

# Optimisation pour la correction de rayures d'un imageur satellitaire à balayage

Hervé CARFANTAN

Institut de Recherche en Astrophysique et Planétologie (IRAP), OMP, Toulouse



Collaborateurs : Mehdi-Chahine AMROUCHE, IRAP,  
Jérôme IDIER, LS2N, Nantes  
Vincent MARTIN, CNES


Journées Optimisation fonctionnelle – CNES, COMETS-TSI

26 juin 2024

## I. INTRODUCTION

### Imageur satellitaire à balayage (Pushbroom instrument)

- Barrette de détecteurs
- Acquisition d'une ligne de l'image à chaque acquisition





- Le déplacement du satellite balaye l'ensemble des lignes

### Imageur satellitaire à balayage (Pushbroom instrument)



### Rayures dans les imageurs à balayage

- Réponse d'un détecteur de la barrette



- Chaque détecteur de la barrette a une réponse différente

Chaque colonne de l'image acquise par un détecteur

⇒ Effet de rayures sur l'image

## Rayures dans les imageurs à balayage




## Correction de rayures pour un imageur satellitaire à balayage


- **Lors des tests de qualification au sol** du satellite  
Réponse des détecteurs pour des images d'intensités constantes  
Effet peut être modifié lors du lancement !
- **Lors de la recette en vol** du satellite
  - $\left\{ \begin{array}{l} \text{Aux pôles : intensité quasi-constante élevée} \\ \text{Ciel, océan : intensité quasi-nulle} \end{array} \right.$   
Effet peut être modifié avec le temps
- **Correction à partir d'une image quelconque**

???

## Correction de rayures d'un imageur satellitaire à balayage à partir d'une image quelconque



## II. MÉTHODOLOGIE



Correction de l'image  $\Rightarrow$  Algorithmes d'optimisation

### III. CAS D'UN MODÈLE AFFINE POUR CHAQUE DÉTECTEUR

#### Modèle pour la réponse des détecteurs

Scène observée  $S_{\ell,c}$  (ligne  $\ell$ , colonne  $c$ )  $\rightarrow$  Image acquise  $I_{\ell,c}$

- Modèle de réponse affine des détecteurs : gain  $g_c$  et offset  $o_c$  pour colonne  $c$   
 $I_{\ell,c} = g_c S_{\ell,c} + o_c$  détecteur idéal gain  $g_c = 1$  et offset  $o_c = 0$

Changement de paramètres : gain et offset de correction  $a_c$  et  $\gamma_c$


$$I_{\ell,c} = g_c S_{\ell,c} + o_c \Rightarrow S_{\ell,c} = a_c I_{\ell,c} - \gamma_c$$

Valeur moyenne de la scène inconnue ! On impose  $\frac{1}{C} \sum_c a_c = 1$  et  $\sum_c \gamma_c = 0$  !

- Hypothèse statistique : Gains  $a_c$  indépendants Gaussiens  
 $a_c$  de moyenne 1 et de variance  $\sigma_a^2$  fixée :  $a_c \sim \mathcal{N}(1, \sigma_a^2)$
- Hypothèse statistique : Offsets  $\gamma_c$  indépendants Gaussiens  
 $\gamma_c$  de moyenne nulle et de variance  $\sigma_\gamma^2$  fixée :  $\gamma_c \sim \mathcal{N}(0, \sigma_\gamma^2)$

#### Modèle pour la scène observée : corrélation entre pixels voisins

Deux pixels voisins ont des valeurs proches, sauf aux niveau des contours !

