



HAL
open science

Méthodes de démixage et de fusion des images multispectrales et hyperspectrales de télédétection spatiale

Fatima Zohra Benhalouche

► **To cite this version:**

Fatima Zohra Benhalouche. Méthodes de démixage et de fusion des images multispectrales et hyperspectrales de télédétection spatiale. Traitement des images [eess.IV]. Université Paul Sabatier - Toulouse III, 2018. Français. NNT : 2018TOU30083 . tel-02100067

HAL Id: tel-02100067

<https://theses.hal.science/tel-02100067>

Submitted on 15 Apr 2019

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



THÈSE

En vue de l'obtention du

DOCTORAT DE L'UNIVERSITÉ DE TOULOUSE

Délivré par :

Université Toulouse 3 Paul Sabatier (UT3 Paul Sabatier)

Cotutelle internationale avec "l'Université des Sciences et de la Technologie d'Oran - Mohamed Boudiaf (Algérie)"

Présentée et soutenue par :
Fatima Zohra BENHALOUCHE

le jeudi 3 mai 2018

Titre :

Méthodes de démixtion et de fusion des images multispectrales et hyperspectrales de télédétection spatiale

École doctorale et discipline ou spécialité :

ED MITT : Image, Information, Hypermedia

Unité de recherche :

Institut de Recherche en Astrophysique et Planétologie (IRAP)

Directeur/trice(s) de Thèse :

Yannick DEVILLE et Abdelaziz OUAMRI

Jury :

Hadria FIZAZI	Professeur USTO-MB, Oran (Algérie)	Présidente du Jury
Nasreddine TALEB	Professeur Université SBA (Algérie)	Rapporteur
Karim ABED-MERAIM	Professeur Université d'Orléans (France)	Rapporteur
Ahmed H. BELBACHIR	Professeur USTO-MB, Oran (Algérie)	Examinateur
Yannick DEVILLE	Professeur IRAP-UPS, Toulouse (France)	Directeur de thèse
Abdelaziz OUAMRI	Professeur USTO-MB, Oran (Algérie)	Co-directeur de thèse
Moussa Sofiane KAROUI	Maître de recherche- A CTS Arzew (Algérie)	Encadrant

THÈSE

En vue de l'obtention du Diplôme de Doctorat

Présentée par : FATIMA ZOHRA BENHALOUCHE

Intitulé

**MÉTHODES DE DÉMÉLANGE ET DE FUSION DES IMAGES MULTISPECTRALES ET
HYPERSPÉCTRALES DE TÉLÉDÉTECTION SPATIALE**

Faculté : Génie Électrique

Département : Électronique

Domaine : Sciences et Technologie

Filière : Électronique

Intitulé de la Formation : Techniques modernes de l'information et de la communication.

Devant le Jury Composé de :

<i>Membres de Jury</i>	<i>Grade</i>	<i>Qualité</i>	<i>Domiciliation</i>
<i>Hadria FIZAZI</i>	<i>Prof.</i>	<i>Présidente</i>	<i>USTO MB, Algérie</i>
<i>Abdelaziz OUAMRI</i>	<i>Prof.</i>	<i>Encadrant</i>	<i>USTO MB, Algérie</i>
<i>Yannick DEVILLE</i>	<i>Prof.</i>	<i>Encadrant</i>	<i>UPS Toulouse III, France</i>
<i>Nasreddine TALEB</i>	<i>Prof.</i>	<i>Examineurs</i>	<i>Université SBA, Algérie</i>
<i>Ahmed H. BELBACHIR</i>	<i>Prof.</i>		<i>USTO MB, Algérie</i>
<i>Karim ABED-MERAIM</i>	<i>Prof.</i>	<i>Invité</i>	<i>Université d'Orléans, France</i>
<i>Moussa Sofiane KAROUI</i>	<i>MR-A</i>		<i>CTS, Arzew, Algérie</i>

Année Universitaire : 2017/2018

Dédicaces

A ma mère

A mon père

A mes frères et sœurs

A mes chers amis

Remerciements

Je souhaiterais tout d'abord remercier vivement mes encadrants et directeurs de thèse, avec lesquels cela a été un grand plaisir de travailler pendant ces années, et qui ont su être présents malgré leurs emplois du temps bien chargés. Alors un grand Merci au Professeur Yannick DEVILLE et à Moussa Sofiane KAROUI pour nos nombreux échanges et pour les très nombreuses corrections des articles et du manuscrit. Je remercie également mon co-directeur de thèse, le Professeur Abdelaziz OUAMRI.

Je souhaiterais aussi d'abord remercier les membres de mon jury d'avoir accepté d'évaluer mon travail. Merci à M. Nasreddine TALEB et à M. Karim ABED-MERAIM d'avoir relu mon manuscrit et de l'ensemble de leurs retours. Je remercie aussi M. Ahmed H. BELBACHIR pour sa présence dans mon jury et Mme. Hadria FIZAZI qui a accepté de présider ce jury et d'avoir examiné mon travail. Je remercie également l'ensemble du jury pour ses questions lors de la soutenance. Elles ont amené des discussions intéressantes concernant les différentes suites possible de mes travaux.

Et enfin un grand merci à tous ceux qui ont contribué de près ou de loin à l'élaboration cette thèse, et qui m'ont permis de mener à bien mes travaux et qui m'ont soutenue et encouragée dans les moments difficiles de cette thèse.

Résumé

Au cours de cette thèse, nous nous sommes intéressés à deux principales problématiques de la télédétection spatiale de milieux urbains qui sont : le "démélange spectral " et la "fusion".

Dans la première partie de la thèse, nous avons étudié le démélange spectral d'images hyperspectrales de scènes de milieux urbains. Les méthodes développées ont pour objectif d'extraire, d'une manière non-supervisée, les spectres des matériaux présents dans la scène imagée. Le plus souvent, les méthodes de démélange spectral (méthodes dites de séparation aveugle de sources) sont basées sur le modèle de mélange linéaire. Cependant, lorsque nous sommes en présence de paysage non-plat, comme c'est le cas en milieu urbain, le modèle de mélange linéaire n'est plus valide et doit être remplacé par un modèle de mélange non-linéaire. Ce modèle non-linéaire peut être réduit à un modèle de mélange linéaire-quadratique/bilinéaire. Les méthodes de démélange spectral proposées sont basées sur la factorisation matricielle avec contrainte de non-négativité, et elles sont conçues pour le cas particulier de scènes urbaines. Les méthodes proposées donnent généralement de meilleures performances que les méthodes testées de la littérature.

La seconde partie de cette thèse a été consacrée à la mise en place de méthodes qui permettent la fusion des images multispectrale et hyperspectrale, afin d'améliorer la résolution spatiale de l'image hyperspectrale. Cette fusion consiste à combiner la résolution spatiale élevée des images multispectrales et la haute résolution spectrale des images hyperspectrales. Les méthodes mises en place sont des méthodes conçues pour le cas particulier de fusion de données de télédétection de milieux urbains. Ces méthodes sont basées sur des techniques de démélange spectral linéaire-quadratique et utilisent la factorisation en matrices non-négatives. Les résultats obtenus montrent que les méthodes développées donnent globalement des performances satisfaisantes pour la fusion des données hyperspectrale et multispectrale. Ils prouvent également que ces méthodes surpassent significativement les approches testées de la littérature.

Mots-clés: Imagerie hyper/multispectrale, amélioration de la résolution spatiale/spectrale, démélange spectral linéaire-quadratique/bilinéaire, factorisation en matrices non-négatives linéaire-quadratique/bilinéaire, fusion de données.

Abstract

In this thesis, we focused on two main problems of the spatial remote sensing of urban environments which are: "spectral unmixing" and "fusion".

In the first part of the thesis, we are interested in the spectral unmixing of hyperspectral images of urban scenes. The developed methods are designed to unsupervisedly extract the spectra of materials contained in an imaged scene. Most often, spectral unmixing methods (methods known as blind source separation) are based on the linear mixing model. However, when facing non-flat landscape, as in the case of urban areas, the linear mixing model is not valid any more, and must be replaced by a nonlinear mixing model. This nonlinear model can be reduced to a linear-quadratic/bilinear mixing model. The proposed spectral unmixing methods are based on matrix factorization with non-negativity constraint, and are designed for urban scenes. The proposed methods generally give better performance than the tested literature methods.

The second part of this thesis is devoted to the implementation of methods that allow the fusion of multispectral and hyperspectral images, in order to improve the spatial resolution of the hyperspectral image. This fusion consists in combining the high spatial resolution of multispectral images and high spectral resolution of hyperspectral images. The implemented methods are designed for urban remote sensing data. These methods are based on linear-quadratic spectral unmixing techniques and use the non-negative matrix factorization. The obtained results show that the developed methods give good performance for hyperspectral and multispectral data fusion. They also show that these methods significantly outperform the tested literature approaches.

Keywords: Hyper/multispectral imaging, spatial/spectral resolution enhancement, linear-quadratic/bilinear spectral unmixing, linear-quadratic/bilinear nonnegative matrix factorization, data fusion, multi-sharpening.

ملخص

في هذه الرسالة، ركّزنا على مشكلتين رئيسيتين للاستشعار عن بعد للبيئات الحضرية وهما : "الفصل الطيفي" و "الدمج":

في الجزء الأول من الأطروحة، إهتمنا بالفصل الطيفي لصور الاستشعار عن بعد جد متعددة الأطياف للبيئات الحضرية. تم تصميم طرق لاستخراج، بطريقة غير خاضعة للرقابة، أطياف المواد الموجودة في المكان المصور. في معظم الأحيان، تستند طرق الفك الطيفي (الطرق المعروفة باسم الفصل المكثف للمصادر) إلى نموذج الخلط الخطي. لكن عند دراسة مناظر طبيعية غير مسطحة، كما هو الحال في المناطق الحضرية، نموذج الخلط الخطي لا يصبح صالحاً، ويجب أن يحل محله نموذج خلط غير خطي. يمكن تخفيض هذا النموذج الغير الخطي إلى نموذج خلط خطي تربيعي/ثنائي خطي. تستند طرق فك الطيفي المقترحة على تحليل إلى مصفوفات غير سلبية، مصممة لمشاهد حضرية. الطرق المقترحة عموماً تعطي أداء أفضل مقارنة مع الطرق التقليدية.

أما الجزء الثاني من هذه الأطروحة، فقد خصص لتنفيذ الأساليب التي تسمح بدمج صور متعددة الأطياف و جد متعددة الأطياف من أجل تحسين الدقة المكانية للصورة جد متعددة الأطياف، وذلك بدمج الدقة المكانية العالية للصور متعددة الأطياف و الدقة الطيفية العالية للصور جد متعددة الأطياف. الطرق المنفذة هي طرق مصممة لبيانات الاستشعار عن بعد الحضرية. تظهر النتائج التي تم الحصول عليها أن الأساليب المقدمة تعطي أداء جيد لدمج الصور متعددة الأطياف و الصور جد متعددة الأطياف. وتظهر أيضاً أن هذه الأساليب تتفوق بشكل ملحوظ على الطرق التقليدية.

كلمات المفتاح : صور متعددة الأطياف و جد متعددة الأطياف، تعزيز القرار المكاني/الطيفي، الفصل الطيفي الغير خطي، طرق تحليل إلى المصفوفات الغير سلبية، دمج الصور.

Table des matières

DEDICACES	I
REMERCIEMENTS.....	II
RESUME.....	III
ABSTRACT	IV
ملخص.....	V
TABLE DES MATIERES	VI
LISTE DES FIGURES.....	X
LISTE DES TABLEAUX.....	XIII
NOTATIONS.....	XV
TABLE DES ACRONYMES	XVI
INTRODUCTION GENERALE	1
1. L'imagerie de télédétection en observation de la Terre.....	2
2. Analyse d'images de télédétection et extraction d'informations.....	5
3. Problématiques de la thèse	6
4. Plan du manuscrit.....	8
PARTIE 1 : DEMELANGE SPECTRAL DES IMAGES DE TELEDETECTION SPATIALE.....	10
INTRODUCTION	11
CHAPITRE 1 : SEPARATION AVEUGLE DE SOURCES (SAS) ET DEMELANGE SPECTRAL.....	13
1.1. Introduction.....	14
1.2. Présentation de la Séparation Aveugle de Sources (SAS)	14
1.3. Les modèles de mélanges usuels	15
1.3.1. Mélanges linéaires	15
1.3.2. Mélanges non-linéaires.....	17
1.4. Méthodes de séparation de sources pour les mélanges linéaires	18
1.4.1. Méthodes basées sur l'Analyse en Composantes Indépendantes	19
1.4.2. Méthodes basées sur l'Analyse en Composantes Parcimonieuses	21

1.4.3. Méthodes basées sur la Factorisation en Matrices Non-négatives	22
1.5. Méthodes de séparation de sources pour les mélanges non-linéaires	26
1.6. Le démixage spectral.....	28
1.6.1. Méthodes de démixage spectral pour le mélange linéaire	28
1.6.1.1. Méthodes géométriques de démixage spectral	30
1.6.1.2. Les méthodes basées sur l'analyse en composantes indépendantes.....	33
1.6.1.3. Les méthodes basées sur l'analyse en composantes parcimonieuses.....	34
1.6.1.4. Les méthodes basées sur la factorisation en matrices non-négatives	34
1.6.2. Méthodes de démixage spectral pour des mélanges non-linéaires	35
1.6.2.1. Méthodes de démixage spectral pour des modèles de mélange non-linéaires non-définis	36
1.6.2.2. Méthodes de démixage spectral pour des modèles de mélange non-linéaires spécifiques	36
1.7. Conclusion.....	40
CHAPITRE 2 : METHODES NON-LINEAIRES DE DEMELANGE SPECTRAL PROPOSEES	42
2.1. Introduction.....	43
2.2. Modèle mathématique de données	43
2.3. Méthodes proposées	46
2.3.1. Critère optimisé	46
2.3.2. Première méthode proposée : méthode à gradient projeté.....	48
2.3.2.1. Algorithme pour mélanges bilinéaires.....	50
2.3.2.2. Algorithme pour mélanges linéaire-quadratiques.....	51
2.3.3. Deuxième méthode proposée : méthode multiplicative.....	53
2.3.3.1. Algorithme multiplicatif pour mélanges bilinéaires.....	54
2.3.3.2. Algorithme multiplicatif pour mélanges linéaire-quadratiques.....	54
2.4. Conclusion.....	55
CHAPITRE 3 : TESTS ET PERFORMANCES	56
3.1. Introduction.....	57
3.2. Protocoles de test	57
3.2.1. Initialisation des algorithmes	57
3.2.1.1. Initialisations sans information a priori (<i>init 1</i>)	57
3.2.1.2. Initialisation avec information a priori (<i>init 2</i>)	58
3.2.2. Critères de performances	58

3.3. Résultats et discussion.....	60
3.3.1. Test 1	61
3.3.1.1. Résultats avec l'initialisation <i>init 1</i>	63
3.3.1.2. Résultats avec l'initialisation <i>init 2</i>	65
3.3.2. Test 2	70
3.4. Conclusion.....	80
CONCLUSION ET PERSPECTIVES	81
<i>PARTIE 2 : FUSION D'IMAGES DE TELEDETECTION SPATIALE</i>	83
INTRODUCTION	84
CHAPITRE 1 : ÉTAT DE L'ART EN FUSION D'IMAGES DE TELEDETECTION SPATIALE.....	87
1.1. Introduction.....	88
1.2. Hypothèses	88
1.3. Méthodes de Pansharpening.....	88
1.3.1. Les méthodes à substitution de composantes	89
1.3.2. Les méthodes d'analyse multirésolution	91
1.3.3. Les méthodes variationnelles.....	93
1.4. Méthodes de Multisharpening.....	94
1.4.1. Les méthodes bayésiennes.....	94
1.4.2. Méthodes fondées sur la Factorisation en Matrices Non-négatives	95
1.4.2.1. Méthode dite Coupled Non-negative Matrix Factorization (CNMF).....	97
1.4.2.2. Méthode dite Joint Non-negative Matrix Factorization (JNMF).....	100
1.5. Conclusion.....	101
CHAPITRE 2 : METHODES PROPOSEES POUR LE MULTISHARPENING.....	103
2.1. Introduction.....	104
2.2. Modèle mathématique de données	105
2.2.1. Rappel sur le modèle mathématique d'une image de télédétection	105
2.2.2. Modèles mathématiques des images considérées	107
2.3. Les méthodes de multisharpening proposées.....	107
2.3.1. Critères optimisés	108
2.3.2. Première méthode proposée.....	110
2.3.2.1. Première approche : HMF-LQNMF	110
2.3.2.2. Deuxième approche : CHMF-LQNMF	113
2.3.2.3. Troisième approche : JHMF-LQNMF.....	114

2.3.2.4. Quatrième approche : Multi-JCLQNMF	114
2.3.3. Deuxième méthode proposée.....	120
2.4. Conclusion.....	124
CHAPITRE 3 : TESTS ET PERFORMANCES	125
3.1. Introduction.....	126
3.2. Protocoles de tests.....	126
3.2.1. Données testées.....	126
3.2.1.1. Données synthétiques	126
3.2.1.2. Données réelles.....	129
3.2.2. Initialisation des algorithmes	129
3.2.3. Critères de performances	131
3.3. Résultats et discussion.....	134
3.3.1. Performances de l'approche HMF-LQNMF	135
3.3.1.1. Résultats avec les données synthétiques.....	135
3.3.1.2. Résultats avec les données réelles	147
3.3.2. Comparaison des performances des méthodes proposées	150
3.3.2.1. Résultats avec les données synthétiques.....	151
3.3.2.2. Résultats avec les données réelles	157
3.4. Conclusion.....	159
CONCLUSION ET PERSPECTIVES	160
CONCLUSION GENERALE	162
REFERENCES BIBLIOGRAPHIQUES.....	165
PUBLICATIONS SCIENTIFIQUES DE L'AUTEUR.....	180

Liste des figures

Introduction générale

Figure 1 :	Représentation d'une image hyperspectrale sous forme d'hypercube.	3
Figure 2 :	Images de télédétection spatiale optique avec différentes résolutions spatiales. (a) Image de basse résolution spatiale. (b) Image de haute résolution spatiale.	4
Figure 3 :	(a) Spectre multispectral (vu par le capteur multispectral Landsat Thematic Mapper). (b) Spectre hyperspectral (vu par le capteur AVIRIS).	4
Figure 4 :	Schéma de base des différentes étapes du processus d'analyse d'images et extraction d'informations en télédétection spatiale.	5
Figure 5 :	Illustration d'un mixel (pixel mélangé) contenant plusieurs matériaux purs.	6

Partie 1 : Démélange spectral des images de télédétection spatiale

Chapitre 1 : Séparation Aveugle de Sources (SAS) et démélange spectral

Figure 1.1 :	Structure générale du problème de séparation de sources.	15
Figure 1.2 :	Différents cônes englobant des données observées.	23
Figure 1.3 :	Illustration du modèle de mélange linéaire.	29
Figure 1.4 :	Représentation en deux bandes des observations contenues dans un simplexe.	31
Figure 1.5 :	Illustration du modèle de mélanges non-linéaires : (a) réflexions multiples, (b) mélange intime.	35

Chapitre 3 : Tests et performances

Figure 3.1 :	Spectres originaux. (a) Premier ensemble : spectres sélectionnés aléatoirement (USGS). (b) Deuxième ensemble : spectres de milieux urbains (JHU).	62
Figure 3.2 :	Exemple d'un spectre original (dataset 1.1 du Test 1- générées selon le modèle de mélange bilinéaire) avec ses estimés.	68
Figure 3.3 :	Exemple d'un spectre original (dataset 2.1 du Test 1- générées selon le modèle de mélange bilinéaire) avec ses estimés.	68
Figure 3.4 :	Exemple d'un spectre original (dataset 1.2 du Test 1- générées selon le modèle de mélange linéaire-quadratique) avec ses estimés.	69
Figure 3.5 :	Exemple d'un spectre original (dataset 2.2 du Test 1- générées selon le modèle de mélange linéaire-quadratique) avec ses estimés.	69
Figure 3.6 :	Cartes de fractions d'abondances linéaires.	71

Figure 3.7 :	Spectres originaux (spectres N°1-N°4) et spectres estimés - spectres de milieux urbains - donnée data 2.1 du Test 2- générée selon le modèle de mélange bilinéaire.	76
Figure 3.8 :	Spectres originaux (spectres N°5-N°8) et spectres estimés - spectres de milieux urbains - donnée data 2.1 du Test 2- générée selon le modèle de mélange bilinéaire	77
Figure 3.9 :	Spectres originaux (spectres N°1-N°4) et spectres estimés - spectres de milieux urbains - donnée data 2.2 du Test 2- générée selon le modèle de mélange linéaire-quadratique	78
Figure 3.10 :	Spectres originaux (spectres N°5-N°8) et spectres estimés - spectres de milieux urbains - donnée data 2.2 du Test 2- générée selon le modèle de mélange linéaire-quadratique.	79

Partie 2 : Fusion d'images de télédétection spatiale

Introduction

Figure 1 :	Illustration de spectres obtenus à partir d'images de télédétection : (a) image hyperspectrale, (b) image multispectrale.	84
Figure 2 :	Images de télédétection spatiale avec différentes résolutions spatiales : (a) image hyperspectrale de faible résolution spatiale, (b) image multispectrale de haute résolution spatiale.	85

Chapitre 1 : État de l'art en fusion d'images de télédétection spatiale

Figure 1.1 :	Schéma de la méthode IHS.	89
Figure 1.2 :	Schéma du principe de fusion par l'analyse en composantes principales.	90
Figure 1.3 :	Décomposition d'une image sous forme matricielle.	96
Figure 1.4 :	Concept de la CNMF.	98

Chapitre 3 : Tests et performances

Figure 3.1 :	Image semi-réelle hyperspectrale associée aux données DSM dérivées du LIDAR.	128
Figure 3.2 :	Bande spectrale (dans la région de 0.815 μm) de l'image hyperspectrale de référence (originale) à haute résolution spatiale, image hyperspectrale à faible résolution spatiale, images hyperspectrales à haute résolution spatiale fusionnée. - ensemble de données dataset 1.1, facteur d'échelle 4.	139
Figure 3.3 :	Bande spectrale (dans la région de 0.815 μm) de l'image hyperspectrale de référence (originale) à haute résolution spatiale, image hyperspectrale à faible résolution spatiale, images hyperspectrales à haute résolution spatiale fusionnée. - ensemble de données dataset 2.1, facteur d'échelle 4.	140
Figure 3.4 :	Bande spectrale (dans la région de 0.815 μm) de l'image hyperspectrale de référence (originale) à haute résolution spatiale, image hyperspectrale à faible résolution spatiale, images hyperspectrales à haute résolution spatiale	141

	fusionnée. - ensemble de données dataset 1.2, facteur d'échelle 4.	
Figure 3.5 :	Bande spectrale (dans la région de 0.815 μm) de l'image hyperspectrale de référence (originale) à haute résolution spatiale, image hyperspectrale à faible résolution spatiale, images hyperspectrales à haute résolution spatiale fusionnée. - ensemble de données dataset 2.2, facteur d'échelle 4.	142
Figure 3.6 :	Histogramme des valeurs du critère SAM (en degrés) et des valeurs du critère PSNR (en décibels) - ensemble de données dataset 1.1, facteur d'échelle 4.	143
Figure 3.7 :	Histogramme des valeurs du critère SAM (en degrés) et des valeurs du critère PSNR (en décibels) - ensemble de données dataset 2.1, facteur d'échelle 4.	144
Figure 3.8 :	Histogramme des valeurs du critère SAM (en degrés) et des valeurs du critère PSNR (en décibels) - ensemble de données dataset 1.2, facteur d'échelle 4.	145
Figure 3.9 :	Histogramme des valeurs du critère SAM (en degrés) et des valeurs du critère PSNR (en décibels) - ensemble de données dataset 2.2, facteur d'échelle 4.	146
Figure 3.10 :	Bande spectrale (dans la région de 0.815 μm) pour les données réelles (EO-1 Hyperion et EO-1 Landsat ETM +), de l'image hyperspectrale à faible résolution spatiale et des images hyperspectrales estimées.	149
Figure 3.11 :	Bande spectrale (dans la région de 0.815 μm) pour les données réelles (EO-1 Hyperion et EO-1 ALI), de l'image hyperspectrale à faible résolution spatiale et des images hyperspectrales estimées.	150
Figure 3.12 :	Histogramme des valeurs du critère SAM (en degrés) et les valeurs du critère PSNR (en décibels).	157

Liste des tableaux

Partie 1 : Démélange spectral des images de télédétection spatial

Tableau 3.1 :	Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 1.1 (générées selon le modèle de mélange bilinéaire) du Test 1.	63
Tableau 3.2 :	Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 2.1 (générées selon le modèle de mélange bilinéaire) du Test 1.	63
Tableau 3.3 :	Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 1.2 (générées selon le modèle de mélange linéaire-quadratique) du Test 1.	64
Tableau 3.4 :	Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 2.2 (générées selon le modèle de mélange linéaire-quadratique) du Test 1.	64
Tableau 3.5 :	Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 1.1 (générées selon le modèle de mélange bilinéaire) du Test 1.	65
Tableau 3.6 :	Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 2.1 (générées selon le modèle de mélange bilinéaire) du Test 1.	66
Tableau 3.7 :	Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 1.2 (générées selon le modèle de mélange linéaire-quadratique) du Test 1.	66
Tableau 3.8 :	Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 2.2 (générées selon le modèle de mélange linéaire-quadratique) du Test 1.	67
Tableau 3.9 :	Moyennes des valeurs des critères obtenues sur la donnée data 1.1 (générée selon le modèle de mélange bilinéaire) du Test 2.	72
Tableau 3.10 :	Moyennes des valeurs des critères obtenues sur donnée data 2.1 (générée selon le modèle de mélange bilinéaire) du Test 2.	72
Tableau 3.11 :	Moyennes des valeurs des critères obtenues sur la donnée data 1.2 (générée selon le modèle de mélange linéaire-quadratique) du Test 2.	73
Tableau 3.12 :	Moyennes des valeurs des critères obtenues sur la donnée data 2.2 (générée selon le modèle de mélange linéaire-quadratique) du Test 2.	73

Partie 2 : Fusion d'images de télédétection spatiale

Tableau 3.1 :	Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 1.1.	136
Tableau 3.2 :	Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 2.1.	137
Tableau 3.3 :	Coûts de calcul et moyennes des critères spectraux et spatiaux pour	137

	l'ensemble de données dataset 1.2.	
Tableau 3.4 :	Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 2.2.	138
Tableau 3.5 :	Valeurs des coûts de calcul et des critères d'évaluation pour les données réelles : EO-1 Hyperion avec Landsat ETM +.	147
Tableau 3.6 :	Valeurs des coûts de calcul et des critères d'évaluation pour les données réelles : EO-1 Hyperion avec EO-1 ALI.	147
Tableau 3.7 :	Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 1.1.	151
Tableau 3.8 :	Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 2.1.	152
Tableau 3.9 :	Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 1.2.	152
Tableau 3.10 :	Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 2.2.	153
Tableau 3.11 :	Coûts de calcul et moyennes des critères spectraux et spatiaux.	155
Tableau 3.12 :	Valeurs des coûts de calcul et des critères d'évaluation pour les données réelles: EO-1 Hyperion avec Landsat ETM +.	1578
Tableau 3.13 :	Valeurs des coûts de calcul et des critères d'évaluation pour les données réelles: EO-1 Hyperion avec EO-1 ALI.	158

Notations

Symboles mathématiques

α	Scalaire
x	Vecteur
X	Matrice
X^{-1}	Inverse de la matrice X
X^+	Matrice pseudo-inverse de Moore-Penrose de X
I	Matrice identité avec les dimensions appropriées.
$(.)^T$ ou $[.]^T$	Transposition (peut être appliquée à un vecteur ou une matrice)
x_{ij} ou $[X]_{ij}$	(ij) -ème élément de la matrice X
R^+	Ensemble des nombres réels non négatifs
$[.]_+$	Projection sur R^+
$\ \cdot \ _2$	Norme l_2
$\ \cdot \ _F$	Norme de Frobenius (pour les matrices)
$\langle \cdot, \cdot \rangle$	Produit scalaire
$ \cdot $	Valeur absolue
$\ln(\cdot)$	Logarithme népérien
$*$	Opérateur de convolution
$\cdot \leftarrow \cdot$	Affectation de la valeur du terme à droite de la flèche à la variable à gauche de la flèche
\odot	Multiplication élément par élément (utilisée pour des vecteurs ou des matrices)
\oslash ou $./$	Division élément par élément (utilisée pour des vecteurs ou des matrices)
ε	Terme ajouté au dénominateur d'un quotient et choisi positif et très petit pour éviter les divisions par zéro.

Table des acronymes

ACI	Analyse en Composantes Indépendantes.
ACP	Analyse en Composantes Principales.
ACPa	Analyse en Composantes Parcimonieuses.
ALI	Advanced Land Imager.
ALS	Alternating Least Square.
AMARTIS	Advanced Modelling of the Atmospheric Radiative Transfer for Inhomogeneous Surfaces.
AMUSE	Algorithm for Multiple Unknown Signals Extraction.
ARSIS	Amélioration de la Résolution Spatiale par Injection de Structures.
AS	Angle Spectral.
BMI	Blind Mixture Identification.
BSS	Blind Source Separation.
CHMF-LQNMF	Coupled Hyperspectral and Multispectral data Fusion based on Linear-Quadratic Nonnegative Matrix Factorization.
CNMF	Coupled Nonnegative Matrix Factorization.
CS	Component Substitution.
DIS	Divergence d'Information Spectrale.
DSM	Digital Surface Model.
DWT	Discrete Wavelet Transform.
EO	Earth Observation.
EQMN	Erreur Quadratique Moyenne Normalisée.
ERGAS	Erreur Relative Globale Adimensionnelle de Synthèse.
FastICA	Fast Independent Component Analysis.
FCLS	Fully Constrained Least Squares.
FMN	Factorisation en Matrices Non-négatives.
FMP	Factorisation en Matrices Positives.
GBM	Generalized Bilinear Model.
GIHS	Generalized Intensity Hue Saturation.

GLP	Generalized Laplacian Pyramid.
GP	Gaussian Pyramid.
GPLVM	Gaussian Process Latent Variable Model.
Grd-LQNMF	Gradient Linear-Quadratic Nonnegative Matrix Factorization.
Grd-LS-NS-LQMF	Gradient-based Least-Squares Nonnegative-Spectra Linear-Quadratic Matrix Factorization.
Grd-New-LQNMF	Gradient-Newton Linear-Quadratic Nonnegative Matrix Factorization.
Grd-NS-LS-BMF	Gradient-based Nonnegative-Spectra Least-Squares Bilinear Matrix Factorization.
GS	Gram-Schmidt.
GSA	Gram-Schmidt Adaptative.
HFC	Harsanyi-Farrand-Chang eigenthresholding based methods.
HMF-LQNMF	Hyperspectral and Multispectral data Fusion based on Linear-Quadratic Nonnegative Matrix Factorization.
HySime	Hyperspectral Signal identification by minimum error.
IAM	Identification Aveugle de Mélanges.
ICA	Independent Component Analysis.
IFOV	Instantaneous Field Of View.
IHS	Intensity Hue Saturation.
ITS	Intensité, Teinte et Saturation.
JADE	Joint Approximate Diagonalization of Eigenmatrices.
JHMF-LQNMF	Joint Hyperspectral and Multispectral data Fusion based on Linear-Quadratic Nonnegative Matrix Factorization.
JHU	Johns Hopkins University.
JNMF	Joint Nonnegative Matrix Factorization.
KFCLS	Kernel Fully Constrained Least Squares.
KL	Kullback-Leibler.
Landsat ETM+	Land satellite Enhanced Thematic Mapper Plus.
Landsat TM	Land satellite Thematic Mapper.
Lin-Ext-NMF	Linear Extended Nonnegative Matrix Factorization.
LI-TEPCORR	Linear Instantaneous-TEMPoral CORRelation.

LI-TEMPROM	Linear Instantaneous-TEMPoral Ratio Of Mixtures.
LI-TIFCORR	Linear Instantaneous-TIme-Frequency CORRelation.
LI-TIFROM	Linear Instantaneous-TIme-Frequency Ratio Of Mixtures.
Local- HMF-LQNMF	Local Hyperspectral Data Multi-Sharpening Based on Linear/Linear-Quadratic Nonnegative Matrix Factorization.
LP	Laplacian Pyramid.
LQ	Linéaire-Quadratique (<i>Linear-Quadratic</i>)
LQNMF	Linear-Quadratic Nonnegative Matrix Factorization.
LQSU	Linear-Quadratic Spectral Unmixing. Démélange Spectral Linéaire-Quadratique.
LSU	Linear Spectral Unmixing. Démélange Spectral Linéaire.
MAP	Maximum a Posteriori.
MBG	Modèle Bilinéaire Généralisé.
ML	Maximum likelihood (<i>Maximum de Vraisemblance</i>).
MNF	Maximum Noise Fraction.
MNT	Modèle Numérique de Terrain.
mQNR	modified Quality with No Reference.
MRA	MultiResolution Analysis (<i>Analyse MultiRésolution</i>).
Multi-JCLQNMF	Multiplicative Joint-Criterion Linear-Quadratic Nonnegative Matrix Factorization.
Multi-NS-LS-BMF	Multiplicative Nonnegative-Spectra Least-Squares Bilinear Matrix Factorization.
Multi-NS-LS-LQMF	Multiplicative Nonnegative-Spectra Least-Squares Linear-Quadratic Matrix Factorization.
Mult-LQNMF	Multiplicative Linear-Quadratic Nonnegative Matrix Factorization.
MVC-NMF	Minimum Volume Constrained-Nonnegative Matrix Factorization.
MVSA	Minimum Volume Simplex Analysis.
NCLS	Non-Negativity Constrained Least Squares.
N-FINDR	Fast autonomous spectral endmember determination algorithm.
NLPCA	NonLinear Principal Component Analysis (<i>Analyse en Composantes Principales Non Linéaire</i>).
NM	Modèle Nascimento.
NMF	Nonnegative Matrix Factorization.

NMSE	Normalized Mean Square Error.
NWHFC	Noise Whitened Harsanyi-Farrand-Chang eigenthresholding based methods.
PCA	Principal Component Analysis.
PG	Pyramide Gaussienne.
PL	Pyramide Laplacienne.
PMF	Positive Matrix Factorization.
PPI	Pixel Purity Index.
PSNR	Peak Signal to Noise Ratio.
RKHS	Reproducing Kernel Hilbert Spaces.
RMSE	Root Mean Square Error.
SAM	Spectral Angle Mapper.
SAS	Séparation Aveugle de Sources.
SCA	Sparse Component Analysis.
SFIM	Smoothing Filter-based Intensity Modulation.
SGM	Split Gradient Method.
SID	Spectral Information Divergence.
SISAL	Simplex Identification via Split Augmented Lagrangian.
SMACC	Sequential Maximum Angle Convex Cone.
SOBI	Second-Order Blind Identification.
SPICE	Sparsity-Promoting Iterated Constrained Endmember.
Spot HRV	Système pour l'observation de la Terre Haute Résolution Visible.
SU	Spectral Umixing (<i>Démélange Spectral</i>).
TDO	Transformée Discrètes en Ondelettes.
UIQI	Universal Image Quality Index (<i>Indice de Qualité d'Image Universel</i>).
USGS	United States Geological Survey.
VCA	Vertex Component Analysis.
VD	Virtual Dimensionality.
WDO	W-Disjoint-Orthogonality.

Introduction générale

Sommaire

1. L'imagerie de télédétection en observation de la Terre.....	2
2. Analyse d'images de télédétection et extraction d'informations.....	5
3. Problématiques de cette thèse	6
4. Plan du manuscrit	8

Dans cette introduction, des généralités sur les principes de base de l'imagerie de télédétection spatiale pour des applications d'observation de la Terre sont données. Nous commençons par présenter les principales caractéristiques à prendre en compte lors du choix des images de télédétection. Nous abordons aussi les différentes étapes du processus d'analyse de l'imagerie de télédétection et d'extraction d'informations. Par la suite, nous détaillons les problématiques abordées ainsi que les objectifs de cette thèse.

1. L'imagerie de télédétection en observation de la Terre

La télédétection (*Remote Sensing*) est la technique qui, par l'acquisition, permet d'obtenir de l'information sur la surface de la Terre par des mesures effectuées à distance et collectées par des dispositifs (avion, satellite...etc.) qui ne sont pas en contact direct avec celle-ci [1].

Le développement des techniques de la télédétection résulte, d'une part de l'invention des ballons, plates-formes satellitaires et aéroportées qui permettent de mesurer un signal en provenance des surfaces observées, et d'autre part de la constante évolution des capteurs permettant d'enregistrer ce signal, pour le suivi de multiples phénomènes qui affectent la surface de la Terre ou de l'atmosphère.

Cette évolution a permis d'élargir les champs d'application de la télédétection spatiale. En effet, ces possibilités d'application se sont multipliées dans de nombreux domaines : la météorologie, la climatologie, la cartographie ou la géographie, la géologie, la prospection minière, l'agriculture, l'aménagement des territoires, l'urbanisme, la surveillance des catastrophes naturelles, l'océanographie et bien d'autres applications.

Il existe deux types de capteurs en télédétection : les capteurs passifs, qui dépendent d'une source d'énergie externe, généralement le soleil. Ils captent, d'une manière générale, l'énergie réfléchi par l'objet ou la zone observés. D'autre part, les capteurs actifs, ont leur propre source d'énergie. Ils émettent de l'énergie qui est rétrodiffusée par la zone observée et détectée par le même capteur. Dans ce manuscrit, nous nous intéresserons exclusivement aux capteurs passifs.

L'acquisition d'informations à distance se fait sous forme d'images à l'aide d'un capteur. Le porteur de ce flux d'informations entre l'objet et le capteur, est un rayonnement électromagnétique. Ce dernier est une onde électromagnétique qui est, d'une manière générale, réfléchi par le corps observé. La télédétection utilise les propriétés du rayonnement

électromagnétique pour l'analyse des caractéristiques physiques et biologiques de la surface observée. En effet, chaque objet réagit différemment au rayonnement électromagnétique, et l'énergie réfléchie est mesurée par le capteur. La variation de la réflectance (rapport entre l'énergie réfléchie et celle reçue) en fonction de la longueur d'onde, elle constitue la "signature spectrale" de l'objet.

Les images de télédétection spatiale sont des données agencées en cubes avec deux dimensions spatiales et une dimension spectrale (dans le cas d'une image hyperspectrale, il est appelé "hypercube" (Figure 1)), où un spectre est associé à chaque pixel. Chaque cube est représenté comme une superposition d'images spectrales correspondant chacune à une des bandes spectrales utilisées. Ces images sont issues de capteurs embarqués à bord de systèmes d'observation. Ces capteurs sont caractérisés par trois types principaux de résolution : la résolution spatiale, la résolution spectrale, et la résolution radiométrique [1].

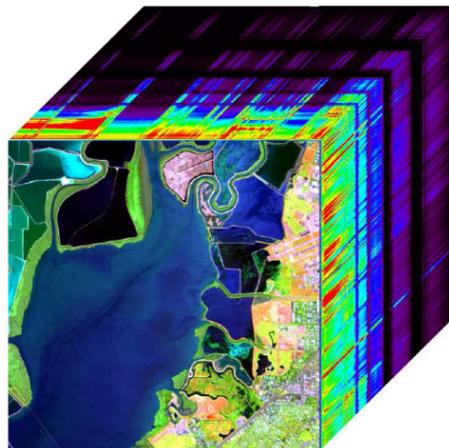


Figure 1 : Représentation d'une image hyperspectrale sous forme d'hypercube.

- **La résolution spatiale** d'un capteur désigne l'aptitude de ce dernier à distinguer deux objets spatialement adjacents, et elle dépend principalement de son "champ de vision instantanée" (en anglais, Instantaneous Field Of View (IFOV)).



Figure 2 : Images de télédétection spatiale optique avec différentes résolutions spatiales.

(a) Image de basse résolution spatiale. (b) Image de haute résolution spatiale.

Ainsi les images sur lesquelles nous ne pouvons distinguer que de grands éléments sont de faible résolution spatiale, tandis que les images sur lesquelles nous pouvons discerner de petits objets sont de haute résolution spatiale (Figure 2).

- **La résolution spectrale** désigne l'aptitude d'un capteur à discerner les différentes longueurs d'onde. Nous parlons de capteurs multispectraux lorsque ces derniers utilisent une dizaine de bandes spectrales larges et le plus souvent non contiguës pour amasser les données. Lorsque ces capteurs produisent des centaines de bandes spectrales étroites et contiguës, nous parlons de capteurs hyperspectraux (Figure 3).

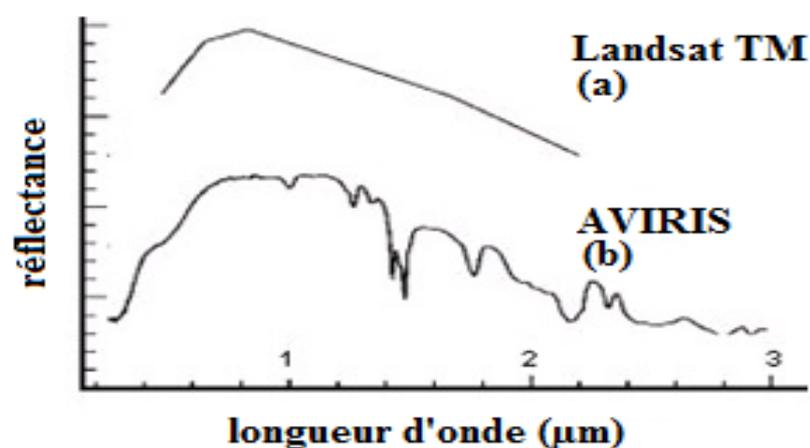


Figure 3 : (a) Spectre multispectral (vu par le capteur multispectral Landsat Thematic Mapper). (b) Spectre hyperspectral (vu par le capteur AVIRIS).

- **La résolution radiométrique** d'un capteur est définie comme la capacité à reconnaître, dans une bande spectrale définie, de petites différences dans l'énergie réfléchie et codée. Plus la résolution radiométrique est fine, plus le capteur est sensible à de petites différences dans l'intensité de l'énergie reçue.

La conception d'un capteur satellitaire passe inévitablement par un compromis entre ces différentes résolutions. Plus la résolution spatiale est fine, plus la quantité d'énergie reçue diminue et donc plus la résolution radiométrique est faible. Si nous voulons augmenter la résolution radiométrique sans réduire la résolution spatiale, cela nécessite d'élargir les intervalles spectraux du capteur, ce qui revient à diminuer la résolution spectrale. Inversement, une basse résolution spatiale permet une résolution radiométrique plus grande et une résolution spectrale plus fine.

2. Analyse d'images de télédétection et extraction d'informations

Le processus d'analyse d'images de télédétection passe par plusieurs étapes, depuis la réception des données brutes fournies par le capteur jusqu'à l'extraction d'informations pour les utilisateurs de la scène observée dans différentes applications. Ces différentes étapes du processus d'analyse et d'extraction d'informations utilisant des images de télédétection spatiale sont représentées sur la figure suivante :

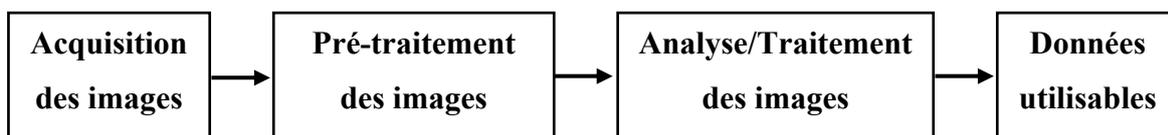


Figure 4 : Schéma de base des différentes étapes du processus d'analyse d'images et extraction d'informations en télédétection spatiale.

- **L'étape d'acquisition** est réalisée par un capteur embarqué sur une plate-forme (exemple : satellite d'observation de la Terre). Ce capteur a pour objectif d'enregistrer le rayonnement réfléchi qui lui parvient, et de le traduire en une image numérique.

- **L'étape de pré-traitement** vise à améliorer les images acquises et réduire les erreurs induites par le bruit lié aux capteurs ou bien les erreurs dues aux conditions atmosphériques [2, 3]. En effet, les principales corrections appliquées sont des corrections radiométrique, géométrique.

- L'étape de traitement et d'analyse des données a pour objectif d'extraire les informations recherchées à partir des images prétraitées. Cette dernière étape a par exemple pour rôle la réalisation de cartes d'occupation des sols à l'aide du processus dit de classification.

3. Problématiques de la thèse

Comme expliqué ci-dessus, la télédétection a pour objectif l'analyse et l'interprétation des images acquises pour en extraire des informations utiles. En effet l'information extraite (spatiale ou spectrale) permet l'identification et la classification des différents matériaux présents dans une scène imagée.

L'imagerie multispectrale est actuellement connue pour avoir une meilleure résolution spatiale que les images hyperspectrales. Cependant, le nombre de bandes spectrales utilisées est généralement inférieur à dix. Par contre, dans l'imagerie hyperspectrale le nombre de bandes spectrales utilisées est généralement supérieur à cent.

Lorsque la résolution spatiale des capteurs utilisés n'est pas assez fine, ces derniers fournissent des pixels plus hétérogènes, appelés également "mixels", dans lesquels plusieurs "matériaux purs" sont présents comme illustré dans la Figure 5. Par conséquent, le spectre de réflectance observé au niveau de ce pixel est un mélange des spectres de réflectance des matériaux purs présents dans ce même pixel. Dans ce cas, nous parlons de "mélange spectral" (spectral mixing).

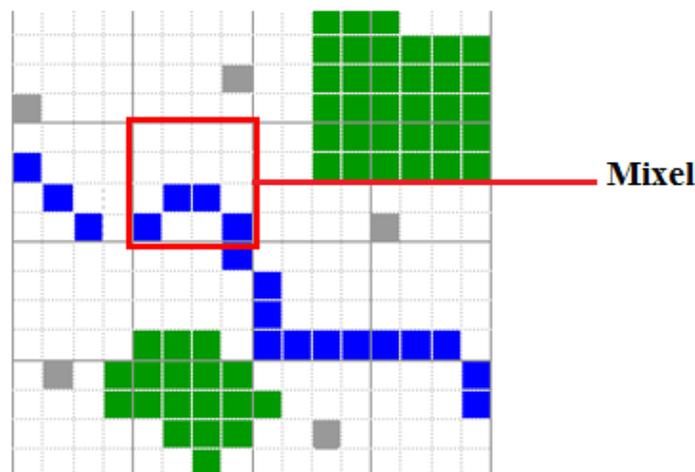


Figure 5 : Illustration d'un mixel (pixel mélangé) contenant plusieurs matériaux purs.

La présence de mixels dans une image de télédétection peut générer des erreurs dans le processus classificatoire en cartographie, en particulier dans le cas où nous voulons mesurer la superficie de la région associée à une classe particulière.

Dans cette thèse, nous nous intéressons à deux principales problématiques de la télédétection spatiale qui sont : le "Démélange Spectral (Spectral Unmixing (SU))" et la "Fusion". Ces deux problématiques sont présentées dans deux parties différentes.

Il est à noter que la fusion ici est celle relative à l'amélioration de la résolution spatiale/spectrale des capteurs. Aussi, les méthodes développées sont issues du domaine du démélange spectral.

Dans la première partie de ce manuscrit (Démélange Spectral), nous proposons de mettre en place des méthodes non-supervisées, permettant à partir de signaux observés (spectres), qui sont des mélanges, d'estimer les signaux sources (spectres) qui sont à l'origine de ces mélanges. Généralement, cette estimation se fait sans beaucoup d'informations a priori sur ces sources et sur les paramètres de mélange. De ce fait, notre problème de démélange peut être considéré comme un problème de Séparation Aveugle de Sources (SAS) [4-6].

Le but de cette première partie est de développer des méthodes de démélange spectral qui consistent à extraire de nos données (ici des images hyperspectrales), les composantes spectrales pures contenues dans une image, qui sont appelées "endmembers", et à déterminer leurs proportions dans chaque pixel de l'image considérée.

Le modèle le plus couramment utilisé pour modéliser le mélange est le modèle linéaire. Dans ce type de modèle, le spectre du pixel est considéré comme une combinaison linéaire des spectres de réflectance des matériaux purs présents dans ce dernier [7, 8]. Un tel modèle de mélange est valide lorsque nous nous intéressons à une scène avec des reliefs relativement plats. Cependant, lorsque nous sommes en présence de paysage non-plat dans la scène observée (comme en milieu urbain), le modèle le plus adéquat pour représenter le mélange présent dans le pixel est le modèle non-linéaire, qui peut être réduit à un modèle de mélange linéaire-quadratique [7, 9-11]. Dans cette partie de notre manuscrit, nous présentons nos approches proposées pour déterminer la composition de nos images hyperspectrales en matériaux purs. Nous nous intéressons plus particulièrement à des images de milieux urbains.

Dans la seconde partie, nous abordons la deuxième problématique qui est la fusion d'images de télédétection spatiale. En effet, en imagerie de télédétection spatiale, les capteurs hyperspectraux ont une résolution spectrale élevée, mais leur résolution spatiale est souvent inférieure à celle des capteurs multispectraux à faible résolution spectrale. Une façon d'améliorer la résolution spatiale des données hyperspectrales est de fusionner l'information spectrale de ces dernières avec l'information spatiale obtenue pour la même scène à partir de données multispectrales à haute résolution spatiale. Ce processus est appelé multisharpening ou bien hypersharpening [12, 13].

Dans cette deuxième partie, nous proposons de nouvelles méthodes de multisharpening pour améliorer la résolution spatiale des données hyperspectrales correspondant au modèle de mélange non-linéaire, plus particulièrement au modèle linéaire-quadratique. Cette approche originale, basée sur le concept de démélange spectral linéaire-quadratique (en anglais Linear-Quadratic Spectral Unmixing (LQSU)), utilise l'algorithme multiplicatif LQNMF (Linear-Quadratic Nonnegative Matrix Factorization) [10]. Les méthodes développées consistent d'abord à démélanger les données hyperspectrales de faible résolution spatiale et les données multispectrales de haute résolution spatiale. Les informations spectrales et spatiales de haute résolution obtenues sont ensuite recombinaées, selon le modèle de mélange considéré, afin d'obtenir des données hyperspectrales à haute résolution spatiale non observables.

