning autumn 2015)

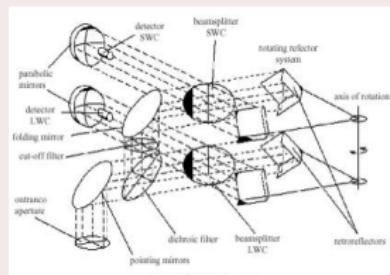
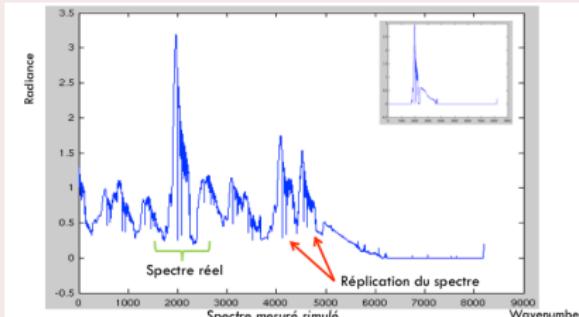


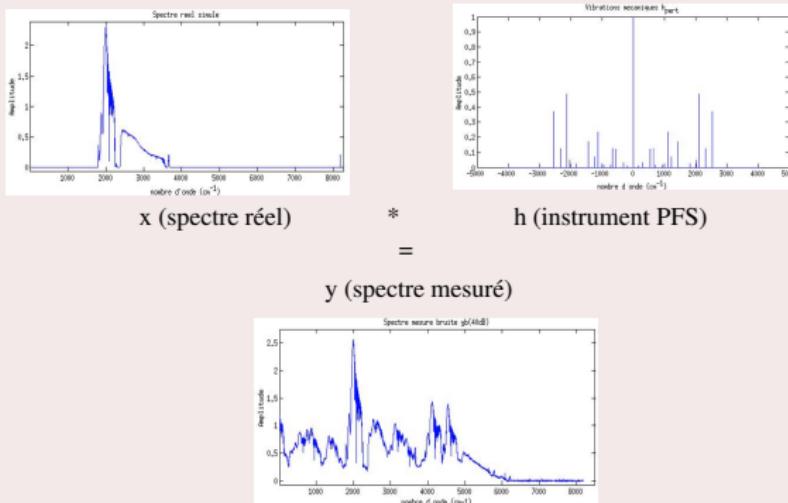
Fig. 1. PFS optical scheme.

Instrument PFS (Planetary Fourier Spectrum) de la mission MARS EXPRESS



# Correction de vibrations mécaniques par déconvolution 1D

Instrument modélisé par une convolution 1D



Taille gigantesque des données

Des années d'enregistrements de la mission MARS EXPRESS (2003) donc potentiellement 1 milliard de spectres (de 8192 échantillons) !

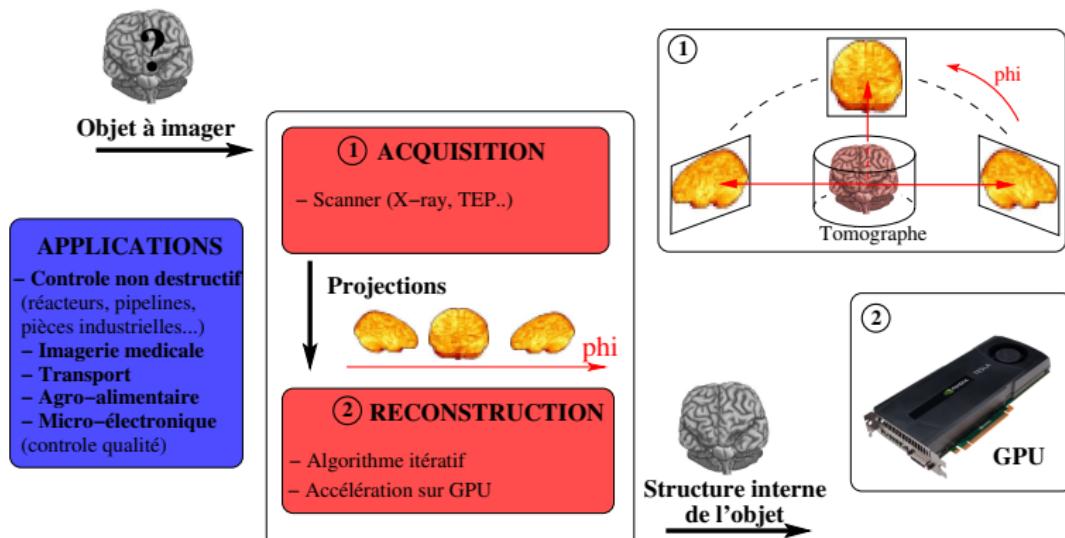
# Projet ANR Magellan (OCA Nice/ENS Cachan/Telecom ParisTech)

Méthodes de reconstruction pour interféromètres du futur (très grands réseaux d'antennes)

Objectif du projet est de s'attaquer à 3 verrous :

- Complexité de la calibration
- Taille des données
- Précisions des méthodes de restauration

# Algorithmes de reconstruction tomographique



# Calcul de $Hf$ et $H^t \delta g$ : choix de la méthode

## ❶ Calcul matriciel

- ⌚ lecture des coefficients  $h_{ij}$  dans la mémoire SDRAM
- ⚠ volume  $2048^3 \rightarrow$  matrice  $H = 1$  To !