- Champs de Gibbs :  
 $\rightarrow$  Loi de probabilité  $f(\mathbf{S}) \propto \exp \left( -\frac{1}{T} \sum_{(\ell,c) \sim (\ell',c')} \phi(S_{\ell,c} - S_{\ell',c'}) \right)$   
 $(\ell, c) \sim (\ell', c')$  


$\rightarrow$  Fonction  $\phi$

$$\phi_2(x) = x^2$$

$$\phi_1(x) = |x|$$

$$\phi_{21}(x) = \sqrt{x^2 + s^2} - s$$

$$\phi_{20}(x) = \frac{x^2}{x^2 + s^2}$$



- Loi de probabilité de l'image : vraisemblance  
Changement de variable  $S_{\ell,c} \rightarrow I_{\ell,c} : f(\{I_{\ell,c}\}_{\ell,c} | \{a_c, \gamma_c\}_c)$

#### Définition des estimateurs des paramètres

##### Cadre Bayésien

Loi *a posteriori* :  $f(\{a_c, \gamma_c\}_c | \{I_{\ell,c}\}_{\ell,c}) \propto \overbrace{f(\{I_{\ell,c}\}_{\ell,c} | \{a_c, \gamma_c\}_c)}^{\text{Vraisemblance}} \overbrace{f(\{a_c, \gamma_c\}_c)}^{a \text{ priori}}$

##### Estimateur du maximum *a posteriori*

$$\arg \max_{\{a_c, \gamma_c\}_c} f(\{a_c, \gamma_c\}_c | \{I_{\ell,c}\}_{\ell,c}) = \arg \min_{\{a_c, \gamma_c\}_c} J_{\text{MAP}}(\{a_c, \gamma_c\}_c)$$

Avec  $J_{\text{MAP}}(\{a_c, \gamma_c\}_c) = \frac{1}{T} \sum_{\ell,c} \phi((a_c I_{\ell,c} - \gamma_c) - (a_c I_{\ell,c+1} - \gamma_c))$  Voisins horizontaux  
 $+ \frac{1}{T} \sum_{\ell,c} \phi(a_c(I_{\ell,c} - I_{\ell+1,c}))$  Voisins verticaux  
 $+ L \sum_c \log |a_c|$  Changement de var.  
 $+ \frac{1}{\sigma_a^2} \sum_c (a_c - 1)^2 + \frac{1}{\sigma_\gamma^2} \sum_c \gamma_c^2$  *a priori* sur  $a_c$  et  $\gamma_c$

##### Problème de barrière logarithmique

Terme  $\log |a_c|$  délicat à prendre en compte dans des algorithmes classique...

- Contraintes égalités :  $\frac{1}{C} \sum_c a_c = 1$  et  $\sum_c \gamma_c = 0$  !

#### Calcul de l'estimateur

$\Rightarrow$  Algorithmes d'optimisation

- Contraintes  $\frac{1}{C} \sum_c a_c = 1$  et  $\sum_c \gamma_c = 0$

On peut montrer que le minimiseur de  $J_{\text{MAP}}$  vérifie  $\sum_c \gamma_c = 0$

$\Rightarrow$  Une unique contrainte égalité :  $\frac{1}{C} \sum_{c=1}^C a_c = 1$

- Minimisation de  $J_{\text{MAP}}$  :

$\rightarrow$  Transformation du problème contraint en un problème non contraint

Par exemple  $a_1 = C - \sum_{c=2}^C a_c$

$\rightarrow$  Algorithmes de type gradient conjugués pré-conditionnés

$\Rightarrow$  Préconditionnement par matrice diagonale (inverse de la diagonale du Hessian)

$\rightarrow$  Minimisation 1D prenant en compte la barrière logarithmique


$\Rightarrow$  Méthode itérative de type approximation quadratique Majorante

### □ Simplification de la fonction coût à minimiser

$$K_{\text{MAP}}(\{a_c, \gamma_c\}_c) = \frac{1}{T} \sum_{\ell,c} \phi((a_c I_{\ell,c} - \gamma_c) - (a_c I_{\ell,c+1} - \gamma_c)) + \frac{1}{\sigma_a^2} \sum_c (a_c - 1)^2 + \frac{1}{\sigma_\gamma^2} \sum_c \gamma_c^2 \\ + \frac{1}{T} \sum_{\ell,c} \phi(a_c(I_{\ell,c} - I_{\ell+1,c})) + L \sum_c \log |a_c|$$

### □ Algorithme d'optimisation (sous contrainte $\sum_c \gamma_c = C$ )

- Algorithme de type *Majorize-Minimize* : **approximation majorante quadratique**
  - Exploitation de la structure du problème (voisins)
- ⇒ A chaque itération : résolution d'un système linéaire Tri-diagonal par bloc