4. Plan du manuscrit

Notre manuscrit est constitué de deux parties :

La première partie "Démélange Spectral" est organisée comme suit : dans le premier chapitre, nous commençons par présenter ce qu'est la Séparation Aveugle de Sources (SAS), où un état de l'art des méthodes les plus répandues est donné. Par la suite, nous nous intéressons aux méthodes de démélange spectral. Nous présentons ainsi les principales méthodes conçues pour le modèle de mélange linéaire, puis les méthodes dédiées au modèle de mélange non-linéaire. Dans le deuxième chapitre, nous présentons le modèle de mélange considéré ainsi que ses contraintes, et nous décrivons nos méthodes de démélange spectral proposées et testées pour le cas d'images hyperspectrales d'environnements urbains. Enfin, nous détaillons dans le dernier chapitre les résultats des tests réalisés sur des données synthétiques, où les performances des méthodes proposées sont comparées avec celles des méthodes de la littérature.

Dans la seconde partie de notre manuscrit, nous commençons dans le premier chapitre par présenter un état de l'art des méthodes les plus populaires pour la fusion d'images de télédétection spatiale. Dans le deuxième chapitre, nous présentons nos méthodes pour la fusion de données hyperspectrales et multispectrales de télédétection. Ces méthodes sont conçues pour le cas particulier de données de milieux urbains. Par la suite, les performances des méthodes proposées obtenues avec des données synthétiques et réelles sont données dans le dernier chapitre.

Partie 1 : Démélange spectral des images de télétection spatiale

Sommaire

INTRODUCTION.....	11
CHAPITRE 1 : SEPARATION AVEUGLE DE SOURCES (SAS) ET DEMELANGE SPECTRAL.....	13
CHAPITRE 2 : METHODES NON-LINEAIRES DE DEMELANGE SPECTRAL PROPOSEES	42
CHAPITRE 3 : TESTS ET PERFORMANCES	56
CONCLUSION ET PERSPECTIVES	81

Introduction

La Séparation Aveugle de Sources (SAS) (Blind Source Separation (BSS)) est devenue depuis ces dernières décennies un des problèmes importants en traitement du signal et d'images. Le problème de la séparation de sources a tout d'abord été développé par Héroult, Jutten et Ans au début des années 1980, époque à laquelle ils ont décrit le problème biologique qui a initié les travaux sur cette discipline. Leur travaux consistaient à modéliser les messages véhiculés par le système nerveux [14].

Depuis les années 90, la séparation aveugle de sources a connu une constante évolution et diverses techniques ont été développées pour résoudre ce problème, dans divers champs d'application : l'audio, l'acoustique, le domaine biomédical, les télécommunications, l'astrophysique, la télédétection spatiale, la détection et la localisation radar et bien d'autres applications [5, 15-20].

La SAS consiste à estimer, avec très peu d'informations a priori, un ensemble de signaux sources inconnus à partir d'un ensemble d'observations qui sont des mélanges de ces signaux sources. Plusieurs classes de méthodes ont été proposées dans la littérature pour résoudre le problème de la SAS, dans le cadre de mélanges linéaires. Parmi ces méthodes : l'Analyse en Composantes Indépendantes, l'Analyse en Composantes Parcimonieuses et la Factorisation en Matrices Non-négatives. Cependant le modèle de mélange linéaire considéré dans ces méthodes peut s'avérer insuffisant pour décrire certains phénomènes réels.

Le but de notre travail de thèse, dans cette première partie, est de développer des méthodes de séparation de sources pour des applications en imagerie de télédétection spatiale, dans lesquelles l'image considérée représente l'observation, les spectres de matériaux présents dans l'image sont les signaux sources et les coefficients d'abondances représentent le mélange considéré.

Les méthodes proposées sont basées sur le concept de démixage spectral pour le cas particulier d'images hyperspectrales de milieux urbains, où le modèle de mélange considéré est le mélange linéaire-quadratique/bilinéaire [11], qui prend en compte les réflexions doubles, entre différents matériaux, observées dans ce type de données considéré. Ces méthodes utilisent le concept de la factorisation matricielle proposé dans [21].

Dans cette première partie, nous commençons dans le premier chapitre par présenter des généralités sur la séparation aveugle de sources ainsi que les modèles de mélange usuels. Par la suite, un état de l'art des méthodes de séparation de sources les plus répandues est donné. Nous présentons, dans la section suivante, quelques méthodes de séparation de sources développées dans le cadre du démélange spectral. Dans cette section, nous commençons par détailler les principales méthodes de démélange spectral pour le cas du mélange linéaire, puis nous présentons quelques méthodes conçues pour des mélanges non-linéaires. Dans le deuxième chapitre, nous présentons le modèle mathématique du mélange considéré pour le cas particulier de données de télédétection en milieux urbains. Nous présentons par la suite les méthodes développées pour résoudre notre problématique. Ces méthodes sont basées sur la factorisation en matrices avec contraintes de non-négativité. Les tests et performances de nos méthodes sont présentés dans le dernier chapitre.

Chapitre 1 : Séparation Aveugle de Sources (SAS) et démélange spectral

Sommaire

1.1. Introduction	14
1.2. Présentation de la Séparation Aveugle de Sources (SAS)	14
1.3. Les modèles de mélanges usuels	15
1.3.1. Mélanges linéaires	15
1.3.2. Mélanges non-linéaires	17
1.4. Méthodes de séparation de sources pour les mélanges linéaires.....	18
1.4.1. Méthodes basées sur l'Analyse en Composantes Indépendantes	19
1.4.2. Méthodes basées sur l'Analyse en Composantes Parcimonieuses	21
1.4.3. Méthodes basées sur la Factorisation en Matrices Non-négatives	22
1.5. Méthodes de séparation de sources pour les mélanges non-linéaires	26
1.6. Le démélange spectral.....	28
1.6.1. Méthodes de démélange spectral pour le mélange linéaire	28
1.6.1.1. Méthodes géométriques de démélange spectral	30
1.6.1.2. Les méthodes basées sur l'analyse en composantes indépendantes.....	33
1.6.1.3. Les méthodes basées sur l'analyse en composantes parcimonieuses.....	34
1.6.1.4. Les méthodes basées sur la factorisation en matrices non-négatives	34
1.6.2. Méthodes de démélange spectral pour des mélanges non-linéaires	35
1.6.2.1. Méthodes de démélange spectral pour des modèles de mélange non-linéaires non-définis	36
1.6.2.2. Méthodes de démélange spectral pour des modèles de mélange non-linéaires spécifiques	36
1.7. Conclusion.....	40

1.1. Introduction

Ce premier chapitre est dédié en partie à un état de l'art sur la discipline de séparation aveugle de sources (SAS), dans lequel nous présentons d'une manière générale cette problématique, ainsi que les différents modèles de mélange usuels. Nous présentons dans la section consacrée aux méthodes de séparation de sources, les différentes catégories de méthodes et critères utilisés en SAS, où un panorama des principaux travaux effectués dans chaque catégorie est aussi donné.

Par la suite, nous nous proposons de détailler quelques méthodes de séparation de sources développées pour le démélange spectral, nous nous intéressons particulièrement aux méthodes de démélange spectral pour l'imagerie de télédétection spatiale qui est le domaine d'application sur lequel sont basés nos travaux. Nous commençons d'abord par décrire les méthodes de démélange spectral pour le modèle linéaire, puis nous nous intéressons plus particulièrement au cas non-linéaire. Nous donnons aussi une description des principales méthodes existantes basées sur la SAS.

1.2. Présentation de la Séparation Aveugle de Sources (SAS)

La SAS consiste à extraire M signaux sources s_j inconnus à partir de N signaux observés x_i qui correspondent à des mélanges de ces sources sans ou avec très peu d'informations a priori sur ces dernières, d'où le terme "aveugle". Ces observations sont des mélanges des signaux sources reçus sur plusieurs capteurs, tels que des antennes, des microphones, des capteurs CCD...

L'objectif des méthodes de séparation est de déterminer à partir des observations, la fonction de démélange qui permet d'estimer les signaux qui correspondent aux sources réelles.

En général, le problème de la séparation de sources peut être divisé en deux parties (Figure 1.1) :

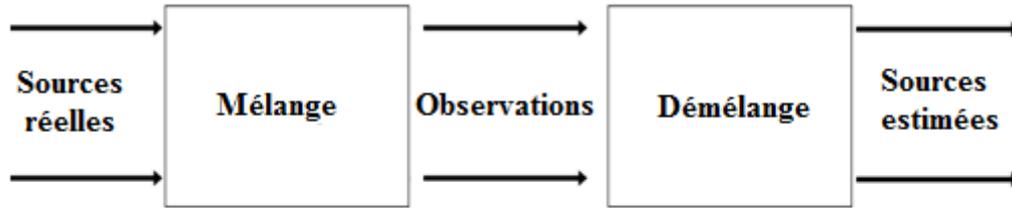


Figure 1.1 : Structure générale du problème de séparation de sources.

– Modélisation du problème : estimation du modèle de mélange qui lie les observations et les sources réelles, appelé problème d'Identification Aveugle de Mélanges (IAM) (Blind Mixture Identification (BMI)) [22].

– Traitement du problème : estimation des sources à partir des observations afin de résoudre le problème [6].

1.3. Les modèles de mélange usuels

Nous pouvons classer les problèmes de séparation aveugle de sources en fonction de la nature de la fonction de mélange.

1.3.1. Mélanges linéaires

Nous retrouvons dans la littérature plusieurs types de mélanges. Les plus étudiés sont les mélanges linéaires. Dans ces modèles, les observations sont des mélanges linéaires des signaux sources. Cette catégorie est découpée en trois sous-catégories :

- Mélange linéaire instantané

C'est le mélange le plus simple et le plus répandu dans la littérature, l'observation s'écrit comme une combinaison linéaire des sources

$$x_i(t) = \sum_{j=1}^M a_{ij} s_j(t), \quad (1.1)$$

avec x_i la i -ème observation, les a_{ij} sont les coefficients de mélange et s_j la j -ième source à estimer.

Nous parlons ici de mélange "instantané" car à un instant donné t , l'observation x_i dépend uniquement des valeurs des sources s_j à ce même instant t . Dans le cas par exemple où les

signaux observés sont des images multispectrales ou hyperspectrales (voir Figure 1- Figure 3 de l'introduction générale), ce modèle de mélange peut également être réécrit de la manière suivante :

$$x_i = \sum_{j=1}^M a_{ij} s_j. \quad (1.2)$$

ici $x_i \in R_+^{L \times 1}$ correspond au signal observé pour un pixel de l'image, composé de L échantillons spectraux. Les $s_j \in R_+^{L \times 1}$ correspondent aux signaux sources et les a_{ij} aux coefficients de mélange.

À partir de cette dernière équation (1.2), nous pouvons exprimer ce mélange sous la forme matricielle suivante (toujours pour l'exemple de signaux images) :

$$X = AS, \quad (1.3)$$

où la matrice $X = [x_1, \dots, x_P]^T \in R_+^{P \times L}$ est la matrice des observations (signaux réels positifs), la matrice $S = [s_1, \dots, s_M]^T \in R_+^{M \times L}$ est la matrice des sources et $A = [a_{i,j}]_{\substack{1 \leq i \leq P \\ 1 \leq j \leq M}} \in R_+^{P \times M}$ est la matrice de mélange, avec P le nombre d'observations (ou mélanges) correspondant à l'indice i de l'équation (1.2), L le nombre d'échantillons par signal source et M correspondant au nombre de sources. $[\cdot]^T$ représente la transposition d'un vecteur.

- Mélange linéaire à atténuations et retards

Dans ce type de mélange, le temps de propagation est pris en considération.

$$x_i(t) = \sum_{j=1}^M a_{ij} s_j(t - t_{ij}), \quad (1.4)$$

où t_{ij} , correspond au retard de la source s_j sur le capteur i .

- Mélange linéaire convolutif

Dans ce type de mélange, une observation s'écrit comme une somme des sources convoluées chacune par un filtre qui lui est propre [23, 24].

$$x_i(t) = \sum_{j=1}^M a_{ij} * s_j(t), \quad (1.5)$$

où $*$ désigne l'opérateur de convolution et a_{ij} la réponse impulsionnelle du filtre propre à l'observation i et à la source j .

1.3.2. Mélanges non-linéaires

La seconde catégorie concerne les mélanges non-linéaires. Ces modèles ont été proposés dans les cas où le modèle linéaire est insuffisant pour décrire les données dans certaines applications réelles. Parmi les configurations les plus connues de cette dernière catégorie de mélanges, le mélange post-non-linéaire [5, 9, 25] et le mélange linéaire-quadratique/bilinéaire [9, 11, 26].

- Mélange post-non-linéaire

Dans ce type de mélanges, chaque observation est considérée comme une fonction non-linéaire instantanée des sorties d'un premier étage du mélange instantané, ou parfois convolutif [27].

- Mélange linéaire-quadratique/bilinéaire

Le mélange linéaire-quadratique/bilinéaire a suscité un intérêt croissant au cours de ces dernières années pour sa capacité à modéliser les effets de diffusions doubles. C'est d'ailleurs le modèle de mélange qui sera utilisé dans nos applications de télédétection en milieu urbain. Le modèle linéaire-quadratique s'écrit comme suit [11, 28] :

$$x_i = \sum_{j=1}^M a_{ij} s_j + \sum_{j=1}^M \sum_{l=j}^M a_{i(j,l)} s_j \odot s_l. \quad (1.6)$$

Comme pour le cas linéaire, $x_i \in R_+^{L \times 1}$ correspond ici à un signal observé composé de L échantillons. Les $s_j \in R_+^{L \times 1}$ correspondent aux signaux sources et les a_{ij} aux coefficients linéaires du mélange. En plus de ces termes viennent s'ajouter les termes quadratiques suivants : les $s_j \odot s_l$ correspondent aux produits terme à terme des signaux sources et les $a_{i(j,l)}$ correspondent, quant à eux, aux coefficients quadratiques du mélange.

Un cas particulier du mélange linéaire-quadratique est le mélange bilinéaire. Dans ce modèle, les doubles réflexions possibles impliquant une même source ne sont pas prises en compte [26, 29] :

$$x_i = \sum_{j=1}^M a_{ij} s_j + \sum_{j=1}^{M-1} \sum_{l=j+1}^M a_{i(j,l)} s_j \odot s_l. \quad (1.7)$$

Le problème de séparation aveugle de sources peut aussi être classé suivant le nombre P d'observations considérées et le nombre M de sources : nous parlons de mélange sous-déterminé lorsque le nombre de sources est supérieur au nombre d'observations, de mélange sur-déterminé lorsque le nombre d'observations est supérieur au nombre de sources, et de mélange déterminé lorsque les nombres de sources et d'observations sont égaux.

Comme les sources et le mélange sont inconnus, leurs estimations ne peuvent pas être uniques [5, 6]. Très souvent, les sources sont estimées avec les indéterminations suivantes :

- Indétermination d'échelle : les sources sont estimées à un facteur près.
- Indétermination sur l'ordre des sources : une possible permutation dans l'ordre des signaux sources retrouvés.

Néanmoins, ces indéterminations peuvent être dans certains cas réduites en ajoutant des contraintes supplémentaires (certaines contraintes sont détaillées dans ce qui suit) [5, 6].

L'originalité de la SAS provient de la faible exploitation des connaissances a priori sur les sources et/ou paramètres de mélange. Toutefois, un certain nombre de contraintes ou d'hypothèses est nécessaire au bon fonctionnement des méthodes de SAS. Ces contraintes ou hypothèses dépendent du type de données traitées [6], elles donnent ainsi lieu à différentes familles de méthodes de séparation.

1.4. Méthodes de séparation de sources pour les mélanges linéaires

Il existe différentes méthodes permettant de résoudre le problème de séparation de sources. Ces méthodes sont généralement répertoriées dans trois grandes catégories : les méthodes d'Analyse en Composantes Indépendantes (Independent Component Analysis (ICA)), les méthodes d'Analyse en Composantes Parcimonieuses (Sparse Component Analysis (SCA)) et les méthodes de Factorisation en Matrices Non-négatives (Non-negative Matrix Factorization (NMF)).

Une quatrième catégorie de méthodes de séparation peut être considérée dans le cas d'applications en imagerie de télédétection, ces méthodes sont le plus souvent basées sur des critères géométriques [30-32].

Il est possible de trouver plus d'informations sur ces méthodes de séparation ainsi qu'un panorama général des méthodes dans [5, 6, 18, 25, 30-36].

Dans cette section nous nous intéressons aux méthodes de séparation les plus connues dans la littérature pour le cas de mélanges linéaires. Nous présentons les classes de méthodes de SAS dans le cadre général. Par la suite, nous évoquons les méthodes de séparation dans le cas particulier de la télédétection où des hypothèses supplémentaires sur les données sont considérées.

1.4.1. Méthodes basées sur l'Analyse en Composantes Indépendantes

L'ICA constitue l'une des catégories de méthodes les plus utilisées en séparation. Cette catégorie de méthodes exploite l'hypothèse de l'indépendance statistique mutuelle des signaux sources. Dans [4], P. Comon a généralisé le principe de l'ICA permettant d'obtenir des signaux de sortie, statistiquement indépendants, égaux aux signaux sources dans le cadre du mélange linéaire instantané, inversible et non bruité avec la présence d'au plus une source gaussienne. Pour une analyse plus détaillée sur des méthodes ICA et sur la séparation aveugle de sources, il est possible de se référer à [5, 6, 33]. Différents critères peuvent être utilisés pour réaliser l'ICA, parmi eux nous citons :

1) La minimisation de l'information mutuelle

Cette approche, issue de la théorie de l'information, est basée sur la minimisation de l'information mutuelle entre les sources estimées, ce qui consiste à maximiser l'indépendance entre elles. Plusieurs méthodes ont été développées en utilisant l'information mutuelle comme critère pour résoudre le problème de séparation de sources, notamment les travaux de P. Comon [4], M. Babaie-Zadeh [37, 38], L. B. Almeida [39] et D. T. Pham [40, 41].

2) La maximisation de la vraisemblance

Cette approche a pour objectif de retrouver les paramètres des mélanges qui maximisent la vraisemblance de réalisation des observations. L'inconvénient majeur du critère de

maximisation de la vraisemblance réside dans le fait que nous ne connaissons pas la densité de probabilité des signaux sources. Nous pouvons alors soit la supposer connue a priori, soit supposer qu'elle appartient à une famille donnée de distributions.

Les premières méthodes basées sur la maximisation de la vraisemblance ont été introduites par M. Gaeta et J. L. Lacoume [42]. Nous pouvons aussi citer les travaux de D. T. Pham [43, 44], A. Belouchrani et J. F. Cardoso [45] et les travaux de R. Guidara, S. Hosseini et Y. Deville [46].

3) La maximisation de la non-gaussianité

Cette dernière approche est l'une des approches les plus utilisées en ICA, le principe de ce genre d'approches est de forcer la non-gaussianité de chaque signal de sortie.

En pratique, le kurtosis, qui est le cumulants d'ordre quatre normalisé, est le critère le plus utilisé pour mesurer la non-gaussianité [47, 48]. Un deuxième critère de mesure de la non-gaussianité est basé sur l'entropie différentielle ou la néguentropie. L'une des méthodes les plus connues basées sur la maximisation de la non-gaussianité est FastICA [33, 49].

4) Les approches tensorielles

Les approches tensorielles sont basées généralement sur l'utilisation de cumulants d'ordre 4 pour retrouver les signaux sources. Parmi les approches basées sur un tel critère, la méthode JADE (Joint Approximate Diagonalization of Eigenmatrices) [50].

5) Méthodes basées sur les statistiques d'ordre deux

Les approches d'ICA présentées ci-dessus font l'hypothèse que chaque source est non gaussienne et i.i.d. (indépendante et identiquement distribuée). Cependant dans les méthodes basées sur les statistiques d'ordre deux, l'hypothèse de la non-gaussianité est relâchée (les sources peuvent être gaussiennes) [51], et la séparation peut être effectuée en supposant une des deux hypothèses suivantes :

a) Les méthodes ICA basées sur les statistiques d'ordre deux avec l'hypothèse d'autocorrélation des signaux sources : parmi ces méthodes, nous pouvons citer : AMUSE (pour : Algorithm for Multiple Unknown Signals Extraction) [52] et SOBI (Second-Order Blind Identification) [53].

b) Les méthodes ICA basées sur les statistiques d'ordre deux avec l'hypothèse de la non-stationnarité des signaux sources : parmi les travaux traitant des signaux sources non-stationnaires, citons par exemple les travaux de [54, 55].

1.4.2. Méthodes basées sur l'Analyse en Composantes Parcimonieuses

L'analyse en composantes parcimonieuses est une catégorie de méthodes actuellement très populaire en séparation aveugle de sources. Elles partent de l'hypothèse que les signaux ont une structure particulière. Un signal est dit parcimonieux dans un domaine de représentation donné (temporel, spatial, fréquentiel, temps-fréquence, temps-échelle) si la plupart de ses coefficients dans ce domaines sont nuls. Nous distinguons ainsi trois types d'approches tirant parti de la parcimonie des sources :

1) Approches basées sur l'hypothèse de fortes conditions de parcimonie

Appelées WDO (W-Disjoint-Orthogonality), elles supposent l'Orthogonalité W-Disjointe des sources, ce qui suppose qu'au plus une source est présente ou active dans chaque point du domaine d'analyse. La WDO permet de séparer les sources dans les cas dits "sous-déterminés". Parmi les méthodes basées sur cette approche, nous pouvons citer celles dans [56, 57].

2) Approches basées sur la quasi-non-parcimonie

Ces méthodes nécessitent de petites zones du domaine d'analyse, dans lesquelles chaque source est isolée. Ces zones "mono-sources" (où une seule source est présente) sont retrouvées par l'utilisation d'un critère de détection. Parmi les méthodes basées sur cette approche, celles proposées par F. Abrard et Y. Deville. Les méthodes LI-TEMPROM et LI-TIFROM [58] utilisent la variance des rapports des observations pour la détection des zones mono-sources. Les méthodes LI-TEMPCORR et LI-TIFCORR [59] utilisent quant à elles la corrélation pour la détection de ces zones.

D'autres méthodes ont été proposées comme extensions des différentes méthodes citées ci-dessus afin de pallier certaines de leur limitations [60, 61].

3) Approches hybrides

Ces approches "hybrides" se basent à la fois sur les méthodes utilisant le concept de la WDO et sur celui de la quasi-non-parcimonie. Parmi les méthodes qui utilisent cette approche, la méthode d'Arberet, R. Gribonval et F. Bimbot proposée dans [62].

1.4.3. Méthodes basées sur la Factorisation en Matrices Non-négatives

1) Principe général

Les méthodes de factorisation en matrices non-négatives (NMF), sont une catégorie de méthodes basées sur l'hypothèse de "positivité" ou de "non-négativité" des données (sources et coefficients de la matrice de mélange comme dans le cas d'applications en télédétection spatiale). Nous exploitons dans nos travaux cette catégorie de méthodes étant donné la propriété de non-négativité de nos données (positivité des observations, des sources et des coefficients de mélange).

Initialement proposée par Paatero et Tapper avec des travaux fondés sur la Factorisation en Matrices Positives (Positive Matrix Factorization (PMF)) [63], la NMF a connu un succès depuis le milieu des années 90, suite aux travaux de D. D. Lee et H. S. Seung [64, 65], comme une nouvelle technique de séparation aveugle de sources.

Le principe de la factorisation en matrices non-négatives en terme de séparation de sources, consiste à décomposer la matrice non-négative des observations $X \in R_+^{P \times L}$, P et L étant respectivement les nombres d'observations et d'échantillons, sous la forme suivante [65] :

$$X \approx AS, \quad (1.8)$$

et sous contrainte de positivité des matrices $A \in R_+^{P \times M}$ et $S \in R_+^{M \times L}$, respectivement la matrice de mélange et la matrice des sources, avec $M \leq \min(P, L)$, correspondant au nombre de sources que nous cherchons à séparer.

Il existe plusieurs types de méthodes de NMF qui diffèrent par la mesure du critère utilisé pour évaluer l'écart entre X et le produit des matrices estimées AS . Lee et Seung [65] ont proposé deux méthodes basées sur la minimisation de deux fonctions objectives J (ou fonctions de coût J_1 ou J_2) différentes, sous la contrainte de positivité :

$$\min_{A,S} J(X, A, S), \text{ avec } A \geq 0 \text{ et } S \geq 0. \quad (1.9)$$

La première méthode est basée sur la minimisation de la norme de Frobenius de la matrice $X - AS$, qui équivaut à la distance euclidienne entre la matrice des observations X et le produit AS . Celle-ci est définie comme suit :

$$J_1(X, A, S) = \frac{1}{2} \|X - AS\|_F^2 = \sum_{ij} (X_{ij} - (AS)_{ij})^2. \quad (1.10)$$

La deuxième méthode est basée sur la minimisation de la divergence de Kullback-Leibler (KL) entre X et le produit AS . Cette dernière est définie comme suit:

$$J_2(X, A, S) = \sum_{ij} X_{ij} \ln \left(\frac{X_{ij}}{(AS)_{ij}} - X_{ij} + (AS)_{ij} \right). \quad (1.11)$$

2) Unicité de la solution et convergence

D. D. Lee et H. S. Seung [65] ont prouvé que les algorithmes proposés font décroître les deux fonctions objectives à chaque itération, et convergent toujours vers une solution de l'approximation (1.8).

Dans [66], D. Donoho et V. Stodden présentent une interprétation géométrique de la NMF. Dans ce travail, les auteurs définissent la NMF comme étant une procédure permettant l'identification d'un cône appartenant à l'orthant positif englobant le nuage de points des données observées. Il est donc possible de voir à partir de la Figure 1.2 que le cône identifié n'est pas toujours unique sans contraintes supplémentaires.

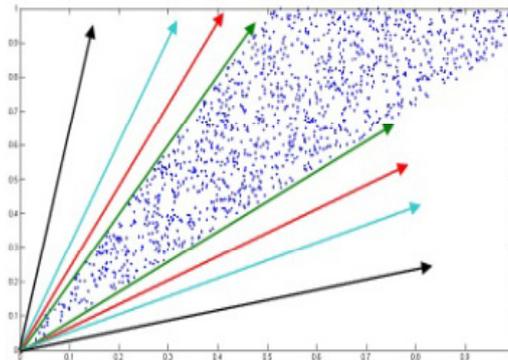


Figure 1.2 : Différents cônes englobant des données observées [67].

L'un des principaux inconvénients que présente la NMF est que le problème d'optimisation de l'équation (1.8) est convexe soit suivant A ou S , mais pas pour les deux, ce qui signifie que les algorithmes garantissent la convergence uniquement vers un minimum local [65]. Par conséquent, le résultat de convergence dépend fortement de l'initialisation de l'algorithme. Dans la pratique, les utilisateurs de la NMF comparent souvent les minimas locaux de plusieurs initialisations différentes, et utilisent les résultats du meilleur minimum local trouvé.

- Initialisation

La convergence de la NMF dépend fortement de l'initialisation, un bon choix d'initialisation permet une convergence plus probable vers la solution souhaitée. Plusieurs méthodes d'initialisation ont été proposées dans la littérature suivant les applications [68-71].

- Contraintes sur les matrices produit

Dans la littérature, différentes méthodes ont été proposées pour contraindre la factorisation, en ajoutant un terme de pénalité à la fonction objective usuelle de NMF (la divergence de KL ou la distance euclidienne). Ces contraintes peuvent concerner une seule des deux matrices produit ou les deux. Quelle que soit la contrainte considérée, ces algorithmes partagent une approche commune, plutôt que la minimisation exclusive d'un terme J quantifiant l'erreur de reconstruction (la divergence de KL ou la distance euclidienne), la fonction de coût globale J à minimiser inclut un terme J_c quantifiant la propriété que nous souhaitons imposer. Le problème de la NMF avec contraintes s'écrit alors sous la forme suivante :

$$\min_{A,S} (J(X, A, S) + \lambda J_c(A, S)) , \text{avec } A \geq 0 \text{ et } S \geq 0, \quad (1.12)$$

où λ est un paramètre de pondération.

Différentes contraintes peuvent être imposées selon la nature des données traitées. Parmi les contraintes les plus utilisées dans la littérature : la parcimonie [68, 72] et la contrainte de lissage [73, 74].

3) Algorithmes de type NMF

Divers algorithmes NMF ont été préposés pour chacune des fonctions de coût envisagées. Dans ce manuscrit nous présentons ces algorithmes en considérant la fonction J_1 décrite dans

(1.10) qui correspond à la norme de Frobenius. Nous chercherons donc à minimiser la fonction suivante :

$$\min_{A,S} J_1(X, A, S) = \min_{A,S} \left(\frac{1}{2} \|X - AS\|_F^2 \right), \text{ avec } A \geq 0 \text{ et } S \geq 0. \quad (1.13)$$

- Algorithme multiplicatif

L'algorithme multiplicatif est le plus populaire des algorithmes NMF. Initialement proposé par Lee et Seung [65], il est une extension de l'algorithme du gradient, où le pas est exprimé en fonction des matrices A et S de façon à obtenir une forme multiplicative. Dans le cas où la fonction objective est la norme de Frobenius (1.10), les règles de mise à jour des deux matrices s'expriment sous la forme suivante [65] :

$$A \leftarrow A \odot (XS^T \oslash ASS^T), \quad (1.14)$$

$$S \leftarrow S \odot (A^T X \oslash A^T AS). \quad (1.15)$$

L'avantage de cet algorithme est que toutes les composantes de A et S restent non-négatives pour toutes les itérations [65, 68], à partir du moment où elles sont initialisées par des valeurs non-négatives.

Une bibliographie détaillée sur les algorithmes de ce type ainsi que sur leur contraintes peut être consultée dans la référence [75].

- Algorithme du gradient projeté

Les méthodes considérées ici utilisent un algorithme de type gradient avec projection des mises à jour, à chaque itération, sur le sous-ensemble des nombres réels non-négatifs R^+ [75, 76]. Ainsi, les règles de mises à jour dans le cas d'une NMF par algorithme de gradient projeté sont données par les expressions matricielles suivantes :

$$A \leftarrow \left[A - \alpha_A \frac{\partial J}{\partial A} \right]_+, \quad (1.16)$$

$$S \leftarrow \left[S - \alpha_S \frac{\partial J}{\partial S} \right]_+, \quad (1.17)$$

avec α_* un pas positif, dont la valeur peut être fixe ou calculée par une méthode automatique pour l'adapter aux différentes itérations. $[\cdot]_+$ correspond à la projection sur R^+ . Cette projection, notée $[\xi]_+$, peut être effectuée en remplaçant toutes les valeurs de ξ , si elles sont négatives, par zéro, ou dans la pratique, par un petit nombre ε positif afin d'éviter des instabilités numériques. Cela nous donne $[\xi]_+ = \max[\varepsilon, \xi]$ [76-78]. Les expressions de mise à jour deviennent comme suit :

$$A \leftarrow \max \left[\varepsilon, \left(A - \alpha_A \frac{\partial J}{\partial A} \right) \right], \quad (1.18)$$

$$S \leftarrow \max \left[\varepsilon, \left(S - \alpha_S \frac{\partial J}{\partial S} \right) \right]. \quad (1.19)$$

- Algorithme des moindres carrés alternés

L'algorithme ALS (pour Alternating Least Squares), est un algorithme itératif qui met à jour alternativement chacune des matrices estimées en fixant l'une d'elles et en calculant l'autre par moindres carrés avec contraintes de positivité [79, 80].

Dans cette première partie du manuscrit, nous nous intéressons seulement aux méthodes basées sur la factorisation en matrices non-négatives et particulièrement aux algorithmes de type multiplicatif et de type gradient projeté dans le développement de nos approches.

1.5. Méthodes de séparation de sources pour les mélanges non-linéaires

Comme indiqué auparavant, les mélanges linéaires peuvent s'avérer insuffisants pour décrire toutes les situations réelles. Dans ces cas il est nécessaire de considérer une extension de ce modèle. Beaucoup moins étudiés dans la littérature de séparation de sources, les modèles de mélanges non-linéaires ont été proposés afin de représenter d'une façon plus générale les phénomènes existants. Dans cette section, nous nous intéressons plus particulièrement au modèle linéaire-quadratique, nous donnons un panorama de l'essentiel des travaux effectués dans le cadre de ce type de mélange [81].

Parmi les méthodes basées sur l'ICA du modèle linéaire-quadratique sur-déterminé, les premiers travaux sont attribués à M. Krob et M. Benidir [82], qui proposent une méthode

d'identification aveugle d'un mélange linéaire-quadratique en utilisant des statistiques d'ordre 2 et 3.

K. Abed-Meraim, A. Belouchrani et Y. Hua, dans [83], abordent le problème d'identification aveugle du mélange linéaire-quadratique instantané de variables aléatoires statistiquement indépendantes. Il propose une nouvelle technique basée sur la diagonalisation conjointe d'un ensemble de matrices de corrélation.

Dans [84] et [85], les auteurs proposent une approche pour la séparation du mélange linéaire-quadratique des sources réelles et statistiquement indépendantes. La méthode est basée sur une structure de séparation de type réseau récurrent [86], qui utilise soit les statistiques d'ordre supérieur, soit le maximum de vraisemblance. Une extension à leur approche a été proposée dans [87, 88], et l'intérêt est d'optimiser les problèmes de stabilité du réseau récurrent rencontrés dans les travaux précédents grâce à des degrés de liberté supplémentaires. Dans [87], les auteurs présentent une généralisation de leur approche à d'autres classes de mélanges plus complexes.

F. Mokhtari dans [89] présente une autre approche pour la séparation de sources de mélange bilinéaire. L'algorithme utilise la même structure récurrente que dans [84] et [85] pour séparer ces mélanges. Cependant, au lieu d'une approche basée sur le maximum de vraisemblance, l'algorithme proposé est basé sur la minimisation de l'information mutuelle des sorties pour récupérer les composantes indépendantes.

Dans [90], les auteurs proposent une extension à l'approche et modèle proposés dans [84, 85], en utilisant la structure de séparation qui y est proposée pour traiter des images scannées.

Nous terminons ce panorama des méthodes, en citant quelques travaux basés sur la parcimonie pour les mélanges linéaire-quadratiques. Parmi ces méthodes, une extension de la méthode LI-TEPCORR [59] au modèle linéaire-quadratique est proposée dans [91]. Une autre méthode basée sur la parcimonie est présentée dans [92]. Les auteurs proposent une nouvelle approche de séparation pour les mélanges linéaires-quadratiques sur-déterminés. La méthode permet l'annulation de la partie non-linéaire du processus de mélange et après cela, la séparation peut être réalisée par des algorithmes de séparation linéaires.

Nous abordons dans ce qui suit d'autres approches de séparation de sources dédiées principalement à l'imagerie de télédétection spatiale, aussi bien dans le cas de mélange

linéaire que non-linéaire. Ces approches de démixage spectral sont détaillées davantage dans la section suivante.

1.6. Le démixage spectral

Comme expliqué en introduction de la thèse, les images de télédétection spatiale sont généralement prises sur des scènes hétérogènes, dans lesquelles plusieurs matériaux dits "matériaux purs" sont présents. Ainsi un pixel d'une image de télédétection spatiale peut contenir plusieurs matériaux purs, nous parlons alors de pixel mélangé appelé "mixel", et le spectre de ce mixel est un mélange des réponses spectrales des différents matériaux purs présents dans ce même pixel [7].

Afin d'analyser ce type d'images, il est nécessaire de retrouver les principaux matériaux présents (chaque matériau étant caractérisé par sa propre signature spectrale). Pour ce faire, nous réalisons un démixage spectral (en anglais Spectral Unmixing (SU)). Cette procédure permet la décomposition d'un spectre issu d'un pixel mélangé en un ensemble de spectres de matériaux purs appelés "endmembers", ainsi qu'un ensemble de coefficients d'abondances qui représentent les proportions d'apparition de chaque endmember dans le pixel mélangé.

Il est à rappeler que les méthodes utilisées pour le démixage spectral peuvent être considérées comme étant des méthodes de séparation aveugle de sources [67, 93, 94].

1.6.1. Méthodes de démixage spectral pour le mélange linéaire

Ces méthodes de démixage spectral reposent sur un modèle de mélange linéaire, dans lequel chaque spectre de pixel est considéré comme étant la combinaison linéaire de M endmembers représentant les spectres de réflectance des matériaux purs présents dans ce même pixel (comme représenté dans la Figure 1.3).

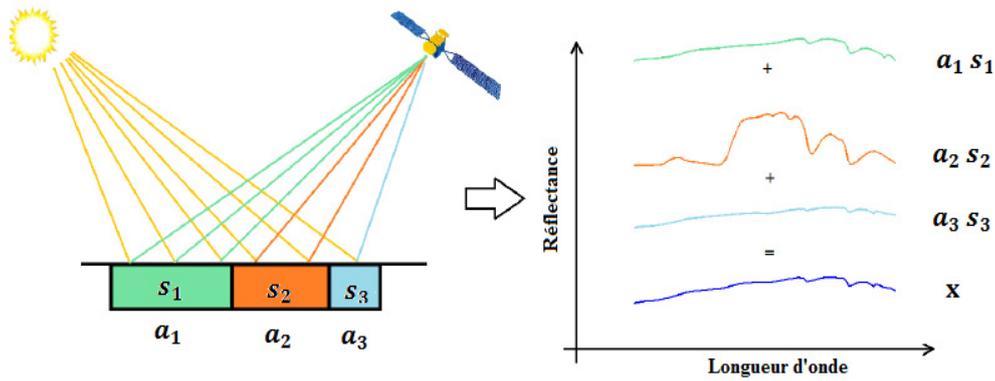


Figure 1.3 : Illustration du modèle de mélange linéaire [8].

La représentation mathématique du spectre de réflectance, qui est non-négatif, associé à un pixel i est donc la suivante :

$$x_i = \sum_{j=1}^M a_j(i) s_j, \quad (1.20)$$

où

- s_j (vecteur colonne de taille L) est le spectre de réflectance non-négatif du j -ième matériau pur.

- $a_j(i)$ est le coefficient d'abondance du j -ième endmember dans le pixel i . Il représente la proportion de surface occupée par le matériau j dans le pixel i . Compte tenu de la nature des données que nous traitons, des contraintes supplémentaires sont considérées, les coefficients d'abondances $a_j(i)$ doivent vérifier les conditions suivantes :

- Contrainte de non-négativité

$$a_j(i) \geq 0, \quad j = 1 \dots M, i = 1 \dots P, \quad (1.21)$$

car la surface occupée au sol est positive ou nulle.

- Contrainte de somme égale à un

$$\sum_{j=1}^M a_j(i) = 1, \quad i = 1 \dots P, \quad (1.22)$$

car la somme des proportions de surface occupées par les endmembers, correspond à la surface totale du pixel.

- M est le nombre d'endmembers (matériaux purs) présents dans la scène observée.

- L est le nombre de bandes spectrales de l'image.

Le modèle donné dans l'équation (1.20) peut être réécrit sous forme matricielle pour $P \geq 2$, P étant le nombre de pixels (observations) de l'image de télédétection :

$$X = A S, \quad (1.23)$$

où X représente ici l'image de télédétection observée de dimension $P \times L$, est définie comme suit :

$$X = [x_1 \dots x_P]^T, \text{ avec } x_i = [x_i(1) \dots x_i(L)]^T. \quad (1.24)$$

La matrice A de dimension $P \times M$ contient les coefficients d'abondances des endmembers présents dans l'image considérée. Celle-ci est présentée comme suit :

$$A = \begin{bmatrix} a_1(1) & \dots & a_M(1) \\ \vdots & \ddots & \vdots \\ a_1(P) & \dots & a_M(P) \end{bmatrix}. \quad (1.25)$$

La matrice S de dimension $M \times L$ représente la matrice des spectres, elle est définie comme suit :

$$S = [s_1 \dots s_M]^T, \text{ avec } s_j = [s_j(1) \dots s_j(L)]^T. \quad (1.26)$$

En tenant compte des contraintes physiques présentées ci-dessus, de nombreuses méthodes ont été proposées pour résoudre le problème de démixage spectral dans le domaine de la télédétection. Dans ce qui suit nous allons citer certaines de ces méthodes appliquées aux images de télédétection basées sur le modèle linéaire. Nous commençons par citer les méthodes géométriques de démixage spectral, puis nous exposons d'autres types de méthodes fondées sur les mêmes principes que les méthodes classiques de SAS, où des contraintes supplémentaires liées à la nature des données sont considérées.

1.6.1.1. Méthodes géométriques de démixage spectral

Parmi les méthodes les plus populaires pour le démixage spectral d'images de télédétection, sont celles qui exploitent les propriétés géométriques du problème. Selon ces approches géométriques, les observations (les pixels) sont contenues dans un simplexe dont les sommets

correspondent aux spectres des endmembers recherchés dans le mélange, comme l'illustre la figure 1.4.

Si nous considérons une scène constituée de M matériaux, tous les pixels purs correspondent à des points qui sont localisés aux sommets d'un simplexe de dimension $M - 1$. Les mixels (pixels mélangés) sont à l'intérieur du simplexe. Ainsi, plus un pixel est proche d'un des sommets, plus il est pur. Le but du démixage est alors de retrouver les sommets de ce simplexe [30-32].

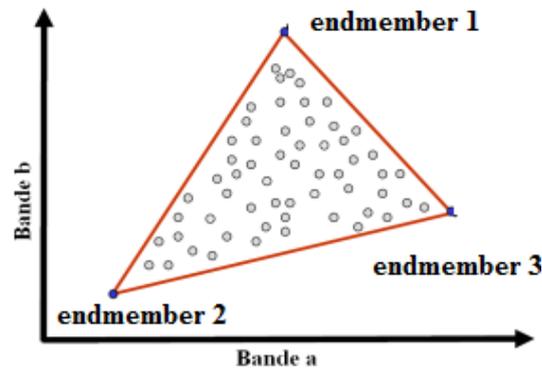


Figure 1.4 : Représentation en deux bandes des observations contenues dans un simplexe.

1) Estimation des spectres d'endmembers

Nous distinguons deux types de méthodes d'extraction des spectres d'endmembers qui utilisent la géométrie du simplexe [8, 31].

a) Méthodes avec existence de pixels purs

L'hypothèse principale sur laquelle reposent ces méthodes est l'existence de pixels purs pour chaque matériau dans l'image étudiée pour extraire les endmembers à partir de ces pixels. Ces méthodes ont pour but de retrouver un simplexe englobant les observations dont les sommets sont les éléments purs. Parmi ces méthodes, les plus populaires sont :

- **La méthode PPI (Pixel Purity Index)** [95] utilise une MNF (Maximum Noise Fraction) comme une étape de pré-traitement pour réduire la dimensionnalité. Cette méthode cherche à retrouver le simplexe d'intérêt à partir de projections sur des espaces appropriés.

- **La méthode N-FINDR** [96] est une des méthodes d'estimation des composantes pures les plus utilisées. Elle repose sur le calcul itératif du simplexe de plus grand volume englobant l'ensemble des points de l'image considérée.

- **La méthode SMACC (Sequential Maximum Angle Convex Cone)** développée dans [97] est basée sur un modèle de cône convexe pour représenter des vecteurs spectraux. L'algorithme commence avec un seul endmember et augmente de façon incrémentielle en dimension. Un nouveau endmember est identifié en fonction de l'angle qu'il fait avec le cône existant, le vecteur de données formant l'angle maximal avec le cône existant est choisi comme le suivant endmember pour agrandir l'ensemble d'endmembers.

- **La méthode VCA (Vertex Component Analysis)** [98] est une méthode qui exploite la projection dans des sous-espaces orthogonaux afin de retrouver directement les endmembers.

Plus de détails sur ce type de méthodes sont présentés dans [8].

b) Méthodes sans l'hypothèse d'existence de pixels purs

Ces méthodes ne font pas l'hypothèse d'existence de pixels purs dans l'image traitée. Les méthodes de cette catégorie ont pour but de chercher à minimiser le volume du simplexe formé par les données projetées. Parmi ces méthodes, nous pouvons citer :

- **La méthode MVC-NMF (Minimum Volume Constrained Non-negative Matrix Factorization)**, développée par L. Miao et H. Qi [99], introduit dans la NMF un terme de régularisation du volume afin de retrouver le plus petit simplexe parmi ceux possibles pouvant contenir les données.

- **La méthode MVSA (Minimum Volume Simplex Analysis)** de J. Li et J.M. Bioucas-Dias [100] résout ce problème en implémentant une séquence de sous-contraintes quadratiques.

- **La méthode SISAL (Simplex Identification via Split Augmented Lagrangian)** [101] résout le problème d'optimisation en ayant recours à un algorithme de type Lagrangien augmenté.

Les deux algorithmes MVSA et SISAL utilisent une initialisation issue de la méthode VCA, et ces deux méthodes remplacent la contrainte de non-négativité des abondances par une contrainte plus souple. Cette dernière est réalisée en rajoutant à la fonction d'optimisation utilisée dans la version de base un terme de régularisation.

La connaissance du nombre d'endmembers présents dans une image est généralement obligatoire pour extraire ces derniers. Ce nombre peut être estimé en effectuant une PCA comme dans [7], ou en utilisant la méthode proposée par J.M. Bioucas-Dias et J.M.P. Nascimento [102] appelée Hyperspectral Signal identification by minimum error (HySime), ou encore les méthodes HFC ou NWHFC décrites dans [103].

2) Estimation des fractions d'abondances

Il existe des méthodes qui permettent d'estimer les fractions d'abondances une fois que les spectres d'endmembers sont connus, ces méthodes sont appelées méthodes de régression. Parmi les méthodes les plus connues dans la littérature nous citons, la méthode Non-Negativity Constrained Least Squares (NCLS) proposée par C-I. Chang [104], Fully Constrained Least Squares (FCLS) de D. C. Heinz et C. I. Chang [105], la Split Gradient Method (SGM) de C. Theys [106], et les méthodes bayésiennes proposées dans [107].

1.6.1.2. Les méthodes basées sur l'analyse en composantes indépendantes

Ces méthodes sont des méthodes qui supposent l'indépendance statistique des sources, et sur ce principe plusieurs approches ont été proposées dans la littérature : J. Bayliss [108] introduit une méthode basée sur le maximum de vraisemblance appliquée à des problèmes de démixage spectral en considérant les "sources = abondances" (cette méthode repose sur un algorithme proposé par B.A. Pearlmutter et L. Parra [109]). Dans [110], les auteurs proposent une méthode en considérant les "sources = spectres". Cependant, ces méthodes se basent sur l'indépendance des sources, ce qui n'est pas le cas pour des images de télédétection car dans le cas d'approche "sources = spectres", l'hypothèse d'indépendance statistique n'est pas respectée du fait de la nature de ces spectres dans certains cas très corrélés (notamment lorsqu'ils appartiennent à la même grande classe par exemple : végétation ...etc.), tandis que dans le cas d'approche "sources = abondances", l'indépendance statistique n'est également pas respectée du fait des contraintes de somme égale à un sur chaque pixel des cartes d'abondances [67].

Dans [111], les auteurs proposent une comparaison entre plusieurs méthodes d'ICA et où l'efficacité de ces méthodes est étudiée. Ils démontrent ainsi que la dépendance des sources altère les performances de ces méthodes, ces méthodes sont donc difficilement applicables au problème de démixage des images de télédétection.

Dans [112, 113], les auteurs proposent une approche appelée Modified Independent Component Analysis for initializing Non-negative Matrix Factorization (ModifICA-NMF). Cette approche permet de mieux résoudre le problème de démixage spectral des images hyperspectrales, en utilisant les résultats d'une ICA modifiée comme initialisation d'une NMF.

1.6.1.3. Les méthodes basées sur l'analyse en composantes parcimonieuses

Plusieurs méthodes de démixage basées sur la SCA ont été proposées dans la littérature. Les méthodes proposées dans [114-116] sont des approches pour démixer chaque pixel d'une image contenant des pixels purs. Ces méthodes sont basées sur un critère de corrélation. Dans [94], les auteurs proposent le même type d'approche, applicable à des images multispectrales/hyperspectrales de télédétection spatiale, qui reposent sur l'hypothèse de présence de zones à deux sources. Dans [117], les auteurs proposent une méthode, qui permet d'extraire les spectres d'endmembers à partir d'une image hyperspectrale contenant des pixels purs, en utilisant une méthode de SCA basée sur la variance spatiale.

D'autres méthodes utilisent une approche qui permet l'estimation des spectres d'endmembers qui interviennent dans le mélange en utilisant une bibliothèque de spectres (comme par exemple la bibliothèque U.S.G.S [118] contenant plus de 1300 spectres de divers matériaux naturels, mesurés au niveau du sol par des spectroradiomètres, ou bien la bibliothèque spectrale AGC [119]). En général, ces méthodes imposent la parcimonie de la solution (elles imposent aux pixels mixtes d'être composés de peu de matériaux) en minimisant un critère sous contraintes (un des critères les plus utilisés, revient à minimiser la norme l_1) [8].

1.6.1.4. Les méthodes basées sur la factorisation en matrices non-négatives

Ces méthodes sont basées sur la non-négativité des données. Elles consistent de manière générale à factoriser une matrice en un produit de deux matrices dont les coefficients sont aussi positifs. L'inconvénient majeur de ces méthodes est leur problème de non-unicité de la solution. Plusieurs méthodes ont été proposées afin d'éviter ce problème ainsi que celui de

l'initialisation. Dans [120], l'algorithme NMF a été appliqué pour le démixage d'images hyperspectrales. Ce dernier met à jour alternativement les matrices des sources suivant l'hypothèse de non-négativité. Cependant, il ne tient pas compte de la contrainte d'additivité.

Il est possible de se référer aux articles suivants [8, 30, 32, 121] ainsi que les références qui y sont citées pour plus de détails sur les méthodes linéaires.