# Calcul de $Hf$ et $H^t\delta g$ : choix de la méthode

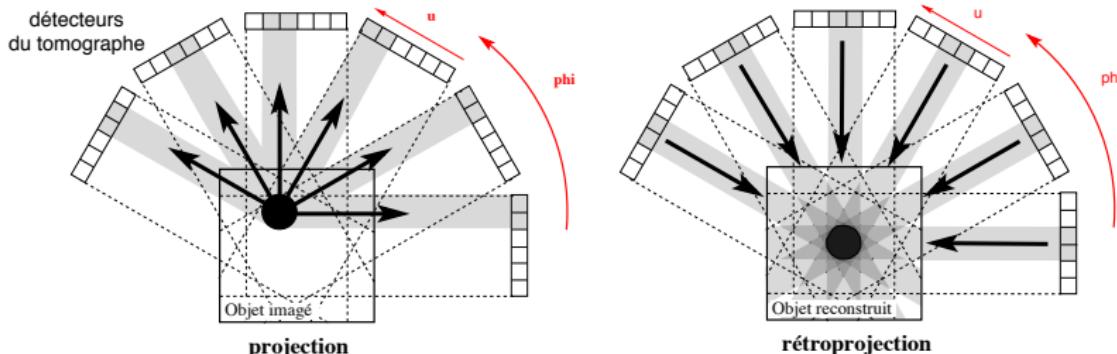
## ❶ Calcul matriciel

- ▷ lecture des coefficients  $h_{ij}$  dans la mémoire SDRAM
- ⚠ volume  $2048^3 \rightarrow$  matrice  $H = 1$  To !

## ❷ Opérateurs géométriques

- ▷ calcul en ligne des coefficients  $h_{ij}$

Paire de projection/rétroprojection en tomographie à émission (géométrie parallèle)



## Temps de reconstruction mono-GPU

Opérateurs	Temps de calcul	
	v1	v2
Projection $2 \times H_P$	4.1 h (42.5 %)	7.1 mn (64.9 %) → $\times 35$
Rétroréprojection $H_{RP}^t$	5.5 h (56.9 %)	21.8 s (3.3 %) → $\times 908$
Convolution $3 \times D$	3.2 mn (0.6 %)	3.2 mn (29.2 %)
Autre	17 s (0.0 %)	17 s (2.6 %)
<b>Total</b>	9.7 h	10.9 mn → $\times 53$

v1 :  $H_P$ ,  $H_{RP}^t$  et  $D$  sur CPU (⚠ code "naif" non optimisé)

v2 :  $H_P$  et  $H_{RP}^t$  sur 1 GPU,  $D$  sur CPU

v3 :  $H_P$  et  $H_{RP}^t$  sur 8 GPUs,  $D$  sur CPU

v4 :  $H_P$  et  $H_{RP}^t$  sur 8 GPUs,  $D$  sur 1 GPU

## Temps de reconstruction multi-GPUs

Opérateurs	Temps de calcul			
	v1	v2	v3	v4
Projection $2 \times H_P$	4.1 h (42.5 %)	7.1 mn (64.9 %) → $\times 35$	57 s (21.1 %) → $\times 7$	57 s (63.3 %)
Rétroprojection $H_{RP}^t$	5.5 h (56.9 %)	21.8 s (3.3 %) → $\times 908$	4.0 s (1.5 %) → $\times 5$	4.0 s (4.4 %)
Convolution $3 \times D$	3.2 mn (0.6 %)	3.2 mn (29.2 %)	3.2 mn (71.1 %)	12.1 s (13.4 %) → $\times 16$
Autre	17 s (0.0 %)	17 s (2.6 %)	17 s (6.3 %)	17 s (18.9 %)
<b>Total</b>	9.7 h	10.9 mn → $\times 53$	4.5 mn → $\times 2.4$	1.5 mn → $\times 3.0$

v1 :  $H_P$ ,  $H_{RP}^t$  et  $D$  sur CPU (⚠ code "naif" non optimisé)

v2 :  $H_P$  et  $H_{RP}^t$  sur 1 GPU,  $D$  sur CPU

v3 :  $H_P$  et  $H_{RP}^t$  sur 8 GPUs,  $D$  sur CPU

v4 :  $H_P$  et  $H_{RP}^t$  sur 8 GPUs,  $D$  sur 1 GPU

# Temps de transfert mémoire PC - GPU

	<b>1 GPU</b>	<b>8 GPUs</b>
Projecteur $H_P$	10 %	37.5 %
Rétroprojecteur $H_{RP}^t$	1.4 %	6.8 %
Convolution $D$	68.9 %	

Proportion du temps de traitement consacré au transfert mémoire entre le PC et la carte graphique pour chaque opérateur lors de la reconstruction d'un volume de  $1024^3$  à partir de 256 projections.