Résultats similaires à  $J_{\text{MAP}} \Rightarrow$  Gain d'un facteur 10 en temps de calcul

### □ Comparaison avec d'autres méthodes Chang *et. al*, IEEE TGRS 2020

*Toward Universal Stripe Removal via Wavelet-Based Deep Convolutional Neural Network*

Method	Year	Input	Imaging	Brief Description	Direction	Estimation
Horn [1]	1979	Single Image	Landsat MSS	Histogram Matching	No	Image
Wegener [2]	1990	Single Image	Landsat MSS	Histogram Matching	No	Image
Corsini [3]	2000	Single Image	MOS-B	Moment Equalization	No	Image
Gadallah [4]	2000	Single Image	Landsat TM	Moment Matching	No	Image
Meza [5]	2016	Multispectral	Hyperspectral	Equalization	No	Image
Simpson [6]	1998	Single Image	GOES-7	Finite Impulse Filters	No	Image
Chen [7]	2003	Single Image	CMODIS	Filtering	No	Image
Chen [8]	2006	Single Image	CMODIS	Wavelet+ FFT	Yes	Image
Liu [9]	2006	Single Image	Landsat-7	FFT + Adaptive Filtering	Yes	Image
Rakwatin [10]	2007	Single Image	MODIS	Moment Matching + Facet Filtering	No	Image
Gómez [11]	2008	Multispectral	CHRIS	Filtering	Yes	Image
Rakwatin [12]	2009	Multispectral	MODIS Band6	Moment Matching + Facet Filtering	No	Image
Münch [13]	2009	Single Image	Medical	Wavelet + FFT	Yes	Image
Wang [14]	2008	Multispectral	MODIS Band6	Interpolation	No	Image
Jung [15]	2010	Multispectral	SPOT4	Detection + Interpolation	No	Image
Chhetri [16]	2011	Single Image	Hyperspectral	Wavelet + FFT	Yes	Image
Gladkova [17]	2011	Multispectral	MODIS Band6	Multivariate Regression	No	Image
Duan [18]	2014	Single Image	Hyperspectral	Reference Calibration + Filtering	No	Image
Cao [19]	2016	Single Image	Infrared	1D Guided Filtering	Yes	Image

### □ Correction de l'image

$$\hat{S}_{\ell,c} = \hat{a}_c I_{\ell,c} - \hat{\gamma}_c$$



### □ Comparaison avec d'autres méthodes Chang *et. al*, IEEE TGRS 2020

Shen [20]	2009	Single Image	MODIS	MAP Framework with Huber-Markov Prior	No	Image
Bisceglie [21]	2009	Single Image	MODIS	Least Squares Minimization	No	Image
Carfantan [22]	2010	Single Image	SPOT3	MAP Framework with Markov field Prior	No	Stripe
Bouali [23]	2011	Single Image	MODIS	Unidirectional Variational	Yes	Image
Fehrenbach [24]	2012	Single Image	Medical	MAP Framework with Huber-Markov Prior	Yes	Stripe
Yuan [25]	2012	Multispectral	Hyperspectral	Spectral-spatial Adaptive Total Variation	No	Image
Chang [26]	2013	Single Image	General	Framelet + Unidirectional Variational	Yes	Image
Chang [27]	2014	Single Image	General	Sparse + Unidirectional Variational	Yes	Image
Chang [28]	2015	Multispectral	General	Anisotropic Spectral-Spatial Total Variation	Yes	Image
Liu [29]	2015	Single Image	General	Sparse + Unidirectional Variational	Yes	Stripe
Aggarwal [30]	2016	Multispectral	Hyperspectral	Spectral-spatial Total Variation	No	Image
Fitschen [31]	2017	Single Image	Medical	Framelet + Unidirectional Variational	Yes	Image
Liu [32]	2018	Single Image	General	Oriented Variational	Yes	Image
Liu [33]	2018	Single Image	General	Feature based Unidirectional Variational	Yes	Image
Acio [35]	2011	Multispectral	Hyperspectral	Orthogonal Subspace Learning	No	Stripe
Lu [36]	2013	Multispectral	Hyperspectral	Graph-regularized Low-rank Representation	No	Both
Zhang [37]	2014	Multispectral	Hyperspectral	Low-rank Matrix Recovery	No	Both
Zhao [38]	2015	Multispectral	Hyperspectral	Sparse + Low-rank Matrix Recovery	No	Image
Wang [39]	2016	Multispectral	Hyperspectral	Group Low-rank Representation	Yes	Both
He [40]	2016	Multispectral	Hyperspectral	Total variation based Low-rank Representation	No	Both
Chang [41]	2016	Multispectral	General	Low-rank Image Decomposition	Yes	Both
Chen [42]	2017	Single Image	General	Group Sparsity + Unidirectional Variational	Yes	Stripe
Chang [43]	2017	Single Image	General	Transformed Low-rank Matrix Recovery	Yes	Image