1.6.2. Méthodes de démixage spectral pour des mélanges non-linéaires

La plupart des procédures de démixage spectral supposent que le modèle de mélange est linéaire en raison de sa relative simplicité. Cependant, le modèle linéaire peut s'avérer insuffisant pour décrire la complexité de certains phénomènes physiques [7, 8]. Cela est le cas lorsque la lumière réfléchie par la cible interagit avec plusieurs matériaux avant de remonter vers le capteur comme illustré dans la Figure 1.5. Ce phénomène de réflexions multiples se produit généralement lorsque la scène observée présente un relief non plat (par exemple une scène urbaine) [122], ou dans le cas de présence de mélange intime (mélange homogène) (par exemple le cas des grains de sable) [123]. Dans ces conditions, un modèle non-linéaire est plus adapté pour représenter la complexité du mélange spectral.

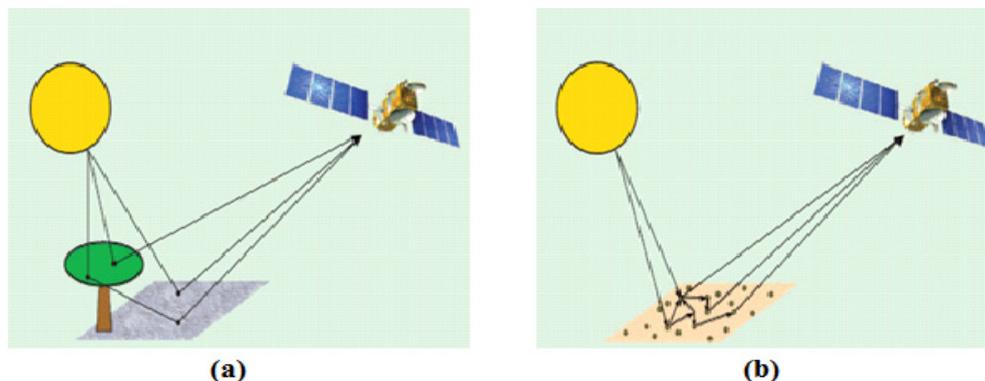


Figure 1.5 : Illustration du modèle de mélanges non-linéaires : (a) réflexions multiples, (b) mélange intime.

Récemment dans la littérature, des méthodes ont été proposées pour résoudre le problème de démixage spectral en palliant les limitations des modèles linéaires tout en tenant compte de la non-linéarité des données traitées. Pour plus de détails sur ce type de modèles et des méthodes de démixage correspondantes il est possible de se référer à [10, 124].

1.6.2.1. Méthodes de démixtion spectrale pour des modèles de mélange non-linéaires non-définis

Le processus de démixtion spectrale est d'autant plus difficile lorsque le modèle de mélange est inconnu. Plusieurs méthodes non-linéaires ont été proposées pour résoudre ce problème sans modèle de mélange (non-linéaire) prédéfini, comprenant des méthodes non-supervisées basées sur des techniques d'apprentissage de variété [125-127]. Les approches basées sur un noyau adaptatif (Kernel-based) ont également reçu un intérêt croissant ces dernières années. Dans [123, 128], les auteurs ont proposé l'algorithme KFCLS (Kernel Fully Constrained Least Squares), qui est une généralisation de l'algorithme FCLS [105], dans lequel ils introduisent une fonction noyau dans le critère à minimiser, avec un paramètre réglable qui dépend de la linéarité du mélange, avec le but de tenir compte de la non-linéarité des mélanges.

Plus récemment, dans [129], les auteurs ont proposé un algorithme non-linéaire supervisé (RKHS (Reproducing Kernel Hilbert Spaces)) qui prend en compte les interactions non-linéaires des endmembers lorsque ces derniers sont supposés être connues a priori. Dans [130], une autre approche a été proposée, et celle-ci est basée sur une réduction de la dimension en utilisant un modèle de variable latente de processus gaussien (GPLVM (Gaussian Process Latent Variable Model)). L'algorithme proposé dans [130] estime les paramètres du noyau, les spectres des endmembers et les abondances.

Dans la suite de ce manuscrit, nous nous intéressons particulièrement au modèle de mélange linéaire-quadratique/bilinéaire, étant donné que ce modèle est le plus adapté pour décrire la complexité des phénomènes physiques des scènes de milieux urbains [11].

1.6.2.2. Méthodes de démixtion spectrale pour des modèles de mélange non-linéaires spécifiques

Il existe dans la littérature des méthodes non-linéaires de démixtion spectrale qui reposent sur un modèle de mélange spécifique. Ces méthodes ont pour but de tenir compte des interactions entre les différents matériaux en présence de relief, ce qui est souvent le cas pour les images acquises sur des scènes avec végétation et/ou en milieux urbains [10, 131, 132]. Nous nous intéressons dans cette section aux différents modèles non-linéaires proposés dans

la littérature ainsi que les modèles sur lesquels sont basées nos approches. Nous citons par la suite quelques méthodes de démixage pour ces modèles non-linéaires.

Plusieurs modèles ont été proposés pour décrire analytiquement les interactions entre les différents matériaux présents dans une scène imagée. Cependant, ces modèles ne prennent en compte que les interactions d'ordre deux "n'impliquant que les interactions entre deux matériaux" (les interactions d'ordres supérieurs à deux sont négligées). Parmi ces modèles nous citons :

1) Les modèles bilinéaires

Les modèles bilinéaires ont reçu un intérêt croissant au cours des dernières années pour leur capacité à représenter le phénomène de diffusion double se produisant dans les images hyperspectrales, lorsque la lumière diffusée par un matériau donné se reflète sur d'autres matériaux avant d'atteindre le capteur.

La plupart des modèles bilinéaires proposés dans la littérature peuvent être exprimés sous la forme suivante :

$$x_i = \sum_{j=1}^M a_j(i) s_j + \sum_{j=1}^{M-1} \sum_{l=j+1}^M \beta_{j,l}(i) s_j \odot s_l. \quad (1.27)$$

Le premier terme du côté droit de l'équation contient la partie linéaire du mélange, tandis que le second terme modélise les interactions non-linéaires entre les matériaux. Le paramètre supplémentaire $\beta_{j,l}(i)$ est un coefficient qui détermine la quantité de non-linéarité entre les composants s_j et s_l dans le pixel x_i . Plusieurs alternatives pour imposer des contraintes sur ces coefficients non-linéaires ont été proposées :

Nascimento et Bioucas-Dias [133] ont proposé d'imposer les contraintes suivantes :

$$\begin{cases} a_j(i) \geq 0, \\ \beta_{j,l}(i) \geq 0, \\ \sum_{j=1}^M a_j(i) + \sum_{j=1}^{M-1} \sum_{l=j+1}^M \beta_{j,l}(i) = 1. \end{cases} \quad j < l. \quad (1.28)$$

Comme pour le cas du modèle (1.27), le modèle proposé appelé "Modèle Nascimento (NM)", peut être considéré comme un modèle linéaire où les endmembers des termes quadratiques sont considérés "virtuels", n'ayant pas d'existence physique dans la surface représentée par un pixel.

Dans [131], les auteurs proposent un deuxième modèle bilinéaire, connu comme le modèle de Fan, dans lequel la non-linéarité est exprimée en fonction des coefficients d'abondances linéaires : $\beta_{j,l}(i) = a_j(i) a_l(i)$ ($j < l$). Le modèle est représenté par l'équation suivante :

$$x_i = \sum_{j=1}^M a_j(i) s_j + \sum_{j=1}^{M-1} \sum_{l=j+1}^M a_j(i) a_l(i) s_j \odot s_l, \quad (1.29)$$

où $a_j(i)$ et $a_l(i)$ sont les abondances de la partie linéaire, correspondant aux matériaux j et l . Les contraintes présentées dans (1.28) sont aussi imposées à ce modèle. Si le j -ième matériau est absent du pixel x_i , soit $a_j(i) = 0$, il n'y a donc pas d'interaction entre le spectre du matériau s_j et les spectres d'autres matériaux s_l ($j \neq l$) présents dans ce même pixel.

Dans [134], les auteurs présentent une nouvelle proposition pour le modèle bilinéaire : le Modèle Bilineaire Généralisé (Generalized Bilinear Model GBM), basé sur le modèle de Fan qui généralise le modèle de mélange linéaire. Ce modèle est représenté par l'équation suivante :

$$x_i = \sum_{j=1}^M a_j(i) s_j + \sum_{j=1}^{M-1} \sum_{l=j+1}^M \gamma_{j,l}(i) a_j(i) a_l(i) s_j \odot s_l, \quad (1.30)$$

avec

$$\begin{cases} a_j(i) \geq 0, \\ \sum_{j=1}^M a_j(i) = 1, \\ 0 \leq \gamma_{j,l}(i) \leq 1. \end{cases} \quad j < l, \quad (1.31)$$

où $\gamma_{j,l}(i)$ est le coefficient d'interaction, qui quantifie l'interaction non-linéaire entre les composantes spectrales des matériaux s_j et s_l . Le modèle bilinéaire généralisé GBM a l'avantage de généraliser à la fois le modèle linéaire ($\gamma_{j,l}(i) = 0$) et le modèle de Fan ($\gamma_{j,l}(i) = 1$).

2) Le modèle linéaire-quadratique

Dans [11], un nouveau modèle de mélange est présenté : le modèle Linéaire-Quadratique (LQ). En effet, les auteurs montrent dans leur travaux basés sur une analyse physique de scènes modélisant du relief de type urbain (en présence de structures 3D) [135], que le modèle linéaire-quadratique décrit mieux les phénomènes de réflexions dans ce type de scènes. Le modèle linéaire-quadratique proposé est décrit comme suit :

$$x_i = \sum_{j=1}^M a_j(i)s_j + \sum_{j=1}^M \sum_{l=j}^M a_{j,l}(i)s_j \odot s_l, \quad (1.32)$$

avec

$$\begin{cases} a_j(i) \geq 0, \\ \sum_{j=1}^M a_j(i) = 1, \\ 0 \leq a_{j,l}(i) \leq 0.5. \end{cases} \quad \begin{matrix} j = 1 \dots M, \\ 1 \leq j \leq l \leq M \end{matrix} \quad (1.33)$$

où $a_{j,l}(i)$ est le coefficient de mélange correspondant à la partie quadratique du modèle. Contrairement aux modèles bilinéaires qui modélisent uniquement les réflexions doubles entre différents matériaux, ce dernier prend en compte des réflexions impliquant un même matériau $s_j \odot s_j, j = 1 \dots M$.

Nous trouvons aussi dans la littérature d'autres propositions de modèles non-linéaires. Dans [136] par exemple, les auteurs proposent un modèle d'approximations capable de décrire une large classe de non-linéarités..

3) Méthodes de démixage spectral

Plusieurs méthodes de démixage spectral ont été proposées afin de faire face aux non-linéarités dans les scènes hyperspectrales. Dans [134], les auteurs proposent un algorithme de démixage non-linéaire pour le modèle de mélange bilinéaire dans lequel ils introduisent des termes quadratiques pour modéliser les effets de diffusion de la lumière sur les différents matériaux. La méthode de démixage proposée commence par inspecter l'ensemble de l'image afin de détecter les pixels purs de chaque classe de matériaux d'une manière supervisée. Par la suite, les abondances (matrice de mélange) sont estimées par une méthode de moindres carrés avec contraintes.

Dans [131] et [134], des algorithmes dédiés respectivement aux modèles de Fan et GBM sont proposés. Ces derniers sont considérés comme une approximation au premier ordre, par séries de Taylor, d'un modèle non-linéaire inconnu. Dans [134], l'algorithme proposé permet d'estimer les abondances en connaissant les endmembers qui sont préalablement estimés par l'algorithme VCA [98]. Lorsque les endmembers présents dans un modèle doivent également être identifiés en plus des abondances, des algorithmes de démixage plus ambitieux doivent être conçus. Dans [137], les auteurs proposent un algorithme qui permet d'estimer à la fois les spectres et les abondances. Ce dernier généralise l'algorithme de SPICE (Sparsity-Promoting

Iterated Constrained Endmember (ICE)) [138], proposé pour le mélange linéaire, au modèle Nascimento (NM). D'autres algorithmes non-supervisés de démélange spectral basés sur la factorisation en matrices non-négatives (NMF) ont été proposés : [139] pour le modèle bilinéaire généralisé GBM et [10, 11, 93] pour le modèle linéaire-quadratique (LQ). Parmi ces méthodes, nous pouvons citer : La NMF linéaire multiplicative étendue (en anglais Linear Extended NMF (Lin-Ext-NMF)) [10], cette méthode est une extension de la méthode NMF linéaire multiplicative [64], dans laquelle les termes quadratiques ("pseudo-endmembers" issus des interactions entre les vrais endmembers) sont considérés comme des endmembers supplémentaires, sans tenir compte du lien entre ces pseudo-endmembers et les vrais endmembers. Cette méthode utilise les mêmes règles de mise à jour que l'algorithme multiplicatif de Lee et Seung [64], auquel les deux contraintes supplémentaires liées au modèle de mélange sont ajoutées :

$$[a_1(i) \dots a_M(i)] \leftarrow [a_1(i) \dots a_M(i)] / \sum_{j=1}^M a_j(i), \quad (1.34)$$

$$a_{j,l}(i) \leftarrow \min \{a_{j,l}(i), 0.5\}. \quad (1.35)$$

Dans [10], les auteurs ont proposé la méthode NMF Linéaire-Quadratique à Gradient (en anglais Gradient Linear-Quadratic NMF (Grd-LQNMF)), qui est basée sur un algorithme de gradient projeté à pas fixe, qui minimise une fonction coût. Cette méthode, contrairement à la précédente, tient compte du fait que les pseudo-sources (pseudo-endmembers) sont le produit des vraies sources dans les calculs, donnant lieu à de nouvelles règles de mise à jour. Une version multiplicative de cette dernière méthode a également été proposée dans [10].

1.7. Conclusion

Dans ce chapitre, des généralités sur la séparation aveugle de sources ont été introduites. Dans une première partie, nous avons décrit les différents modèles de mélange usuels, ensuite un panorama des principales méthodes de séparation de sources a été présenté pour le cas des mélanges linéaires. Nous avons ainsi décrit les trois grandes catégories de méthodes pour ce type de mélange : la première basée sur l'Analyse en Composantes Indépendantes, la deuxième basée sur l'Analyse en Composantes Parcimonieuses (SCA), et enfin la catégorie des méthodes de Factorisation en Matrices Non-négatives (NMF). Puis nous avons présenté l'essentiel des travaux effectués dans le cas des mélanges non-linéaires, plus précisément des

mélanges bilinéaires et linéaire-quadratiques, ces derniers cas étant ceux qui seront étudiés dans cette thèse.

Dans la deuxième partie de ce chapitre, nous nous sommes intéressés aux méthodes de séparation de sources pour le démixtion spectral. Nous avons ainsi présenté un panorama des méthodes de démixtion spectral en télédétection. Dans cette partie, un état de l'art des principales méthodes existantes a été donné dans le cas d'un modèle linéaire puis dans le cas de modèles non-linéaires. Par la suite, nous avons présenté certaines méthodes de démixtion spectral non-linéaires, et plus particulièrement celles dédiées aux mélanges bilinéaires et aux mélanges linéaire-quadratiques, qui sont ceux qui modélisent le mieux les phénomènes étudiés dans ce manuscrit.

Dans le chapitre suivant, nous nous proposons de décrire les méthodes, de démixtion d'images hyperspectrales, développées et conçues dans le cadre de cette thèse pour des modèles non-linéaires adaptés aux milieux urbains.

Chapitre 2 : Méthodes non-linéaires de démixtion spectrale proposées

Sommaire

2.1. Introduction	43
2.2. Modèle mathématique de données	43
2.3. Méthodes proposées	46
2.3.1. Critère optimisé	46
2.3.2. Première méthode proposée : méthode à gradient projeté.....	48
2.3.2.1. Algorithme pour mélanges bilinéaires.....	50
2.3.2.2. Algorithme pour mélanges linéaire-quadratiques.....	51
2.3.3. Deuxième méthode proposée : méthode multiplicative.....	53
2.3.3.1. Algorithme multiplicatif pour mélanges bilinéaires.....	54
2.3.3.2. Algorithme multiplicatif pour mélanges linéaire-quadratiques.....	54
2.4. Conclusion.....	55

2.1. Introduction

Dans le chapitre précédent, nous avons présenté les principales méthodes de démixage spectral qui existent dans la littérature, ainsi que les différentes classes de méthodes de séparation aveugle de sources (SAS) en rapport avec le domaine de la télédétection. Nous avons aussi défini les différents modèles de mélange sur lesquels sont basées ces méthodes.

Dans ce chapitre, nous présentons les méthodes proposées dans notre thèse. Ces méthodes sont basées sur la factorisation matricielle avec contraintes de non-négativité conçues pour le cas particulier d'images hyperspectrales de milieux urbains. La réduction du nombre de variables considérées, lors de l'optimisation de la fonction de coût utilisée, constitue l'originalité principale des méthodes proposées.

Pour rappel, le modèle de mélange le plus couramment utilisé dans les méthodes de démixage spectral est le modèle linéaire. Cependant, lorsque nous sommes en présence de paysage non-plat dans la scène observée (comme en milieu urbain), le modèle de mélange linéaire n'est plus valide et doit être remplacé par un modèle de mélange non-linéaire. Ce modèle non-linéaire peut être réduit à un modèle de mélange linéaire-quadratique ou bilinéaire [11]. Dans ce chapitre nous commençons donc par présenter notre modèle mathématique de données pour notre cas d'images hyperspectrales de scènes de milieux urbains. Par la suite, nous présentons nos approches développées pour le démixage spectral non-supervisé, basées sur la NMF, et adaptées au modèle de mélange linéaire-quadratique ou bilinéaire présent dans le type des données considérées.

2.2. Modèle mathématique de données

Nous rappelons que la problématique abordée dans cette première partie de la thèse est l'extraction des spectres d'endmembers à partir d'images hyperspectrales de milieux urbains. Le modèle de mélange considéré dans notre étude est le modèle linéaire-quadratique ou bilinéaire [11] introduit dans le chapitre précédent. Dans ce modèle, chaque vecteur spectral associé à un pixel dans une image de télédétection est supposé être un mélange linéaire-quadratique ou bilinéaire de différents spectres de matériaux purs (spectres d'endmembers). Mathématiquement, le spectre de réflectance non-négatif x_i d'un pixel i ($i = 1 \dots P$, P étant le nombre de pixels) est donné par [10] (pour le mélange linéaire-quadratique, qui englobe le mélange bilinéaire) :

$$x_i = \sum_{j=1}^M a_j(i) s_j + \sum_{j=1}^M \sum_{l=j}^M a_{j,l}(i) s_j \odot s_l, \quad (2.1)$$

avec

- s_j : (vecteur colonne de taille L) est le spectre de réflectance non négatif du j -ième endmember ($s_j \odot s_l$ est considéré ici comme le spectre d'un "pseudo-endmember")
- $a_j(i)$ et $a_{j,l}(i)$: correspondent respectivement aux fractions d'abondances linéaires et quadratiques pour le pixel i .
- L et M : correspondent respectivement au nombre de bandes spectrales dans l'image et au nombre d'endmembers présents dans la zone observée.

Notons que dans l'équation (2.1), nous considérons $a_{j,l} = a_{l,j}$. Ce dernier terme ne peut être présent au maximum qu'une seule fois pour le couple $(j, l) = (l, j)$ donné.

Le modèle de mélange considéré dans nos travaux doit également répondre à certaines contraintes pour le démixage spectral des images hyperspectrales de milieux urbains. Ces contraintes concernent les fractions d'abondances du modèle considéré [11] :

$$\begin{cases} \sum_{j=1}^M a_j(i) = 1, \\ a_j(i) \geq 0, & j = 1 \dots M \\ 0 \leq a_{j,l}(i) \leq 0.5, & 1 \leq j \leq l \leq M \end{cases} \quad (2.2)$$

Afin de mettre en évidence les termes linéaires, les auto-termes et les termes croisés d'ordre deux du modèle de mélange considéré dans nos méthodes, nous choisissons de réécrire le modèle présenté dans l'équation (2.1) comme suit :

$$x_i = \sum_{j=1}^M a_j(i) s_j + \sum_{j=1}^{M-1} \sum_{l=j+1}^M a_{j,l}(i) s_j \odot s_l + \sum_{j=1}^M a_{j,j}(i) s_j \odot s_j, \quad (2.3)$$

où

- $\sum_{j=1}^M a_j(i) s_j$ représente les termes linéaires.
- $\sum_{j=1}^{M-1} \sum_{l=j+1}^M a_{j,l}(i) s_j \odot s_l$ représente les termes croisés, où $s_j \odot s_l$ (avec $j \neq l$) représente le spectre d'un "cross-pseudo-endmember".
- $\sum_{j=1}^M a_{j,j}(i) s_j \odot s_j$ représente les auto-termes, où $s_j \odot s_j$ représente ici le spectre d'un

"auto-pseudo-endmember".

L'équation (2.3) décrit l'expression générale du modèle linéaire-quadratique pour le spectre de réflectance non-négatif x_i d'un pixel i . Si nous négligeons les termes au carré (dernier terme à droite de l'équation) cette dernière décrit alors l'expression du modèle bilinéaire.

Le modèle décrit dans l'équation (2.3) peut être reformulé sous forme matricielle comme suit (pour P pixels, $P \geq 2$) :

$$X = AS = A_a S_a + A_b S_b + A_c S_c, \quad (2.4)$$

où $X = [x_1 \dots x_P]^T$ (matrice des spectres des pixels observés, de dimension $P \times L$), $A = [A_a \ A_b \ A_c]$ (matrice des fractions d'abondances linéaires et quadratiques), et $S = \begin{bmatrix} S_a \\ S_b \\ S_c \end{bmatrix}$

(matrice des spectres d'endmembers et pseudo-endmembers), avec :

$$A_a = \begin{bmatrix} a_1(1) & \dots & a_M(1) \\ \vdots & \ddots & \vdots \\ a_1(P) & \dots & a_M(P) \end{bmatrix}, \quad (2.5)$$

$$A_b = \begin{bmatrix} a_{1,2}(1) & a_{1,3}(1) & \dots & a_{M-1,M}(1) \\ \vdots & \vdots & \ddots & \vdots \\ a_{1,2}(P) & a_{1,3}(P) & \dots & a_{M-1,M}(P) \end{bmatrix}, \quad (2.6)$$

$$A_c = \begin{bmatrix} a_{1,1}(1) & a_{2,2}(1) & \dots & a_{M,M}(1) \\ \vdots & \vdots & \ddots & \vdots \\ a_{1,1}(P) & a_{2,2}(P) & \dots & a_{M,M}(P) \end{bmatrix}, \quad (2.7)$$

$$S_a = [s_1 \dots s_M]^T, \quad (2.8)$$

$$S_b = [s_1 \odot s_2 \quad s_1 \odot s_3 \quad \dots \quad s_{M-1} \odot s_M]^T, \quad (2.9)$$

$$S_c = [s_1 \odot s_1 \quad s_2 \odot s_2 \quad \dots \quad s_M \odot s_M]^T. \quad (2.10)$$

Dans les méthodes proposées, nous imposons un ordre de position des termes quadratiques de notre modèle de mélange : les spectres cross-pseudo-endmembers sont ainsi contenus dans la matrice S_b et les spectres auto-pseudo-endmembers sont contenus dans la matrice S_c . Ces

termes quadratiques sont calculés à partir des M spectres de la partie linéaire par une multiplication élément par élément. Le modèle présenté ci-dessus est le cas général du modèle linéaire-quadratique. Dans le cas d'un modèle bilinéaire, où les termes au carré ne sont pas pris en compte, les matrices A_c et S_c n'existent pas.

Les lignes de la matrice S (matrice des spectres d'endmembers et pseudo-endmembers) sont utilisées pour décomposer les vecteurs lignes de la matrice X (matrice des spectres des pixels observés), tandis que la matrice A contient les fractions d'abondances (linéaires et quadratiques) de cette décomposition. De plus, la matrice S est contrainte comme décrit dans (2.8), (2.9) et (2.10), où seule la partie supérieure de la matrice (soit les M lignes supérieures), qui contient les spectres d'endmembers, est libre, toutes les lignes qui suivent sont des produits élément par élément de ces M lignes supérieures [21]. La matrice A est contrainte par (2.5)-(2.7).

Il est à noter que dans nos travaux, le nombre de matériaux M est supposé connu. Cependant il peut être automatiquement calculé par des méthodes d'estimation de nombre d'endmembers qui existent dans la littérature: [102, 103] dans le cas du modèle linéaire et [140] pour le cas non-linéaire.

2.3. Méthodes proposées

L'objectif de nos travaux est de développer des méthodes de démixage spectral qui permettent de bien estimer les spectres de réflectance des endmembers (qui correspondent à la composition réelle des pixels) dans le cas de mélange linéaire-quadratique ou bilinéaire, et cela en tenant compte des interactions possibles représentées par les termes quadratiques (afin d'améliorer l'estimation des spectres des endmembers dans le cas où ces termes ne peuvent être négligés). Les méthodes de démixage proposées dans cette partie du manuscrit sont basées sur le concept du démixage spectral linéaire-quadratique (LQSU (Linear-Quadratic Spectral Unmixing)) et utilisent la NMF.

2.3.1. Critère optimisé

Les méthodes de type NMF ont pour objectif de retrouver à partir d'une matrice d'observation X non-négative, deux autres matrices \tilde{A} et \tilde{S} (qui visent à estimer respectivement les matrices A et S) également non-négatives, où la factorisation est effectuée

en minimisant une fonction de coût avec contraintes et donnant lieu à différentes règles de mise à jour. Pour les méthodes mises en place dans cette première partie du manuscrit, nous avons choisi de minimiser le critère classique de la norme de Frobenius défini comme suit :

$$J_1 = \frac{1}{2} \|X - \tilde{A}\tilde{S}\|_F^2, \text{ avec } \tilde{A}, \tilde{S} \geq 0. \quad (2.11)$$

Nos méthodes proposées pour l'estimation de la matrice des spectres d'endmembers sont basées sur l'approche présentée dans [21] :

– Seuls les éléments des M premiers vecteurs lignes de la matrice \tilde{S} sont considérés comme des variables maîtresses.

– Les éléments de la matrice \tilde{A} sont considérés comme des variables esclaves, où \tilde{A} est définie par la solution de moindres carrés optimale qui minimise la fonction de coût J_1 pour une valeur considérée de \tilde{S} , qui est supposée être de rang de ligne plein.

Ainsi, la matrice \tilde{A} est prédéterminée comme suit :

$$\tilde{A}_{opt} = X \tilde{S}^T (\tilde{S}\tilde{S}^T)^{-1}. \quad (2.12)$$

En remplaçant la matrice \tilde{A} par sa valeur optimale \tilde{A}_{opt} dans l'équation (2.11), nous obtenons une nouvelle fonction de coût à optimiser qui est comme suit :

$$J_2 = \frac{1}{2} \|X - X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S}\|_F^2. \quad (2.13)$$

Cette expression de la fonction de coût J_2 , est réécrite comme suit :

$$J_2 = \frac{1}{2} Tr \left(\left(X - X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S} \right) \left(X - X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S} \right)^T \right), \quad (2.14)$$

$$= \frac{1}{2} Tr \left(\left(X - X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S} \right) \left(X^T - \tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S} X^T \right) \right), \quad (2.15)$$

$$\begin{aligned}
&= \frac{1}{2} \text{Tr}(XX^T - X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S}X^T - X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S}X^T \\
&\quad + X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S}\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S}X^T),
\end{aligned} \tag{2.16}$$

$$= \frac{1}{2} \text{Tr}(XX^T - 2 \times (X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S}X^T) + X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S}X^T), \tag{2.17}$$

$$= \frac{1}{2} \text{Tr}(XX^T - X\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}\tilde{S}X^T). \tag{2.18}$$

Lorsque nous considérons que la matrice \tilde{S} a plus de colonnes que de lignes, comme c'est le cas dans nos approches, $\tilde{S}^T(\tilde{S}\tilde{S}^T)^{-1}$ est remplacée par \tilde{S}^+ (la matrice pseudo-inverse de Moore-Penrose de \tilde{S}) dans l'expression (2.18). Cela nous donne une nouvelle expression de J_2 :

$$J_2 = \frac{1}{2} \text{Tr}(XX^T - X\tilde{S}^+\tilde{S}X^T). \tag{2.19}$$

2.3.2. Première méthode proposée : méthode à gradient projeté

Cette méthode vise à modéliser la fonction de mélange définie par l'équation (2.4). Les variables, impliquées dans la méthode de démixtion considérée, sont constituées des deux matrices \tilde{A} et \tilde{S} , où \tilde{A} est remplacée par son expression (2.12).

Nous commençons par calculer l'expression du gradient de J_2 par rapport à un élément \tilde{s}_{ml} , élément de la ligne m parmi les M lignes maîtresses de la matrice \tilde{S} (les variables \tilde{s}_{ml} sont les seules variables à considérer dans le calcul du gradient). Ce dernier peut être calculé à partir de l'expression (2.19) comme suit [141] :

$$\frac{\partial J_2}{\partial \tilde{s}_{ml}} = \frac{1}{2} \frac{\partial}{\partial \tilde{s}_{ml}} \text{Tr}(XX^T - X\tilde{S}^+\tilde{S}X^T), \tag{2.20}$$

$$= \frac{1}{2} \left(\text{Tr} \left(\frac{\partial}{\partial \tilde{s}_{ml}} (XX^T) \right) - \text{Tr} \left(\frac{\partial}{\partial \tilde{s}_{ml}} (X\tilde{S}^+\tilde{S}X^T) \right) \right), \tag{2.21}$$

$$= -\frac{1}{2} \text{Tr} \left(\frac{\partial}{\partial \tilde{s}_{ml}} (X\tilde{S}^+ \tilde{S}X^T) \right), \quad (2.22)$$

$$= -\frac{1}{2} \text{Tr} \left(\frac{\partial X}{\partial \tilde{s}_{ml}} \tilde{S}^+ \tilde{S}X^T + X \frac{\partial}{\partial \tilde{s}_{ml}} (\tilde{S}^+ \tilde{S}X^T) \right), \quad (2.23)$$

$$= -\frac{1}{2} \text{Tr} \left(X \frac{\partial}{\partial \tilde{s}_{ml}} (\tilde{S}^+ \tilde{S}X^T) \right), \quad (2.24)$$

$$= -\frac{1}{2} \text{Tr} \left(X \frac{\partial \tilde{S}^+}{\partial \tilde{s}_{ml}} \tilde{S}X^T + X\tilde{S}^+ \frac{\partial}{\partial \tilde{s}_{ml}} (\tilde{S}X^T) \right). \quad (2.25)$$

Cette dernière expression contient deux termes à dériver. La dérivée du premier terme est la suivante :

$$\frac{\partial \tilde{S}^+}{\partial \tilde{s}_{ml}} = (I - \tilde{S}^+ \tilde{S}) \frac{\partial \tilde{S}^T}{\partial \tilde{s}_{ml}} (\tilde{S} \tilde{S}^T)^{-1} - \tilde{S}^+ \frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}} \tilde{S}^+. \quad (2.26)$$

La dérivée du second terme est la suivante :

$$\frac{\partial}{\partial \tilde{s}_{ml}} (\tilde{S}X^T) = \frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}} X^T. \quad (2.27)$$

Ainsi, l'expression du gradient de J_2 par rapport à \tilde{s}_{ml} est donnée comme suit :

$$\frac{\partial J_2}{\partial \tilde{s}_{ml}} = \text{Tr} \left((X\tilde{S}^+ \tilde{S} - X)^T X\tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}} \right) \right), \quad (2.28)$$

$$\frac{\partial J_2}{\partial \tilde{s}_{ml}} = \text{Tr} \left((X\tilde{S}^+ \tilde{S})^T X\tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}} \right) \right) - \text{Tr} \left(X^T X\tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}} \right) \right), \quad (2.29)$$

$$\frac{\partial J_2}{\partial \tilde{s}_{ml}} = \text{Tr} \left(\tilde{S}^+ \tilde{S} X^T X\tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}} \right) \right) - \text{Tr} \left(X^T X\tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}} \right) \right), \quad (2.30)$$

Nous rappelons que dans cette première approche deux modèles de mélange différents sont considérés (le linéaire-quadratique et le bilinéaire). Ainsi l'expression finale du gradient de J_2 par rapport à un élément \tilde{s}_{ml} peut être facilement déduite en calculant la valeur de $\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}$. Cette valeur dépend du modèle de mélange considéré, donnant lieu à deux algorithmes différents :

2.3.2.1. Algorithme pour mélanges bilinéaires

Le premier algorithme proposé est l'algorithme Grd-NS-LS-BMF pour "Gradient-based Nonnegative Spectra Least-Squares Bilinear Matrix Factorization", dans lequel le modèle de mélange considéré est le modèle bilinéaire qui est un cas particulier du modèle linéaire-quadratique. Dans cet algorithme, la matrice $\frac{\partial \tilde{s}}{\partial \tilde{s}_{ml}}$ est une matrice de dimension $\left[M + \frac{M(M-1)}{2} \right] \times L$ dont la valeur de $\left[\frac{\partial \tilde{s}}{\partial \tilde{s}_{ml}} \right]_{pq}$ (un élément de cette matrice à la position (p, q)) est égale à :

$$\left\{ \begin{array}{ll} 1 & \text{Si } p = m \text{ et } q = l \\ \tilde{s}_{m'l} & \text{Si } m \in \{1, \dots, M-1\}, m' \in \{m+1, \dots, M\} / \\ & p = M + [B]_{mm'}, \text{ et } q = l \\ 0 & \text{ailleurs} \end{array} \right. \quad (2.31)$$

La matrice B est une matrice symétrique de dimension $M \times M$ dont la diagonale principale est inutilisée, et dont la partie supérieure est organisée comme suit : chaque élément $[B]_{rt}$ à la position (r, t) dans la matrice B avec $t > r$, correspond au cross-pseudo-endmember $s_r \odot s_t$ et est égale à l'indice de la ligne dans la matrice \tilde{S}_b qui contient ce cross-pseudo-endmember. Ces valeurs $[B]_{rt}$ sont des nombres entiers et sont stockées de gauche à droite et de haut en bas dans la partie supérieure de la matrice B dans l'ordre croissant, c'est à dire de 1 à $(M-1)$ dans la première rangée, de M à $(2M-3)$ dans la deuxième rangée et ainsi de suite. Ces valeurs peuvent ainsi être calculées en utilisant l'expression suivante (pour $t > r$) :

$$[B]_{rt} = \frac{1}{2} [M(M-1) - (M-r)(M-r+1)] + (t-r). \quad (2.32)$$

La matrice B est identique dans toutes les équations suivantes.

L'expression finale du gradient de J_2 par rapport à un élément \tilde{s}_{ml} donne la règle de mise à jour suivante (pour les éléments maîtres \tilde{s}_{ml} des M lignes supérieures de \tilde{S}) en appliquant la méthode de descente du gradient :

$$\tilde{s}_{ml} \leftarrow \tilde{s}_{ml} - \alpha \frac{\partial J_2}{\partial \tilde{s}_{ml}}, \quad (2.33)$$

avec un taux d'apprentissage fixe α (pas du gradient), pour tous les éléments \tilde{s}_{ml} , choisi suffisamment petit pour que l'algorithme converge.

Cette règle de mise à jour n'est pas suffisante pour garantir la non-négativité de nos variables. Afin d'assurer cette contrainte, une nouvelle règle itérative de mise à jour est déduite de la précédente. Cette règle consiste à projeter l'élément \tilde{s}_{ml} obtenu avec la règle de mise à jour (2.33) sur R^+ . La règle itérative finale de mise à jour du gradient projeté est alors exprimée comme suit :

$$\tilde{s}_{ml} \leftarrow \max \left[\varepsilon, \tilde{s}_{ml} - \alpha \frac{\partial J_2}{\partial \tilde{s}_{ml}} \right], \quad (2.34)$$

où ε est un nombre positif et très petit.

Notons que dans cette approche les variables esclaves de \tilde{S} sont mises à jour conjointement avec les variables maîtresses. Nous avons donc pour chaque itération les règles de mise à jour suivantes :

- Règle de mise à jour des variables maîtresses de \tilde{S} :

$$\tilde{s}_{ml} \leftarrow \tilde{s}_{ml} - \alpha \left(\text{Tr} \left((X\tilde{S}^+ \tilde{S} - X)^T X\tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}} \right) \right) \right), \text{ avec } m \in \{1, \dots, M\}, \quad (2.35)$$

$$l \in \{1, \dots, L\},$$

et

$$\tilde{s}_{ml} \leftarrow \max [\varepsilon, \tilde{s}_{ml}]. \quad (2.36)$$

- Règle de mise à jour des variables esclaves de \tilde{S} :

$$\tilde{s}_{kl} \leftarrow \tilde{s}_{ml} \times \tilde{s}_{m'l}, \text{ avec } k = M + [B]_{mm'} / m \in \{1, \dots, M - 1\}, \quad (2.37)$$

$$m' \in \{m + 1, \dots, M\} \text{ et } l \in \{1, \dots, L\}.$$

2.3.2.2. Algorithme pour mélanges linéaire-quadratiques

Le deuxième algorithme proposé est l'algorithme Grd-NS-LS-LQMF "Gradient-based Nonnegative Spectra Least-Squares Linear-Quadratic Matrix Factorization". Le modèle de mélange considéré ici est

le modèle linéaire-quadratique. La matrice $\frac{\partial \tilde{s}}{\partial \tilde{s}_{ml}}$ est une matrice de dimension $\left[2M + \frac{M(M-1)}{2}\right] \times L$ dont la valeur de $\left[\frac{\partial \tilde{s}}{\partial \tilde{s}_{ml}}\right]_{pq}$ (un élément de cette matrice à la position (p, q)) est égale à :

$$\left\{ \begin{array}{ll} 1 & \text{Si } p = m \text{ et } q = l \\ \tilde{s}_{m'l} & \text{Si } m \in \{1, \dots, M-1\}, m' \in \{m+1, \dots, M\} / \\ & p = M + [B]_{mm'}, \text{ et } q = l \\ 2\tilde{s}_{ml} & \text{Si } p = M + \frac{M(M-1)}{2} + m \text{ et } q = l \\ 0 & \text{ailleurs} \end{array} \right. . \quad (2.38)$$

- Règle de mise à jour des variables maîtresses de \tilde{S} :

$$\tilde{s}_{ml} \leftarrow \tilde{s}_{ml} - \alpha \left(\text{Tr} \left((X\tilde{S}^+ \tilde{S} - X)^T X\tilde{S}^+ \left(\frac{\partial \tilde{s}}{\partial \tilde{s}_{ml}} \right) \right) \right), \text{ avec } m \in \{1, \dots, M\}, \quad (2.39)$$

$$l \in \{1, \dots, L\},$$

et

$$\tilde{s}_{ml} \leftarrow \max[\varepsilon, \tilde{s}_{ml}]. \quad (2.40)$$

- Règle de mise à jour des variables esclaves de \tilde{S} :

$$\tilde{s}_{kl} \leftarrow \tilde{s}_{ml} \times \tilde{s}_{m'l}, \text{ avec } k = M + [B]_{mm'} / m \in \{1, \dots, M-1\}, \quad (2.41)$$

$$m' \in \{m+1, \dots, M\} \text{ et } l \in \{1, \dots, L\}.$$

$$\tilde{s}_{nl} \leftarrow \tilde{s}_{ml}^2, \text{ avec } n = M + \frac{M(M-1)}{2} + m, m \in \{1, \dots, M\} \text{ et } l \in \{1, \dots, L\}. \quad (2.42)$$

La méthode présentée dans cette section a été développée pour l'extraction des spectres d'endmembers hyperspectraux. Celle-ci est conçue pour les mélanges linéaire-quadratiques et les mélanges bilinéaires, avec des contraintes de non-négativité liées à la nature de nos données. Cette approche donne des résultats assez encourageants (voir chapitre 3), néanmoins elle a comme inconvénient une convergence relativement lente dû à l'utilisation d'un pas fixe dans la descente de gradient. Afin de remédier à ce dernier problème, nous proposons dans la

section qui suit une variante de cette méthode qui permet de s'affranchir du choix du pas.

2.3.3. Deuxième méthode proposée : méthode multiplicative

Afin de s'affranchir du pas de descente dans les algorithmes de gradient, nous nous proposons de développer une nouvelle méthode qui est une version multiplicative de ces derniers, dans laquelle le calcul de la mise à jour de la matrice \tilde{S} se fait à partir de la mise à jour des algorithmes précédents.

A partir de l'équation (2.30), la dérivée $\frac{\partial J_2}{\partial \tilde{s}_{ml}}$ de notre fonction de coût J_2 par rapport à un élément \tilde{s}_{ml} peut être exprimée comme la différence de deux fonctions :

$$\frac{\partial J_2}{\partial \tilde{s}_{ml}} = \frac{\partial J_2^+}{\partial \tilde{s}_{ml}} - \frac{\partial J_2^-}{\partial \tilde{s}_{ml}} \quad (2.43)$$

où la fonction $\frac{\partial J_2^+}{\partial \tilde{s}_{ml}}$, idéalement positive, correspond aux termes précédés d'un signe plus, tandis que la fonction $\frac{\partial J_2^-}{\partial \tilde{s}_{ml}}$, idéalement positive aussi, correspond aux termes précédés d'un signe moins. La contrainte de non-négativité peut alors être satisfaite en initialisant \tilde{s}_{ml} avec une valeur non-négative et en choisissant la valeur de chaque pas α_{ml} comme suit [65] :

$$\alpha_{ml} = \frac{\tilde{s}_{ml}}{\frac{\partial J_2^+}{\partial \tilde{s}_{ml}}} = \frac{\tilde{s}_{ml}}{\text{Tr}\left(\tilde{S}^+ \tilde{S} X^T X \tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}\right)\right)}, \text{ avec } m \in \{1, \dots, M\} \text{ et } l \in \{1, \dots, L\}. \quad (2.44)$$

En remplaçant l'expression du pas α_{ml} dans l'équation (2.33), le calcul de la mise à jour de \tilde{s}_{ml} élément de la matrice \tilde{S} se fait comme suit :

$$\tilde{s}_{ml} \leftarrow \tilde{s}_{ml} \times \frac{\frac{\partial J_2^-}{\partial \tilde{s}_{ml}}}{\frac{\partial J_2^+}{\partial \tilde{s}_{ml}}}, \quad (2.45)$$

$$\tilde{s}_{ml} \leftarrow \tilde{s}_{ml} \times \frac{\text{Tr}\left(X^T X \tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}\right)\right)}{\text{Tr}\left(\tilde{S}^+ \tilde{S} X^T X \tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}\right)\right) + \varepsilon}, \quad (2.46)$$

où ε (positif et très petit) est ajouté au dénominateur de (2.46) pour éviter les éventuelles divisions par zéro.

Notons ici que la matrice pseudo-inverse \tilde{S}^+ peut contenir des valeurs négatives. Afin d'assurer la non-négativité de nos variables, la contrainte suivante est ajoutée avant le calcul de la mise à jour de \tilde{s}_{ml} (2.46).

$$\tilde{S}^+ \leftarrow \max [\varepsilon, \tilde{S}^+]. \quad (2.47)$$

Comme dans l'approche présentée précédemment section 2.3.2, l'expression finale de mise à jour dépend de la valeur de la matrice $\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}$. La valeur de cette dernière dépend alors du modèle de mélange considéré. Nous obtenons ainsi deux algorithmes différents :

2.3.3.1. Algorithme multiplicatif pour mélanges bilinéaires

L'algorithme proposé dans cette section est l'algorithme Multi-NS-LS-BMF "Multiplicative Nonnegative Spectra Least-Squares Bilinear Matrix Factorization", le modèle de mélange considéré dans ce dernier est le modèle bilinéaire.

- Règle de mise à jour des variables maîtresses de \tilde{S} :

$$\tilde{s}_{ml} \leftarrow \tilde{s}_{ml} \times \frac{\text{Tr}\left(X^T X \tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}\right)\right)}{\text{Tr}\left(\tilde{S}^+ \tilde{S} X^T X \tilde{S}^+ \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}\right) + \varepsilon\right)}, \text{ avec } m \in \{1, \dots, M\}, l \in \{1, \dots, L\}, \quad (2.48)$$

où l'expression de $\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}$ est définie par (2.31).

- Règle de mise à jour des variables esclaves de \tilde{S} :

Les variables esclaves de \tilde{S} sont calculées en utilisant l'expression (2.37).

2.3.3.2. Algorithme multiplicatif pour mélanges linéaire-quadratiques

L'algorithme proposé pour le modèle linéaire-quadratique est l'algorithme Multi-NS-LS-LQMF "Multiplicative Nonnegative Spectra Least-Squares Linear-Quadratic Matrix Factorization".

- Règle de mise à jour des variables maîtresses de \tilde{S} :

$$\tilde{s}_{ml} \leftarrow \tilde{s}_{ml} \times \frac{\text{Tr}\left(X^T X \tilde{S} + \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}\right)\right)}{\text{Tr}\left(S + S X^T X \tilde{S} + \left(\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}\right)\right) + \varepsilon}. \quad (2.49)$$

où l'expression de $\frac{\partial \tilde{S}}{\partial \tilde{s}_{ml}}$ est ici définie par (2.38).

- Règle de mise à jour des variables esclaves de \tilde{S} :

Les variables esclaves de \tilde{S} sont calculées en utilisant les expressions (2.41) et (2.42).

L'intérêt de l'approche proposée dans cette section est de s'affranchir de l'inconvénient du choix du pas de descente dans l'algorithme de gradient.

Les algorithmes de cette deuxième approche ont une convergence plus rapide que ceux de l'approche présentée dans la section précédente, ce qui réduit le temps de calcul de ces dernières.

Les performances des approches proposées ainsi que les performances des méthodes de la littérature sont comparées dans le chapitre suivant.

2.4. Conclusion

Dans ce chapitre, nous avons présenté nos méthodes pour le démixage non-supervisé dans le cas d'images hyperspectrales urbaines. Ces méthodes sont conçues pour un modèle de mélange linéaire-quadratique ou bilinéaire. Ces méthodes sont aptes à modéliser le phénomène de diffusions doubles qui se produit dans de telles scènes et cela en tenant compte de la fonction de mélange non-linéaire entre matériaux. Deux approches basées sur la factorisation en matrices non-négatives ont été présentées. La première approche est une approche de type gradient projeté, où deux algorithmes ont été proposés, l'un conçu pour un modèle de mélange bilinéaire et l'autre pour un modèle de mélange linéaire-quadratique. La deuxième, est une approche multiplicative, où là encore deux algorithmes ont été proposés. Les performances de ces méthodes sont présentées et comparées dans le chapitre suivant.

Chapitre 3 : Tests et performances

Sommaire

3.1. Introduction	57
3.2. Protocoles de test.....	57
3.2.1. Initialisation des algorithmes	57
3.2.1.1. Initialisations sans information a priori (init 1).....	57
3.2.1.2. Initialisation avec information a priori (init 2).....	58
3.2.2. Critères de performances	58
3.3. Résultats et discussion.....	60
3.3.1. Test 1	61
3.3.1.1. Résultats avec l'initialisation init 1	63
3.3.1.2. Résultats avec l'initialisation init 2	65
3.3.2. Test 2	70
3.4. Conclusion.....	80

3.1. Introduction

Dans ce chapitre, nous présentons les différents tests réalisés dans cette première partie de notre thèse ainsi que les performances des méthodes testées. Les résultats présentés sont obtenus à partir de tests réalisés sur des données synthétiques générées à partir de spectres réels issus de bibliothèques spectrales.

Nous commençons tout d'abord par présenter dans la première section les protocoles et les conditions de test, où nous décrivons également les différents critères utilisés pour évaluer les performances des méthodes. Dans la section suivante, nous détaillons les différents tests réalisées ainsi que les résultats obtenus avec nos méthodes sur les différents types de données considérées. Dans cette seconde section une comparaison avec les performances de méthodes de la littérature est également donnée.

3.2. Protocoles de test

Dans cette section nous présentons les protocoles de test afin d'évaluer les performances des méthodes testées.

3.2.1. Initialisation des algorithmes

Comme tous les algorithmes basés sur la factorisation en matrices avec des contraintes de non-négativité, nos algorithmes ne garantissent pas de fournir une solution unique et leur convergence dépend de leur initialisation. Pour cette raison, et afin d'évaluer le comportement global de nos algorithmes, plusieurs initialisations sont testées :

3.2.1.1. Initialisations sans information a priori (*init 1*)

Dans cette première configuration, nous supposons qu'aucune information a priori sur les spectres n'est disponible. Les spectres d'endmember $\widetilde{S}_a^{(0)}$ sont alors initialisés avec une valeur constante égale à 0.5. Les spectres de pseudo-endmembers initiaux $\widetilde{S}_b^{(0)}$ et $\widetilde{S}_c^{(0)}$ sont déduits de la matrice initiale des spectres $\widetilde{S}_a^{(0)}$ en utilisant la multiplication élément par élément.

Pour ce qui est de la matrice des fractions d'abondances linéaires $\widetilde{A}_a^{(0)}$, cette dernière est initialisée avec une valeur constante égale à $1/M$ (M nombre d'endmembers). Les matrices

des fractions d'abondances quadratiques $\widetilde{A}_b^{(0)}$ et $\widetilde{A}_c^{(0)}$ sont déduites de la matrice $\widetilde{A}_a^{(0)}$ suivant le principe du modèle de Fan [131] comme suit : pour un pixel i , chaque élément $\widetilde{a}_{j,l}^{(0)}(i)$ (avec $j < l$) de la matrice $\widetilde{A}_b^{(0)}$ est égal au min $\{0.5, \widetilde{a}_j^{(0)}(i) \cdot \widetilde{a}_l^{(0)}(i)\}$ et chaque élément $\widetilde{a}_{j,j}^{(0)}(i)$ de la matrice $\widetilde{A}_c^{(0)}$ est égal au min $\{0.5, \widetilde{a}_j^{(0)}(i) \cdot \widetilde{a}_j^{(0)}(i)\}$, où $\widetilde{a}_j^{(0)}(i)$ et $\widetilde{a}_l^{(0)}(i)$ sont deux éléments de la matrice $\widetilde{A}_a^{(0)}$.

3.2.1.2. Initialisation avec information a priori (*init 2*)

Afin d'éviter une initialisation aléatoire des algorithmes, les M spectres d'endmembers $\widetilde{S}_a^{(0)}$ sont initialisés en utilisant la méthode SISAL [101]. Les spectres de pseudo-endmembers initiaux $\widetilde{S}_b^{(0)}$ et $\widetilde{S}_c^{(0)}$ sont déduits de la matrice initiale des spectres d'endmember $\widetilde{S}_a^{(0)}$ en utilisant la multiplication élément par élément.

Pour ce qui est de l'initialisation de la matrice des fractions d'abondances $\widetilde{A}_a^{(0)}$, deux initialisations différentes sont utilisées :

1. La matrice des fractions d'abondances linéaires $\widetilde{A}_a^{(0)}$ est initialisée avec une valeur constante égale à $1/M$ (M nombre d'endmembers). Nous désignons cette initialisation par *init 2.1*.
2. La matrice initiale des fractions d'abondances linéaires $\widetilde{A}_a^{(0)}$ est déduite de l'image X et de la matrice initiale des spectres $\widetilde{S}_a^{(0)}$ (des M spectres d'endmembers), au moyen de la méthode des moindres carrés avec contraintes (FCLS) [105]. Nous désignons cette initialisation par *init 2.2*.

Pour ces deux initialisations (*init 2.1* et *init 2.2*), les matrices des fractions d'abondances quadratiques $\widetilde{A}_b^{(0)}$ et $\widetilde{A}_c^{(0)}$ sont déduites de la matrice $\widetilde{A}_a^{(0)}$ de la même manière que pour *init 1* (section 3.2.1.1).

3.2.2. Critères de performances

Afin d'évaluer les performances des approches considérées pour l'extraction des spectres d'endmembers à partir des données considérées, différents critères sont utilisés pour mesurer

la ressemblance entre les vrais spectres et les spectres estimés. Dans cette section, nous présentons les critères de performances utilisés dans ce chapitre.

- **L'Angle Spectral (AS) (Spectral Angle Mapper (SAM))**

$$SAM_j = \arccos \left(\frac{\langle s_j, \tilde{s}_j \rangle}{\|s_j\|_2 \|\tilde{s}_j\|_2} \right), \quad (3.1)$$

avec $j = 1 \dots M$, où s_j et \tilde{s}_j sont respectivement le j -ième spectre réel et le j -ième spectre estimé, $\langle s_j, \tilde{s}_j \rangle$ représente le produit scalaire, $\|s_j\|_2$ et $\|\tilde{s}_j\|_2$ représentent respectivement la norme de s_j et \tilde{s}_j .

- **L'Erreur Quadratique Moyenne Normalisée (EQMN) (Normalized Mean Square Error (NMSE))**

$$NMSE_j = \frac{\|s_j - \tilde{s}_j\|_F^2}{\|s_j\|_F^2}. \quad (3.2)$$

- **Divergence d'Information Spectrale (Spectral Information Divergence (SID)) [142]**

$$SID_j = |s_j^T \ln (s_j \oslash \tilde{s}_j) + \tilde{s}_j^T \ln (\tilde{s}_j \oslash s_j)|. \quad (3.3)$$

où $\ln(\cdot)$ désigne le logarithme népérien et \oslash désigne la division élément par élément.

Notons que la comparaison des performances des algorithmes testés est réalisée sur la base des valeurs moyennes des critères cités ci-dessus sur les spectres d'endmembers estimés. Des valeurs plus petites de ces critères indiquent une meilleure extraction des spectres.

3.3. Résultats et discussion

Dans cette section nous présentons les différents tests réalisés, avec les différents types de données synthétiques utilisées, afin de comparer les performances des méthodes proposées dans le chapitre précédent et qui sont notées comme suit :

- *Grd-NS-LS-BMF*: Gradient-based Nonnegative-Spectra Least-Squares Bilinear Matrix Factorization et sa version multiplicative (*Multi-NS-LS-BMF*).
- *Grd-NS-LS-LQMF*: Gradient-based Nonnegative-Spectra Least-Squares Linear-Quadratic Matrix Factorization et sa version multiplicative (*Multi-NS-LS-LQMF*).

Ces méthodes seront aussi comparées aux performances de méthodes de la littérature qui sont :

- *NMF* linéaire [65].
- *Lin-Ext-NMF* (qui est une extension de la NMF, dans laquelle les termes quadratiques sont pris en compte [10]).
- *Mult-LQNMF* (Multiplicative Linear-Quadratic NMF).
- *Grd-LQNMF* (Gradient Linear-Quadratic NMF) et *Grd-New-LQNMF* (Gradient-Newton Linear-Quadratic NMF) [10].

Chacune de ces méthodes testées est initialisée de la manière expliquée dans la section 3.2.1. De plus, certains paramètres sont également pris en compte durant nos tests :

- Un pas fixé à $\alpha = 0.001$ pour les algorithmes à gradient projeté.
- Une précision de $\varepsilon = 10^{-6}$ pour le critère d'arrêt défini comme suit :

$$\left| \frac{J^{(t)} - J^{(t+1)}}{J^{(t)}} \right| \leq \varepsilon, \quad (3.4)$$

où J désigne la fonction de coût de la méthode considérée et t désigne une itération.

- Un nombre maximal d'itérations fixé à 50, pour chacune des méthodes testées, est utilisé comme critère d'arrêt supplémentaire, pour éviter un nombre élevé d'itérations dans le cas où le premier critère d'arrêt n'est pas atteint.

3.3.1. Test 1

Comme premier test, les méthodes proposées ainsi que les méthodes de la littérature citées plus haut sont testées sur des images synthétiques générées de la manière suivante :

- Deux ensembles de huit spectres hyperspectraux ($M = 8$ endmembers) sont choisis dans des bibliothèques spectrales, mesurées de 0.4 à 2.5 μm avec $L = 184$ bandes spectrales différentes. Le premier ensemble contient huit spectres sélectionnés aléatoirement à partir de la bibliothèque spectrale compilée par United States Geological Survey (USGS) (Figure 3.1(a)) [118]. Le second ensemble contient huit spectres de matériaux utilisés en milieu urbains, choisis aléatoirement parmi la bibliothèque spectrale compilée par l'Université Johns Hopkins (JHU) (Figure 3.1(b)) [143].

- Huit cartes de fractions d'abondances contenant chacune $P = 20 \times 20$ pixels, qui correspondent à la partie linéaire, générées aléatoirement et uniformément sur l'intervalle $[0,1]$, puis normalisées pour avoir une somme égale à 1. En plus des cartes de fractions d'abondances de la partie linéaire, les cartes de fractions d'abondances correspondant à la partie quadratique sont générées à partir des abondances linéaires en utilisant le modèle de Fan [131].

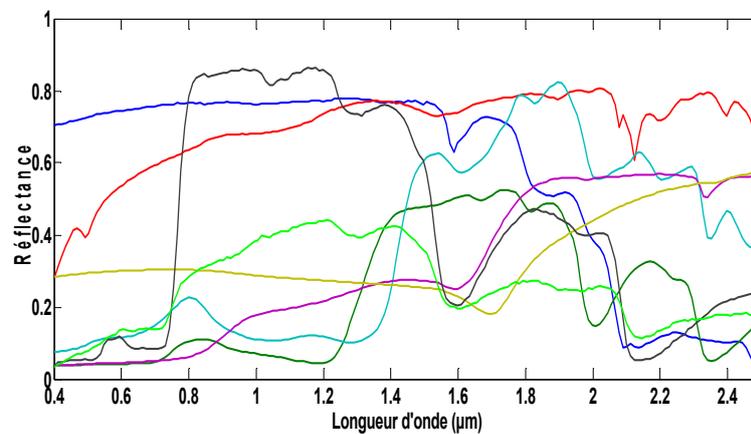
- Les spectres hyperspectraux et les cartes d'abondances sont ensuite utilisés pour générer deux images hyperspectrales de 20×20 pixels ($P = 400$ pixels) pour chaque ensemble de spectres. Ainsi, une image hyperspectrale est générée suivant le modèle de mélange bilinéaire et une autre image hyperspectrale est générée suivant le modèle de mélange linéaire-quadratique [10].

Afin de tester les performances des méthodes développées, dix images sont générées à partir de dix différentes cartes de fractions d'abondances générées de façon aléatoire. Par la suite, nous calculons les moyennes des résultats obtenus.

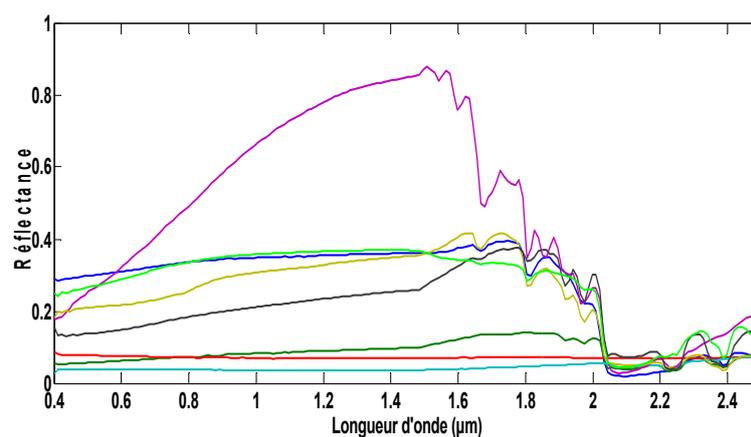
L'intérêt de ce premier test est d'étudier le comportement global des méthodes testées avec différentes initialisation. Ces tests sont réalisés dans quatre configurations :

- Données générées selon le modèle de mélange bilinéaire avec une sélection aléatoire de spectres réels issus de la bibliothèque spectrale USGS (Figure 3.1(a)) que nous nommons dataset 1.1.

- Données générées selon le modèle de mélange bilinéaire avec une sélection aléatoire de spectres réels de milieux urbains issus de la bibliothèque spectrale JHU (Figure 3.1(b)) que nous nommons dataset 2.1.
- Données générées selon le modèle de mélange linéaire-quadratique avec une sélection aléatoire de spectres réels issus de la bibliothèque spectrale USGS que nous nommons dataset 1.2.
- Données générées selon le modèle de mélange linéaire-quadratique avec une sélection aléatoire de spectres réels de milieux urbains issus de la bibliothèque spectrale JHU que nous nommons dataset 2.2.



(a)



(b)

Figure 3.1 : Spectres originaux. (a) Premier ensemble : spectres sélectionnés aléatoirement (USGS). (b) Deuxième ensemble : spectres de milieux urbains (JHU).

3.3.1.1. Résultats avec l'initialisation *init 1*

Les tableaux ci-dessous (Tableau 3.1-Tableau 3.4) montrent les moyennes des résultats obtenus avec une initialisation aléatoire (*init 1*) sur les images synthétiques du Test 1, générées pour chacun des modèles de mélange (bilinéaire et linéaire-quadratique).

Tableau 3.1 : Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 1.1 (générées selon le modèle de mélange bilinéaire) du Test 1.

	SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-BMF</i>	48.87	80.55	331.87
<i>Multi-NS-LS-BMF</i>	49.27	99.61	438.87
<i>NMF</i>	24.10	58.84	35.44
<i>Lin-Ext-NMF</i>	24.46	56.63	30.69
<i>Multi-LQNMF</i>	23.98	56.88	30.70
<i>Grd-LQNMF</i>	26.89	63.09	46.68
<i>Grd-New-LQNMF</i>	26.63	62.52	45.38

Tableau 3.2 : Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 2.1 (générées selon le modèle de mélange bilinéaire) du Test 1.

	SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-BMF</i>	49.05	451.34	303.78
<i>Multi-NS-LS-BMF</i>	46.94	186.35	302.51
<i>NMF</i>	14.60	153.23	22.15
<i>Lin-Ext-NMF</i>	13.70	103.42	19.77
<i>Multi-LQNMF</i>	14.08	117.42	19.72
<i>Grd-LQNMF</i>	19.86	377.12	94.12
<i>Grd-New-LQNMF</i>	19.58	361.81	88.24

Tableau 3.3 : Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 1.2 (générées selon le modèle de mélange linéaire-quadratique) du Test 1.

	SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-LQMF</i>	49.05	126.28	417.72
<i>Multi-NS-LS-LQMF</i>	45.29	79.64	560.64
<i>NMF</i>	24.12	60.67	39.69
<i>Lin-Ext-NMF</i>	24.51	57.23	31.40
<i>Multi-LQNMF</i>	23.99	57.28	31.86
<i>Grd-LQNMF</i>	26.89	63.10	46.73
<i>Grd-New-LQNMF</i>	26.60	62.57	45.60

Tableau 3.4 : Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 2.2 (générées selon le modèle de mélange linéaire-quadratique) du Test 1.

	SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-LQMF</i>	44.09	540.18	339.07
<i>Multi-NS-LS-LQMF</i>	30.93	386.66	186.14
<i>NMF</i>	14.88	164.48	23.51
<i>Lin-Ext-NMF</i>	13.73	109.52	19.67
<i>Multi-LQNMF</i>	14.23	123.87	19.91
<i>Grd-LQNMF</i>	19.86	377.24	94.15
<i>Grd-New-LQNMF</i>	19.56	362.40	88.41

A partir des résultats présentés dans les tableaux 3.1 et 3.2, nous pouvons remarquer que pour les images générées suivant le modèle de mélange bilinéaire, la méthode *Lin-Ext-NMF* donne globalement de meilleures performances que nos approches, mais aussi de meilleures performances que les autres méthodes testées de la littérature, avec un NMSE moyen égal à 56.63% et un SID moyen égal à 30.69, obtenus sur l'ensemble de données dataset 1.1 et un SAM moyen égal à 13.70° et un NMSE égal à 103.42%, obtenus sur l'ensemble de données dataset 2.1.

Pour ce qui est des résultats obtenus avec les images générées suivant le modèle de mélange linéaire-quadratique, les tableaux 3.3 et 3.4 montrent également que la méthode *Lin-Ext-NMF* donne de meilleures performances avec un NMSE égal à 57.23% et SID égal à

31.40 pour l'ensemble de données dataset 1.2, et un SAM égal à 13.73° , un NMSE égal à 109.52% et un SID égal à 19.67 l'ensemble de données dataset 2.2.

A partir de ces tableaux (Tableau 3.1-Tableau 3.4) nous pouvons conclure que pour une initialisation des spectres d'endmembers avec une valeur constante, les méthodes proposées dans ces travaux de thèse donnent de moins bonnes performances comparées à la meilleure des méthodes testées de la littérature. Ceci peut être expliqué par le fait que l'initialisation considérée peut amener les algorithmes proposés à des minima locaux non souhaités.

3.3.1.2. Résultats avec l'initialisation *init 2*

Dans cette section, nous comparons les résultats obtenus avec nos méthodes ainsi que les méthodes de la littérature testées sur les différentes données utilisées dans cette première expérience. Ces méthodes sont testées dans le cas d'une initialisation avec information a priori (*init 2*).

Les tableaux ci-dessous (Tableau 3.5-Tableau 3.8) représentent les moyennes des résultats obtenus avec l'initialisation *init 2* sur les différentes images générées pour chacun des modèles de mélange (bilinéaire et linéaire-quadratique).

Tableau 3.5 : Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 1.1 (générées selon le modèle de mélange bilinéaire) du Test 1.

		SAM ($^\circ$)	NMSE (%)	SID
<i>Grd-NS-LS-BMF</i>	<i>Init 2</i>	<u>2.98</u>	7.91	<u>1.19</u>
<i>Multi-NS-LS-BMF</i>	<i>Init 2</i>	2.99	8.15	1.22
<i>NMF</i>	<i>Init 2.1</i>	5.67	27.31	4.49
	<i>Init 2.2</i>	3.26	23.37	3.51
<i>Lin-Ext-NMF</i>	<i>Init 2.1</i>	5.88	10.65	2.48
	<i>Init 2.2</i>	3.12	<u>7.77</u>	1.22
<i>Multi-LQNMF</i>	<i>Init 2.1</i>	5.98	10.81	2.30
	<i>Init 2.2</i>	3.00	8.16	1.21
<i>Grd-LQNMF</i>	<i>Init 2.1</i>	3.35	22.67	3.48
	<i>Init 2.2</i>	3.34	22.69	3.49
<i>Grd-New-LQNMF</i>	<i>Init 2.1</i>	3.42	21.74	3.40
	<i>Init 2.2</i>	3.39	21.87	3.35

Tableau 3.6 : Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 2.1 (générées selon le modèle de mélange bilinéaire) du Test 1.

		SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-BMF</i>	<i>Init 2</i>	4.66	<u>14.50</u>	<u>0.73</u>
<i>Multi-NS-LS-BMF</i>	<i>Init 2</i>	4.70	14.51	0.74
<i>NMF</i>	<i>Init 2.1</i>	7.55	26.13	1.73
	<i>Init 2.2</i>	5.07	17.14	1.19
<i>Lin-Ext-NMF</i>	<i>Init 2.1</i>	7.25	19.60	1.32
	<i>Init 2.2</i>	<u>4.60</u>	14.63	<u>0.73</u>
<i>Multi-LQNMF</i>	<i>Init 2.1</i>	7.28	17.36	1.04
	<i>Init 2.2</i>	4.62	14.62	<u>0.73</u>
<i>Grd-LQNMF</i>	<i>Init 2.1</i>	5.06	17.12	1.17
	<i>Init 2.2</i>	5.06	17.07	1.16
<i>Grd-New-LQNMF</i>	<i>Init 2.1</i>	5.01	17.03	1.12
	<i>Init 2.2</i>	5.02	16.89	1.07

Tableau 3.7 : Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 1.2 (générées selon le modèle de mélange linéaire-quadratique) du Test 1.

		SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-BMF</i>	<i>Init 2</i>	3.35	<u>9.77</u>	<u>0.78</u>
<i>Multi-NS-LS-BMF</i>	<i>Init 2</i>	<u>2.54</u>	14.52	1.24
<i>NMF</i>	<i>Init 2.1</i>	6.08	35.01	7.10
	<i>Init 2.2</i>	3.54	33.78	5.86
<i>Lin-Ext-NMF</i>	<i>Init 2.1</i>	6.28	12.53	2.18
	<i>Init 2.2</i>	2.62	12.37	1.00
<i>Multi-LQNMF</i>	<i>Init 2.1</i>	6.36	17.28	2.53
	<i>Init 2.2</i>	<u>2.54</u>	14.42	1.22
<i>Grd-LQNMF</i>	<i>Init 2.1</i>	3.37	36.43	6.34
	<i>Init 2.2</i>	3.35	36.48	6.33
<i>Grd-New-LQNMF</i>	<i>Init 2.1</i>	3.55	35.40	6.05
	<i>Init 2.2</i>	3.49	35.63	6.10

Tableau 3.8 : Moyennes des valeurs des critères obtenues sur l'ensemble de données dataset 2.2 (générées selon le modèle de mélange linéaire-quadratique) du Test 1.

		SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-BMF</i>	<i>Init 2</i>	2.87	<u>5.80</u>	<u>0.22</u>
<i>Multi-NS-LS-BMF</i>	<i>Init 2</i>	3.15	17.14	1.28
<i>NMF</i>	<i>Init 2.1</i>	7.59	25.66	2.35
	<i>Init 2.2</i>	3.25	12.01	0.99
<i>Lin-Ext-NMF</i>	<i>Init 2.1</i>	7.28	11.56	0.73
	<i>Init 2.2</i>	<u>2.83</u>	6.45	0.29
<i>Multi-LQNMF</i>	<i>Init 2.1</i>	6.87	12.41	0.66
	<i>Init 2.2</i>	2.94	6.18	0.24
<i>Grd-LQNMF</i>	<i>Init 2.1</i>	5.10	11.31	1.22
	<i>Init 2.2</i>	4.71	12.38	1.21
<i>Grd-New-LQNMF</i>	<i>Init 2.1</i>	3.82	14.24	1.20
	<i>Init 2.2</i>	3.69	15.11	1.21

À partir des résultats reportés ci-dessus, nous remarquons que la méthode *Grd-NS-LS-BMF* donne, en général, de meilleures performances que les méthodes testées de la littérature, pour les tests sur les images générées suivant le modèle de mélange bilinéaire (Tableau 3.5 et 3.6), avec une valeur moyenne de l'angle spectrale (SAM) égale à 2.98° et un SID moyen égal à 1.19, pour l'ensemble de données dataset 1.1. Pour ce qui est des résultats obtenus sur les images générées avec une sélection aléatoire de spectres de milieux urbains (dataset 2.1), là encore la méthode *Grd-NS-LS-BMF* donne de meilleures performances, avec une valeur moyenne égale à 14.50% pour le NMSE et une moyenne de 0.73 pour le SID, alors que la méthode *Lin-Ext-NMF* donne de meilleurs performances en terme d'angle spectrale (SAM moyen égal à 4.60°) obtenue avec l'initialisation *init 2.2*.

Pour les images générées suivant le modèle linéaire-quadratique, les tableaux 3.7 et 3.8 montrent également que notre méthode à gradient *Grd-NS-LS-LQMF* donne de meilleurs résultats en terme de NMSE (9.77%) et de SID (0.78) pour l'ensemble de données dataset 1.2, et un NMSE moyen égal à 5.80% et un SID moyen égal à 0.22 pour l'ensemble de données dataset 2.2.

À partir de ces tableaux (Tableau 3.5 - 3.8), nous constatons également que pour ce type de données, les méthodes à gradient mises en place donnent des résultats très satisfaisants comparés à leurs versions multiplicatives (*Multi-NS-LS-BMF* et *Multi-NS-LS-LQMF*). Néanmoins, ces dernières restent assez concluantes par rapport à certaines méthodes testées de la littérature.

Dans les figures suivantes (Figure 3.3 - Figure 3.6) nous présentons respectivement, un des spectres utilisés ainsi que ses spectres estimés avec les méthodes proposées pour l'extraction des spectres et cela dans les quatre configurations considérées.

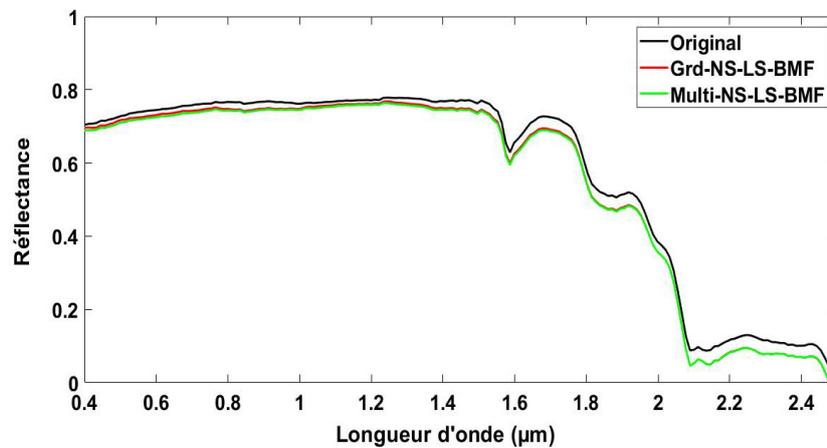


Figure 3.2 : Exemple d'un spectre original (dataset 1.1 du Test 1- générées selon le modèle de mélange bilinéaire) avec ses estimées.

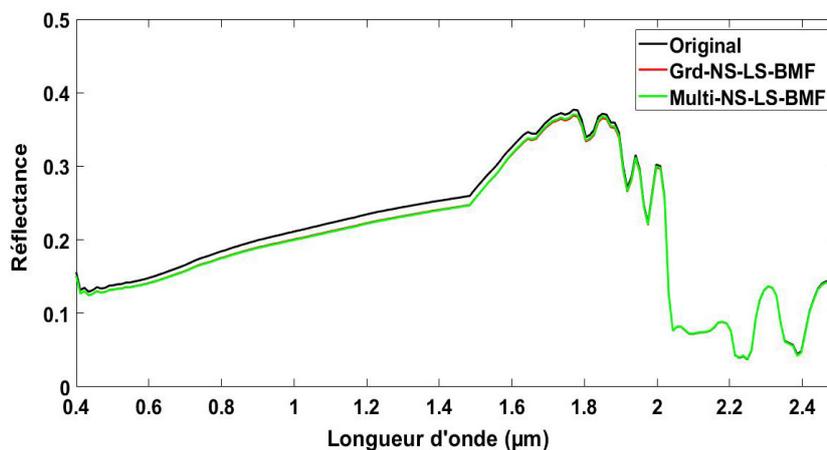


Figure 3.3 : Exemple d'un spectre original (dataset 2.1 du Test 1- générées selon le modèle de mélange bilinéaire) avec ses estimées.

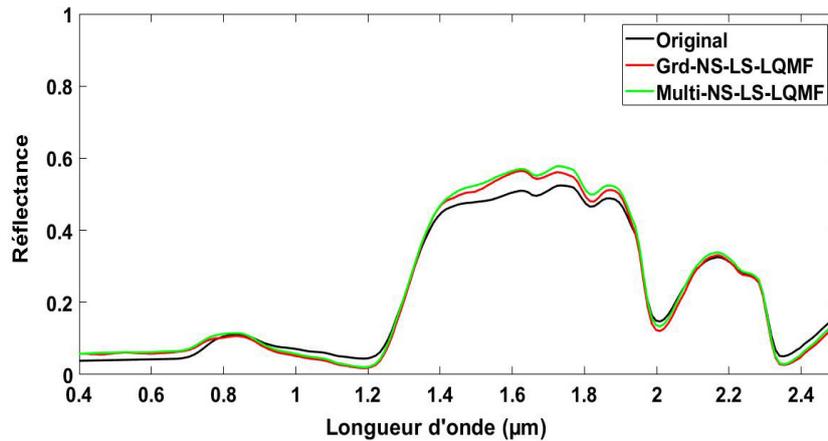


Figure 3.4 : Exemple d'un spectre original (dataset 1.2 du Test 1- générées selon le modèle de mélange linéaire-quadratique) avec ses estimées.

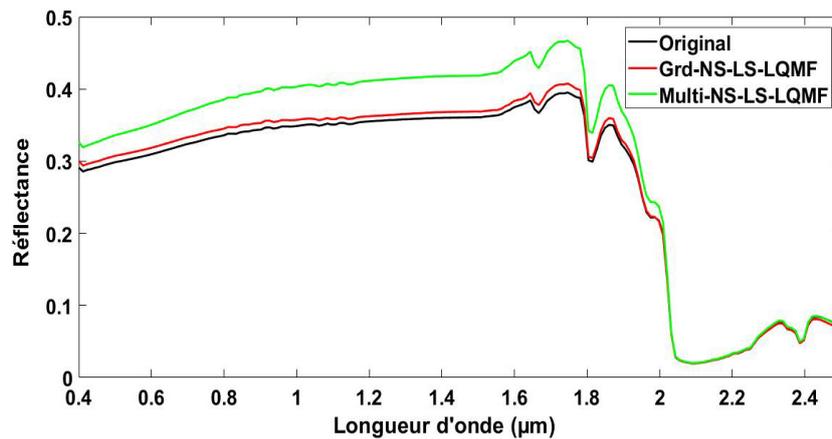


Figure 3.5 : Exemple d'un spectre original (dataset 2.2 du Test 1- générées selon le modèle de mélange linéaire-quadratique) avec ses estimées.

Globalement et à partir des figures 3.2-3.5, nous pouvons conclure que l'estimation des spectres avec nos méthodes proposées est assez précise pour les données générées suivant le modèle de mélange bilinéaire et un peu moins précise pour les données générées suivant le modèle linéaire-quadratique : nous remarquons que la forme des spectres estimés est assez fidèle à celle des spectres originaux. Nous constatons également que les spectres obtenus avec les méthodes à gradient *Grd-NS-LS-BMF* et *Grd-NS-LS-LQMF* représentent plus fidèlement les spectres originaux que les spectres obtenus avec leur versions multiplicatives, en particulier dans le cas de données générées avec un modèle de mélange linéaire-quadratique.

À partir de ces premiers résultats, nous pouvons conclure que les méthodes développées pour l'extraction des spectres hyperspectraux, à partir d'images qui présentent des modèles de mélange adaptés au cas urbain, donnent des performances assez satisfaisantes, surtout en ce qui concerne les méthodes à gradient (*Grd-NS-LS-BMF* et *Grd-NS-LS-LQMF*) et cela pour les différentes configurations (bilinéaire et linéaire-quadratique) de données considérées.

Nous concluons également que les performances de nos méthodes dépendent fortement du type d'initialisation. En effet, nous remarquons que les résultats obtenus à partir d'une initialisation avec information a priori sur les spectres sont de meilleures performances que ceux obtenus avec une initialisation aléatoire. Pour ce qui est des résultats obtenus avec l'initialisation *init 2* (initialisation avec information a priori), nos méthodes proposées offrent dans l'ensemble de meilleures performances sur ce type de données que les méthodes de la littérature testées, en particulier en termes de critères NMSE et SID.

3.3.2. Test 2

Dans cette section nous testons les performances de nos approches ainsi que les méthodes considérées de la littérature sur de nouvelles données synthétiques générées de la manière suivante :

- Deux ensembles de huit spectres hyperspectraux ($M = 8$ endmembers) sont choisis dans des bibliothèques spectrales, mesurées de 0.4 à 2.5 μm avec $L = 184$ bandes spectrales différentes (spectres utilisés dans Test 1 section 3.3.1).
- Huit cartes de fractions d'abondances linéaires (Figure 3.6) sont indépendamment créées à partir d'une classification réelle de la couverture terrestre, en moyennant les valeurs des pixels de la classification sur une fenêtre glissante de taille 5x5 pixels.
- Les fractions d'abondances quadratiques sont générées à partir des fractions d'abondances linéaires en utilisant le modèle de Fan [131]. Dans le cas d'images générées suivant le modèle de mélange bilinéaire, nous ne considérons pas les termes au carré, tandis que dans le cas d'images générées suivant le modèle de mélange linéaire-quadratique, les termes au carré sont pris en compte.

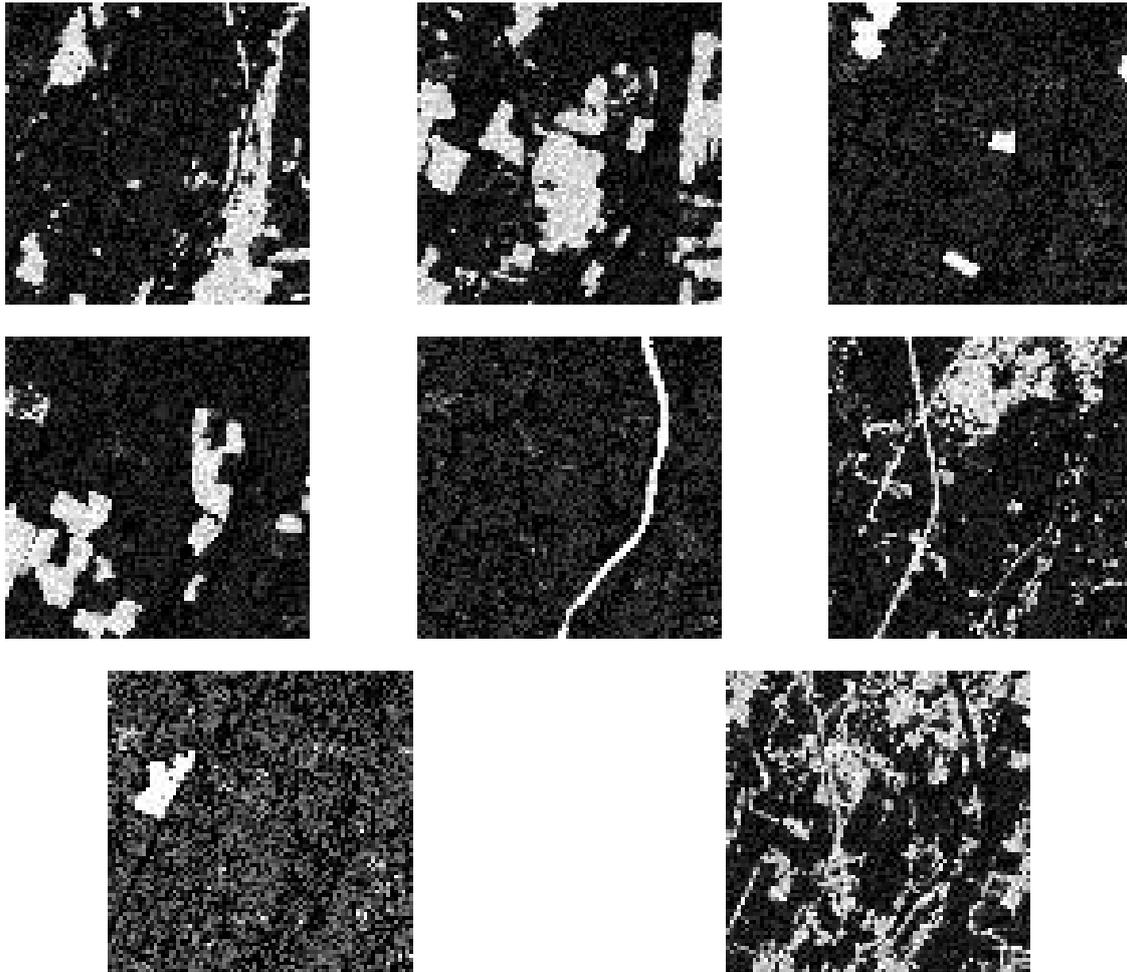


Figure 3.6 : Cartes de fractions d'abondances linéaires.

– Ces cartes d'abondances sont ensuite utilisées pour générer deux images hyperspectrales de 80×80 pixels ($P = 400$ pixels) pour chaque ensemble de spectres : une image hyperspectrale générée suivant le modèle de mélange bilinéaire et une image hyperspectrale générée suivant le modèle de mélange linéaire-quadratique [10]. Nous obtenons ainsi quatre configurations de données comme pour les tests précédents, et nous choisissons de les nommer dataset 1.1, 1.2, 2.1 et 2.2 comme en section 3.3.1.

Les tableaux ci-dessous (Tableaux 3.9-3.12) représentent les valeurs obtenues des critères utilisés sur les données synthétiques décrites dans le Test 2.

Dans cette deuxième expérience, les algorithmes testés sont initialisés avec *init 2.2*, décrite dans la section 3.2.1.2, qui est l'initialisation ayant donné les meilleurs résultats dans la première expérience pour l'ensemble des méthodes testées.

Tableau 3.9 : Moyennes des valeurs des critères obtenues sur les données dataset 1.1 (générée selon le modèle de mélange bilinéaire) du Test 2.

	SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-BMF</i>	5.60	11.70	14.07
<i>Multi-NS-LS-BMF</i>	12.40	27.88	29.96
<i>NMF</i>	6.26	27.18	6.69
<i>Lin-Ext-NMF</i>	8.72	99.99	869.7
<i>Multi-LQNMF</i>	5.54	12.55	23.92
<i>Grd-LQNMF</i>	13.00	24.43	54.56
<i>Grd-New-LQNMF</i>	8.88	21.76	24.84

Tableau 3.10 : Moyennes des valeurs des critères obtenues sur les données dataset 2.1 (générée selon le modèle de mélange bilinéaire) du Test 2.

	SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-BMF</i>	1.40	4.76	0.34
<i>Multi-NS-LS-BMF</i>	1.92	9.25	1.83
<i>NMF</i>	1.91	9.18	1.81
<i>Lin-Ext-NMF</i>	1.53	5.30	0.58
<i>Multi-LQNMF</i>	1.50	5.44	0.61
<i>Grd-LQNMF</i>	10.04	26.19	6.38
<i>Grd-New-LQNMF</i>	5.82	15.04	2.08

Tableau 3.11 : Moyennes des valeurs des critères obtenues sur les données dataset 1.2 (générée selon le modèle de mélange linéaire-quadratique) du Test 2.

	SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-LQMF</i>	5.44	11.76	9.18
<i>Multi-NS-LS-LQMF</i>	7.18	11.70	32.93
<i>NMF</i>	5.63	25.34	21.99
<i>Lin-Ext-NMF</i>	5.44	12.04	19.84
<i>Multi-LQNMF</i>	5.38	12.71	19.84
<i>Grd-LQNMF</i>	6.34	25.70	12.56
<i>Grd-New-LQNMF</i>	8.76	21.78	21.80

Tableau 3.12 : Moyennes des valeurs des critères obtenues sur les données dataset 2.2 (générée selon le modèle de mélange linéaire-quadratique) du Test 2.

	SAM (°)	NMSE (%)	SID
<i>Grd-NS-LS-LQMF</i>	1.87	8.87	0.22
<i>Multi-NS-LS-LQMF</i>	22.65	91.55	18.53
<i>NMF</i>	1.94	9.57	1.18
<i>Lin-Ext-NMF</i>	1.24	4.16	0.51
<i>Multi-LQNMF</i>	1.28	4.47	0.80
<i>Grd-LQNMF</i>	2.07	7.07	2.01
<i>Grd-New-LQNMF</i>	5.58	15.33	2.21

Les tableaux ci-dessus (Tableaux 3.9-3.12) montrent que nos méthodes donnent des résultats assez satisfaisants pour l'extraction des spectres d'endmembers hyperspectraux pour ces données synthétiques comparativement aux résultats obtenus avec certaines des méthodes de la littérature testées. En outre, ces tableaux révèlent également que les méthodes proposées à gradient produisent des performances globales meilleures que celles obtenues avec leurs versions multiplicatives.

Pour les données dataset 1.1 générées avec une sélection aléatoire de spectres et suivant le modèle de mélange bilinéaire, le tableau 3.9 montre que la méthode *Multi-LQNMF* donne de meilleures performances en terme d'angle spectral (5.54°) suivi de notre méthode à gradient *Grd-NS-LS-BMF* avec un SAM moyen égal à 5.60° , tandis que la méthode *Grd-NS-LS-BMF* donne de meilleures performances pour le critère NMSE avec une valeur moyenne égale à 11.70%.

Pour les données dataset 2.1 générées avec une sélection de spectres de matériaux urbains, le tableau 3.10 montre que la méthode *Grd-NS-LS-BMF* donne de meilleurs résultats pour l'extraction des spectres hyperspectraux d'endmembers, avec une valeur moyenne pour le critère SAM égale à 1.40° , alors que les méthodes de la littérature utilisées atteignent une moyenne entre 1.50° et 10.04° pour ce même critère. Pour les mêmes données, et pour le critère NMSE, le tableau 3.10 montre que la méthode *Grd-NS-LS-BMF* est capable d'atteindre une valeur moyenne de 4.76%, tandis que les méthodes de la littérature utilisées atteignent une moyenne entre 9.18% et 26.19%. Ce tableau rapporte également que la méthode *Grd-NS-LS-BMF* donne une valeur moyenne de 0.34 pour le critère SID, tandis que les méthodes de la littérature donnent une valeur moyenne entre 0.58 et 6.38 pour ce critère.

A partir de résultats reportés sur ces tableaux (Tableau 3.9 et Tableau 3.10) nous pouvons également conclure que la version multiplicative de notre méthode (*Multi-NS-LS-BMF*) donne des performances moins bonnes que la plupart des méthodes testées.

Dans les tableaux 3.11 et 3.12 sont données les valeurs moyennes obtenues des critères utilisés pour le cas de données générées suivant le modèle de mélange linéaire-quadratique. Les résultats présentés dans ces tableaux suivent les mêmes tendances que ceux des tableaux précédents pour le modèle de mélange bilinéaire. Pour les résultats obtenus avec les données dataset 1.2 générées suivant le modèle linéaire-quadratique, avec une sélection de spectres aléatoire dans la bibliothèque USGS [118], le tableau 3.11 montre qu'en terme d'angle spectrale la méthode *Mult-LQNMF* donne de meilleures performances avec un SAM moyen égal à 5.38° , tandis que nos méthodes proposées produisent de meilleures performances en terme des critères NMSE et SID, avec une valeur moyenne égale à 11.70% pour le NMSE (obtenu avec la méthode *Multi-NS-LS-LQMF*), et un SID moyen égal à 9.18 (obtenu avec la méthode *Grd-NS-LS-LQMF*).

Pour les données dataset 2.2 générées avec une sélection de spectres de matériaux urbains, le tableau 3.12 montre qu'en général la méthode *Lin-Ext-NMF* produit de meilleures performances en comparaison avec les méthodes testées, avec un SAM moyen égal à 1.24° et un NMSE moyen égal à 4.16%, cependant la méthode *Grd-NS-LS-LQM* produit de meilleurs résultats en terme de critère SID (SID moyen égal à 0.22).

A partir des tableaux 3.11 et 3.12 nous pouvons également remarquer que la version multiplicative de notre méthode (*Multi-NS-LS-LQMF*) donne, en général, de moins bons

résultats que notre méthode à gradient, mais aussi de moins bons résultats que la plupart des méthodes testées en particuliers pour sur données dataset 2.2.

Les figures ci-dessous (Figure 3.7- Figure 3.10) montrent quatre parmi les huit spectres originaux qui correspondent à l'ensemble de spectres de matériaux urbains, ainsi que leurs versions estimées par les différentes méthodes testées sur les deux données dataset 2.1 et dataset 2.2 considérées dans le Test 2.

Ces figures montrent que dans l'ensemble, nos méthodes proposées à gradient arrivent à estimer correctement la plupart des spectres, avec une allure globale assez fidèle aux spectres originaux, en particulier en ce qui concerne les spectres estimés avec la méthode *Grd-NS-LS-BMF* à partir des données générées suivant le modèle bilinéaire, où nous arrivons à obtenir une superposition sur certains des vrais spectres. Aussi, ces figures montrent que la méthode multiplicative *Multi-NS-LS-LQMF* estime moins bien les spectres par rapport à la version à gradient pour les données générées avec un modèle de mélange bilinéaire, et encore moins bien que les méthodes de la littérature testées pour le cas des données générées avec le modèle de mélange linéaire-quadratique. Cela peut s'expliquer par l'opération de projection (2.47) réalisée sur la matrice \tilde{S}^+ qui peut contenir des éléments négatifs.

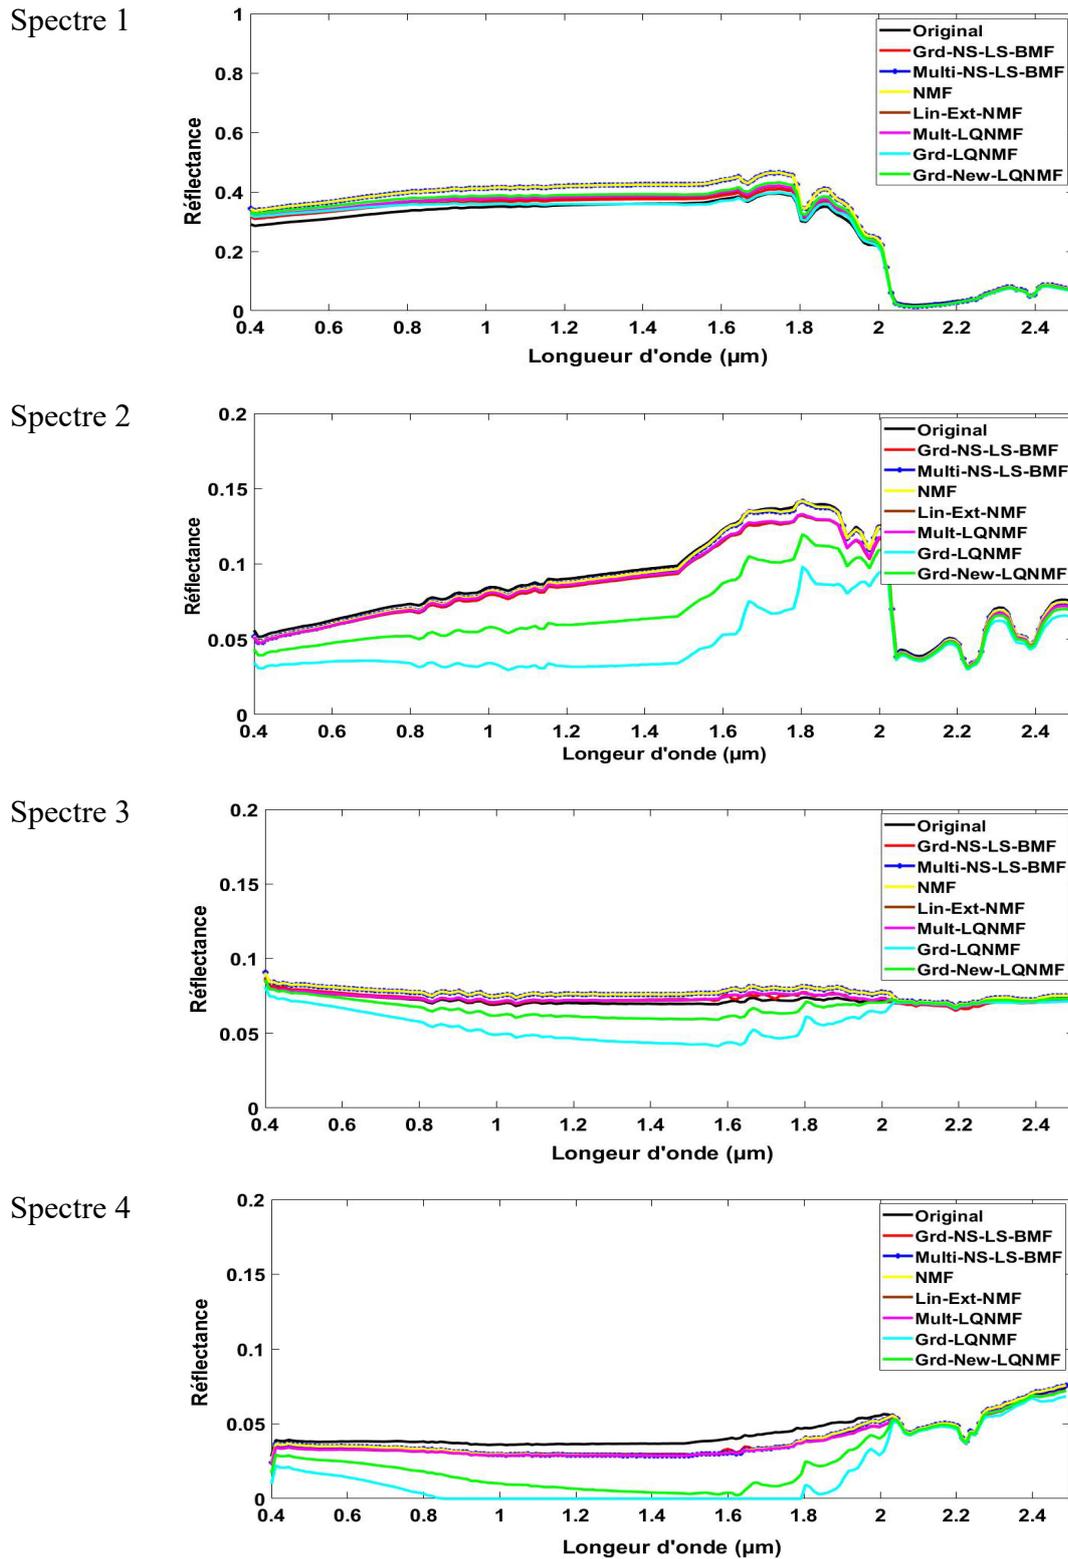


Figure 3.7 : Spectres originaux (spectres N°1-N°4) et spectres estimés - spectres de milieux urbains - données dataset 2.1 du Test 2- générées selon le modèle de mélange bilinéaire.

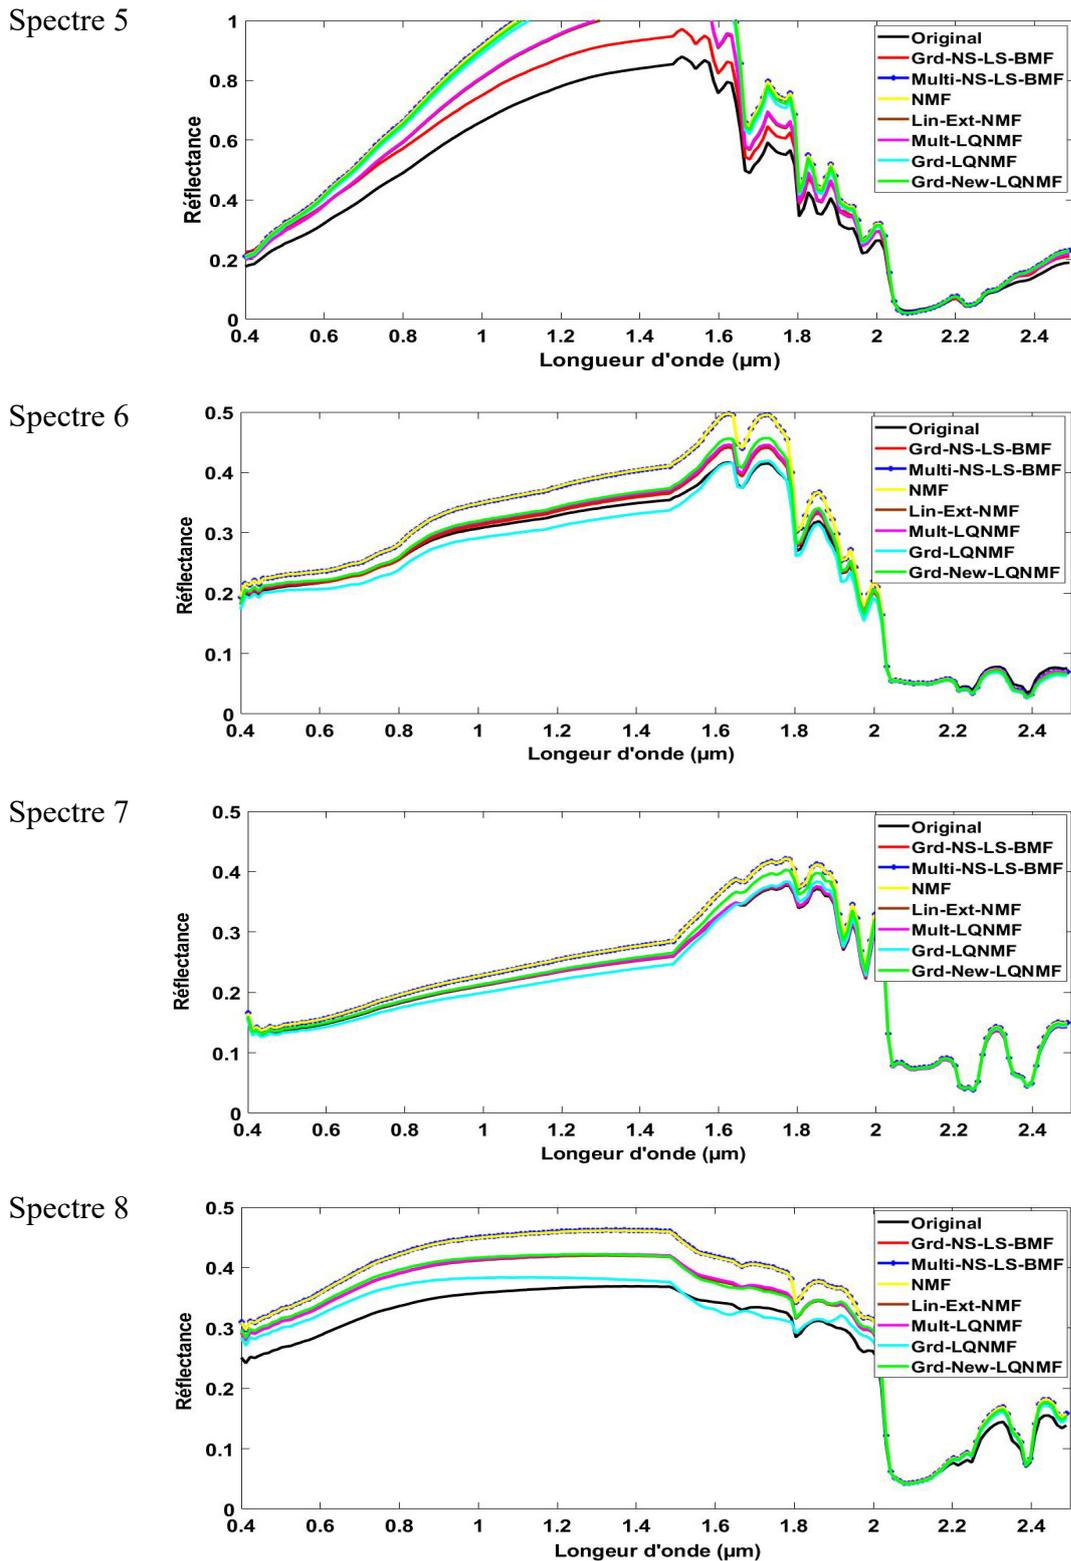


Figure 3.8 : Spectres originaux (spectres N°5-N°8) et spectres estimés - spectres de milieux urbains - données dataset 2.1 du Test 2- générées selon le modèle de mélange bilinéaire.