## ❑ Comparaison avec d'autres méthodes Chang *et. al*, IEEE TGRS 2020

Toward Universal Stripe Removal via Wavelet-Based Deep Convolutional Neural Network

Xie [46]	2016	Multispectral	Hyperspectral	Intrinsic Tensor Sparsity	No	Image
Chang [47]	2017	Multispectral	Hyperspectral	Unidirectional Low-rank Tensor Recovery	No	Image
Fan [48]	2017	Multispectral	Hyperspectral	Low-rank Tensor Recovery	No	Both
Chen [49]	2018	Multispectral	Hyperspectral	ASSTV + Low-rank Tensor Decomposition	Yes	Both
Cao [50]	2018	Multispectral	Hyperspectral	SSTV + Low-rank Tensor Recovery	No	Both
Fan [51]	2018	Multispectral	Hyperspectral	SSTV + Low-rank Tensor Recovery	No	Both
Wang [52]	2018	Multispectral	Hyperspectral	SSTV + Low-rank Tensor Decomposition	No	Both
Kuang [53]	2017	Single Image	Infrared	CNN	No	Image
He [54]	2018	Single Image	Infrared	CNN	No	Image
Xiao [55]	2018	Single Image	Infrared	Local-global CNN	No	Image
Xie [56]	2018	Multispectral	Hyperspectral	Residual Deep CNN	No	Stripe
Zhang [57]	2018	Multispectral	Hyperspectral	Spatial-spectral Gradient CNN	No	Stripe
Chang [58]	2019	Multispectral	Hyperspectral	Residual Deep CNN	No	Stripe
Chang [60]	2019	Single Image	Infrared	Multiscale Residual Deep CNN	No	Stripe

## IV. EXTENSION DE CES TRAVAUX

### ❑ Réglage automatique des paramètres : $T$ et $s$ (de la fonction $\phi$ )

⇒ Réglages empiriques simples à partir de l'image observée !

### ❑ Cas de colonnes atypiques

- Quelques colonnes avec  $a_c \gg 1$  ou  $\gamma_c \gg 0$  : détection simple  
⇒ Modifications simples du modèle/de l'algorithme

### ❑ Modèle de réponse non affine des détecteurs

- Quels modèles? Quadratique, exponentiel, fraction rationnelle?


Pas de modèle simple lié à la physique des détecteurs!

⇒ Correction possible pour un unique détecteur non affine!

⇒ Correction très délicate si tous détecteurs non affines!


## ❑ Comparaison avec d'autres méthodes Chang *et. al*, IEEE TGRS 2020

Toward Universal Stripe Removal via Wavelet-Based Deep Convolutional Neural Network



## ❑ Cas des images multi-spectrales

- Observation de la scène dans plusieurs bandes spectrales



- Profiter de la **corrélation inter-bande** de la scène observée  
⇒ Modifications du modèle pour la scène  
⇒ Modifications de l'algorithme

## ❑ Cadre de ces travaux

- R&T CNES 1999, 2000, 2002 et 2016

## ❑ Publications

- MaxEnt 2000
- IEEE TGRS 2010 : *Statistical Linear Destriping*
- IEEE TGRS 2022 : *Statistical Affine Destriping*