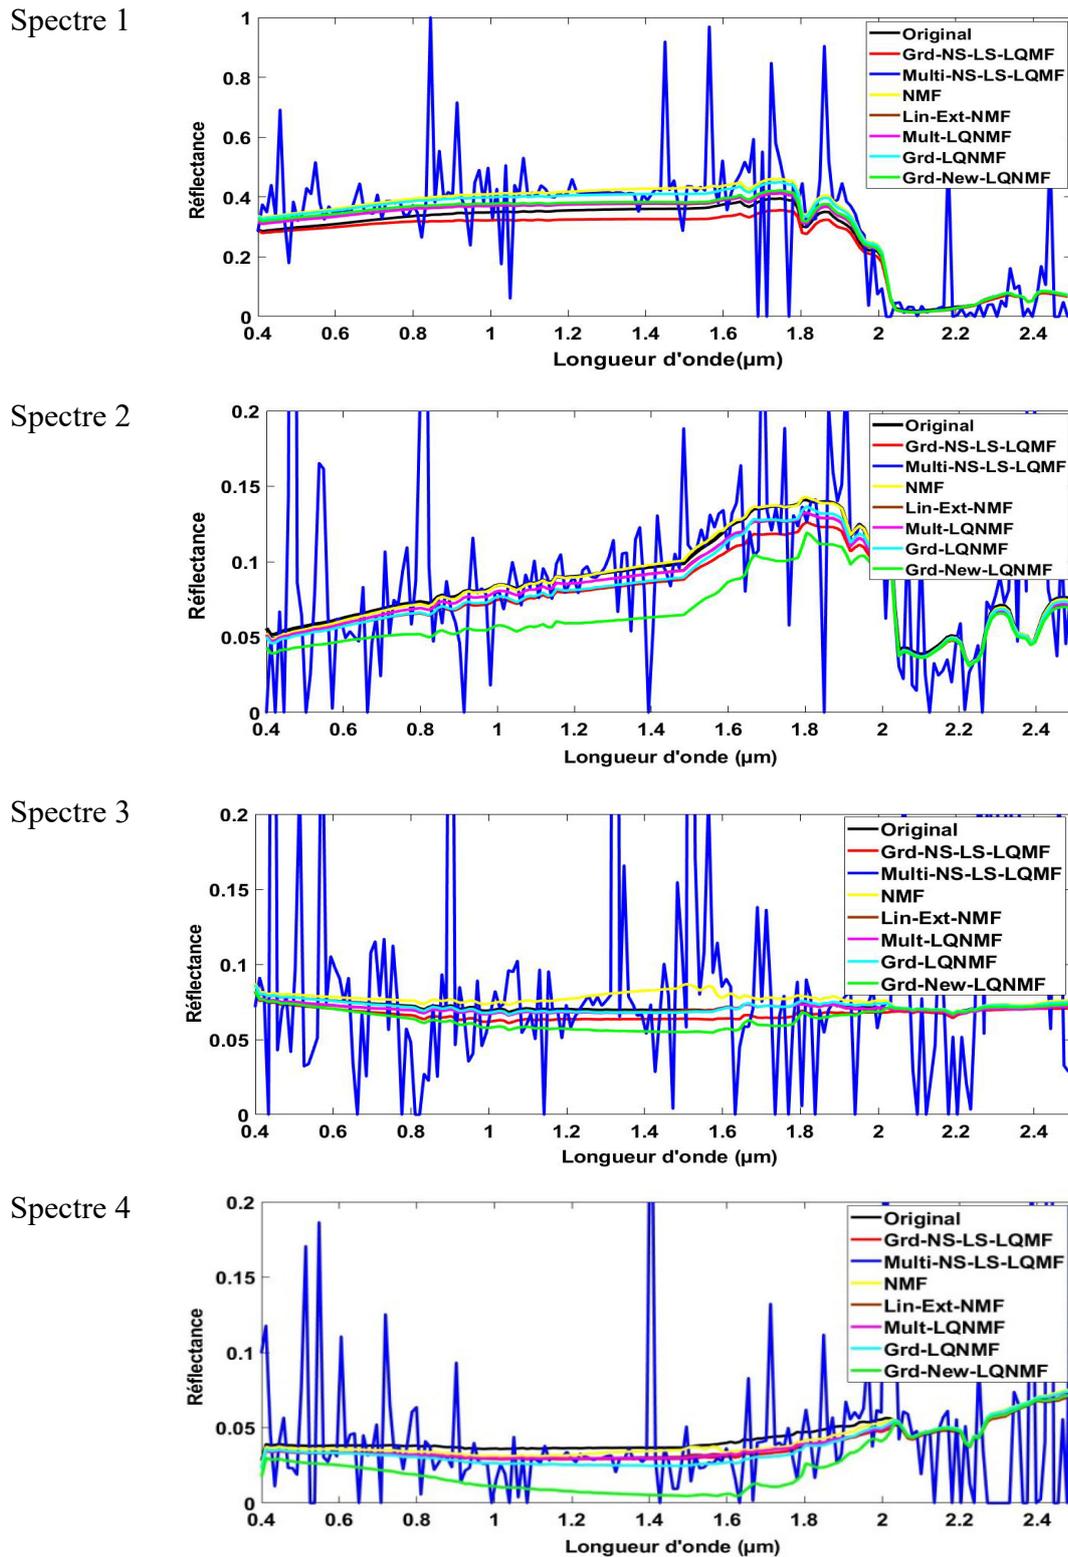


Figure 3.9 : Spectres originaux (spectres N°1-N°4) et spectres estimés - spectres de milieux urbains - données dataset 2.2 du Test 2- générées selon le modèle de mélange linéaire-quadratique.

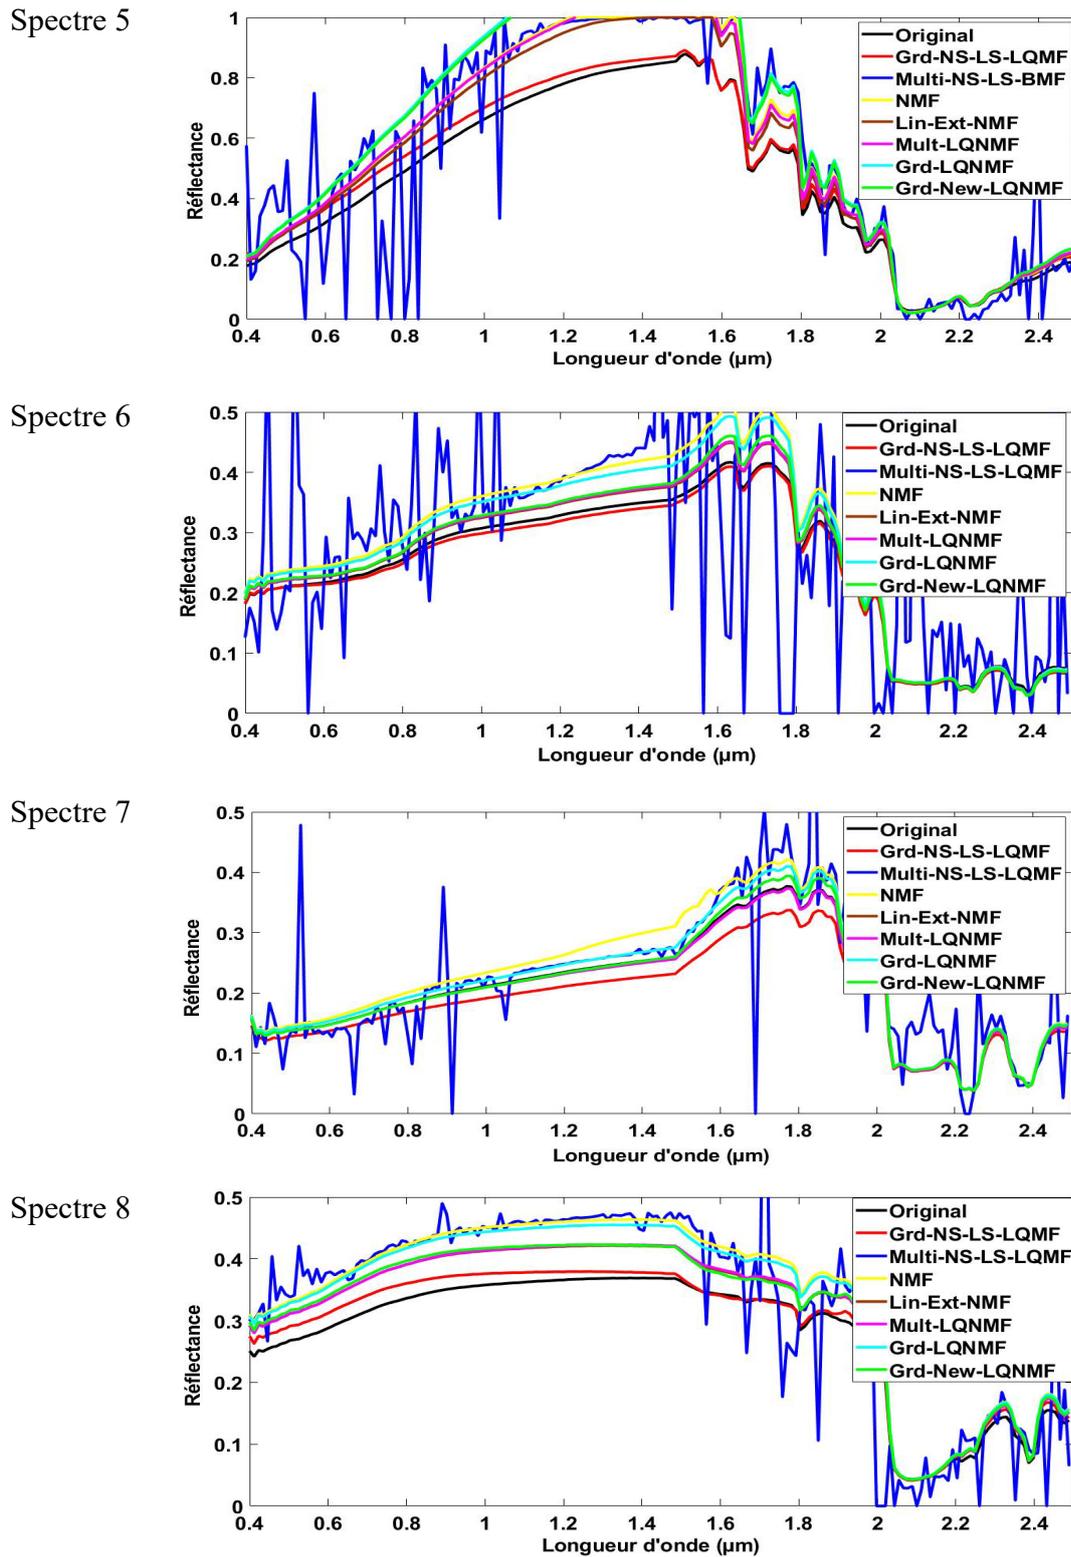


Figure 3.10 : Spectres originaux (spectres N°5-N°8) et spectres estimés - spectres de milieu urbains - données dataset 2.2 du Test 2- générées selon le modèle de mélange linéaire-quadratique.

3.4. Conclusion

Dans ce chapitre nous avons présenté les performances des méthodes proposées dans le cadre de cette thèse pour l'extraction des spectres d'endmembers hyperspectraux. Ces méthodes ont été développées pour le cas de données de milieux urbains, dans lesquelles le modèle de mélange considéré est le modèle bilinéaire ou linéaire-quadratique.

Globalement, les résultats obtenus sur données synthétiques sont satisfaisants. Ils montrent que les méthodes proposées, particulièrement les méthodes à gradient projeté, produisent dans l'ensemble de meilleures performances pour l'extraction des spectres d'endmembers hyperspectraux que les méthodes testées de la littérature.

Conclusion et perspectives

Dans cette partie de notre manuscrit de thèse, nous nous sommes intéressés à la problématique de séparation aveugle de sources pour des applications en télédétection. Le but de notre travail de thèse était de développer des méthodes de SAS pour le démixage spectral d'images hyperspectrales de milieux urbains afin d'en extraire les spectres des matériaux présents dans une scène imagée.

Dans le premier chapitre, nous avons présenté des généralités sur la séparation aveugle de sources ainsi que sur les modèles de mélange utilisés. Après, un état de l'art sur ces principaux aspects a été donné. Dans la section suivante, nous nous sommes intéressés aux méthodes de SAS qui utilisent le concept de démixage spectral de données de télédétection spatiale sur lequel est basé notre travail. Nous avons présenté ainsi un panorama des méthodes les plus connues dans la littérature pour un mélange linéaire puis pour les mélanges non-linéaires.

Le deuxième chapitre a été consacré à la description de nos méthodes proposées pour le démixage spectral d'images hyperspectrales de télédétection spatiale. Dans ce chapitre, nous avons commencé par établir le modèle mathématique considéré pour le cas particulier de données de milieux urbains. Par la suite, nous avons présenté les différentes approches de démixage développées dans le cadre de notre thèse pour le cas particulier de modèles de mélange linéaire-quadratique et bilinéaire. Ces méthodes sont basées sur la factorisation en matrices avec contraintes de non-négativité.

Dans le dernier chapitre, les méthodes mises en place ont été évaluées sur des données synthétiques et comparées aux performances de méthodes de la littérature. Les tests ont été réalisés avec différentes configurations qui peuvent être rencontrées en milieux urbains.

Les premiers tests ont été réalisés sur des données synthétiques générées à partir de spectres issus de bibliothèques spectrales et de cartes d'abondances générées d'une manière aléatoire, tandis que les seconds ont été réalisés sur des données synthétiques générées à partir de cartes d'abondances issues d'une classification réelle de la couverture terrestre. Les résultats obtenus montrent que les méthodes proposées donnent généralement de meilleures performances comparées aux méthodes testées de la littérature, et cela dans les deux configurations de données (mélanges linéaire-quadratique et bilinéaire).

Les résultats obtenus avec nos méthodes, pour le démelange spectral non-linéaire de données de milieux urbains, sont finalement assez satisfaisants et très encourageants, ce qui nous permet d'envisager plusieurs perspectives :

- Validation des méthodes proposées sur des données réelles de milieux urbains.
- Pour les approches à gradient avec pas fixe, tester les performances de ces dernières avec un pas variable.
- Évaluer les performances des fractions d'abondances calculées (\tilde{A}_{opt}) à partir des spectres d'endmembers estimés, et faire tourner par la suite une NMF, avec comme initialisation les spectres et les fractions d'abondances estimées, pour voir l'apport de la NMF sur les performances des méthodes proposées.
- Tester les performances des méthodes proposées sur des données avec ou sans pixels purs.

Partie 2 : Fusion d'images de télédétection spatiale

Sommaire

INTRODUCTION.....	84
CHAPITRE 1 : ÉTAT DE L'ART EN FUSION D'IMAGES DE TELEDETECTION SPATIALE	87
CHAPITRE 2 : METHODES PROPOSEES POUR LE MULTISHARPENING	103
CHAPITRE 3 : TESTS ET PERFORMANCES	125
CONCLUSION ET PERSPECTIVES	160

Introduction

Les satellites d'observation de la Terre ont permis à la télédétection spatiale de devenir un outil incontournable pour la compréhension et la connaissance de notre environnement. En effet, les satellites d'observation de la Terre fournissent différentes données issues de divers capteurs passifs ou actifs qui peuvent présenter des caractéristiques très différentes, en particulier en termes de résolutions spatiale, spectrale, temporelle et radiométrique.

Dans cette thèse nous nous intéressons particulièrement aux capteurs optiques (passifs). Les images produites par ces capteurs ont pour objectif la distinction entre différents matériaux.

Au cours des deux dernières décennies, le nombre de bandes spectrales dans la technologie de télédétection optique a continué à croître de façon constante, passant des ensembles de données multispectrales aux ensembles de données hyperspectrales. Les images hyperspectrales emploient des centaines de bandes spectrales étroites et contiguës pour capturer des informations spectrales sur une plage de longueurs d'onde (Figure 1(a)), par opposition aux dizaines de bandes spectrales utilisées dans les images multispectrales (Figure 1(b)) [144]. Cette augmentation de la précision spectrale fournit plus d'informations, ce qui permet toute une gamme d'applications nouvelles et plus précises. Cependant, il existe un compromis entre les résolutions spatiale et spectrale en raison de limitations physiques de transfert de données. Dans la plupart des cas, les résolutions spatiale et spectrale élevées ne sont pas disponibles en une seule image, ce qui rend la résolution spatiale des images hyperspectrales plus faible que celle des images multispectrales [145].

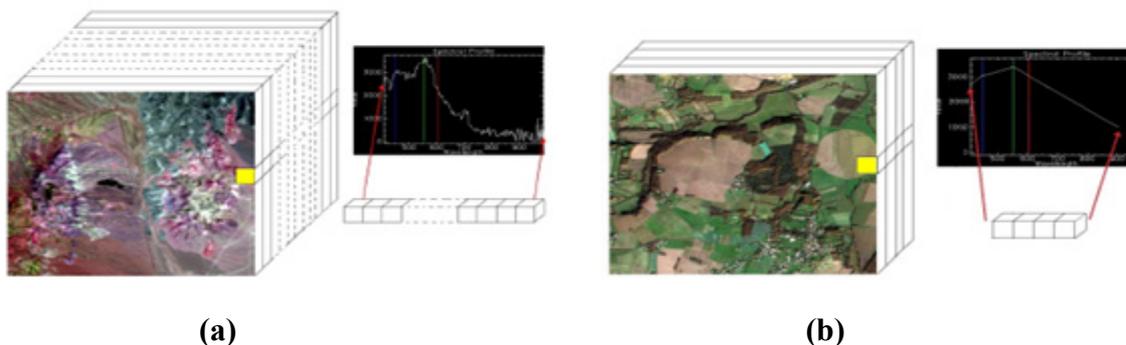


Figure 1 : Illustration de spectres obtenus à partir d'images de télédétection : (a) image hyperspectrale, (b) image multispectrale.

Dans la pratique, de nombreuses applications nécessitent une grande précision à la fois spectrale et spatiale, ce qui inspire la recherche sur les techniques d'amélioration de la résolution spatiale pour l'imagerie hyperspectrale [145].

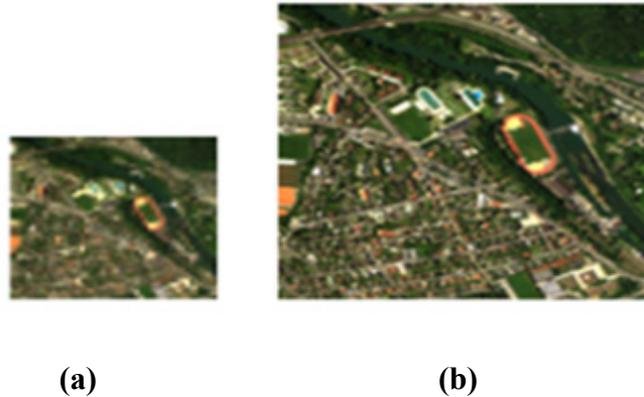


Figure 2 : Images de télédétection spatiale avec différentes résolutions spatiales : (a) image hyperspectrale de faible résolution spatiale, (b) image multispectrale de haute résolution spatiale.

La Figure ci-dessus montre des images de télédétection spatiale de différentes résolutions spatiales. La Figure 2(a) représente une image hyperspectrale à faible résolution spatiale, sur laquelle seuls les objets de grandes dimensions sont visibles, tandis que la Figure 2(b) représente une image multispectrale à haute résolution spatiale, sur laquelle nous pouvons distinguer des objets de plus petites dimensions.

Une des procédures les plus connues qui permet d'améliorer la résolution spatiale des images est la fusion (appelée aussi sharpening), dans laquelle une image de résolution spectrale élevée est généralement fusionnée à une image de résolution spatiale élevée pour obtenir une image de haute résolution à la fois spectrale et spatiale. La plupart des techniques de fusion pour l'amélioration de la résolution spatiale ont été développées dans le but d'améliorer la résolution spatiale d'une image multispectrale ou hyperspectrale en utilisant une image panchromatique de résolution spatiale plus élevée. Cette technique est appelée "Pansharpening". Parmi les méthodes les plus connues, nous citons celles basées sur l'Analyse en Composantes Principales (ACP) et La transformée Intensity-Hue-Saturation (IHS) [146, 147]. D'autres techniques ont aussi été développées pour le pansharpening, qui utilisent des transformées en ondelettes et l'analyse multirésolution. Une description détaillée et une comparaison de ces techniques est donnée dans [146-148]. Plus récemment, de

nouvelles approches ont été proposées pour réaliser le processus de "Multisharpening" [145, 149-153] qui consiste à fusionner des données hyperspectrales de haute résolution spectrale mais de faible résolution spatiale avec des données multispectrales de faible résolution spectrale mais de haute résolution spatiale. Les méthodes de multisharpening récentes sont celles qui utilisent des techniques de démixage spectral (SU) [8], basées sur la Factorisation en Matrices Non-négatives (NMF) [12, 64, 65, 154-156] qui, pour rappel, consistent à décomposer une matrice non-négative en un produit de deux matrices non-négatives.

Le but de cette partie de notre thèse est donc d'améliorer la résolution spatiale des images hyperspectrales tout en préservant l'information spectrale. Une manière de procéder est de combiner l'information spectrale issue de données hyperspectrales à haute résolution spectrale/faible résolution spatiale et des informations spatiales obtenues à partir de données multispectrales à faible résolution spectrale/haute résolution spatiale.

Il s'agit donc de développer de nouvelles méthodes de multisharpening pour la fusion de données hyperspectrale et multispectrale de télédétection spatiale. Les méthodes proposées sont conçues pour le cas particulier de fusion de données de milieux urbains. Ces méthodes originales sont basées sur les techniques de démixage spectral conçues pour un modèle de mélange linéaire-quadratique qui considèrent les réflexions multiples entre différents matériaux dans une zone observée, et utilisent l'algorithme multiplicatif LQNMF proposé dans [10]. Cette technique de démixage spectral a été présentée dans la première partie de cette thèse.

Dans cette partie du manuscrit, nous commençons par présenter dans le premier chapitre un état de l'art des méthodes de fusion des images de télédétection spatiale, dans lequel nous détaillons davantage les méthodes citées ci-dessus, en nous focalisant sur les méthodes de fusion des images hyperspectrale et multispectrale. Dans le deuxième chapitre, nous décrivons notre modèle mathématique de mélange considéré pour le cas particulier de données de milieux urbains, et nous présentons par la suite les méthodes proposées pour résoudre notre problématique. Les tests et performances de nos méthodes sont présentés dans le dernier chapitre avant la conclusion de cette partie du manuscrit.

Chapitre 1 : État de l'art en fusion d'images de télédétection spatiale

Sommaire

1.1. Introduction	88
1.2. Hypothèses	88
1.3. Méthodes de Pansharpening.....	88
1.3.1. Les méthodes à substitution de composantes	89
1.3.2. Les méthodes d'analyse multirésolution	91
1.3.3. Les méthodes variationnelles.....	93
1.4. Méthodes de Multisharpening.....	94
1.4.1. Les méthodes bayésiennes	94
1.4.2. Méthodes fondées sur la Factorisation en Matrices Non-négatives	95
1.4.2.1. Méthode dite Coupled Non-negative Matrix Factorization (CNMF).....	97
1.4.2.2. Méthode dite Joint Non-negative Matrix Factorization (JNMF).....	100
1.5. Conclusion.....	101

1.1. Introduction

Dans ce chapitre, nous présentons un état de l'art des différentes méthodes de fusion d'images satellitaires (panchromatiques, multispectrales et hyperspectrales). Nous commençons par donner un panorama des méthodes de pansharpening proposées dans la littérature, qui consistent à fusionner une image hyperspectrale ou multispectrale avec une image panchromatique dans le but de produire une image avec des résolutions spatiale et spectrale élevées. Nous nous intéressons dans la section suivante aux méthodes de multisharpening, pour la fusion des images hyperspectrale et multispectrale. Les méthodes présentées dans cette section sont par la suite comparées aux méthodes de fusion développées dans le cadre de cette thèse.

1.2. Hypothèses

La plupart des méthodes de fusion font l'hypothèse que les deux capteurs impliqués dans le processus de fusion observent la même scène en même temps ou à un intervalle de temps réduit. Si le temps d'acquisition est différent (plusieurs heures, jours, mois, etc.), certaines différences peuvent apparaître : changement dans le paysage, variation de l'éclairage. Ces dernières peuvent générer des distorsions dans le processus de fusion. Les images doivent aussi représenter la même physique et doivent avoir la même unité de mesure (luminance ou réflectance). Pour optimiser au mieux ces méthodes de fusion, il est nécessaire d'opérer un certain nombre de prétraitements dans les images de télédétection. La phase de prétraitement vise à réduire les distorsions possibles issues de la phase d'acquisition. En général, ces distorsions sont de nature radiométrique ou géométrique, dues principalement aux conditions atmosphériques, à la géométrie de vision, ou encore à la réponse du capteur.

1.3. Méthodes de Pansharpening

Une large collection de méthodes de pansharpening a été proposée dans la littérature afin d'améliorer la résolution spatiale des images hyperspectrales ou multispectrales en utilisant les informations spatiales provenant d'une image panchromatique. Ces méthodes peuvent être classées en plusieurs catégories selon la technique principale qu'elles utilisent :

1.3.1. Les méthodes à substitution de composantes

Ces méthodes sont basées sur la transformation de l'image de résolution spectrale élevée d'un espace vers un autre, dans le but de séparer l'information spectrale de l'information spatiale [147]. Une fois la composante contenant l'information spatiale isolée, cette dernière est remplacée par l'image panchromatique qui possède une meilleure résolution spatiale. Enfin, l'image fusionnée est obtenue par la transformation inverse pour le retour vers l'espace d'origine [146, 157].

Cette catégorie de méthodes comprend de nombreuses approches populaires pour le pansharpening, parmi ces approches :

- La méthode basée sur la transformation Intensity Hue Saturation (IHS)

Cette méthode fait passer l'image multispectrale "sur-échantillonnée spatialement" (à la résolution spatiale de l'image panchromatique) de l'espace RVB (espace Rouge Vert et Bleu) à l'espace IHS (espace Intensité, Teinte et Saturation (ITS)), où la composante intensité est remplacée par l'image panchromatique. Par la suite, une transformation inverse d'espace est réalisée pour obtenir une image multispectrale fusionnée de haute résolution spatiale comme le montre la Figure 1.1 [158-160].

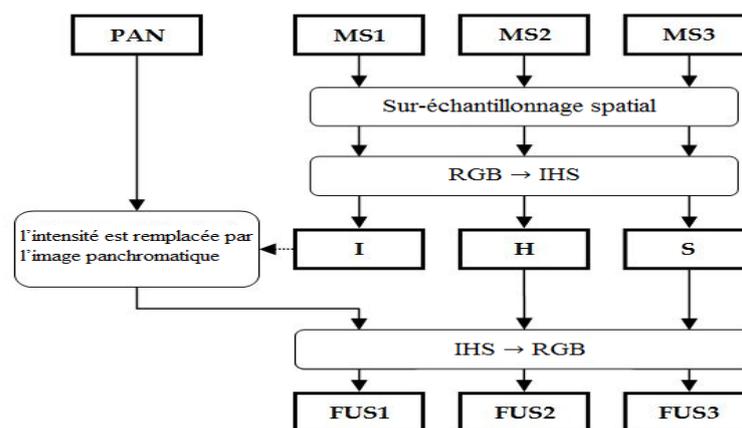


Figure 1.1 : Schéma de la méthode IHS [161].

L'inconvénient de cette méthode est qu'elle se limite aux images multispectrales à trois bandes. Dans [160], les auteurs ont proposé une méthode (Generalized IHS (GIHS)) qui

permet de remédier à cet inconvénient. Cette dernière généralise la méthode basée sur l'IHS à des images avec plus de trois bandes spectrales.

- La méthode basée sur l'Analyse en Composantes Principales (ACP)

Cette méthode présente l'avantage de pouvoir traiter un nombre de bandes spectrales supérieur à trois [162].

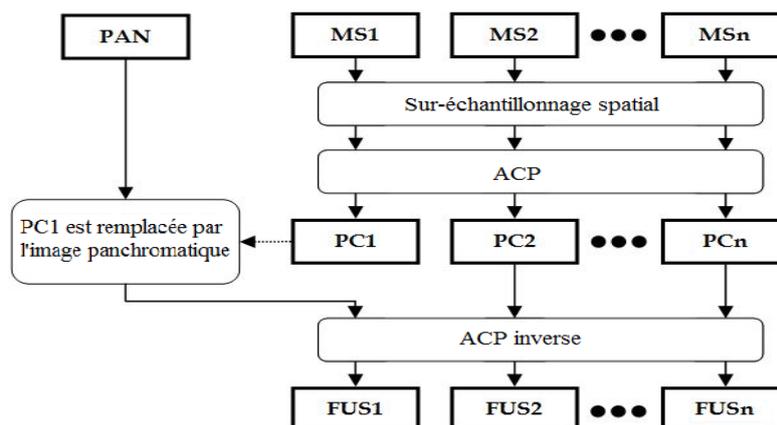


Figure 1.2 : Schéma du principe de fusion par l'analyse en composantes principales [161].

Après avoir appliqué une ACP à l'image hyperspectrale/multispectrale sur-échantillonnée spatialement, afin de la ramener à la même résolution que l'image panchromatique, la première composante principale (PC1) est remplacée par la bande panchromatique. Par la suite, une transformation inverse est appliquée pour revenir à l'espace de départ (Figure 1.2). Dans [163], une méthode de fusion fondée sur l'Analyse en Composantes Principales Non Linéaire (NLPCA) est proposée. Celle-ci combine à la fois la réduction de dimensionnalité et la fusion pour améliorer la résolution spatiale des images hyperspectrales.

- La méthode de Gram-Schmidt (GS)

Cette méthode a été inventée par Laben et Brover en 1998 et brevetée par Eastman Kodak [164]. Le processus de pansharpening commence par l'utilisation, comme première composante de l'entrée de la transformation GS, d'une image panchromatique synthétique à faible résolution (à la même résolution spatiale que l'image hyperspectrale/multispectrale [165]). Une décomposition orthogonale complète est ensuite effectuée, en commençant par

cette composante. La procédure de pansharpening est complétée en remplaçant cette composante par l'image panchromatique à haute résolution, et en inversant la décomposition.

Dans [166], les auteurs ont proposé une version améliorée, appelée GS Adaptative (GSA), dans laquelle l'image panchromatique à faible résolution est générée par la moyenne pondérée des bandes de l'image hyperspectrale/multispectrale avec des poids estimés par la minimisation de l'erreur quadratique moyenne entre la composante estimée et la version sous-échantillonnée de l'image panchromatique.

Les méthodes de cette catégorie sont généralement rapides et faciles à mettre en œuvre. Cependant, elles souffrent de distorsions spectrales en raison des différences entre les caractéristiques des images panchromatiques et des images hyperspectrales/multispectrales [147, 148]. Pour remédier à cette faiblesse, certaines solutions ont été proposées dans [166-168].

1.3.2. Les méthodes d'analyse multirésolution

Les méthodes de pansharpening de cette catégorie sont basées sur l'Amélioration de la Résolution Spatiale par Injection de Structures (ARSIS), qui consiste à injecter des composantes à hautes fréquences spatiales obtenues à partir de l'image panchromatique par filtrage spatial [169]. Ces approches extraient des informations spatiales de l'image panchromatique, qui sont par la suite injectées dans l'image à faible résolution spatiale (l'image hyperspectrale/multispectrale).

Plusieurs techniques basées sur l'analyse multirésolution existent dans la littérature. Les plus connues sont : Smoothing Filter-based Intensity Modulation (SFIM) [170], la pyramide laplacienne [171] et la transformation en ondelettes [172]. La plupart de ces techniques ont été utilisées dans le pansharpening des images panchromatique et multispectrale.

- **Modulation d'intensité basée sur le filtre de lissage (Smoothing Filter-based Intensity Modulation (SFIM))**

La technique SFIM [170, 173] consiste à appliquer un filtre moyenneur à l'image panchromatique pour obtenir une version dégradée à la taille de l'image de faible résolution spatiale. Par la suite, les détails spatiaux issus de l'image panchromatique sont injectés par multiplication comme le montre l'équation (1.1) :

$$X_{SFIM_i} = \frac{X_{low_i} X_{high}}{X_{mean}}, \quad (1.1)$$

où X_{SFIM_i} et X_{low_i} représentent respectivement un pixel, de la i -ème bande spectrale, de l'image fusionnée de haute résolution spatiale et de l'image originale de faible résolution spatiale recalée par rapport à l'image panchromatique X_{high} . X_{mean} est la version dégradée de l'image de haute résolution X_{high} .

- Pyramide laplacienne

La pyramide laplacienne (Laplacian Pyramid (LP)) est une technique qui a été développée par Burt et Adelson dans [171] et inspirée de la pyramide gaussienne (Gaussian Pyramid (GP)). Dans la GP, l'image originale est convoluée avec un filtre gaussien, produisant une version filtrée passe-bas de l'image originale. La différence entre l'image originale et la version passe-bas filtrée représente le laplacien. Dans [174], la LP a été étendue à un schéma plus général (GLP) permettant l'utilisation d'un facteur d'échelle différent de deux (entre deux niveaux adjacents de la pyramide).

- Transformation en ondelettes

La fusion basée sur une transformée en ondelettes est une approche bien connue des méthodes de pansharpening multirésolution. Le principe de ces méthodes est de fournir un cadre pour la décomposition des images dans une hiérarchie avec un degré décroissant de résolution, permettant la séparation des informations spatiales détaillées entre les niveaux successifs [175]. En général, les méthodes de fusion à base d'ondelettes ont produit des résultats encourageants [176]. L'approche discrète de la transformée en ondelettes, appelée transformée en ondelettes discrètes (Discrete Wavelet Transform (DWT)), peut être réalisée en utilisant plusieurs algorithmes différents. Parmi les algorithmes les plus connus pour le pansharpening d'images, nous pouvons citer celui de Mallat [169, 177-179] et l'algorithme "à trous" [180-182]. La méthode "à trous" est rapidement apparue comme une méthode produisant des résultats très satisfaisants pour la fusion d'images [176].

Un aperçu des techniques de fusion d'images basées sur la transformée en ondelettes est donné dans [176]. Une comparaison détaillée entre l'algorithme de Mallat et "à trous" pour la fusion d'images est donnée dans [175].

1.3.3. Les méthodes variationnelles

L'idée principale des méthodes variationnelles est de développer une énergie fonctionnelle basée sur certaines propriétés de l'image, où une faible valeur de l'énergie fonctionnelle correspond à une image de bonne qualité. Différents termes pour leur énergie fonctionnelle sont utilisés selon la méthode considérée [183-185]. Cette catégorie de méthodes comprend plusieurs méthodes, la plus connue étant la méthode $P + XS$:

- La méthode $P + XS$

Cette méthode a été développée pour l'amélioration de la résolution spatiale des images SPOT multispectrales (XS), à l'aide de l'image panchromatique associée (P). Dans cette méthode, chaque bande spectrale de l'image fusionnée est obtenue par une combinaison linéaire des bandes spectrales de l'image multispectrale [186].

Il convient de noter que certaines méthodes peuvent être classées dans plus d'une catégorie et que l'hybridation entre les méthodes des catégories citées ci-dessus est possible.

En outre, il est naturel de s'attendre à ce que la réalisation d'un pansharpening avec des données hyperspectrales soit plus complexe que son exécution avec des données multispectrales [146]. En effet, cela s'explique par le fait que la bande spectrale de l'image panchromatique englobe généralement les bandes spectrales des images multispectrales, alors qu'elle n'inclut pas toutes les bandes spectrales des images hyperspectrales, ce qui peut provoquer des distorsions spectrales pendant le processus de fusion. Ainsi, les approches de pansharpening ont été étendues au cours des dernières décennies, afin de fusionner des images hyperspectrale et multispectrale de télédétection. Ce processus de fusion est appelé "Multisharpening". Contrairement au pansharpening où l'information spatiale à haute résolution n'est contenue que dans une bande spectrale, dans le processus de multisharpening l'information spatiale à haute résolution est contenue dans plusieurs bandes spectrales.

1.4. Méthodes de Multisharpening

Les méthodes de multisharpening d'images hyperspectrale et multispectrale, comparées aux méthodes de pansharpening d'images panchromatique et multispectrale/hyperspectrale, peuvent diminuer la distorsion spectrale dans l'image fusionnée du fait que les deux images initiales contiennent des informations spectrales. Les méthodes de multisharpening [145, 149-153] visent à combiner l'information spectrale obtenue à partir de données hyperspectrales à haute résolution spectrale mais de faible résolution spatiale avec l'information spatiale obtenue à partir des données multispectrales à haute résolution spatiale mais de faible résolution spectrale. L'application de ces processus de multisharpening aux images hyperspectrales observables permet d'effectuer une détection, identification et classification précises d'une région imagée à une résolution spatiale plus élevée.

Récemment, d'autres méthodes [12, 155, 156, 187, 188] ont été proposées afin d'améliorer la résolution spatiale d'une donnée hyperspectrale en utilisant une image multispectrale, en utilisant des techniques de démixage spectral linéaire (LSU) [8]. Ces techniques sont basées sur la factorisation en matrices non-négatives (NMF) [64, 65, 154]. Nous rappelons que les techniques LSU, qui correspondent au problème typique de séparation aveugle de sources [5, 189], consistent à démixer linéairement les données de télédétection en une collection de spectres d'endmembers et leurs fractions d'abondances correspondantes.

Un aperçu des principales méthodes de multisharpening est donné dans [190], ainsi qu'une étude comparative des performances de ces différentes techniques.

1.4.1. Les méthodes bayésiennes

Cette catégorie de méthodes utilise les caractéristiques statistiques des images hyperspectrales à faible résolution spatiale et des images multispectrales à haute résolution spatiale dans le processus de multisharpening, où la fusion peut être formulée de manière pratique dans le cadre d'inférence bayésienne [151, 152, 191-193]. Cette formulation permet une interprétation intuitive du processus de fusion par la distribution postérieure du modèle de fusion. Les méthodes bayésiennes offrent un moyen pratique de régulariser le problème de fusion en définissant une distribution a priori appropriée pour la scène d'intérêt.

Suivant cette stratégie, différents estimateurs bayésiens pour la fusion des images multispectrales recalées à haute résolution spatiale et des images hyperspectrales à haute résolution spectrale ont été conçus. La plupart de ces estimateurs bayésiens sont utilisés pour résoudre le problème de fusion des images hyperspectrale et multispectrale en utilisant une formulation Maximum à Posteriori (MAP) [192, 193], ou encore l'erreur quadratique moyenne linéaire minimale (LMMSE) [194].

1.4.2. Méthodes fondées sur la Factorisation en Matrices Non-négatives

Mathématiquement, l'approche de factorisation matricielle pour la fusion des images hyperspectrale et multispectrale vise à décomposer deux matrices X non-négatives, dont l'une correspond à l'image hyperspectrale et la deuxième à l'image multispectrale, chacune d'elle en un produit de deux matrices non-négatives. Chaque décomposition peut être formulée comme suit pour rappel :

$$X = AS, \quad (1.2)$$

où $X = [x_1, \dots, x_p]^T \in R_+^{p \times L}$ représente l'image observée ayant été préalablement redéfinie d'un cube 3D en une matrice 2D, $A = [a_{i,j}]_{\substack{1 \leq i \leq p \\ 1 \leq j \leq M}} \in R_+^{p \times M}$ et $S = [s_1, \dots, s_M]^T \in R_+^{M \times L}$ représentent respectivement la matrice contenant les fractions d'abondances et la matrice des spectres d'endmembers. p correspond au nombre de pixels, L est le nombre de bandes spectrales de l'image observée et M représente le nombre d'endmembers.

Notons que dans les approches de factorisation matricielle pour la fusion d'images de télédétection spatiale, la matrice des fractions d'abondances est soumise à la contrainte de somme-à-un, où la somme de toutes les entrées de n'importe quel vecteur ligne de A est égale à 1.

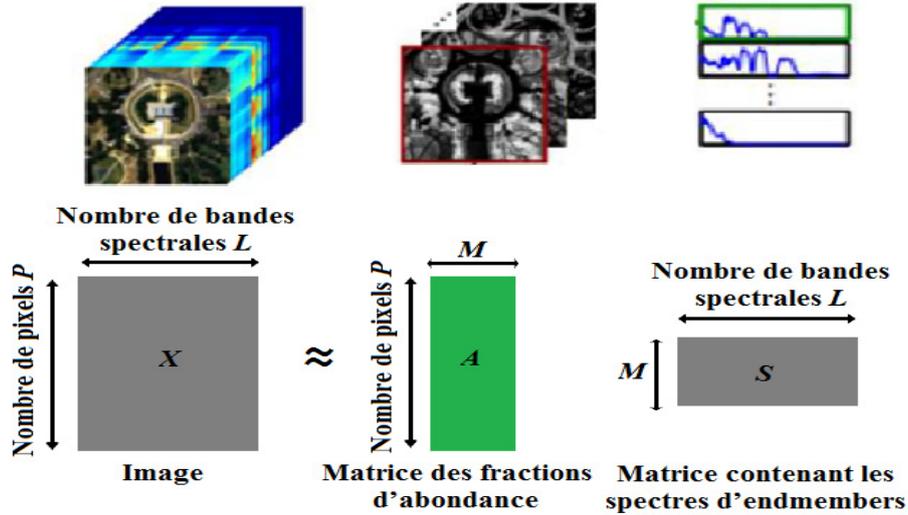


Figure 1.3 : Décomposition d'une image sous forme matricielle.

Notons ici que les techniques de démixage spectral par NMF ont également été utilisées pour le pansharpening des images multispectrales [155, 195-197].

Le modèle de mélange considéré par les méthodes NMF pour le démixage spectral des données hyperspectrale et multispectrale est le modèle linéaire. Ce modèle de mélange est couramment utilisé dans littérature pour le démixage spectral, en raison de son efficacité physique et de sa simplicité mathématique. Dans ce cas, le spectre de chaque pixel est supposé être une combinaison linéaire de plusieurs spectres d'endmembers. Afin d'utiliser la NMF avec le modèle linéaire, chacune des images hyperspectrale et multispectrale est donc reformulée sous forme matricielle comme suit :

$$X_h = A_h S_h, \quad (1.3)$$

$$X_m = A_m S_m, \quad (1.4)$$

où $X_h \in R_+^{P_h \times L_h}$ est l'image hyperspectrale à haute résolution spectrale mais de faible résolution spatiale, $X_m \in R_+^{P_m \times L_m}$ est l'image multispectrale à faible résolution spectrale mais de haute résolution spatiale. L_h (respectivement L_m) correspond au nombre de bandes spectrales de l'image hyperspectrale (respectivement l'image multispectrale). P_h (respectivement P_m) correspond au nombre de pixels de l'image hyperspectrale (respectivement l'image multispectrale). Les matrices $A_h \in R_+^{P_h \times M}$ et $A_m \in R_+^{P_m \times M}$

représentent respectivement les cartes des fractions d'abondances issues des images hyperspectrale et multispectrale. $S_h \in R_+^{M \times L_h}$ et $S_m \in R_+^{M \times L_m}$ représentent respectivement les matrices des spectres d'endmembers hyperspectraux et multispectraux.

Toujours et pour rappel en télédétection, les méthodes NMF ont largement été utilisées ces dernières années, pour connaître la composition des pixels mélangés, aussi appelés "mixels". L'objectif est de trouver des estimations de A et S , respectivement \tilde{A} et \tilde{S} de sorte que :

$$X \approx \tilde{A}\tilde{S}. \quad (1.5)$$

La qualité de la factorisation est alors évaluée au moyen d'une mesure d'écart ou de divergence J entre X et $\tilde{A}\tilde{S}$. Un algorithme de NMF est donc un algorithme de minimisation de cette mesure :

$$\min_{\tilde{A}, \tilde{S} \geq 0} J(X | \tilde{A}\tilde{S}). \quad (1.6)$$

Diverses stratégies de minimisation ont été proposées dans le but d'accélérer la convergence de l'algorithme itératif NMF standard de Lee et de Seung [64]. Trois familles d'algorithmes sont généralement citées :

- Algorithme NMF standard avec mise à jour multiplicative [64, 65].
- Algorithmes des moindres carrés alternés (Alternating Least Square (ALS)) [79, 80].
- Algorithmes du gradient projeté [76].

Dans ce qui suit, nous détaillons quelques méthodes pour la fusion des images hyperspectrale et multispectrale basées sur la factorisation en matrices non-négatives qui utilisent le concept de démélange spectral.

1.4.2.1. Méthode dite Coupled Non-negative Matrix Factorization (CNMF)

La CNMF a été proposée pour la fusion des données hyperspectrales à faible résolution spatiale et des données multispectrales à haute résolution spatiale pour produire des données fusionnées avec des résolutions spatiale et spectrale élevées [156]. Elle est basée sur le démélange non-supervisé, où les données hyperspectrale et multispectrale sont décomposées

"alternativement" et "itérativement" par NMF, pour obtenir les spectres hyperspectraux d'endmembers et les cartes d'abondances à résolution spatiale élevée obtenues à partir de données multispectrales. Ceci permet de générer des données hyperspectrales à haute résolution spatiale. La figure suivante illustre le concept de la CNMF [156].

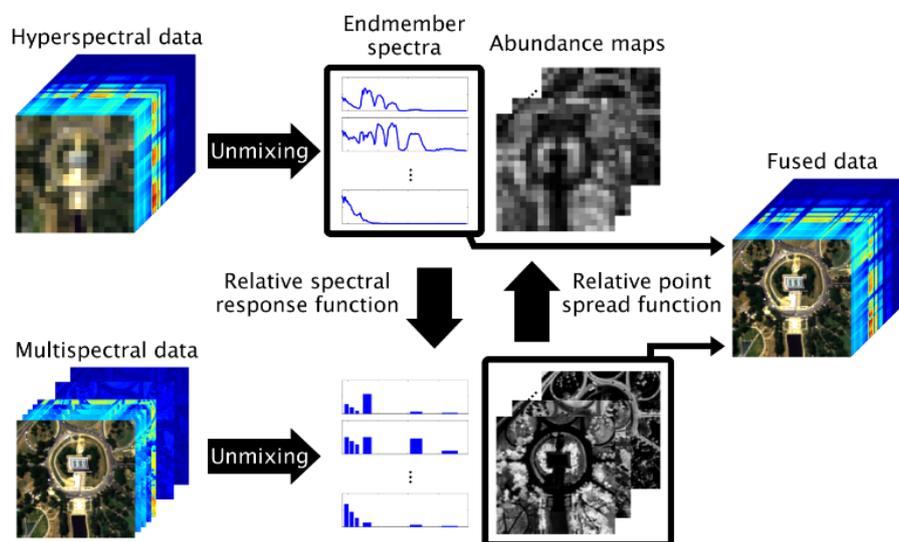


Figure 1.4 : Concept de la CNMF [156].

La CNMF a aussi été utilisée pour la fusion panchromatique, multispectrale et hyperspectrale, où seules les images multispectrale et hyperspectrale sont "alternativement" démêlées par NMF. Par la suite, les cartes d'abondances à haute résolution spatiale sont estimées à partir de l'image panchromatique en utilisant les cartes d'abondances hyperspectrales et multispectrales [198].

La CNMF utilise une boucle externe dans laquelle X_h et X_m sont démêlées alternativement par factorisation en matrices non-négatives (NMF) [64] (en utilisant deux boucles internes). Ceci permet d'estimer la matrice \tilde{A}_m des fractions d'abondances à haute résolution spatiale et la matrice des spectres hyperspectraux \tilde{S}_h qui contient les signatures spectrales des endmembers.

La CNMF commence par démêlanger X_h pour estimer la matrice des spectres hyperspectraux \tilde{S}_h . En tant que phase d'initialisation, le nombre d'endmembers M est fixé et la matrice des endmembers \tilde{S}_h est initialisée par la méthode VCA [98]. \tilde{A}_h est initialisée en tant que valeur constante $1/M$. Comme phase d'optimisation, les matrices \tilde{A}_h et \tilde{S}_h sont mises à jour alternativement dans une première boucle interne en utilisant les règles multiplicatives

de Lee et Seung (1.7)-(1.8) [65] de sorte à minimiser la fonction coût $\frac{1}{2} \|X_h - \tilde{A}_h \tilde{S}_h\|_F^2$. Par la suite, la matrice \tilde{S}_h est sous-échantillonnée (par échantillonnage spectral sur les domaines de longueurs d'ondes considérés dans l'image multispectrale) afin d'être utilisée dans la seconde boucle interne comme initialisation de la matrice des spectres multispectraux.

$$\tilde{A}_h \leftarrow \tilde{A}_h \cdot * (X_h \tilde{S}_h^T) ./ (\tilde{A}_h \tilde{S}_h \tilde{S}_h^T), \quad (1.7)$$

$$\tilde{S}_h \leftarrow \tilde{S}_h \cdot * (\tilde{A}_h^T X_h) ./ (\tilde{A}_h^T \tilde{A}_h \tilde{S}_h), \quad (1.8)$$

$$\tilde{A}_m \leftarrow \tilde{A}_m \cdot * (X_m \tilde{S}_m^T) ./ (\tilde{A}_m \tilde{S}_m \tilde{S}_m^T), \quad (1.9)$$

$$\tilde{S}_m \leftarrow \tilde{S}_m \cdot * (\tilde{A}_m^T X_m) ./ (\tilde{A}_m^T \tilde{A}_m \tilde{S}_m). \quad (1.10)$$

Dans la seconde boucle interne, la matrice \tilde{A}_m est estimée à partir des données de résolution spatiale élevée X_m , où la matrice \tilde{S}_m est initialisé à partir de la matrice \tilde{S}_h (par sous-échantillonnage spectral). \tilde{A}_m est initialisée en tant que valeur constante $1/M$. Comme phase d'optimisation, \tilde{A}_m et \tilde{S}_m sont alternativement mises à jour par (1.9) et (1.10) de sorte à minimiser $\frac{1}{2} \|X_m - \tilde{A}_m \tilde{S}_m\|_F^2$. La matrice \tilde{A}_m est ensuite sous-échantillonnée (par sous-échantillonnage spatial) et utilisée, lors de la prochaine itération de la boucle externe, comme initialisation de la matrice \tilde{A}_h dans la première boucle interne. Les deux étapes de démixage sont répétées alternativement jusqu'à convergence.

Enfin, l'image hyperspectrale $X_f \in R_+^{P_m \times L_h}$ à haute résolution spatiale est produite en multipliant \tilde{A}_m par \tilde{S}_h comme suit :

$$X_f = \tilde{A}_m \tilde{S}_h. \quad (1.11)$$

La contrainte de somme-à-un des abondances est implémentée en utilisant une méthode donnée dans [105]. En tant que condition de convergence, celle selon laquelle le rapport de changement de la fonction de coût atteint une valeur inférieure à un seuil donné ε est utilisée.

La CNMF est facile à mettre en œuvre en raison de ses règles de mise à jour simples, et offre des données fusionnées avec des résolutions spatiale et spectrale élevées qui permettent une meilleure identification et classification des matériaux observés. Cependant son coût de calcul est élevé, car elle utilise un processus alternatif de démixage par NMF impliquant toute une série d'étapes à chaque fois qu'elle change entre l'adaptation des variables multispectrales et hyperspectrales.

1.4.2.2. Méthode dite Joint Non-negative Matrix Factorization (JNMF)

La méthode JNMF [12] est une méthode qui utilise le démixage spectral linéaire (LSU), dans lequel les données hyperspectrales à faible résolution spatiale et multispectrales à haute résolution spatiale sont "simultanément" (contrairement à l'algorithme CNMF) démixées par NMF. Elle consiste à optimiser une fonction de coût étendue ($\frac{1}{2}\|X_h - \tilde{A}_h\tilde{S}_h\|_F^2 + \frac{1}{2}\|X_m - \tilde{A}_m\tilde{S}_m\|_F^2$) en utilisant les règles de mise à jour multiplicatives de Lee et Seung [65]. En plus, deux règles supplémentaires sont aussi utilisées pour la mise à jour conjointe des matrices hyperspectrale et multispectrale :

$$\tilde{A}_h \leftarrow (1 - \alpha)\tilde{A}_h + \alpha\tilde{A}_{dm}, \quad (1.12)$$

$$\tilde{A}_m \leftarrow (1 - \alpha)\tilde{A}_m + \alpha\tilde{A}_{uh}, \quad (1.13)$$

où \tilde{A}_{dm} et \tilde{A}_{uh} représentent respectivement la version sous-échantillonnée de \tilde{A}_m et la version sur-échantillonnée de \tilde{A}_h obtenues en utilisant la méthode d'interpolation des k plus proches voisins.

La JNMF commence par démixer "conjointement" X_h et X_m en utilisant la NMF étendue pour estimer la matrice \tilde{A}_m des cartes des fractions d'abondances de haute résolution spatiale et la matrice \tilde{S}_h des spectres d'endmembers hyperspectraux. En tant que phase d'initialisation, le nombre d'endmembers M est automatiquement détecté en appliquant

l'algorithme décrit dans [199] et la matrice des spectres d'endmembers hyperspectraux \tilde{S}_h est initialisée par la méthode SISAL (Simplex Identification via Split Augmented Lagrangian) [101]. Les cartes des fractions d'abondances de faible résolution spatiale \tilde{A}_h sont initialisées au moyen de la méthode FCLS (Fully Constrained Least Squares) [105]. La matrice des spectres d'endmembers multispectraux \tilde{S}_m est initialisée à partir de la matrice initiale des spectres hyperspectraux \tilde{S}_h , en faisant simplement la moyenne des échantillons de ces derniers spectres sur les régions de longueurs d'onde utilisées dans l'image multispectrale. Les cartes des fractions d'abondances de faible résolution spatiale \tilde{A}_h sont sur-échantillonnées (en utilisant la méthode d'interpolation des k plus proches voisins) pour obtenir les cartes des fractions d'abondances initiales de haute résolution spatiale \tilde{A}_m . Comme phase d'optimisation, les matrices \tilde{A}_h , \tilde{S}_h , \tilde{A}_m et \tilde{S}_m sont conjointement mises à jour comme défini par les équations dans l'ordre suivant (1.12),(1.7)-(1.8) et (1.13),(1.9)-(1.10). Pour satisfaire la contrainte de somme-à-un des abondances durant cette phase d'optimisation, la méthode décrite dans [105] est adoptée. En tant que critère de convergence, la condition selon laquelle le nombre d'itérations atteint un nombre maximal d'itérations prédéfini est utilisée.

L'image hyperspectrale fusionnée à haute résolution spatiale $X_f \in R_+^{P_m \times L_h}$ est ensuite obtenue par (1.11).

La méthode JNMF offre de bonnes performances de reconstruction spatiale et spectrale avec l'avantage d'être plus rapide que la méthode CNMF.

Dans notre thèse nous nous intéressons davantage aux méthodes de multisharpening de données hyperspectrales basées sur la factorisation en matrices non-négatives (NMF).

1.5. Conclusion

Dans ce chapitre nous avons dressé un panorama des différentes méthodes proposées dans la littérature permettant la fusion d'images de télédétection spatiale. Nous les avons ainsi classées en différentes catégories selon la technique principale qu'elles utilisent. Tout d'abord, nous avons donné un état de l'art des différentes méthodes pour le pansharpening, qui consistent à fusionner des images panchromatiques à haute résolution spatiale avec des images hyperspectrales ou multispectrales à faible résolution spatiale mais à haute résolution spectrale. Nous avons ainsi choisi de classer ces méthodes en trois catégories : les méthodes

de type projection-substitution, les méthodes d'analyse multirésolution et enfin, les méthodes variationnelles.

Par la suite, nous nous sommes intéressés aux méthodes de multisharpening pour la fusion des images hyperspectrale et multispectrale. Nous avons détaillé davantage les méthodes qui utilisent des techniques de démixage spectral linéaire en faisant appel à la factorisation en matrices non-négatives (NMF) qui font l'objet des travaux de cette thèse. Nous avons ainsi présenté deux principales méthodes de multisharpening basées sur ce principe.

Dans le chapitre suivant, nous présentons les méthodes de multisharpening proposées dans notre thèse, qui utilisent des techniques de démixage spectral adaptées au modèle de mélange considéré dans notre cas (environnements urbains) et basées sur la factorisation en matrices non-négatives (NMF). Une comparaison des performances de ces méthodes proposées ainsi que des méthodes présentées dans ce chapitre sera réalisée dans le troisième chapitre.

Chapitre 2 : Méthodes proposées pour le multisharpening

Sommaire

2.1. Introduction	104
2.2. Modèle mathématique de données	105
2.3. Les méthodes de multisharpening proposées	107
2.3.1. Critères optimisés	108
2.3.2. Première méthode proposée.....	110
2.3.2.1. Première approche : HMF-LQNMF	110
2.3.2.2. Deuxième approche : CHMF-LQNMF	113
2.3.2.3. Troisième approche : JHMF-LQNMF	114
2.3.2.4. Quatrième approche : Multi-JCLQNMF	114
2.3.3. Deuxième méthode proposée.....	120
2.4. Conclusion.....	124

2.1. Introduction

Dans le chapitre précédent nous avons donné un panorama des méthodes de fusion qui existent dans la littérature. Par la suite, nous nous sommes intéressés aux méthodes de multisharpening pour la fusion des images hyperspectrale et multispectrale, particulièrement aux méthodes qui utilisent des techniques de démixage spectral linéaire (LSU) basées sur la Factorisation en Matrices Non-négatives (NMF). Ces méthodes améliorent la résolution spatiale des images hyperspectrales en utilisant des images multispectrales à haute résolution spatiale. Ces techniques LSU sont conçues pour un modèle de mélange linéaire, dans lequel on suppose que chaque spectre observé est une combinaison linéaire de plusieurs spectres d'endmembers. Les techniques LSU utilisées consistent à démixer linéairement les données de télédétection en une collection de spectres d'endmembers et leurs fractions d'abondances correspondantes [5, 189].

Cependant, lorsque nous sommes en présence de paysage non plat et/ou d'hétérogénéité de l'irradiation dans la zone imagée (comme dans le cas d'environnements urbains), le modèle de mélange linéaire utilisé dans les techniques LSU n'est plus valide et doit être remplacé par un modèle de mélange non-linéaire [124]. Ce modèle non-linéaire peut être réduit à un modèle de mélange linéaire-quadratique [9, 11].

Dans ce chapitre, de nouvelles méthodes de multisharpening sont proposées pour la fusion de données hyperspectrale et multispectrale de télédétection. Ces méthodes sont conçues pour le cas particulier de fusion de données de télédétection de milieux urbains. Les méthodes de multisharpening proposées sont basées sur des techniques de démixage spectral linéaire-quadratique (LQSU) et utilisent l'algorithme NMF Linéaire-Quadratique Multiplicatif décrit dans [10].

Nous commençons ce chapitre par décrire le modèle de mélange linéaire-quadratique considéré dans le concept LQSU ainsi que ses contraintes. Par la suite, nous présentons les différentes méthodes de multisharpening développées pour notre cas particulier de données de milieux urbains. Les performances des méthodes proposées seront données dans le chapitre suivant.

2.2. Modèle mathématique de données

Le modèle de mélange considéré dans les méthodes de multisharpening proposées dans ce manuscrit est le modèle linéaire-quadratique. Le modèle linéaire-quadratique considère les interactions de second ordre entre différents spectres d'endmembers et suppose que les interactions de troisième ou de haut ordre sont négligeables.

2.2.1. Rappel sur le modèle mathématique d'une image de télédétection

Dans nos travaux, chaque vecteur spectral associé à un pixel dans une image de télédétection (soit une image multispectrale ou hyperspectrale) est censé être un mélange linéaire-quadratique de différents spectres d'endmembers. Mathématiquement, le spectre de réflectance non négatif x_i (vecteur colonne de taille L), du pixel i de l'image de télédétection est modélisé comme suit [10] :

$$x_i = \sum_{j=1}^M a_j(i)s_j + \sum_{j=1}^M \sum_{l=j}^M a_{j,l}(i)s_j \odot s_l, \quad (2.1)$$

$$\text{avec} \begin{cases} s_j \geq 0, & j = 1 \dots M \\ \sum_{j=1}^M a_j(i) = 1, \\ a_j(i) \geq 0, & j = 1 \dots M \\ 0 \leq a_{j,l}(i) \leq 0.5, & 1 \leq j \leq l \leq M \end{cases} \quad (2.2)$$

où

- s_j : (vecteur colonne de taille L) est le spectre de réflectance non négatif du j -ième endmember ($s_j \odot s_l$ est considéré ici comme le spectre d'un "pseudo-endmember").
- $a_j(i)$ et $a_{j,l}(i)$: correspondent respectivement aux fractions d'abondances des parties linéaire et quadratique du modèle de mélange.
- L et M : correspondent respectivement aux nombres de bandes spectrales et d'endmembers présents dans la région observée.

Il est à noter que le modèle de mélange considéré est contraint selon (2.2). Ces contraintes sont imposées en fonction de l'analyse physique rapportée dans [10] : analyse effectuée en considérant des environnements urbains et en utilisant plusieurs données synthétiques

simulées avec la modélisation 3D avancée du Transfert Radiatif Atmosphérique pour les Surfaces Inhomogénéiques (3D Advanced Modelling of the Atmospheric Radiative Transfer for Inhomogeneous Surfaces (AMARTIS v2)) [135].

Le modèle décrit dans l'équation (2.1) peut être reformulé sous la forme matricielle comme suit (pour P pixels, $P \geq 2$) [10] :

$$X = A S = A_a S_a + A_b S_b \quad (2.3)$$

avec $X = [x_1 \dots x_P]^T$ (matrice de spectres de pixels observés, de dimensions $P \times L$, où chaque vecteur colonne de X contient une bande spectrale [10]), $A = [A_a \ A_b]$ (matrice des fractions d'abondances linéaires et quadratiques), et $S = \begin{bmatrix} S_a \\ S_b \end{bmatrix}$ (matrice des spectres d'endmembers et pseudo-endmembers), avec :

$$A_a = \begin{bmatrix} a_1(1) & \dots & a_M(1) \\ \vdots & \ddots & \vdots \\ a_1(P) & \dots & a_M(P) \end{bmatrix}, \quad (2.4)$$

$$A_b = \begin{bmatrix} a_{1,1}(1) & a_{1,2}(1) & \dots & a_{M,M}(1) \\ \vdots & \vdots & \ddots & \vdots \\ a_{1,1}(P) & a_{1,2}(P) & \dots & a_{M,M}(P) \end{bmatrix}, \quad (2.5)$$

$$S_a = [s_1 \dots s_M]^T, \quad (2.6)$$

$$S_b = [s_1 \odot s_1 \quad s_1 \odot s_2 \quad \dots \quad s_M \odot s_M]^T, \quad (2.7)$$

où les sous-indices a et b , respectivement, se réfèrent aux parties linéaire et quadratique des variables considérées.

2.2.2. Modèles mathématiques des images multispectrales et hyperspectrales considérées

Le but du multisharpening de données hyperspectrales est de produire des données hyperspectrales à haute résolution spectrale et haute résolution spatiale non observables $X_f \in R_+^{P_m \times L_h}$ à partir de données hyperspectrales observables à haute résolution spectrale et faible résolution spatiale $X_h \in R_+^{P_h \times L_h}$ et des données multispectrales à faible résolution spectrale et haute résolution spatiale $X_m \in R_+^{P_m \times L_m}$. Chaque vecteur colonne des matrices ci-dessus (X_h , X_m et X_f) contient une bande spectrale [10]. Les images hyperspectrale et multispectrale observables sont supposées être corrigées radiométriquement et géométriquement recalées.

Comme expliqué ci-dessus, X_h et X_m peuvent être reformulées sous forme matricielle comme suit :

$$X_h = A_h S_h = A_{ha} S_{ha} + A_{hb} S_{hb}, \quad (2.8)$$

$$X_m = A_m S_m = A_{ma} S_{ma} + A_{mb} S_{mb}, \quad (2.9)$$

avec $A_h = [A_{ha} \ A_{hb}]$, $S_h = \begin{bmatrix} S_{ha} \\ S_{hb} \end{bmatrix}$, $A_m = [A_{ma} \ A_{mb}]$ et $S_m = \begin{bmatrix} S_{ma} \\ S_{mb} \end{bmatrix}$. Les indices h et m se réfèrent, respectivement, aux entités hyperspectrales et multispectrales.

2.3. Les méthodes de multisharpening proposées

Les méthodes de fusion proposées dans ce manuscrit utilisent le concept du démelange spectral linéaire-quadratique LQSU, qui considère la diffusion multiple de la lumière entre les endmembers dans la zone observée, ce qui est le cas lorsque nous disposons d'images d'environnements urbains [11]. Ces méthodes sont basées sur la NMF qui consiste à déduire, à partir des données considérées, les estimations \widetilde{S}_{ha} et \widetilde{S}_{hb} des ensembles S_{ha} et S_{hb} des spectres d'endmembers et pseudo-endmembers hyperspectraux (pour plus de détails voir partie I du manuscrit) et les estimations \widetilde{A}_{ma} et \widetilde{A}_{mb} des ensembles A_{ma} et A_{mb} des fractions d'abondances linéaires et quadratiques à haute résolution spatiale. L'image hyperspectrale X_f

à haute résolution spectrale et haute résolution spatiale souhaitée est alors obtenue par la formule suivante :

$$X_f = \widetilde{A}_{ma}\widetilde{S}_{ha} + \widetilde{A}_{mb}\widetilde{S}_{hb}. \quad (2.10)$$

2.3.1. Critères optimisés

Les méthodes présentées dans ce manuscrit comprennent deux processus de démixage LQSU et utilisent l'algorithme NMFLQ Multiplicatif itératif décrit dans [10]. Le premier processus consiste à démixer l'image hyperspectrale en optimisant le critère suivant :

$$J_1 = \frac{1}{2} \|X_h - \widetilde{A}_{ha}\widetilde{S}_{ha} - \widetilde{A}_{hb}\widetilde{S}_{hb}\|_F^2, \quad (2.11)$$

Ce critère peut être formulé sous forme scalaire comme suit [10] :

$$J_1 = \frac{1}{2} \sum_{i_h, n_h} [X_h - \widetilde{A}_{ha}\widetilde{S}_{ha} - \widetilde{A}_{hb}\widetilde{S}_{hb}]_{i_h, n_h}^2, \quad (2.12)$$

$$J_1 = \frac{1}{2} \sum_{i_h, n_h} [[X_h]_{i_h, n_h} - [\widetilde{A}_{ha}\widetilde{S}_{ha}]_{i_h, n_h} - [\widetilde{A}_{hb}\widetilde{S}_{hb}]_{i_h, n_h}]^2, \quad (2.13)$$

$$J_1 = \frac{1}{2} \sum_{i_h, n_h} \left[[X_h]_{i_h, n_h} - \sum_{j=1}^M \widetilde{a}_{h_j}(i_h) [\widetilde{S}_h]_{j, n_h} - \sum_{j=1}^M \sum_{l=j}^M \widetilde{a}_{h_j, l}(i_h) [\widetilde{S}_h]_{j, n_h} [\widetilde{S}_h]_{l, n_h} \right]^2, \quad (2.14)$$

où $[X_h]_{i_h, n_h}$ est l'élément de X_h avec des indices de ligne et de colonne respectivement égaux à i_h et n_h . Des notations similaires sont utilisées pour les autres matrices. En outre, i_h correspond à un pixel hyperspectral et n_h est l'indice des composantes du spectre hyperspectral, c'est-à-dire les longueurs d'ondes hyperspectrales. Les variables $\widetilde{a}_{h_j}(i_h)$ et $\widetilde{a}_{h_j, l}(i_h)$ représentent respectivement un élément de la matrice \widetilde{A}_{ha} et \widetilde{A}_{hb} , avec $j = 1 \dots M$ et $1 \leq j \leq l \leq M$.

De même, le deuxième processus optimise la norme suivante afin de démélanger l'image multispectrale :

$$J_2 = \frac{1}{2} \|X_m - \widetilde{A}_{ma}\widetilde{S}_{ma} - \widetilde{A}_{mb}\widetilde{S}_{mb}\|_F^2. \quad (2.15)$$

Comme le critère précédent J_1 , ce critère peut être formulé sous forme scalaire comme suit [10] :

$$J_2 = \frac{1}{2} \sum_{i_m, n_m} [X_m - \widetilde{A}_{ma}\widetilde{S}_{ma} - \widetilde{A}_{mb}\widetilde{S}_{mb}]_{i_m, n_m}^2, \quad (2.16)$$

$$J_2 = \frac{1}{2} \sum_{i_m, n_m} [[X_m]_{i_m, n_m} - [\widetilde{A}_{ma}\widetilde{S}_{ma}]_{i_m, n_m} - [\widetilde{A}_{mb}\widetilde{S}_{mb}]_{i_m, n_m}]^2, \quad (2.17)$$

$$J_2 = \frac{1}{2} \sum_{i_m, n_m} [X_m]_{i_m, n_m} - \sum_{j=1}^M \widetilde{a}_{m_j}(i_m) [\widetilde{S}_m]_{j, n_m} - \sum_{j=1}^M \sum_{l=j}^M \widetilde{a}_{m_{j,l}}(i_m) [\widetilde{S}_m]_{j, n_m} [\widetilde{S}_m]_{l, n_m}]^2, \quad (2.18)$$

où $[X_m]_{i_m, n_m}$ est l'élément de X_m avec des indices de ligne et de colonne respectivement égaux à i_m et n_m (i_m correspond à un pixel multispectral et n_m est l'indice des composantes du spectre multispectral). $[\widetilde{S}_m]_{j, n_m}$ est l'élément (j, n_m) de la matrice \widetilde{S}_m (l'estimée de la matrice S_m), $\widetilde{a}_{m_j}(i_h)$ et $\widetilde{a}_{m_{j,l}}(i_h)$ représentent respectivement un élément de la matrice \widetilde{A}_{ma} et \widetilde{A}_{mb} .

Différentes méthodes de multisharpening pour l'amélioration de la résolution spatiale des données hyperspectrales ont été proposées dans ce manuscrit. Ces méthodes proposées visent à minimiser les critères décrits dans les équations (2.14) et (2.18) avec des contraintes relatives à notre modèle de mélange, donnant lieu à différentes règles de mise à jour selon l'approche considérée.

Dans les sections suivantes, nous nous proposons de décrire ces différentes méthodes proposées ainsi que leurs règles de mise à jour.

2.3.2. Première méthode proposée

Les méthodes de multisharpening décrites dans cette section utilisent l'algorithme NMF linéaire-quadratique multiplicatif (LQNMF) [10]. Elles consistent d'abord à démêler les données hyperspectrales observables à haute résolution spectrale/faible résolution spatiale et les données multispectrales à faible résolution spectrale/haute résolution spatiale. Les informations spectrale et spatiale de haute résolution obtenues sont ensuite recombinaées, selon le modèle de mélange linéaire-quadratique, pour obtenir des données hyperspectrales à haute résolution spectrale/haute résolution spatiale non observables. Pour ce faire, quatre approches ont été proposées :

2.3.2.1. Première approche : HMF-LQNMF

Dans cette première approche, appelée Hyperspectral and Multispectral data Fusion based on LQNMF (HMF-LQNMF), les variables hyperspectrales et multispectrales sont optimisées "indépendamment", une fois qu'elles ont été initialisées de manière cohérente. Ainsi, les variables correspondant à chaque image considérée sont mises à jour "alternativement" selon l'algorithme LQNMF multiplicatif. Pratiquement, cette première approche proposée comprend deux boucles successives au cours de la phase d'optimisation. Les matrices hyperspectrales sont mises à jour dans la première boucle en optimisant le critère J_1 . Cette première boucle utilise les règles de mise à jour et les contraintes suivantes [10] :

- Règle de mise à jour (donnée sous forme scalaire) de la matrice \widetilde{S}_{ha} :

$$[\widetilde{S}_{ha}]_{p,n_h} \leftarrow \left(\frac{[\widetilde{A}_{ha}^T X_h]_{p,n_h} + 2[\widetilde{S}_{ha}]_{p,n_h} [\widetilde{A}_{hb}^T X_h]_{(pp),n_h}}{[D_h]_{p,n} + \varepsilon} + \frac{\sum_{j=1, j \neq p}^M [\widetilde{S}_{ha}]_{j,n_h} [\widetilde{A}_{hb}^T X_h]_{(jp),n_h}}{[D_h]_{p,n_h} + \varepsilon} \right), \quad (2.19)$$

où

$$\begin{aligned}
 [D_h]_{p,n_h} &= [\widetilde{A}_{ha}^T \widetilde{A}_h \widetilde{S}_h]_{p,n_h} + \sum_{j=1, j \neq p}^M [\widetilde{S}_{ha}]_{j,n_h} \times [\widetilde{A}_{hb}^T \widetilde{A}_h \widetilde{S}_h]_{(jp),n_h} \\
 &+ 2[\widetilde{S}_{ha}]_{p,n_h} \times [\widetilde{A}_{hb}^T \widetilde{A}_h \widetilde{S}_h]_{(pp),n_h}.
 \end{aligned} \tag{2.20}$$

Le terme ε dans le dénominateur de (2.19) est sélectionné de sorte à être positif et très petit (généralement réglé sur la valeur par défaut de Matlab Epsilon) et est destiné à éviter une division possible par zéro, p est un indice pour le spectre d'endmember [10] et (jp) est l'indice de la colonne des matrices \widetilde{A}_{*b} correspondant aux coefficients $a_{*j,p}(i)$, c'est aussi l'indice de la ligne contenant $s_{*j} \odot s_{*p}$ dans la matrice \widetilde{S}_{*b} (il est par exemple égal à un pour $j = p = 1$).

- Règle de mise à jour (donnée sous forme scalaire) de la matrice \widetilde{S}_{hb} en utilisant \widetilde{S}_{ha} :

$$[\widetilde{S}_{hb}]_{(jp),n_h} \leftarrow [\widetilde{S}_{ha}]_{j,n_h} \times [\widetilde{S}_{ha}]_{p,n_h}. \tag{2.21}$$

- Règle de mise à jour (donnée sous forme matricielle) de la matrice \widetilde{A}_h :

$$\widetilde{A}_h \leftarrow \widetilde{A}_h \odot ((X_h \widetilde{S}_h^T) \oslash (\widetilde{A}_h \widetilde{S}_h \widetilde{S}_h^T + \varepsilon)). \tag{2.22}$$

- Contrainte sur la partie linéaire de la matrice \widetilde{A}_h :

$$[\widetilde{a}_{h_1}(i_h) \dots \widetilde{a}_{h_M}(i_h)] \leftarrow [\widetilde{a}_{h_1}(i_h) \dots \widetilde{a}_{h_M}(i_h)] / \sum_{j=1}^M \widetilde{a}_{h_j}(i_h). \tag{2.23}$$

- Contrainte sur la partie quadratique de la matrice \widetilde{A}_h :

$$\widetilde{\alpha}_{h,l}(i_h) \leftarrow \min \{0.5, \widetilde{\alpha}_{h,l}(i_h)\}. \quad (2.24)$$

Les variables multispectrales sont mises à jour dans la seconde boucle en optimisant le critère J_2 . Cette deuxième boucle utilise les mêmes règles de mise à jour et les mêmes contraintes que ci-dessus, sauf qu'elles sont appliquées aux données multispectrales, au lieu des données hyperspectrales. L'algorithme résultant est donc le même que (2.19) - (2.24), où les indices matriciels "h" sont remplacés par "m" :

- Règle de mise à jour (donnée sous forme scalaire) de la matrice \widetilde{S}_{ma} :

$$[\widetilde{S}_{ma}]_{p,n_m} \leftarrow [\widetilde{S}_{ma}]_{p,n_m} \left(\frac{[\widetilde{A}_{ma}^T X_m]_{p,n_m} + 2[\widetilde{S}_{ma}]_{p,n_m} [\widetilde{A}_{mb}^T X_m]_{(pp),n_m}}{[D_h]_{p,n} + \varepsilon} + \frac{\sum_{j=1, j \neq p}^M [\widetilde{S}_{ma}]_{j,n_m} [\widetilde{A}_{mb}^T X_m]_{(jp),n_m}}{[D_m]_{p,n_m} + \varepsilon} \right), \quad (2.25)$$

où

$$[D_m]_{p,n_m} = [\widetilde{A}_{ma}^T \widetilde{A}_m \widetilde{S}_m]_{p,n_m} + \sum_{j=1, j \neq p}^M [\widetilde{S}_{ma}]_{j,n_m} \times [\widetilde{A}_{mb}^T \widetilde{A}_h \widetilde{S}_h]_{(jp),n_m} + 2[\widetilde{S}_{ma}]_{p,n_m} \times [\widetilde{A}_{mb}^T \widetilde{A}_m \widetilde{S}_m]_{(pp),n_m}. \quad (2.26)$$

- Règle de mise à jour (donnée sous forme scalaire) de la matrice \widetilde{S}_{mb} en utilisant \widetilde{S}_{ma} :

$$[\widetilde{S}_{mb}]_{(jp),n_m} \leftarrow [\widetilde{S}_{ma}]_{j,n_m} \times [\widetilde{S}_{ma}]_{p,n_m}. \quad (2.27)$$

- Règle de mise à jour (donnée sous forme matricielle) de la matrice \widetilde{A}_m :

$$\widetilde{A}_m \leftarrow \widetilde{A}_m \odot ((X_m \widetilde{S}_m^T) \oslash (\widetilde{A}_m \widetilde{S}_m \widetilde{S}_m^T + \varepsilon)). \quad (2.28)$$

- Contrainte sur la partie linéaire de la matrice \widetilde{A}_m :

$$[\widetilde{a}_{m_1}(i_m) \dots \widetilde{a}_{m_M}(i_m)] \leftarrow [\widetilde{a}_{m_1}(i_m) \dots \widetilde{a}_{m_M}(i_m)] / \sum_{j=1}^M \widetilde{a}_{m_j}(i_m). \quad (2.29)$$

- Contrainte sur la partie quadratique de la matrice \widetilde{A}_m :

$$\widetilde{a}_{m_{j,l}}(i_m) \leftarrow \min \{0.5, \widetilde{a}_{m_{j,l}}(i_m)\}. \quad (2.30)$$

2.3.2.2. Deuxième approche : CHMF-LQNMF

La deuxième approche proposée, appelée Coupled Hyperspectral and Multispectral data Fusion based on LQNMF (CHMF-LQNMF), peut être considérée comme une extension de la méthode CNMF [156] à un modèle de mélange linéaire-quadratique, puisque la méthode CNMF est conçue pour un mélange linéaire. Dans cette approche, nous utilisons une boucle externe, dans laquelle les variables hyperspectrales et multispectrales sont mises à jour "en alternance" en utilisant deux boucles internes successives.

Dans la première boucle interne, les variables hyperspectrales sont mises à jour afin de minimiser le critère J_1 en utilisant les règles de mise à jour définies par (2.19)-(2.22) et les contraintes (2.23) et (2.24). Les parties spectrales de ces variables hyperspectrales obtenues en utilisant les règles de mise à jour (2.19), (2.20) et (2.21) sont ensuite sous-échantillonnées en faisant la moyenne des échantillons de ces derniers spectres sur les domaines de longueurs d'ondes considérés dans l'image multispectrale. Ces parties obtenues sont ensuite injectées comme initialisation des spectres utilisés dans la seconde boucle interne. Dans cette boucle, les variables multispectrales sont mises à jour afin de minimiser le critère J_2 en utilisant les règles de mise à jour et contraintes définies dans (2.25)-(2.30) destinée aux variables multispectrales.

Les parties spatiales optimisées de ces variables multispectrales sont ensuite sous-échantillonnées spatialement (au moyen de la technique d'interpolation des k plus proches voisins) et sont utilisées lors de la prochaine itération de la boucle externe comme l'initialisation de la première boucle interne.

2.3.2.3. Troisième approche : JHMF-LQNMF

Cette troisième approche, appelée Joint Hyperspectral and Multispectral data Fusion based on LQNMF (JHMF-LQNMF), est une extension de la méthode JNMF [12] pour un mélange linéaire-quadratique. Cette troisième approche utilise une seule boucle, dans laquelle les variables hyperspectrales et multispectrales considérées sont mises à jour "conjointement" en utilisant, à chaque boucle d'itération, les règles de mise à jour des variables hyperspectrales et multispectrales suivant l'algorithme LQNMF multiplicatif considéré. L'algorithme complet de cette troisième approche proposée comprend deux règles supplémentaires (en plus de (2.19)-(2.24) de la partie hyperspectrale et de (2.25)-(2.30) de la partie multispectrale) qui sont :

$$\widetilde{A}_h \leftarrow (1 - \alpha)\widetilde{A}_h + \alpha \widetilde{A}_{dm}, \quad (2.31)$$

$$\widetilde{A}_m \leftarrow (1 - \alpha)\widetilde{A}_m + \alpha \widetilde{A}_{uh}, \quad (2.32)$$

où la matrice \widetilde{A}_{dm} (respectivement \widetilde{A}_{uh}) représente la version sous-échantillonnée (respectivement sur-échantillonnée) spatialement de \widetilde{A}_m (respectivement \widetilde{A}_h) obtenue au moyen de la technique d'interpolation des k plus proches voisins. Ces règles de mise à jour supplémentaires forcent les cartes des fractions d'abondances linéaires et quadratiques de faible et haute résolution spatiale à être mises à jour de manière cohérente en utilisant un petit paramètre positif $\alpha \in]0, 1[$.

2.3.2.4. Quatrième approche : Multi-JCLQNMF

Cette quatrième approche est la méthode Multi-JCLQNMF (pour Multiplicative Joint-Criterion LQNMF). Elle est basée sur la NMF Linéaire-Quadratique Multiplicative avec critère conjoint. Elle est inspirée des méthodes NMF standard qui utilisent des règles de mise à jour multiplicatives [8] pour réaliser le processus de démixage considéré. Cette approche peut être considérée comme une extension de la méthode HMF-LQNMF, ou encore une extension au modèle de mélange linéaire-quadratique de la méthode pour le modèle de

mélange linéaire proposée dans [13]. L'approche proposée, contrairement aux autres approches proposées dans ce manuscrit, consiste à optimiser le nouveau critère étendu suivant :

$$J_3 = \frac{\alpha}{2} \|X_h - \tilde{A}_h \tilde{S}_h\|_F^2 + \frac{\beta}{2} \|X_m - \tilde{A}_m \tilde{S}_m\|_F^2 + \frac{\gamma}{2} \|\tilde{A}_h^T - \tilde{A}_{dm}^T\|_F^2. \quad (2.33)$$

L'approche proposée optimise ce nouveau critère conjoint J_3 , qui exploite un modèle de dégradation spatiale entre les images considérées (les images hyperspectrale et multispectrale), en utilisant de nouvelles règles de mise à jour multiplicatives, où α , β et γ sont des coefficients d'équilibrage. La matrice \tilde{A}_{dm}^T représente la version dégradée spatialement de la matrice \tilde{A}_m . Cette matrice dégradée peut être exprimée comme suit [13] :

$$\tilde{A}_{dm}^T = \tilde{A}_m^T D, \quad (2.34)$$

où D est un opérateur linéaire, qui effectue la dégradation spatiale [200]. Cet opérateur peut être vu comme une matrice de décimation qui est une matrice diagonale parcimonieuse ayant des valeurs de filtre gaussien. Par conséquent, le critère à optimiser devient comme suit :

$$J_3 = \frac{\alpha}{2} \|X_h - \tilde{A}_h \tilde{S}_h\|_F^2 + \frac{\beta}{2} \|X_m - \tilde{A}_m \tilde{S}_m\|_F^2 + \frac{\gamma}{2} \|\tilde{A}_h^T - \tilde{A}_m^T D\|_F^2. \quad (2.35)$$

Notons ici que le critère J_3 est une extension du critère utilisé dans la méthode HMF-LQNMf auquel est ajouté le terme $\|\tilde{A}_h^T - \tilde{A}_m^T D\|_F^2$ pour la mise à jour conjointe des variables multispectrales et hyperspectrales.

Le critère J_3 peut être réécrit comme suit :

$$\begin{aligned} J_3 = & \frac{\alpha}{2} \text{Tr}(X_h X_h^T - 2 \times X_h \tilde{S}_h^T \tilde{A}_h^T + \tilde{A}_h \tilde{S}_h \tilde{S}_h^T \tilde{A}_h^T) \\ & + \frac{\beta}{2} \text{Tr}(X_m X_m^T - 2 \times X_m \tilde{S}_m^T \tilde{A}_m^T + \tilde{A}_m \tilde{S}_m \tilde{S}_m^T \tilde{A}_m^T) \\ & + \frac{\gamma}{2} \text{Tr}(\tilde{A}_h^T \tilde{A}_h - 2 \times \tilde{A}_h^T D^T \tilde{A}_m + \tilde{A}_m^T D D^T \tilde{A}_m). \end{aligned} \quad (2.36)$$

Cette formulation permet facilement le calcul des expressions de gradient dans notre méthode. Le calcul du gradient par rapport aux matrices \tilde{A}_h et \tilde{A}_m diffère en comparaison avec le cas de l'approche HMF-LQNMF du fait de l'utilisation du nouveau critère J_3 pour la mise à jour conjointe des variables multispectrales et hyperspectrales. A partir de (2.36), les expressions de gradient par rapport à ces matrices sont comme suit :

$$\frac{\partial J_3}{\partial \tilde{A}_h} = \alpha(\tilde{A}_h \tilde{S}_h \tilde{S}_h^T - X_h \tilde{S}_h^T) + \gamma(\tilde{A}_h - D^T \tilde{A}_m), \quad (2.37)$$

$$\frac{\partial J_3}{\partial \tilde{A}_m} = \beta(\tilde{A}_m \tilde{S}_m \tilde{S}_m^T - X_m \tilde{S}_m^T) + \gamma(DD^T \tilde{A}_m - D \tilde{A}_h). \quad (2.38)$$

Cependant, le calcul du gradient par rapport aux matrices \tilde{S}_h et \tilde{S}_m n'est pas altéré par le nouveau critère considéré [10], par rapport à l'approche HMF-LQNMF. En effet, le critère (2.36) a la même dépendance vis-à-vis de ces matrices que cette approche. Pour effectuer ce calcul, le critère J_3 (2.35) est réécrit sous forme scalaire comme suit :

$$\begin{aligned} J_3 = & \frac{\alpha}{2} \sum_{i_h, n_h} \left[X_{h i_h, n_h} - \sum_{j=1}^M \tilde{a}_{h_j}(i_h) \tilde{S}_{h, j, n_h} - \sum_{j=1}^M \sum_{l=j}^M \tilde{a}_{h_{j,l}}(i_h) \tilde{S}_{h, j, n_h} \tilde{S}_{h, l, n_h} \right]^2 \\ & + \frac{\beta}{2} \sum_{i_m, n_m} \left[X_{m i_m, n_m} - \sum_{j=1}^M \tilde{a}_{m_j}(i_m) \tilde{S}_{m, j, n_m} - \sum_{j=1}^M \sum_{l=j}^M \tilde{a}_{m_{j,l}}(i_m) \tilde{S}_{m, j, n_m} \tilde{S}_{m, l, n_m} \right]^2 \\ & + \frac{\gamma}{2} \sum_{j, i_h} \left[[\tilde{A}_h^T]_{j, i_h} - [\tilde{A}_m^T D]_{j, i_h} \right]^2, \end{aligned} \quad (2.39)$$

où n_h (respectivement n_m) est l'indice des composantes hyperspectrales (respectivement multispectrales) et i_h (respectivement i_m) correspond à un pixel hyperspectral (respectivement multispectral). \tilde{S}_{h, j, n_h} est l'élément (j, n_h) de la matrice \tilde{S}_{ha} et \tilde{S}_{m, j, n_m} est l'élément (j, n_m) de la matrice \tilde{S}_{ma} . Ces éléments peuvent être notés $[\tilde{S}_{ah}]_{j, n_h}$ et $[\tilde{S}_{am}]_{j, n_m}$.

En utilisant (2.39), les expressions de gradient par rapport à un élément $[\tilde{S}_{ah}]_{j, n_h}$ et $[\tilde{S}_{am}]_{j, n_m}$ peuvent être écrites comme suit :

$$\begin{aligned}
\frac{\partial J_3}{\partial [\tilde{S}_{ah}]_{pn_h}} &= -\alpha [\tilde{A}_{ah}^T (X_h - \tilde{A}_h \tilde{S}_h)]_{p,n_h} \\
&- \alpha \sum_{j=1, j \neq p}^M [\tilde{S}_{ah}]_{j,n_h} \times [\tilde{A}_{bh}^T (X_h - \tilde{A}_h \tilde{S}_h)]_{(jp),n_h} \\
&- 2\alpha [\tilde{S}_{ah}]_{p,n_h} \times [\tilde{A}_{bh}^T (X_h - \tilde{A}_h \tilde{S}_h)]_{(pp),n_h},
\end{aligned} \tag{2.40}$$

$$\begin{aligned}
\frac{\partial J_3}{\partial [\tilde{S}_{am}]_{pn_m}} &= -\beta [\tilde{A}_{am}^T (X_m - \tilde{A}_m \tilde{S}_m)]_{p,n_m} \\
&- \beta \sum_{j=1, j \neq p}^M [\tilde{S}_{am}]_{j,n_m} \times [\tilde{A}_{bm}^T (X_m - \tilde{A}_m \tilde{S}_m)]_{(jp),n_m} \\
&- 2\beta [\tilde{S}_{am}]_{p,n_m} \times [\tilde{A}_{bm}^T (X_m - \tilde{A}_m \tilde{S}_m)]_{(pp),n_m}.
\end{aligned} \tag{2.41}$$

En appliquant l'algorithme de la descente du gradient, les règles de mise à jour suivantes sont obtenues :

$$\tilde{A}_h \leftarrow \tilde{A}_h - \varphi_{\tilde{A}_h} \frac{\partial J_3}{\partial \tilde{A}_h}, \tag{2.42}$$

$$[\tilde{S}_{ah}]_{p,n_h} \leftarrow [\tilde{S}_{ah}]_{p,n_h} - \varphi_{[\tilde{S}_{ah}]_{p,n_h}} \left[\frac{\partial J_3}{\partial [\tilde{S}_{ah}]_{p,n_h}} \right], \tag{2.43}$$

$$\tilde{A}_m \leftarrow \tilde{A}_m - \varphi_{\tilde{A}_m} \frac{\partial J_3}{\partial \tilde{A}_m}, \tag{2.44}$$

$$[\tilde{S}_{am}]_{p,n_m} \leftarrow [\tilde{S}_{am}]_{p,n_m} - \varphi_{[\tilde{S}_{am}]_{p,n_m}} \left[\frac{\partial J_3}{\partial [\tilde{S}_{am}]_{p,n_m}} \right], \tag{2.45}$$

où $\varphi_{\tilde{A}_h}$, $\varphi_{[\tilde{S}_{ah}]_{p,n_h}}$, $\varphi_{\tilde{A}_m}$ et $\varphi_{[\tilde{S}_{am}]_{p,n_m}}$ sont des taux d'apprentissage exprimés en tant que fonctions des matrices considérées, dans cette approche, afin de produire des mises à jour multiplicatives et de préserver la non-négativité. La multiplicativité est garantie si ces taux

d'apprentissage contiennent le terme de la variable mise à jour considérée dans leur numérateur, pour permettre une factorisation de cette variable mise à jour. Pour garantir la contrainte de non-négativité, tous les termes, dans les expressions de gradient ci-dessus, précédés d'un signe plus doivent être supprimés de (2.42)-(2.45) pour obtenir une somme de termes positifs dans ces règles de mise à jour. Ceci est obtenu en plaçant ces termes dans le dénominateur du taux d'apprentissage utilisé, ce qui permet d'éliminer ces termes en réduisant l'expression entière dans le côté droit de (2.42)-(2.45) au même dénominateur [10]. Sur la base de ce principe, les taux d'apprentissage sont donnés comme suit :

$$\varphi_{\tilde{A}_h} = \tilde{A}_h \oslash (\alpha \tilde{A}_h \tilde{S}_h \tilde{S}_h^T + \gamma \tilde{A}_h). \quad (2.46)$$

$$\varphi_{[\tilde{S}_{ah}]_{p,n_h}} = \frac{[\tilde{S}_{ah}]_{p,n_h}}{D_{h,p,n_h}}, \quad (2.47)$$

avec

$$D_{h,p,n_h} = \alpha [\tilde{A}_{ah}^T \tilde{A}_h \tilde{S}_h]_{p,n_h} + \alpha \sum_{j=1, j \neq p}^M [\tilde{S}_{ah}]_{j,n_h} \times [\tilde{A}_{bh}^T \tilde{A}_h \tilde{S}_h]_{(jp),n_h} \quad (2.48)$$

$$+ 2 \alpha [\tilde{S}_{ah}]_{p,n_h} \times [\tilde{A}_{bh}^T \tilde{A}_h \tilde{S}_h]_{(pp),n_h},$$

$$\varphi_{\tilde{A}_m} = \tilde{A}_m \oslash (\beta \tilde{A}_m \tilde{S}_m \tilde{S}_m^T + \gamma D D^T \tilde{A}_m). \quad (2.49)$$

$$\varphi_{[\tilde{S}_{am}]_{p,n_m}} = \frac{[\tilde{S}_{am}]_{p,n_m}}{D_{m,p,n_m}}, \quad (2.50)$$

avec

$$D_{m,p,n_m} = \beta [\tilde{A}_{am}^T \tilde{A}_m \tilde{S}_m]_{p,n_m} + \beta \sum_{j=1, j \neq p}^M [\tilde{S}_{am}]_{j,n_m} \times [\tilde{A}_{bm}^T \tilde{A}_m \tilde{S}_m]_{(jp),n_m} \quad (2.51)$$

$$+ 2 \beta [\tilde{S}_{am}]_{p,n_m} \times [\tilde{A}_{bm}^T \tilde{A}_m \tilde{S}_m]_{(pp),n_m}.$$

Par conséquent, les règles de mise à jour multiplicatives finales pour les entités hyperspectrales de l'algorithme proposé sont :

- Règle de mise à jour de \tilde{A}_h

$$\tilde{A}_h \leftarrow \tilde{A}_h \odot ((\alpha X_h S_h^T + \gamma \mathcal{D}^T \tilde{A}_m) \oslash (\alpha \tilde{A}_h \tilde{S}_h \tilde{S}_h^T + \gamma \tilde{A}_h + \varepsilon)). \quad (2.52)$$

En plus de cette règle de mise à jour, la matrice \tilde{A}_h est contrainte par (2.23) et (2.24).

- Règle de mise à jour de \tilde{S}_{ha}

$$[\tilde{S}_{ha}]_{p,n_h} \leftarrow [\tilde{S}_{ha}]_{p,n_h} \times \left(\frac{\alpha [\tilde{A}_{ah}^T X_h]_{p,n_h} + 2 \alpha [\tilde{S}_{ha}]_{p,n_h} \times [\tilde{A}_{hb}^T X_h]_{(pp),n_h} + \alpha \sum_{j=1, j \neq p}^M [\tilde{S}_{ha}]_{j,n_h} \times [\tilde{A}_{hb}^T X_h]_{(jp),n_h}}{D_{hp n_h} + \varepsilon} \right), \quad (2.53)$$

$$[\tilde{S}_{hb}]_{(jp),n_h} \leftarrow [\tilde{S}_{ha}]_{j,n_h} \times [\tilde{S}_{ha}]_{p,n_h}. \quad (2.54)$$

Les règles de mise à jour multiplicatives finales pour les entités multispectrales sont :

- Règle de mise à jour de \tilde{A}_m

$$\tilde{A}_m \leftarrow \tilde{A}_m \odot ((\beta X_m S_m^T + \gamma D \tilde{A}_h) \oslash (\beta \tilde{A}_m \tilde{S}_m \tilde{S}_m^T + \gamma D D^T \tilde{A}_m + \varepsilon)). \quad (2.55)$$

En plus de cette règle de mise à jour, la matrice \tilde{A}_m est contrainte par (2.29) et (2.30).

- Règle de mise à jour de \tilde{S}_{ma}

$$[\tilde{S}_{ma}]_{p,n_m} \leftarrow [\tilde{S}_{ma}]_{p,n_m} \times \left(\frac{\beta [\tilde{A}_{am}^T X_m]_{p,n_m} + 2 \beta [\tilde{S}_{ma}]_{p,n_m} \times [\tilde{A}_{mb}^T X_m]_{(pp),n_m} + \beta \sum_{j=1, j \neq p}^M [\tilde{S}_{ma}]_{j,n_m} \times [\tilde{A}_{bm}^T X_m]_{(jp),n_m}}{D_{hp n_h} + \varepsilon} \right), \quad (2.56)$$

$$[\tilde{S}_{mb}]_{(jp),n_m} \leftarrow [\tilde{S}_{ma}]_{j,n_m} \times [\tilde{S}_{ma}]_{p,n_m}. \quad (2.57)$$

Par rapport aux approches précédentes, l'approche décrite dans cette section optimise un nouveau critère qui permet une mise à jour "conjointe" des variables hyperspectrales et multispectrales. Les mises à jour des variables $[\tilde{S}_{ha}]_{p,n_h}$, $[\tilde{S}_{hb}]_{(jp),n_h}$, $[\tilde{S}_{ma}]_{p,n_m}$ et $[\tilde{S}_{mb}]_{(jp),n_m}$ restent inchangées par rapport à la première approche HMF-LQNMF, cependant les mises à jour des variables \tilde{A}_h et \tilde{A}_m diffèrent de celles de la première approche, du fait de la présence du critère conjoint entre les variables hyperspectrales et multispectrales.

L'intérêt de proposer cette méthode (extension de l'approche HMF-LQNMF) est d'évaluer l'apport du critère conjoint dans le processus de fusion sur la qualité des données obtenues. Les performances de cette méthode sont données dans le chapitre suivant.

2.3.3. Deuxième méthode proposée

Lorsque le modèle de mélange n'est pas connu à l'avance, il est difficile de choisir la technique de démixage à utiliser (LSU ou LQSU). Dans cette section, une nouvelle méthode de multisharpening "local" des données hyperspectrales est proposée : Local Hyperspectral Data Multi-Sharpning Based on Linear/Linear-Quadratic NMF by Integrating Lidar Data (Local- HMF-LQNMF), basée sur la NMF Linéaire et Linéaire-Quadratique Multiplicative en intégrant des données LIDAR. Cette méthode intègre un modèle numérique de surface (Digital Surface Model (DSM)) obtenu à partir de données LIDAR. Ces données DSM sont utilisées pour déterminer les élévations d'objets, et ainsi détecter le modèle de mélange (linéaire ou linéaire-quadratique) présent dans la zone considérée.

Le Lidar (acronyme anglais de Light Detection And Ranging, détection et télémétrie par ondes lumineuses) [201] est une technique de télédétection optique qui utilise la lumière laser en vue d'un échantillonnage dense de la surface de la Terre, et produit des mesures d'une grande précision. Le lidar est un capteur optique actif aéroporté qui fonctionne avec un système de multi-échos, où une source laser balaye très rapidement la surface terrestre. Des impulsions laser sont alors interceptées par la végétation, les bâtiments et le sol, et sont réfléchies en direction du capteur qui détecte l'intensité et le temps de retour du signal, donnant ainsi une description plus approfondie de la topographie terrestre, de la végétation

et du milieu urbain. Ce temps de retour dépend de l'altitude du point d'impact, c'est pourquoi il est possible d'estimer les hauteurs relatives entre deux points. Le lidar fournit deux types de modèles d'altitude, le modèle de surface numérique (DSM) et le modèle numérique de terrain (MNT).

Dans la méthode Local-HMF-LQNMf, la nature du modèle de mélange "local" est détectée en utilisant la variance locale des élévations d'objets obtenues à partir des données DSM. Les images hyperspectrale et multispectrale sont alors explorées à l'aide de petites zones. Dans chaque zone, la variance des élévations d'objets est calculée à partir des données DSM de cette même zone. Cette variance est ensuite comparée à un seuil afin de déterminer la technique de démixage spectral adéquate à utiliser dans la zone considérée pour démixer "localement" et "indépendamment" les données hyperspectrale et multispectrale locales, en utilisant l'approche de démixage adéquate. Les informations spectrale et spatiale obtenues, extraites respectivement des images hyperspectrale et multispectrale sont ensuite recombinaées, selon le modèle de mélange sélectionné, afin de réaliser la fusion dans la zone considérée.

L'originalité de cette approche proposée réside dans l'intégration du modèle numérique de surface (DSM) obtenu à partir de données LIDAR pour détecter automatiquement la nature du modèle de mélange local. À partir des données DSM nous calculons la variance des élévations d'objets dans chaque zone de l'image considérée, lorsque la valeur de cette variance est inférieure à un seuil donné cela signifie que les données DSM présentent de faibles variations d'élévations, dans ce cas le modèle de mélange considéré est le modèle linéaire. Cependant lorsque la valeur de cette variance est supérieure au seuil, cela signifie que les données DSM présentent de grandes variations d'élévations, le modèle de mélange considéré dans ce cas est le modèle linéaire-quadratique.

Il convient de noter ici qu'il existe d'autres méthodes de la littérature dans lesquelles les données DSM sont utilisées pour fournir des informations supplémentaires à l'information spectrale des données hyperspectrales [202-204], contrairement à l'approche proposée ici dans laquelle ces données DSM sont utilisées pour améliorer la résolution spatiale des données hyperspectrales à l'aide de données multispectrales.

Lorsque le modèle de mélange local est linéaire, chaque vecteur spectral associé à un pixel dans une zone locale d'une image de télédétection est supposé être un mélange linéaire des spectres d'endmembers dans le pixel.

Pour rappel, dans le modèle de mélange linéaire, le spectre de réflectance non-négatif x_i (vecteur colonne de taille L), du pixel i de l'image locale est donné par [8] :

$$x_i = \sum_{j=1}^M a_j(i)s_j, \quad (2.58)$$

$$\text{avec } \begin{cases} a_j(i), s_j \geq 0, & j = 1 \dots M \\ \sum_{j=1}^M a_j(i) = 1, \end{cases} \quad (2.59)$$

Le modèle linéaire local (2.58) peut être écrit sous forme matricielle comme suit (pour P pixels dans une zone locale, avec $P \geq 2$)

$$X = AS. \quad (2.60)$$

Maintenant, si le modèle de mélange local est linéaire-quadratique, le modèle ci-dessus (2.58) est remplacé par (2.1). Comme ci-dessus, le modèle linéaire-quadratique local peut être écrit sous forme matricielle, et la forme matricielle (2.60) du modèle linéaire est ainsi remplacée par (2.3) [10].

Notons ici, $X_{h_{local}} \in R_+^{P_{h_{local}} \times L_h}$ (respectivement $X_{m_{local}} \in R_+^{P_{m_{local}} \times L_m}$) la matrice non-négative locale contenant, dans chacun de ses vecteurs colonnes, une bande spectrale corrigée radiométriquement et géométriquement de l'image hyperspectrale locale à faible résolution spatiale (respectivement de l'image multispectrale locale à haute résolution spatiale). L_h (respectivement L_m) est le nombre de bandes spectrales de l'image hyperspectrale (respectivement multispectrale). $P_{h_{local}}$ (respectivement $P_{m_{local}}$) indique le nombre de pixels de l'image hyperspectrale locale (respectivement multispectrale locale).

Par conséquent, les matrices $X_{h_{local}}$ et $X_{m_{local}}$ ci-dessus, qui correspondent aux images hyperspectrale/multispectrale locales, peuvent être écrites sous forme de matrice comme suit :

$$\begin{cases} X_{h_{local}} = A_{h_{local}} S_{h_{local}} \\ X_{m_{local}} = A_{m_{local}} S_{m_{local}} \end{cases}, \text{ lorsque le modèle de mélange local est linéaire,} \quad (2.61)$$

ou

$$\begin{cases} X_{h_{local}} = A_{ha_{local}} S_{ha_{local}} + A_{hb_{local}} S_{hb_{local}} \\ X_{m_{local}} = A_{ma_{local}} S_{ma_{local}} + A_{mb_{local}} S_{mb_{local}} \end{cases}, \text{ lorsque le modèle de mélange local} \quad (2.62)$$

est linéaire-quadratique.

Lorsque le modèle de mélange local est linéaire, les processus locaux de démixage entraînent l'estimation des ensembles $\tilde{S}_{h_{local}}$ des spectres d'endmembers hyperspectraux locaux (un ensemble par zone locale) et l'estimation des ensembles $\tilde{A}_{m_{local}}$ des fractions d'abondances locales à haute résolution spatiale. Dans le cas contraire, lorsque le modèle de mélange local est linéaire-quadratique, les processus locaux de démixage entraînent l'estimation des ensembles $\tilde{S}_{ha_{local}}$ et $\tilde{S}_{hb_{local}}$ des spectres d'endmembers et pseudo-endmembers hyperspectraux locaux et l'estimation des ensembles $\tilde{A}_{ma_{local}}$ et $\tilde{A}_{mb_{local}}$ des fractions d'abondances linéaires et quadratiques locales à haute résolution spatiale. Les processus de démixage utilisés sont les mêmes que ceux décrits précédemment.

Les informations spectrales et spatiales locales extraites des images hyperspectrale/multispectrale locales sont ensuite recombinaées dans la zone considérée, selon le modèle de mélange sélectionné. L'image hyperspectrale locale $X_{f_{local}}$ à haute résolution spatiale non-observable est ensuite obtenue comme suit :

$$X_{f_{local}} = \tilde{A}_{m_{local}} \tilde{S}_{h_{local}}, \text{ lorsque le modèle de mélange local est linéaire,} \quad (2.63)$$

ou

$$X_{f_{local}} = \tilde{A}_{ma_{local}} \tilde{S}_{ha_{local}} + \tilde{A}_{mb_{local}} \tilde{S}_{hb_{local}}, \text{ lorsque le modèle de mélange local} \quad (2.64)$$

est linéaire-quadratique.

L'intérêt de cette méthode est d'évaluer les performances d'une approche de multisharpening local, dans laquelle les images sont considérées comme étant un ensemble d'imagettes, auxquelles nous appliquons le processus de démixage/fusion suivant le modèle de mélange détecté dans chaque imagette. Par rapport aux méthodes de fusion linéaire et linéaire-quadratique basées sur la NMF, qui sont utilisées sur l'ensemble des données,

l'approche locale proposée s'avère très attrayante pour le multisharpening des données hyperspectrales à faible résolution spatiale, à condition de disposer des données DSM de la scène imagée.

2.4. Conclusion

Dans ce chapitre, nous avons présenté les différentes méthodes de multisharpening proposées dans le cadre de cette thèse pour résoudre notre problème, à savoir l'amélioration de la résolution spatiale des images hyperspectrales de milieux urbains dans lesquelles le modèle de mélange linéaire-quadratique est considéré. Cinq approches ont été développées pour résoudre notre problème. Ces approches utilisent des techniques de démixage spectral linéaire-quadratique LQSU basées sur la NMF Linéaire-Quadratique Multiplicative. Les performances de ces méthodes sont présentées et comparées dans le chapitre suivant.

Chapitre 3 : Tests et performances

Sommaire

3.1. Introduction	126
3.2. Protocoles de tests	126
3.2.1. Données testées.....	126
3.2.1.1. Données synthétiques	126
3.2.1.2. Données réelles.....	129
3.2.2. Initialisation des algorithmes	129
3.2.3. Critères de performances	131
3.3. Résultats et discussion.....	134
3.3.1. Performances de l'approche HMF-LQNMF	135
3.3.1.1. Résultats avec les données synthétiques.....	135
3.3.1.2. Résultats avec les données réelles	147
3.3.2. Comparaison des performances des méthodes proposées	150
3.3.2.1. Résultats avec les données synthétiques.....	151
3.3.2.2. Résultats avec les données réelles	157
3.4. Conclusion.....	159

3.1. Introduction

Dans ce chapitre, nous présentons les performances des différentes méthodes décrites dans le chapitre précédent ainsi qu'un comparatif entre celles-ci et des méthodes linéaires de la littérature. Les résultats présentés sont obtenus à partir de tests réalisés sur des données synthétiques générées à partir de spectres réels issus de bibliothèques spectrales, ainsi que sur des données réelles.

Nous commençons par présenter dans la première section, les différents types de données testées (création de nos données synthétiques et description des données réelles utilisées), puis nous décrivons la procédure d'initialisation de nos algorithmes, ainsi que les critères de performances utilisés pour évaluer les performances des méthodes. Dans la section suivante, nous présentons les résultats obtenus à partir des tests effectués sur nos données synthétiques et réelles, ainsi qu'une comparaison des performances des méthodes proposées.

3.2. Protocoles de tests

3.2.1. Données testées

3.2.1.1. Données synthétiques

Les performances de nos approches proposées sont évaluées sur différents ensembles d'images synthétiques générées comme suit :

a) Premier jeu de données synthétiques

Ce premier jeu de données contient deux ensembles d'images synthétiques générées de la manière suivante : deux ensembles de huit spectres hyperspectraux sont sélectionnés dans des bibliothèques spectrales, avec des mesures effectuées de 0,4 à 2,5 μm . Le premier ensemble contient huit spectres d'endmembers choisis aléatoirement dans la bibliothèque spectrale compilée par United States Geological Survey (USGS) [118]. Le deuxième ensemble contient huit spectres de matériaux utilisés dans les zones urbaines choisis aléatoirement dans la bibliothèque spectrale compilée par l'Université Johns Hopkins (JHU) [143]. A partir de ces deux ensembles de spectres hyperspectraux, deux autres ensembles de huit spectres d'endmembers multispectraux sont créés en calculant simplement la moyenne des échantillons de ces derniers spectres hyperspectraux sur les domaines de longueurs d'ondes utilisés dans les bandes Landsat TM 1-5 et 7 (c'est-à-dire 0.45-0.52, 0.52-0.60, 0.63-0.69,

0.76-0.90, 1.55-1.75, et 2.08-2.35 μm). Ensuite, ces spectres hyperspectraux et multispectraux sont utilisés pour produire deux ensembles d'images synthétiques. Chaque ensemble d'images correspond à l'un des deux ensembles de spectres ci-dessus et contient deux sous-ensembles d'images. Le premier sous-ensemble d'images est créé selon le modèle de mélange linéaire, et le second sous-ensemble est généré selon le modèle de mélange linéaire-quadratique.

Notons ici que les modèles de mélanges linéaire et linéaire-quadratique sont considérés pour évaluer les performances des méthodes linéaires et linéaire-quadratiques utilisées lorsque ces méthodes sont appliquées sans aucune information sur la nature du mélange de données.

Chaque sous-ensemble du premier ensemble contient : une image hyperspectrale de 200×200 pixels à haute résolution spectrale/haute résolution spatiale (utilisée comme image de référence), une image hyperspectrale de 100×100 pixels à haute résolution spectrale/faible résolution spatiale et une image multispectrale de 200×200 pixels à haute résolution spatiale/faible résolution spectrale. Dans le deuxième ensemble, chaque sous-ensemble contient : la même image hyperspectrale de référence à haute résolution spectrale/haute résolution spatiale de 200×200 pixels, une image hyperspectrale à haute résolution spectrale/faible résolution spatiale de 50×50 pixels et une image multispectrale haute résolution spatiale/faible résolution spectrale de 200×200 pixels. Chaque image hyperspectrale dans chaque ensemble est générée avec 184 bandes spectrales, tandis que chaque image multispectrale est générée avec 6 bandes spectrales.

Les fractions d'abondances linéaires des images hyperspectrale et multispectrale à haute résolution spatiale sont créées à partir d'une classification réelle de la couverture terrestre, avec huit classes, en faisant la moyenne des valeurs de classification des pixels sur une fenêtre glissante de 2×2 pixels sans chevauchement afin de créer des pixels mixtes. Les fractions d'abondances linéaires des images hyperspectrales à haute résolution spectrale/faible résolution spatiale sont créées par sous-échantillonnage des fractions d'abondances linéaires à haute résolution ci-dessus. Le processus de sous-échantillonnage est effectué au moyen de la technique d'interpolation spatiale des k plus proches voisins et en considérant, respectivement, dans les premier et deuxième ensembles d'images, deux facteurs d'échelle (2 et 4) entre les images hyperspectrale et multispectrale considérées. Les fractions d'abondances quadratiques sont générées à partir des abondances linéaires, en utilisant le modèle de Fan [131].

b) Deuxième jeu de données synthétiques

Dans ce deuxième jeu, les données synthétiques sont générées à partir d'une image hyperspectrale réelle, d'une vérité terrain associée et de données DSM réelles (figure 3.1) [202]. Ces données synthétiques sont générées à partir d'une image hyperspectrale avec 144 bandes spectrales dans la région de 0.40-2.50 μm , d'une résolution spatiale de 2.5 m, de 60×380 pixels. Une classification réelle avec 15 classes est aussi utilisée pour générer ces données synthétiques.

Tous les pixels de cette image réelle hyperspectrale sont classés en utilisant la vérité terrain. La fraction de pixels dans une classe donnée, sur une petite sous-zone spatiale, donne les coefficients d'abondances linéaires de cette classe pour un seul pixel mélangé de notre image synthétique à haute résolution spatiale. Les fractions d'abondances à faible résolution spatiale (pour créer les images hyperspectrales à faible résolution spatiale), sont créées par sous-échantillonnage (en utilisant la méthode d'interpolation des k plus proches voisins) des fractions d'abondances linéaires à haute résolution spatiale. Les spectres d'endmembers hyperspectraux et les coefficients d'abondances à faible résolution spatiale sont utilisés (encore, selon chaque modèle de mélange local (se référer au chapitre 2 de cette seconde partie du manuscrit pour plus de détails)) pour générer l'image hyperspectrale à faible résolution spatiale. En outre, uniquement dans les zones où les données DSM présentent de grandes variations d'élévations, le modèle de Fan [131] est utilisé pour créer des coefficients d'abondances quadratiques à haute résolution spatiale.



Figure 3.1 : Image réelle hyperspectrale associée aux données DSM déduites du LIDAR [202].

La vérité terrain est également utilisée pour générer les spectres d'endmembers hyperspectraux, en faisant la moyenne des spectres dans chaque classe. Par la suite, les spectres d'endmembers hyperspectraux et les coefficients d'abondances à haute résolution spatiale sont utilisés pour générer (selon chaque modèle de mélange local) l'image hyperspectrale haute résolution spatiale de référence. À partir des spectres d'endmembers hyperspectraux, les spectres d'endmembers multispectraux sont créés en faisant simplement la moyenne des échantillons de ces derniers spectres hyperspectraux sur les domaines de longueurs d'ondes utilisés dans les bandes Landsat TM 1-5 et 7. Ces spectres multispectraux sont utilisés, avec les coefficients d'abondances à haute résolution spatiale (également selon chaque modèle de mélange local) pour générer l'image multispectrale à haute résolution spatiale.

Notons ici que les données DSM sont également utilisées pour détecter localement la nature du modèle de mélange lors de l'exécution de la fusion d'image hyperspectrale à faible résolution spatiale avec l'image multispectrale à haute résolution spatiale.

3.2.1.2. Données réelles

Dans cette thèse, des données réelles sont également utilisées pour tester les performances des méthodes proposées. Ces données réelles (radiométriquement corrigées et géométriquement recalées), acquises le même jour (3 mars 2003) et en même temps, couvrent une partie de la zone urbaine d'Oran, en Algérie. L'image hyperspectrale à haute résolution spectrale/faible résolution spatiale provient du capteur Hyperion Earth Observing-1 (EO-1). Cette image a une résolution spatiale de 30 m, contient 125 bandes spectrales (après retrait, à partir du cube de données d'origine de 242 bandes spectrales, les bandes spectrales à faible rapport signal/bruit ainsi que les bandes spectrales non-calibrées et chevauchantes). Deux images multispectrales (images multispectrales pansharpened) sont utilisées. La première est acquise par le capteur Landsat Enhanced Thematic Mapper plus (ETM+), se caractérise par 6 bandes spectrales et une résolution spatiale de 15 m. La seconde est acquise par le capteur EO-1 Advanced Land Imager (ALI), avec une résolution spatiale de 10 m, contient 9 bandes spectrales.

3.2.2. Initialisation des algorithmes

Les méthodes basées sur la LQNMF, comme les méthodes basées sur la NMF linéaire standard, ne garantissent pas de fournir une solution unique et leurs points de convergence

peuvent dépendre de leurs initialisations. Par conséquent, et afin d'éviter l'initialisation aléatoire des méthodes, les spectres d'endmembers hyperspectraux initiaux estimés $\widetilde{S}_{ha}^{(0)}$ sont calculés par la méthode SISAL [101], qui est une des méthodes les plus avancées pour l'extraction des spectres d'endmembers, permettant ainsi une meilleure initialisation de ces spectres. La méthode SISAL requiert de connaître le nombre M d'endmembers. Ce nombre peut être déterminé automatiquement en utilisant la méthode décrite dans [140]. Les pseudo-spectres hyperspectraux initiaux estimés $\widetilde{S}_{hb}^{(0)}$ sont déduits de la matrice initiale $\widetilde{S}_{ha}^{(0)}$ en utilisant la multiplication élément par élément.

Ensuite, les fractions d'abondances linéaires initiales estimées à faible résolution spatiale $\widetilde{A}_{ha}^{(0)}$ sont déduites de l'image hyperspectrale X_h et de la matrice initiale estimée $\widetilde{S}_{ha}^{(0)}$, au moyen de la méthode FCLS [105] (appliquée séparément à chaque pixel de l'image hyperspectrale). De la matrice $\widetilde{A}_{ha}^{(0)}$, les fractions d'abondances quadratiques à faible résolution spatiale initiales estimées $\widetilde{A}_{hb}^{(0)}$ sont déduites en utilisant le modèle de Fan [131] avec les contraintes afférentes comme suit : pour un pixel hyperspectral donné i_h , chaque élément $\widetilde{a}_{h,j,l}^{(0)}(i_h)$ (avec $j \leq l$) de la matrice $\widetilde{A}_{hb}^{(0)}$ est fixé à $\min\{0.5, \widetilde{a}_{h_j}^{(0)}(i_h) \cdot \widetilde{a}_{h_l}^{(0)}(i_h)\}$, où $\widetilde{a}_{h_j}^{(0)}(i_h)$ et $\widetilde{a}_{h_l}^{(0)}(i_h)$ sont deux éléments de la matrice $\widetilde{A}_{ha}^{(0)}$. Les spectres d'endmembers multispectraux initiaux estimés $\widetilde{S}_{ma}^{(0)}$ sont déduits des spectres d'endmembers hyperspectraux initiaux estimés $\widetilde{S}_{ha}^{(0)}$ en faisant la moyenne des échantillons de ces derniers spectres sur les domaines de longueurs d'ondes considérés dans l'image multispectrale. Les variables multispectrales restantes, c'est-à-dire $\widetilde{S}_{mb}^{(0)}$, $\widetilde{A}_{ma}^{(0)}$ et $\widetilde{A}_{mb}^{(0)}$ sont déduites de la même manière que les variables hyperspectrales initialisées ci-dessus.

L'initialisation interdépendante ci-dessus des variables hyperspectrales et multispectrales permet d'éviter une permutation possible entre les résultats des deux processus de démixage des images hyperspectrale et multispectrale considérées. En outre, la contrainte de somme-à-un, sur les fractions d'abondances linéaires à faible et haute résolution spatiale, permet d'éviter le problème connu du facteur d'échelle qui peut apparaître dans les résultats des deux processus de démixage.

3.2.3. Critères de performances

Dans cette section sont présentés les différents critères utilisés pour évaluer les performances de nos méthodes. L'évaluation est effectuée dans les domaines spectral et spatial. Pour les données synthétiques testées, les qualités spectrale et spatiale de l'image hyperspectrale fusionnée à haute résolution spectrale/haute résolution spatiale non-observable estimée sont évaluées en la comparant à l'image hyperspectrale de référence.

- Pour évaluer la qualité de la reconstruction spectrale, les critères de performances utilisés sont calculés entre chaque spectre dans l'image hyperspectrale de référence et son analogue dans l'image hyperspectrale fusionnée. Ces critères sont définis comme suit :

- **L'Angle Spectral (AS) (Spectral Angle Mapper (SAM)) [156]**

$$SAM_i = \arccos \left(\frac{\langle x_i, \tilde{x}_i \rangle}{\|x_i\|_2 \cdot \|\tilde{x}_i\|_2} \right), \quad (3.1)$$

avec $i = 1 \dots P$ (P nombre de pixels), où x_i et \tilde{x}_i sont respectivement le i -ème spectre de pixel de l'image de référence et de l'image fusionnée, $\langle x_i, \tilde{x}_i \rangle$ représente le produit scalaire et $\|x_i\|_2$ et $\|\tilde{x}_i\|_2$ représentent respectivement les normes de x_i et \tilde{x}_i .

- **L'Erreur Quadratique Moyenne Normalisée (EQMN) (Normalized Mean Square Error (NMSE _{λ}))**

$$NMSE_{\lambda_i} = \frac{\|x_i - \tilde{x}_i\|_2}{\|x_i\|_2}. \quad (3.2)$$

Une valeur plus petite de ces critères spectraux indique une meilleure reconstruction spectrale.

- Pour évaluer la qualité de la reconstruction spatiale, les critères spatiaux sont calculés entre chaque bande spectrale dans l'image hyperspectrale de référence et son analogue dans l'image hyperspectrale fusionnée. Ces critères sont définis comme suit :

- **L'Erreur Quadratique Moyenne Normalisée (EQMN) (Normalized Mean Square Error (NMSE _{s}))**

$$NMSE_{s_k} = \frac{\|X_{f_k} - \tilde{X}_{f_k}\|_2}{\|X_{f_k}\|_2}, \quad (3.3)$$

où X_{f_k} et \tilde{X}_{f_k} représentent respectivement la k -ième bande spectrale de l'image de référence et de l'image fusionnée.

- **L'Indice de Qualité d'Image Universel (Universal Image Quality Index (UIQI)) [205]**

$$Q(X_f, \tilde{X}_f) = \frac{4 \delta_{X_f \tilde{X}_f} \cdot \mu(X_f) \cdot \mu(\tilde{X}_f)}{(\sigma_{X_f}^2 + \sigma_{\tilde{X}_f}^2) (\mu(X_f)^2 + \mu(\tilde{X}_f)^2)}, \quad (3.4)$$

où le terme $\delta_{X_f \tilde{X}_f}$ représente la covariance entre l'image hyperspectrale de référence X_f et l'image hyperspectrale fusionnée \tilde{X}_f , $\sigma_{X_f}^2$ et $\sigma_{\tilde{X}_f}^2$ représentent respectivement la variance de X_f et \tilde{X}_f et $\mu(X_f)$, $\mu(\tilde{X}_f)$ représentent respectivement la moyenne des pixels de l'image de référence et de l'image fusionnée.

Ce critère est calculé pour chaque bande hyperspectrale, la valeur finale de ce dernier représente la moyenne des valeurs obtenues sur toutes les bandes hyperspectrales.

Cet indice de qualité permet de mesurer la similarité entre l'image hyperspectrale de référence et l'image fusionnée. La valeur du critère UIQI varie de -1 à 1. La valeur 1 correspond à la meilleure qualité de reconstruction spatiale.

- **Le rapport Signal / Bruit (Peak Signal to Noise Ratio (PSNR)) [156]**

$$PSNR_k = 20 \times \log_{10} \left(\frac{\max(X_{fk})}{RMSE_k} \right), \quad (3.5)$$

$$RMSE_k = \sqrt{\frac{1}{P} \sum_{i,j} (X_{fk} - \tilde{X}_{fk})^2}. \quad (3.6)$$

$RMSE_k$ pour Root Mean Square Error, où P représente le nombre de pixels de l'image hyperspectrale à haute résolution spatiale. Le PSNR est exprimé en décibel (dB), plus la valeur du $PSNR$ est élevée, meilleure est la qualité de la reconstruction spatiale.

- **Erreur Relative Globale Adimensionnelle de Synthèse (ERGAS) [206]**

$$ERGAS = \frac{100}{r} \times \sqrt{\frac{1}{L} \sum_{l=1}^L \left(\frac{RMSE_k}{\mu(X_{fk})} \right)^2}, \quad (3.7)$$

où r représente le rapport entre la résolution spatiale de l'image hyperspectrale à faible résolution spatiale et celle de l'image hyperspectrale fusionnée et L est le nombre de bandes de l'image hyperspectrale. Cet indice est capable de mesurer la distorsion spatiale globale entre deux images.

- Pour les tests avec des données réelles, un critère modifié de qualité sans référence (modified Quality with No Reference $mQNR$) est utilisé pour l'évaluation de la qualité de la reconstruction spectrale et spatiale. Partant du critère QNR [207] utilisé pour évaluer la qualité de reconstruction des méthodes de pansharpening, une version modifiée est proposée dans cette thèse afin de l'utiliser dans les procédés de multisharpening considérés. Ce critère spatial-spectral modifié est donné comme suit :

$$mQNR = (1 - D_\lambda)^\sigma (1 - D_s)^\rho, \quad (3.8)$$

où σ et ρ sont des exposants entiers (mis à 1 dans les tests effectués), et D_λ et D_s sont respectivement des indices de distorsions spectrale et spatiale. L'indice spectral est décrit comme suit:

$$D_\lambda = \sqrt[\omega]{\frac{1}{L_h(L_h-1)} \sum_{j=1}^{L_h} \sum_{r=1, r \neq j}^{L_h} \left| \text{UIQI}(\tilde{X}_{f_j}, \tilde{X}_{f_r}) - \text{UIQI}(X_{h_j}, X_{h_r}) \right|^\omega}, \quad (3.9)$$

où ω est un exposant entier positif (mis à 1 dans les tests effectués). X_{f_*} est une bande spectrale de l'image fusionnée. X_{h_*} est une bande spectrale de l'image hyperspectrale.

L'indice de distorsion spatiale D_s est calculé comme suit : pour chaque bande spectrale de l'image multispectrale, un sous-indice de distorsion spatiale est calculé en utilisant l'indice standard défini dans [207], entre la bande multispectrale considérée et les bandes hyperspectrales qui sont couvertes par la bande multispectrale considérée. L'indice final de distorsion spatiale D_s représente la moyenne des sous-indices calculés. Ces deux indices de distorsion utilisent l'indice de qualité image universel (UIQI) défini dans (3.4). Les indices $mQNR$, D_λ et D_s délivrent des valeurs comprises dans l'intervalle [0, 1]. Une valeur plus élevée du critère $mQNR$ indique une qualité de reconstruction spectrale-spatiale plus élevée. Une plus petite valeur de distorsion spatiale D_s (respectivement spectrale D_λ) indique une meilleure reconstruction spatiale (respectivement spectrale).

Notons que la comparaison des méthodes est réalisée sur la base des valeurs moyennes obtenues avec les critères cités ci-dessus.

3.3. Résultats et discussion

Les méthodes développées sont appliquées aux données définies dans la section 3.2.1. Le nombre maximum d'itérations utilisées dans chacune des deux boucles (boucles pour la mise à jour des variables hyperspectrales et multispectrales) des méthodes HMF-LQNMF, Multi-JCLQNMF et de la méthode Local-HMF-LQNMF est fixé à 10. Le même nombre est également considéré dans la méthode JHMF-LQNMF dans laquelle le paramètre α est fixé à 0.01. Dans la méthode CHMF-LQNMF, le nombre maximum d'itérations de la boucle externe (respectivement interne) est fixé à 3 (respectivement 10).

Dans cette dernière méthode nous nous contentons de ce nombre d'itérations pour la boucle externe, car selon [156] un nombre plus élevé semble donner des performances similaires, mais avec un coût de calcul plus important.

Dans les tests effectués, deux méthodes de fusion de la littérature basées sur la NMF linéaire sont également appliquées aux données considérées. La première est la méthode de Factorisation en Matrices Non-négatives Couplée (CNMF) [156], et la seconde est la méthode de Factorisation en Matrices Non-négatives Conjointe (JNMF) [12].

Les méthodes CNMF et JNMF sont utilisées dans deux scénarios. La différence entre ces deux derniers réside dans les tailles des matrices considérées dans le processus de fusion. Dans le premier (Sc. 1), seuls les spectres d'endmembers et les fractions d'abondances linéaires sont considérés (équations (2.4) et (2.6) de cette seconde partie du manuscrit), tandis que dans le deuxième scénario (Sc. 2), en plus des spectres d'endmembers et des fractions d'abondances linéaires, les spectres de pseudo-endmembers et les fractions d'abondances quadratiques sont considérés comme de nouveaux spectres d'endmember et de nouvelles fractions d'abondances linéaires (équations (2.4)- (2.7)). Ces deux scénarios sont considérés afin d'évaluer les performances de ces deux méthodes linéaires de la littérature lorsqu'elles sont appliquées sans aucune information sur la nature du mélange des données.

La CPU utilisée dans les expériences menées est un processeur Intel (R) Core (TM) i5 fonctionnant à 1,80 GHz, avec une capacité de mémoire de 4 Go.

Les coûts de calcul et les moyennes des critères spectraux et spatiaux des méthodes testées sont donnés dans les sections suivantes.

Il convient de noter ici que les coûts de calcul (pour tous les tests effectués) ne sont pas utilisés comme critères de comparaison. Ces coûts de calcul ne sont donnés qu'à titre indicatif du temps d'exécution de chaque méthode utilisée. En effet, il est difficile de comparer des méthodes construites différemment (avec des nombres différents de boucles utilisées), en n'utilisant que leurs coûts de calcul.

3.3.1. Performances de l'approche HMF-LQNMF

Dans cette section, nous comparons les performances de notre méthode de fusion HMF-LQNMF proposée en section 2.3.2.1 dans les deux configurations des données traitées (linéaire et linéaire-quadratique) avec les performances de la méthode CNMF et la méthode JNMF dans les deux scénarios. Les résultats obtenus dans cette section sont issus de tests réalisés sur des données synthétiques et réelles.

3.3.1.1. Résultats avec les données synthétiques

Dans cette section nous testons notre méthode ainsi que les deux méthodes linéaires de la littérature sur le premier jeu de données synthétiques (voir section 3.2.1.1(a)). Chacune de ces méthodes est initialisée comme décrit dans la section 3.2.2. Nous comparons donc ces méthodes dans quatre cas :

- Données générées selon le modèle de mélange linéaire avec une sélection aléatoire de spectres réels issus de la bibliothèque spectrale USGS, que nous nommons dataset 1.1.
- Données générées selon le modèle de mélange linéaire avec une sélection aléatoire de spectres réels de milieux urbains issus de la bibliothèque spectrale JHU, que nous nommons dataset 2.1.
- Données générées selon le modèle de mélange linéaire-quadratique avec une sélection aléatoire de spectres réels issus de la bibliothèque spectrale USGS, que nous nommons dataset 1.2.
- Données générées selon le modèle de mélange linéaire-quadratique avec une sélection aléatoire de spectres réels de milieux urbains issus de la bibliothèque spectrale JHU, que nous nommons dataset 2.2.

Les performances de notre méthode de fusion HMF-LQNMF ainsi que les performances obtenues avec la méthode CNMF et la méthode JNMF dans les deux scénarios (Sc. 1 et Sc. 2) sont présentés dans les tableaux ci-dessous.

Tableau 3.1 : Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 1.1.

			Méthodes de fusion basées sur le démixage spectral				HMF-LQNMF
			CNMF		JNMF		
			Sc. 1	Sc. 2	Sc. 1	Sc. 2	
Facteur d'échelle 2	Temps (sec)		25.10	36.06	3.13	6.45	9.51
	Critère	Valeur idéale					
	SAM (°)	0	1.88	5.80	1.58	1.70	<u>0.81</u>
	NMSE _λ (%)	0	3.51	12.12	2.94	6.18	<u>1.66</u>
	UIQI	1	0.9884	0.9534	0.9787	0.9753	<u>0.9980</u>
	NMSE _s (%)	0	3.98	11.88	5.95	7.70	<u>1.65</u>
	PSNR (dB)	∞	34.83	25.16	30.62	28.23	<u>42.05</u>
	ERGAS	0	4.99	8.75	6.18	7.29	<u>3.16</u>
Facteur d'échelle 4	Temps (sec)		5.40	17.31	2.06	5.18	8.50
	Critère	Valeur idéale					
	SAM (°)	0	3.78	5.79	3.33	3.39	<u>0.82</u>
	NMSE _λ (%)	0	7.18	12.14	6.14	8.33	<u>1.64</u>
	UIQI	1	0.9649	0.9533	0.9686	0.9647	<u>0.9980</u>
	NMSE _s (%)	0	7.43	11.92	7.17	8.72	<u>1.65</u>
	PSNR (dB)	∞	29.10	25.14	29.02	27.20	<u>42.06</u>
	ERGAS	0	6.77	8.77	6.78	7.78	<u>3.13</u>

Tableau 3.2 : Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 2.1.

			Méthodes de fusion basées sur le démixage spectral				
			CNMF		JNMF		HMF-LQNMF
			Sc. 1	Sc. 2	Sc. 1	Sc. 2	
Facteur d'échelle 2	Temps (sec)		13.59	31.09	1.89	2.74	5.29
	Critère	Valeur idéale					
	SAM (°)	0	1.33	1.09	0.84	0.97	<u>0.29</u>
	NMSE _λ (%)	0	2.53	2.11	1.73	8.08	<u>0.87</u>
	UIQI	1	0.9318	0.9727	0.9595	0.9508	<u>0.9989</u>
	NMSE _s (%)	0	3.78	3.04	4.62	9.34	<u>1.05</u>
	PSNR (dB)	∞	36.99	38.04	33.27	26.23	<u>45.76</u>
	ERGAS	0	9.18	7.95	9.45	13.56	<u>4.01</u>
Facteur d'échelle 4	Temps (sec)		13.16	30.42	2.68	5.31	10.43
	Critère	Valeur idéale					
	SAM (°)	0	1.43	1.16	1.70	1.78	<u>0.37</u>
	NMSE _λ (%)	0	2.91	2.41	3.47	8.52	<u>0.92</u>
	UIQI	1	0.9236	0.9702	0.9428	0.9335	<u>0.9982</u>
	NMSE _s (%)	0	42.02	3.35	5.60	10.02	<u>1.04</u>
	PSNR (dB)	∞	35.49	36.76	31.61	25.68	<u>41.63</u>
	ERGAS	0	19.15	16.60	20.81	28.42	<u>8.01</u>

Tableau 3.3 : Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 1.2.

			Méthodes de fusion basées sur le démixage spectral				
			CNMF		JNMF		HMF-LQNMF
			Sc. 1	Sc. 2	Sc. 1	Sc. 2	
Facteur d'échelle 2	Temps (sec)		7.30	22.86	1.60	2.98	6.07
	Critère	Valeur idéale					
	SAM (°)	0	3.31	4.68	1.68	1.71	<u>1.34</u>
	NMSE _λ (%)	0	6.16	9.36	<u>3.09</u>	5.97	3.22
	UIQI	1	0.9742	0.9687	0.9838	0.9815	<u>0.9967</u>
	NMSE _s (%)	0	6.26	9.25	5.37	7.12	<u>2.77</u>
	PSNR (dB)	∞	30.90	27.76	31.87	29.25	<u>38.52</u>
	ERGAS	0	3.63	4.43	3.39	3.99	<u>2.45</u>
Facteur d'échelle 4	Temps (sec)		6.49	17.35	2.71	5.19	8.82
	Critère	Valeur idéale					
	SAM (°)	0	3.31	4.97	3.08	3.06	<u>1.17</u>
	NMSE _λ (%)	0	6.24	9.78	5.67	7.54	<u>2.70</u>
	UIQI	1	0.9746	0.9677	0.9774	0.9752	<u>0.9965</u>
	NMSE _s (%)	0	6.40	9.74	6.34	7.69	<u>2.83</u>
	PSNR (dB)	∞	30.69	27.49	30.41	28.59	<u>37.48</u>
	ERGAS	0	7.33	9.04	7.36	8.28	<u>4.96</u>

Tableau 3.4 : Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 2.2.

			Méthodes de fusion basées sur le démixage spectral				
			CNMF		JNMF		HMF-LQNMF
			Sc. 1	Sc. 2	Sc. 1	Sc. 2	
Facteur d'échelle 2	Temps (sec)		17.82	38.12	1.23	3.14	5.31
	Critère	Valeur idéale					
	SAM (°)	0	1.34	1.11	1.03	1.09	0.73
	NMSE _λ (%)	0	2.62	2.23	2.70	8.40	3.18
	UIQI	1	0.9332	0.9726	0.9598	0.9498	0.9937
	NMSE _s (%)	0	3.82	3.13	5.23	1.00	3.46
	PSNR (dB)	∞	36.91	37.89	31.79	25.61	35.60
	ERGAS	0	9.08	7.96	9.56	13.84	6.45
Facteur d'échelle 4	Temps (sec)		12.87	35.03	2.40	4.91	10.58
	Critère	Valeur idéale					
	SAM (°)	0	1.35	1.13	1.83	1.90	0.47
	NMSE _λ (%)	0	2.86	2.50	3.91	8.66	1.84
	UIQI	1	0.9305	0.9707	0.9424	0.9328	0.9973
	NMSE _s (%)	0	4.14	3.41	5.87	10.33	2.10
	PSNR (dB)	∞	35.43	36.50	31.08	25.41	39.82
	ERGAS	0	9.32	8.23	10.40	14.30	5.35

Globalement, les tableaux ci-dessus (Tableaux 3.1-3.4) montrent que l'approche de fusion proposée offre de très bonnes fidélités spatiale et spectrale pour les images hyperspectrales fusionnées. Ces tableaux montrent aussi que notre méthode HMF-LQNMF proposée surpasse significativement les méthodes linéaires de la littérature testées (dans les deux scénarios) dans les deux configurations linéaire et linéaire-quadratique.

Il convient de noter ici que la supériorité de notre méthode dans la configuration linéaire-quadratique est assez attendue, car cette méthode est conçue pour le modèle de mélange linéaire-quadratique, ce qui n'est pas le cas des méthodes linéaires utilisées. En outre, nous nous attendons à ce que notre méthode fournisse d'assez bons résultats dans le cas de la configuration linéaire en annulant automatiquement les fractions d'abondances quadratiques estimées dans l'étape d'optimisation.

Les figures ci-dessous (Figure 3.2 - Figure 3.5) montrent la bande spectrale, dans la région de 0,815 μm de l'image hyperspectrale à haute résolution spatiale de référence, l'image hyperspectrale à faible résolution spatiale et les images hyperspectrales à haute résolution spatiale estimées par notre méthode HMF-LQNMF ainsi que les méthodes linéaires testées. Les figures représentent une bande spectrale des images considérées dans les deux

configurations (linéaire et linéaire-quadratique), avec les deux ensembles de spectres (spectres d'une sélection aléatoire issus de la bibliothèque spectrale USGS et spectres d'une sélection aléatoire de milieux urbains) et avec un facteur d'échelle entre les résolutions spatiales des données hyperspectrales et multispectrales égal à 4.

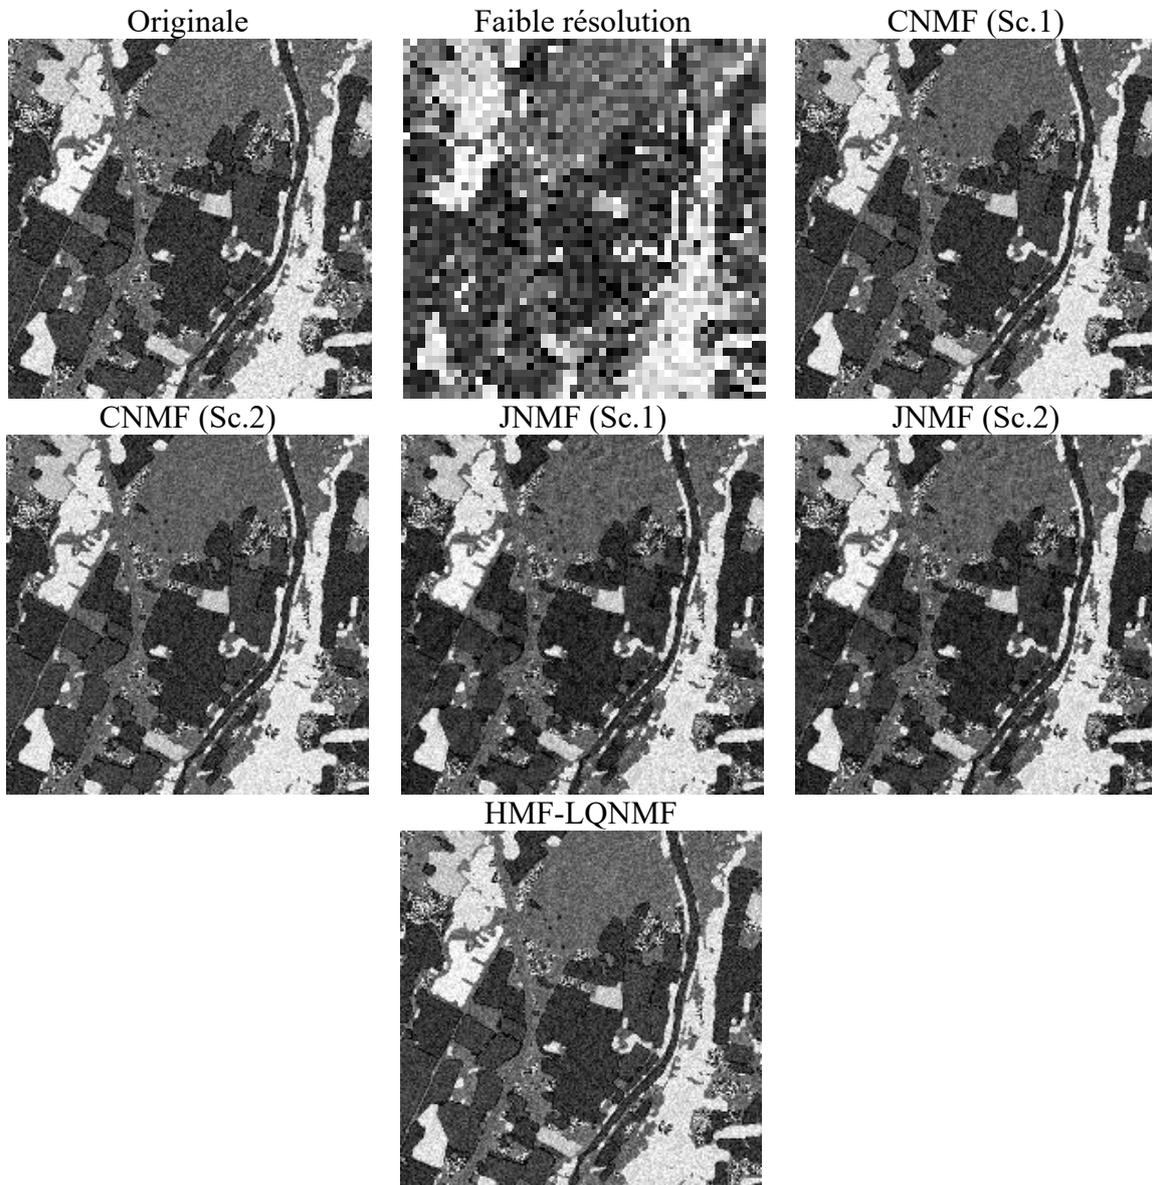


Figure 3.2 : Bande spectrale (dans la région de $0.815 \mu\text{m}$) de l'image hyperspectrale de référence (originale) à haute résolution spatiale, image hyperspectrale à faible résolution spatiale, images hyperspectrales à haute résolution spatiale fusionnée. - ensemble de données dataset 1.1, facteur d'échelle 4.

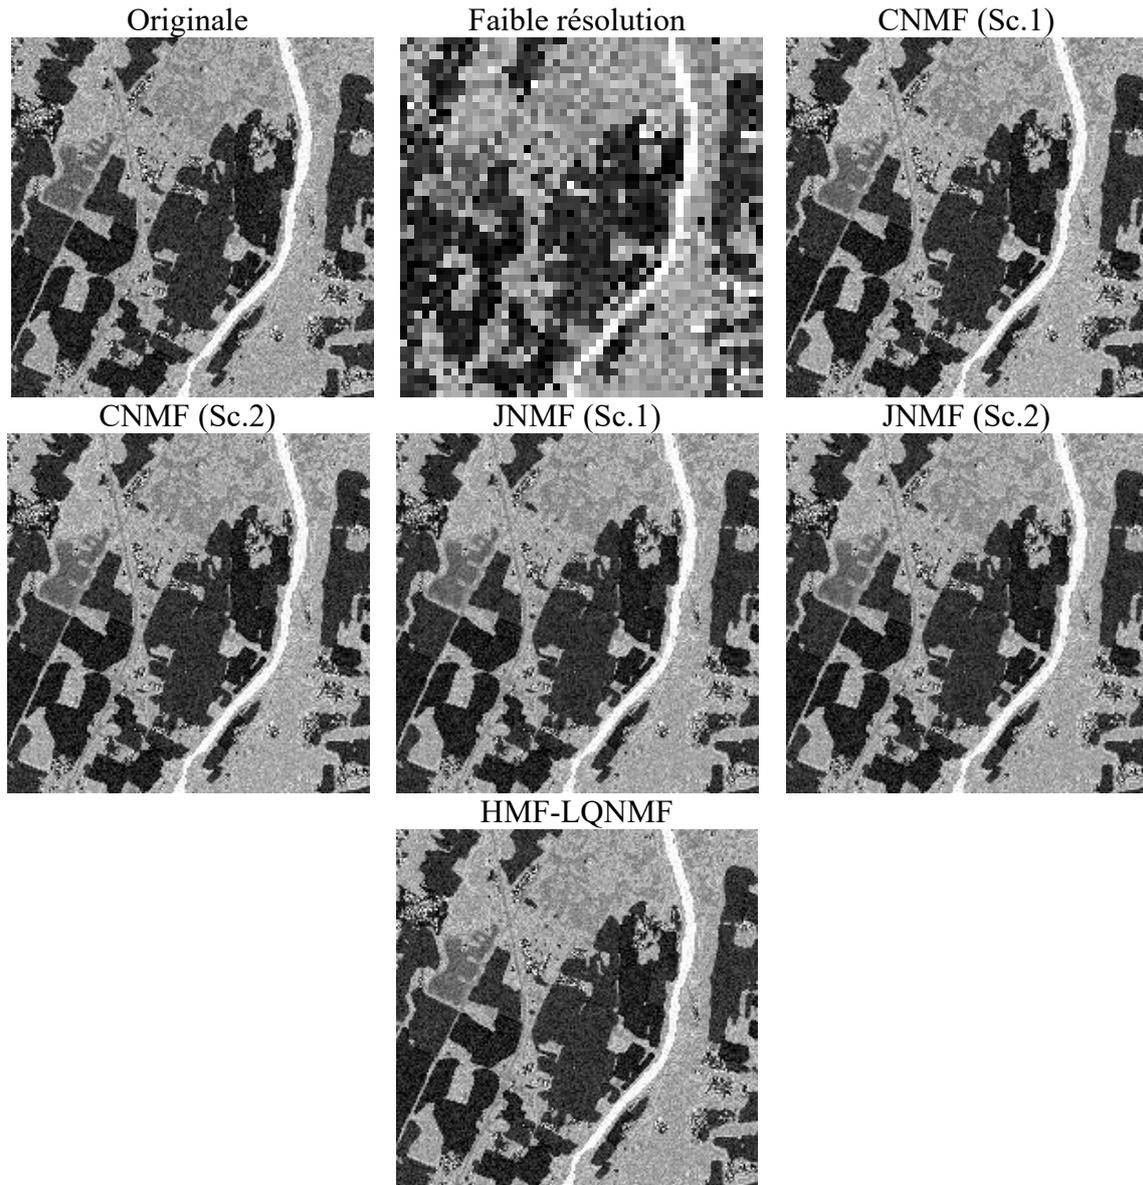


Figure 3.3 : Bande spectrale (dans la région de $0.815 \mu\text{m}$) de l'image hyperspectrale de référence (originale à haute résolution spatiale, image hyperspectrale à faible résolution spatiale, images hyperspectrales à haute résolution spatiale fusionnée. - ensemble de données dataset 2.1, facteur d'échelle 4.

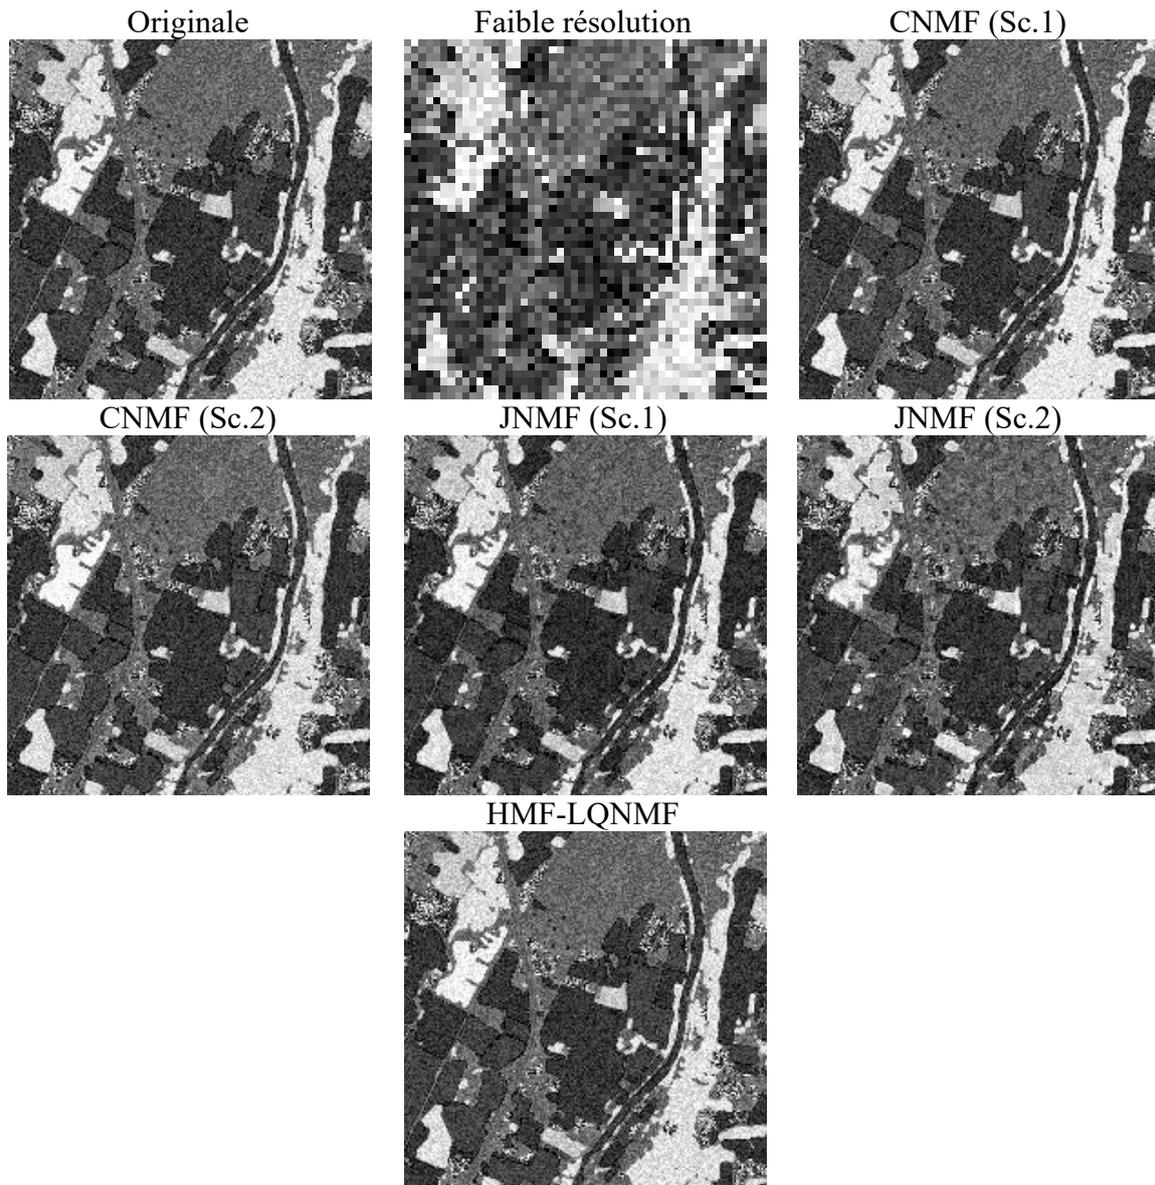


Figure 3.4 : Bande spectrale (dans la région de $0.815 \mu\text{m}$) de l'image hyperspectrale de référence (originale) à haute résolution spatiale, image hyperspectrale à faible résolution spatiale, images hyperspectrales à haute résolution spatiale fusionnée. - ensemble de données dataset 1.2, facteur d'échelle 4.

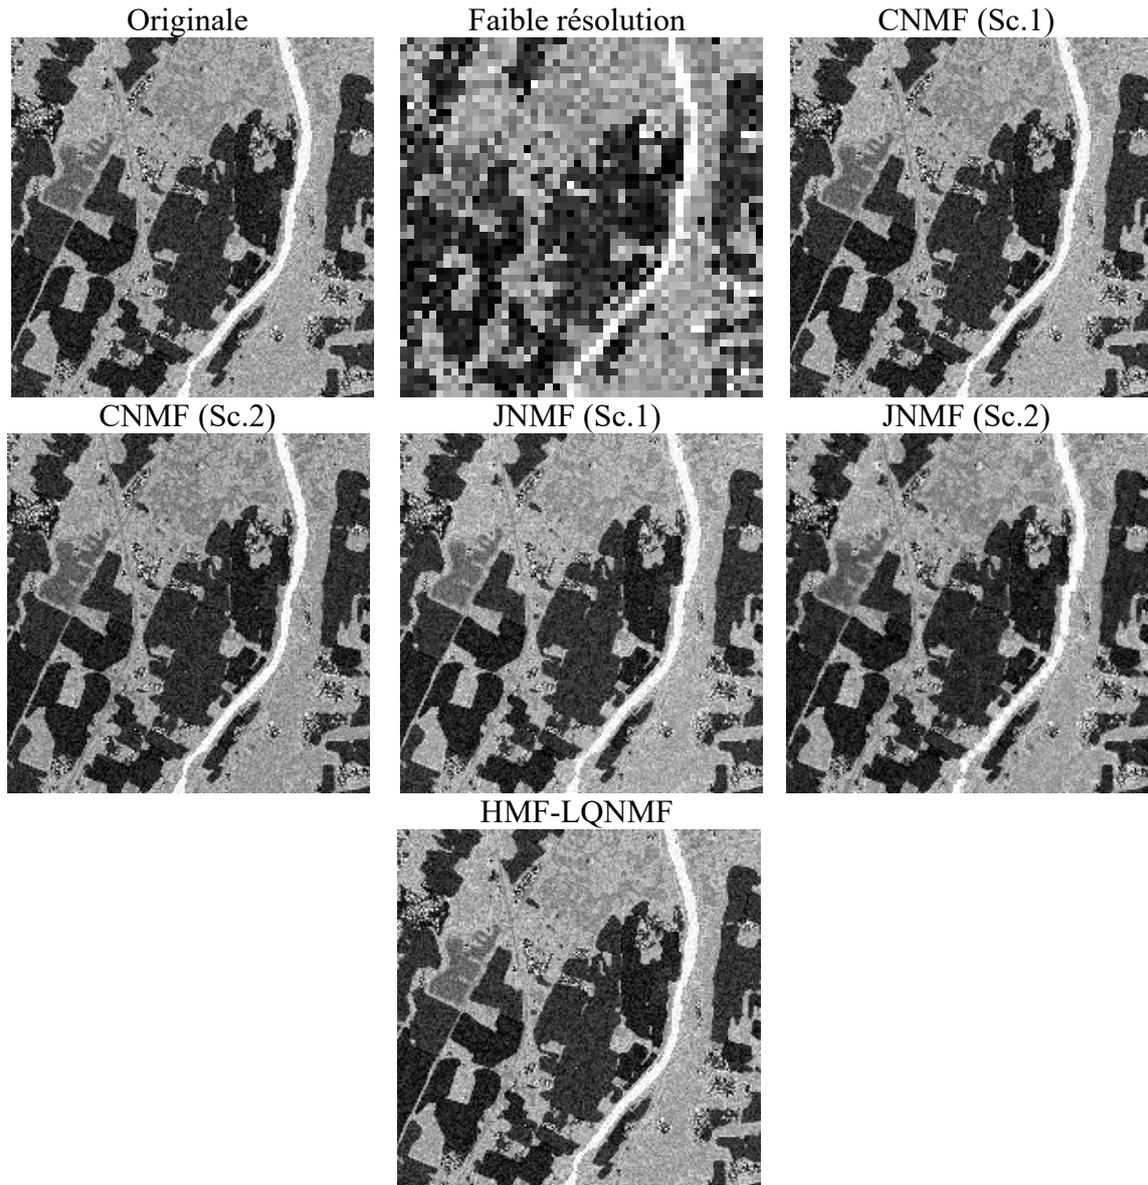


Figure 3.5 : Bande spectrale (dans la région de $0.815 \mu\text{m}$) de l'image hyperspectrale de référence (originale) à haute résolution spatiale, image hyperspectrale à faible résolution spatiale, images hyperspectrales à haute résolution spatiale fusionnée. - ensemble de données dataset 2.2, facteur d'échelle 4.

À partir de ces figures, il est difficile de déterminer les différences entre les bandes spectrales des images de référence et des images estimées avec une inspection visuelle. Par conséquent, pour une meilleure discrimination entre les méthodes testées, les figures suivantes (Figure 3.6 - Figure 3.9) montrent l'histogramme des valeurs du critère *SAM* pour tous les pixels et les valeurs du critère *PSNR* sur tous les pixels et pour toutes les régions de longueurs d'onde hyperspectrales, pour les données synthétiques utilisées dans les deux configurations (mélanges linéaire et linéaire-quadratique), avec un facteur d'échelle égal à 4.

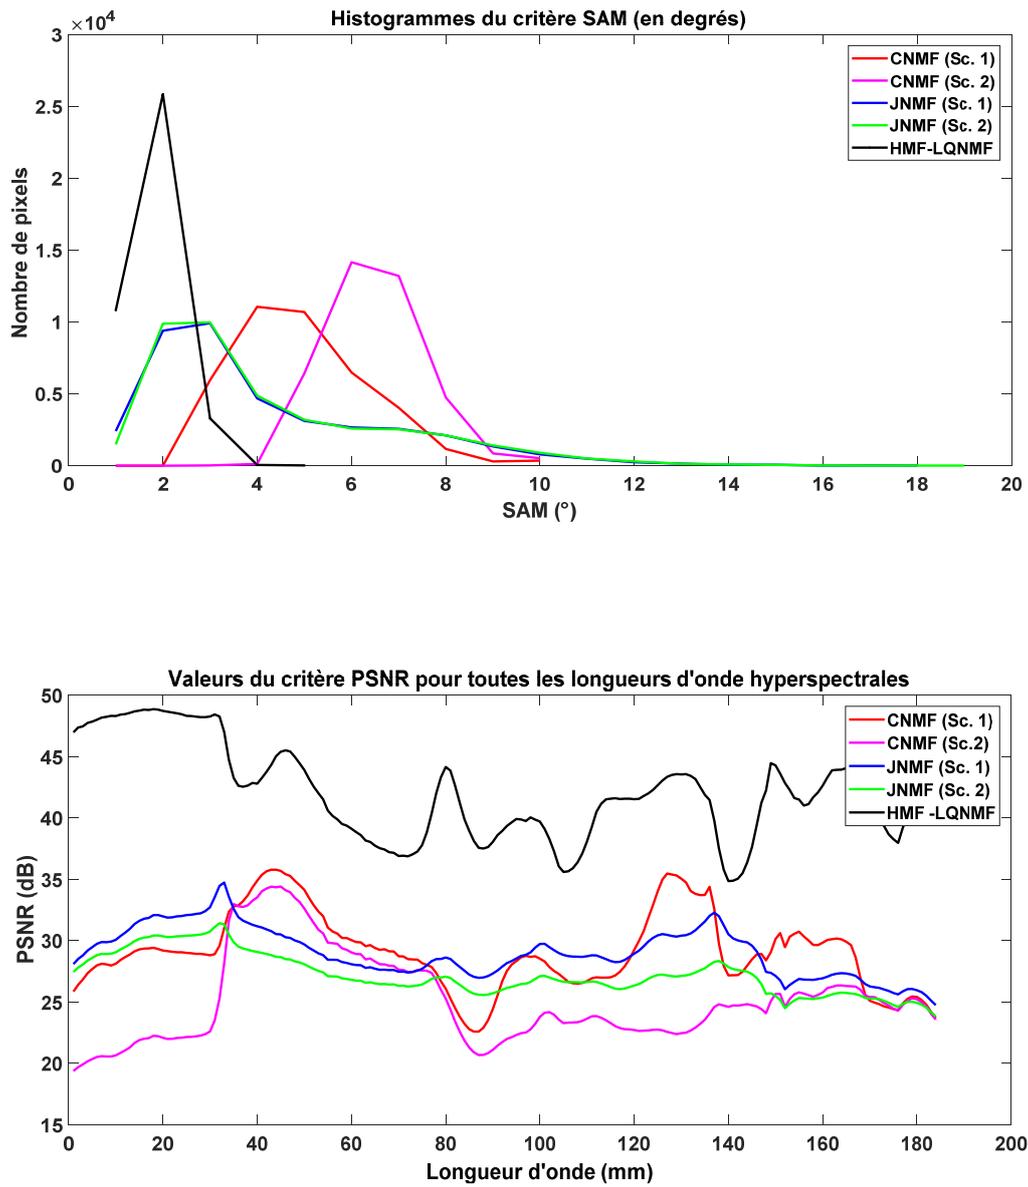


Figure 3.6 : Histogramme des valeurs du critère SAM (en degrés) et valeurs du critère PSNR (en décibels) - ensemble de données dataset 1.1, facteur d'échelle 4.

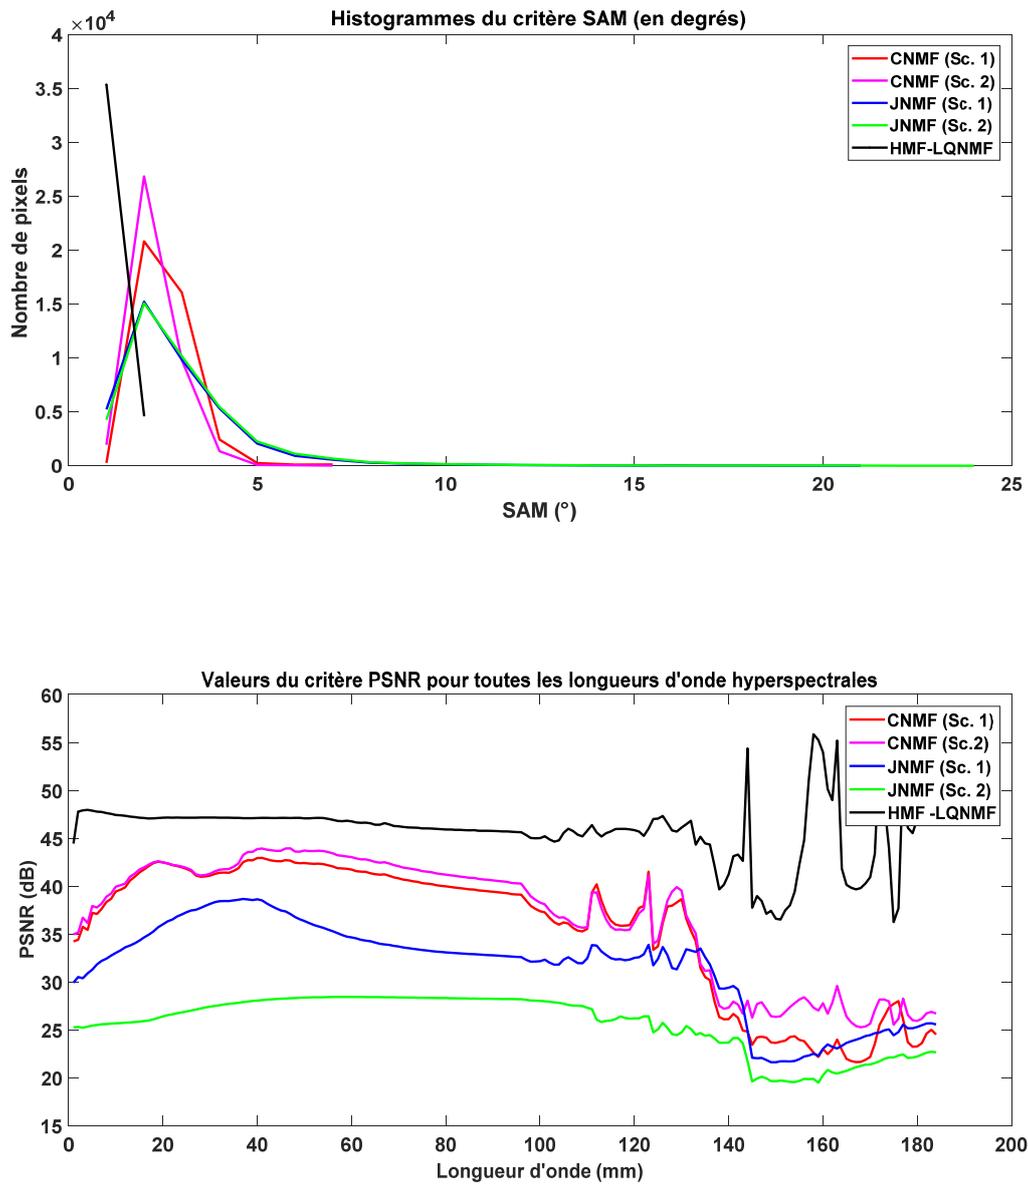


Figure 3.7 : Histogramme des valeurs du critère SAM (en degrés) et valeurs du critère PSNR (en décibels) - ensemble de données dataset 2.1, facteur d'échelle 4.

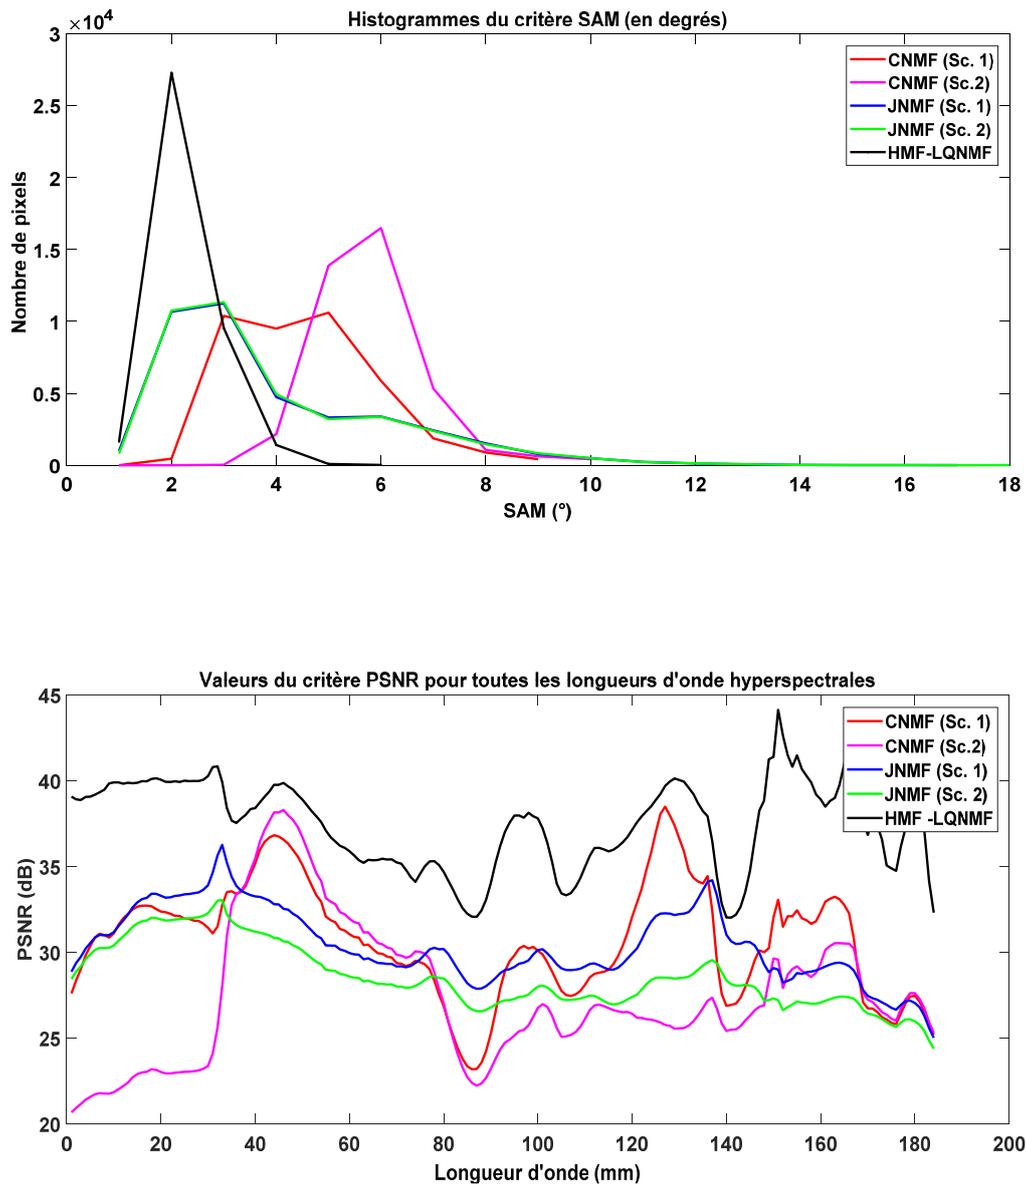


Figure 3.8 : Histogramme des valeurs du critère SAM (en degrés) et valeurs du critère PSNR (en décibels) - ensemble de données dataset 1.2, facteur d'échelle 4.

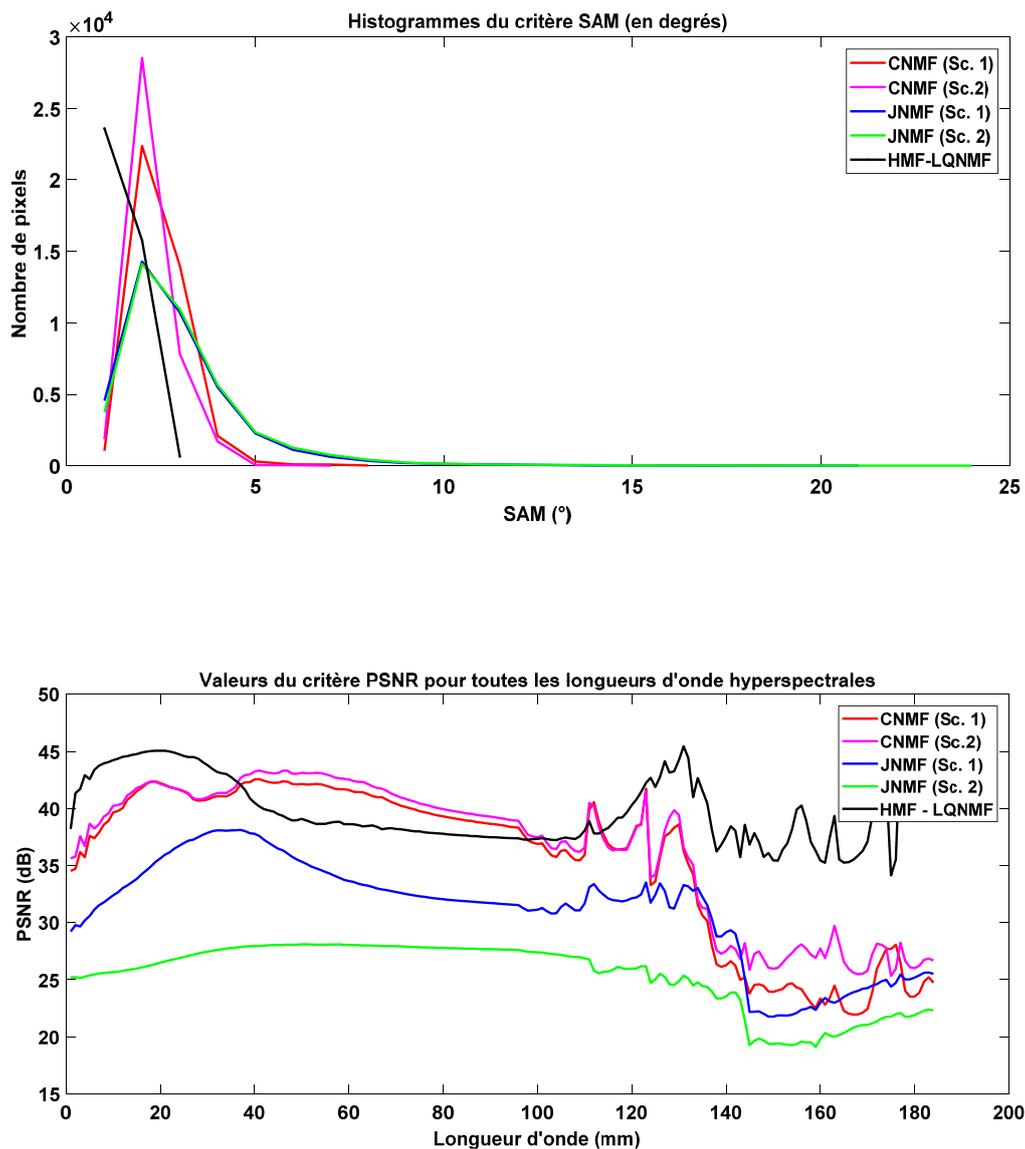


Figure 3.9 : Histogramme des valeurs du critère SAM (en degrés) et valeurs du critère PSNR (en décibels) - ensemble de données dataset 2.2, facteur d'échelle 4.

À partir de ces figures, il est clair que la méthode proposée produit globalement moins de distorsions spectrale et spatiale que les méthodes de la littérature testées. En effet, à partir des histogrammes des valeurs du critère spectral SAM (en degrés), nous remarquons que notre méthode HMF-LQNMF offre dans l'ensemble de meilleures performances dans le domaine spectral que les méthodes de la littérature testées, avec des valeurs du critère SAM très

souvent inférieures à 2° , et cela dans les deux configurations (mélanges linéaire et linéaire-quadratique) et pour les ensembles de données considérés.

En ce qui concerne le domaine spatial, les histogrammes du PSNR montrent que notre méthode offre de meilleures performances avec des valeurs pouvant atteindre 50 dB, très souvent largement supérieures aux valeurs qu'offrent les autres méthodes testées.

3.3.1.2. Résultats avec les données réelles

Pour les données réelles, les résultats obtenus avec notre méthode HMF-LQNMF ainsi que les méthodes linéaires de la littérature sont donnés dans les tableaux suivants (Tableaux 3.5-3.6). Notons ici, que nous avons choisi de fixer le nombre d'endmembers à 10 dans les méthodes de fusion testées. Ce nombre a été estimé par la méthode décrite dans [140].

Tableau 3.5 : Valeurs des coûts de calcul et des critères d'évaluation pour les données réelles : EO-1 Hyperion avec Landsat ETM +.

		Méthodes de fusion basées sur le démixage spectral				
		CNMF		JNMF		HMF-LQNMF
		Sc. 1	Sc. 2	Sc. 1	Sc. 2	
Temps (sec.)		8.32	33.24	1.92	4.27	6.35
Critère	Valeur idéale					
D_λ	0	0.11	0.13	0.10	0.09	0.13
D_s	0	0.60	0.59	0.59	0.59	0.27
mQNR	1	0.35	0.35	0.37	0.38	0.64

Tableau 3.6 : Valeurs des coûts de calcul et des critères d'évaluation pour les données réelles : EO-1 Hyperion avec EO-1 ALI.

		Méthodes de fusion basées sur le démixage spectral				
		CNMF		JNMF		HMF-LQNMF
		Sc. 1	Sc. 2	Sc. 1	Sc. 2	
Temps (sec.)		11.83	42.37	2.98	7.76	10.84
Critère	Valeur idéale					
D_λ	0	0.23	0.25	0.23	0.24	0.24
D_s	0	0.71	0.70	0.69	0.69	0.44
mQNR	1	0.23	0.22	0.24	0.23	0.43

Ces tableaux confirment également les bonnes performances globales de la méthode HMF-LQNMF proposée par rapport aux méthodes linéaires de la littérature (la méthode JNMF et CNMF). Il convient de noter ici que la méthode proposée offre globalement de meilleurs résultats pour les mesures D_λ et D_s . Cependant, l'amélioration est meilleure en ce qui concerne le critère D_s . Cela peut être dû au fait que les données réelles considérées sont issues de milieux urbains, par conséquent, elles mettent en jeu des non-linéarités (de type linéaire-quadratique) qui génèrent des coefficients d'abondances linéaire-quadratiques non nulles qui représentent l'aspect spatial du modèle de mélange considéré. Ainsi, le fait de tenir compte de ces coefficients linéaire-quadratiques peut expliquer l'amélioration de l'indice D_s pour les données fusionnées avec notre méthode.

Ces tableaux montrent aussi que les performances de notre méthode s'améliorent lorsque le facteur d'échelle entre les résolutions spatiales des données hyperspectrale et multispectrale est plus faible. En effet, les résultats obtenus avec la fusion des données réelles d'Hyperion EO-1 avec Landsat ETM+ (où le facteur d'échelle est égal à 2) sont significativement meilleurs que ceux obtenus avec la fusion des données réelles d'Hyperion EO-1 avec ALI (où le facteur d'échelle est égal à 3).

Les figures ci-dessous (Figure 3.10 - Figure 3.11) montrent la bande spectrale dans la région de $0.815 \mu\text{m}$, pour les données réelles de l'image hyperspectrale à faible résolution spatiale et des images hyperspectrales estimées (par notre méthode HMF-LQNMF proposée et les méthodes linéaires testées).

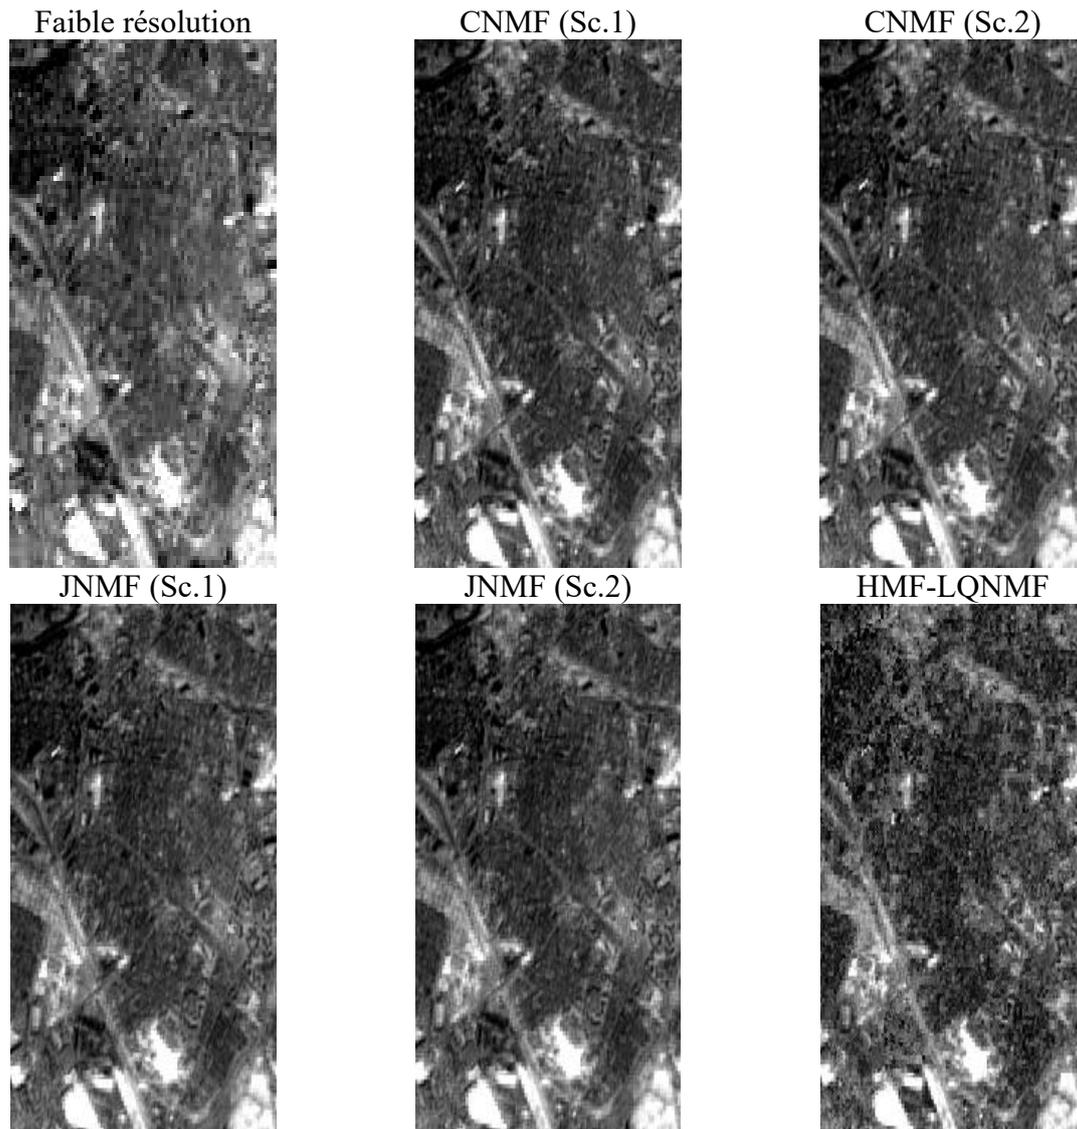


Figure 3.10 : Bande spectrale (dans la région de $0.815 \mu\text{m}$) pour les données réelles (EO-1 Hyperion et EO-1 Landsat ETM +), de l'image hyperspectrale à faible résolution spatiale et des images hyperspectrales estimées.

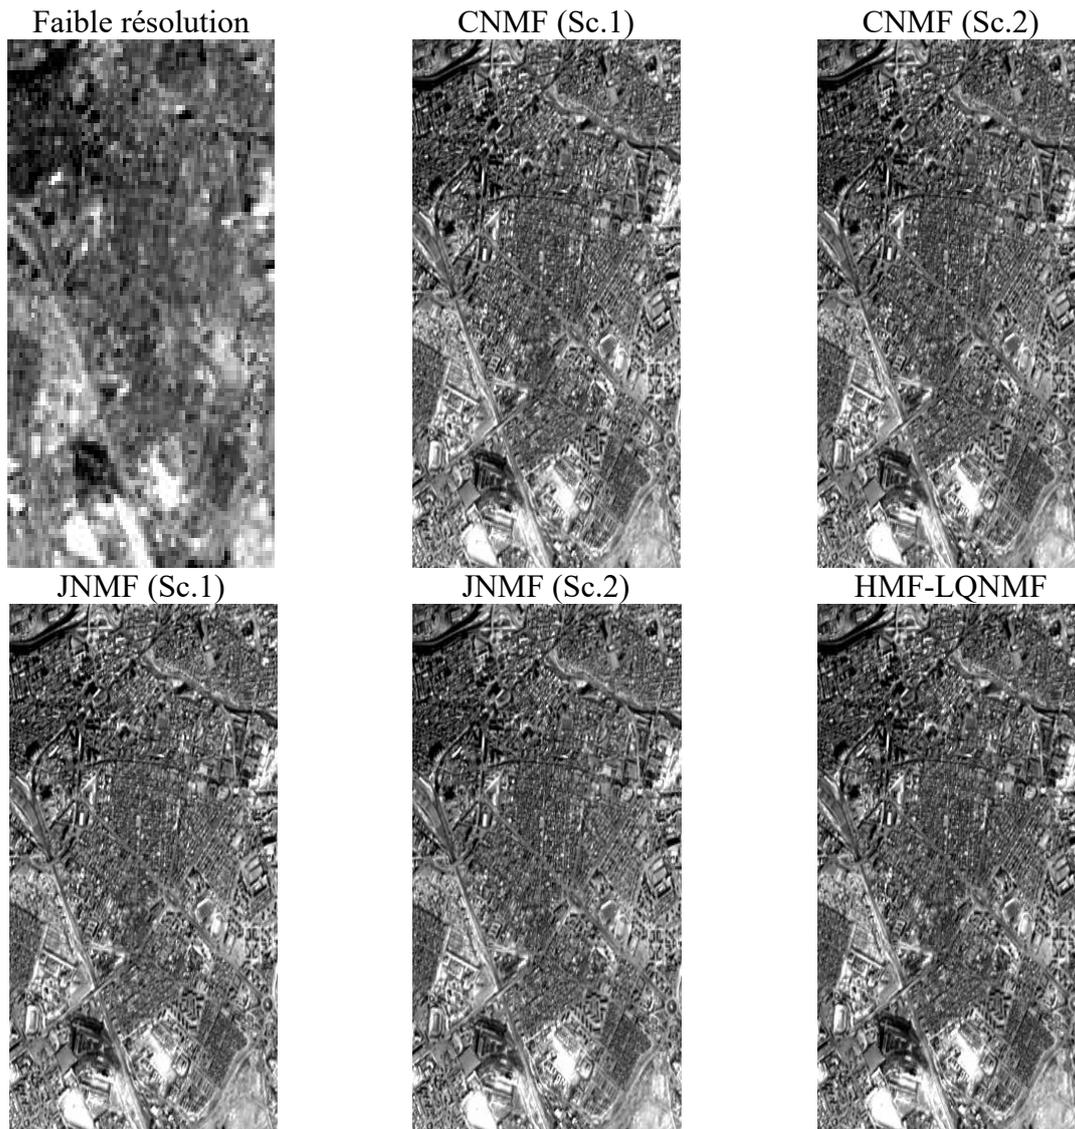


Figure 3.11 : Bande spectrale (dans la région de $0.815 \mu\text{m}$) pour les données réelles (EO-1 Hyperion et EO-1 ALI), de l'image hyperspectrale à faible résolution spatiale et des images hyperspectrales estimées.

Ces figures (Figure 3.10 - Figure 3.11) montrent également que notre méthode donne des résultats visuels assez bons, néanmoins il est difficile de déterminer à l'œil nu les améliorations apportées par notre méthode par rapport aux méthodes de la littérature testées.

3.3.2. Comparaison des performances des méthodes proposées

Dans cette section, une comparaison des résultats obtenus avec les différentes méthodes proposées : HMF-LQNMF, CHMF-LQNMF, JHMF-LQNMF et Multi-JCLQNMF ainsi que la méthode Local-HMF-LQNMF est donnée. Les résultats présentés ici sont issus de tests sur données synthétiques et réelles.

3.3.2.1. Résultats avec les données synthétiques

Dans cette section, nous comparons les performances obtenues avec nos méthodes sur les données synthétiques décrites dans la section 3.2.1.1

a) Résultats avec le premier jeu de données synthétiques

Dans cette section, une comparaison des résultats obtenus avec les différentes variantes de notre première méthode proposée (voir section 2.3.2) est présentée. Cette comparaison est effectuée dans le domaine spectral et spatial sur notre premier jeu de données synthétiques (voir section 3.2.1.1(a)).

Les tableaux suivants (Tableaux 3.7-3.10) représentent les coûts de calcul et moyennes des critères spectraux et spatiaux obtenus avec les différentes méthodes de multisharpening proposées, et cela dans les deux configurations (linéaire et linéaire-quadratique) et avec les deux ensembles de spectres (spectres d'une sélection aléatoire issus de la bibliothèque spectrale USGS et spectres d'une sélection aléatoire de milieux urbains).

Tableau 3.7 : Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 1.1.

			Méthodes de fusion proposées basées sur la LQNMF			
			HMF-LQNMF	CHMF-LQNMF	JHMF-LQNMF	Multi-JCLQNMF
Facteur d'échelle 2	Temps (sec)		9.51	30.14	20.59	7.02
	Critère	Valeur idéale				
	SAM (°)	0	0.81	0.77	0.76	0.80
	NMSE _λ (%)	0	1.66	2.79	1.54	1.64
	UIQI	1	0.9980	0.9974	0.9982	0.9980
	NMSE _s (%)	0	1.65	2.72	1.59	1.65
	PSNR (dB)	∞	42.05	37.46	42.27	42.03
	ERGAS	0	3.16	3.88	3.09	3.14
Facteur d'échelle 4	Temps (sec)		8.50	29.04	19.02	11.47
	Critère	Valeur idéale				
	SAM (°)	0	0.82	0.76	0.77	0.80
	NMSE _λ (%)	0	1.64	2.83	1.54	1.64
	UIQI	1	0.9980	0.9974	0.9981	0.9980
	NMSE _s (%)	0	1.65	2.75	1.60	1.65
	PSNR (dB)	∞	42.06	37.33	42.21	42.06
	ERGAS	0	3.13	3.91	3.10	3.13

Tableau 3.8 : Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 2.1.

			Méthodes de fusion proposées basées sur la LQNMF			
			HMF-LQNMF	CHMF-LQNMF	JHMF-LQNMF	Multi-JCLQNMF
Facteur d'échelle 2	Temps (sec)		5.29	28.67	24.12	6.90
	Critère	Valeur idéale				
	SAM (°)	0	0.29	0.29	0.27	0.30
	NMSE _λ (%)	0	0.87	1.79	0.80	1.00
	UIQI	1	0.9989	0.9988	0.9990	0.9987
	NMSE _s (%)	0	1.05	1.67	1.05	1.21
	PSNR (dB)	∞	45.76	41.54	45.56	44.26
	ERGAS	0	4.01	4.47	4.02	4.21
Facteur d'échelle 4	Temps (sec)		10.43	25.03	22.07	25.55
	Critère	Valeur idéale				
	SAM (°)	0	0.37	0.30	0.30	0.31
	NMSE _λ (%)	0	0.92	1.77	0.88	0.95
	UIQI	1	0.9982	0.9988	0.9990	0.9990
	NMSE _s (%)	0	1.04	1.66	1.07	1.07
	PSNR (dB)	∞	45.82	41.59	45.34	45.61
	ERGAS	0	8.01	8.93	8.12	8.06

Tableau 3.9 : Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 1.2.

			Méthodes de fusion proposées basées sur la LQNMF			
			HMF-LQNMF	CHMF-LQNMF	JHMF-LQNMF	Multi-JCLQNMF
Facteur d'échelle 2	Temps (sec)		6.07	31.12	24.71	14.28
	Critère	Valeur idéale				
	SAM (°)	0	1.34	1.13	1.55	1.59
	NMSE _λ (%)	0	3.22	3.80	3.13	3.21
	UIQI	1	0.9967	0.9955	0.9970	0.9967
	NMSE _s (%)	0	2.77	3.70	2.74	2.78
	PSNR (dB)	∞	38.52	35.18	38.64	38.50
	ERGAS	0	2.45	2.75	2.43	2.45
Facteur d'échelle 4	Temps (sec)		8.82	30.46	20.28	26.32
	Critère	Valeur idéale				
	SAM (°)	0	1.17	1.02	1.12	1.17
	NMSE _λ (%)	0	2.70	3.58	2.59	2.70
	UIQI	1	0.9965	0.9961	0.9965	0.9965
	NMSE _s (%)	0	2.83	3.48	2.78	2.83
	PSNR (dB)	∞	37.48	35.84	37.61	37.48
	ERGAS	0	4.96	3.35	4.91	4.95

Tableau 3.10 : Coûts de calcul et moyennes des critères spectraux et spatiaux pour l'ensemble de données dataset 2.2.

			Méthodes de fusion proposées basées sur la LQNMF			
			HMF-LQNMF	CHMF-LQNMF	JHMF-LQNMF	Multi-JCLQNMF
Facteur d'échelle 2	Temps (sec)		5.31	32.74	25.83	13.04
	Critère	Valeur idéale				
	SAM (°)	0	0.73	0.33	0.71	0.73
	NMSE _λ (%)	0	3.18	2.10	3.21	3.07
	UIQI	1	0.9937	0.9984	0.9932	0.9936
	NMSE _s (%)	0	3.46	1.97	3.50	3.38
	PSNR (dB)	∞	35.60	39.38	35.39	35.71
	ERGAS	0	6.45	4.80	6.47	6.38
Facteur d'échelle 4	Temps (sec)		10.58	30.61	23.18	11.47
	Critère	Valeur idéale				
	SAM (°)	0	0.47	0.33	0.47	0.47
	NMSE _λ (%)	0	1.84	2.10	1.85	1.84
	UIQI	1	0.9973	0.9984	0.9971	0.9973
	NMSE _s (%)	0	2.10	1.99	2.16	2.08
	PSNR (dB)	∞	39.82	39.86	39.47	39.86
	ERGAS	0	5.35	4.81	5.38	5.33

Les tableaux ci-dessus montrent dans l'ensemble que nos méthodes de multisharpening des images hyperspectrales donnent des résultats assez proches dans les deux configurations des données synthétiques testées, avec des performances (spectrales et spatiales) relativement meilleures pour la méthode JHMF-LQNMF proposée dans le cas de données générées selon le modèle de mélange linéaire (avec les deux ensembles de spectres) et dans le cas de données générées selon le modèle de mélange linéaire-quadratique avec une sélection aléatoire de spectres réels issus de la bibliothèque spectrale USGS . Au contraire, la méthode CHMF-LQNMF donne les meilleurs résultats pour les données générées selon le modèle de mélange linéaire-quadratique et avec une sélection de spectres réels de milieux urbains issus de la bibliothèque spectrale JHU.

De plus, les résultats présentés dans ces tableaux confirment les bonnes performances de nos méthodes dans les deux configurations par rapport aux performances obtenues avec les méthodes linéaires de la littérature (voir Tableaux 3.1-3.4).

b) Résultats avec le deuxième jeu de données synthétiques

Ci-dessous est présentée une comparaison des résultats obtenus avec nos méthodes (voir section 2.3.2 et 3.2.3). Cette comparaison est effectuée dans le domaine spectral et spatial sur notre deuxième jeu de données synthétiques (voir section 3.2.1.1(b)).

Pour la méthode Local-HMF-LQNMF, un nouveau paramètre est pris en compte, ce paramètre représente le seuil d'élévation, comparé à la variance des élévations d'objets qui est calculée à partir des données DSM. Il permet de déterminer la nature du modèle de mélange (linéaire ou linéaire quadratique) présent dans chaque zone des images considérées afin de déterminer la technique de démixage/fusion adéquate à employer dans chaque zone.

Les moyennes des critères spectraux et spatiaux et les coûts de calcul des méthodes testées sont donnés dans le tableau suivant. Ce tableau montre que les approches proposées donnent de bonnes fidélités spatiale et spectrale pour la fusion des images. En outre, ce tableau montre également que la méthode basée sur la LQNMF pour le multisharpening local des données surpasse les autres méthodes proposées pour ce type de données synthétiques.

Tableau 3.11 : Coûts de calcul et moyennes des critères spectraux et spatiaux.

		Méthodes de fusion basées sur la NMF				Méthodes de fusion proposées basées sur la LQNMF				
		CNMF		JNMF		HMF- LQNMF	CHMF- LQNMF	JHMF- LQNMF	Multi- JCLQNMF	Local- HMF- LQNMF
		Sc. 1	Sc. 2	Sc. 1	Sc. 2					
Temps (sec)		22.64	47.62	4.30	<u>1.56</u>	4.75	18.92	10.40	11.77	39.26
Critère	Valeur idéale									
SAM (°)	0	1.31	1.28	1.17	1.27	1.03	0.57	1.03	1.07	<u>0.42</u>
NMSE _λ (%)	0	2.80	2.79	3.88	4.56	4.42	3.11	4.02	4.40	<u>0.85</u>
UIQI	1	0.99 06	0.9899	0.98 48	0.9842	0.9904	<u>0.9953</u>	0.9913	0.9900	0.9943
NMSE _s (%)	0	3.43	3.47	5.56	6.00	4.48	3.24	4.18	4.51	<u>2.96</u>
PSNR (dB)	∞	34.68	34.64	30.09	29.50	32.26	34.90	32.83	32.17	<u>35.55</u>
ERGAS	0	3.08	3.10	3.91	4.17	3.51	2.98	3.39	3.52	<u>2.87</u>

Afin de comparer les performances globales des méthodes développées avec les données synthétiques décrites dans cette section, la figure suivante (Figure 3.12) montre l'histogramme des valeurs du critère SAM sur tous les pixels et les valeurs du critère PSNR pour les longueurs d'onde hyperspectrales.

La Figure 3.12 ci-dessous montre que la méthode de multisharpening locale offre de meilleures performances globales que les méthodes de multisharpening mises en place et les méthodes de la littérature testées, qui sont utilisés sur l'ensemble de l'image. Pour l'histogramme des valeurs de SAM, la majorité des valeurs obtenues avec la méthode de fusion locale est inférieure à 3° , néanmoins il existe des valeurs plus élevées mais qui restent de proportion moins importante que ces dernières.

A partir des valeurs du PSNR, là aussi nous remarquons que la méthode de multisharpening locale offre de meilleurs résultats avec des valeurs généralement comprises entre 34 et 38 dB.

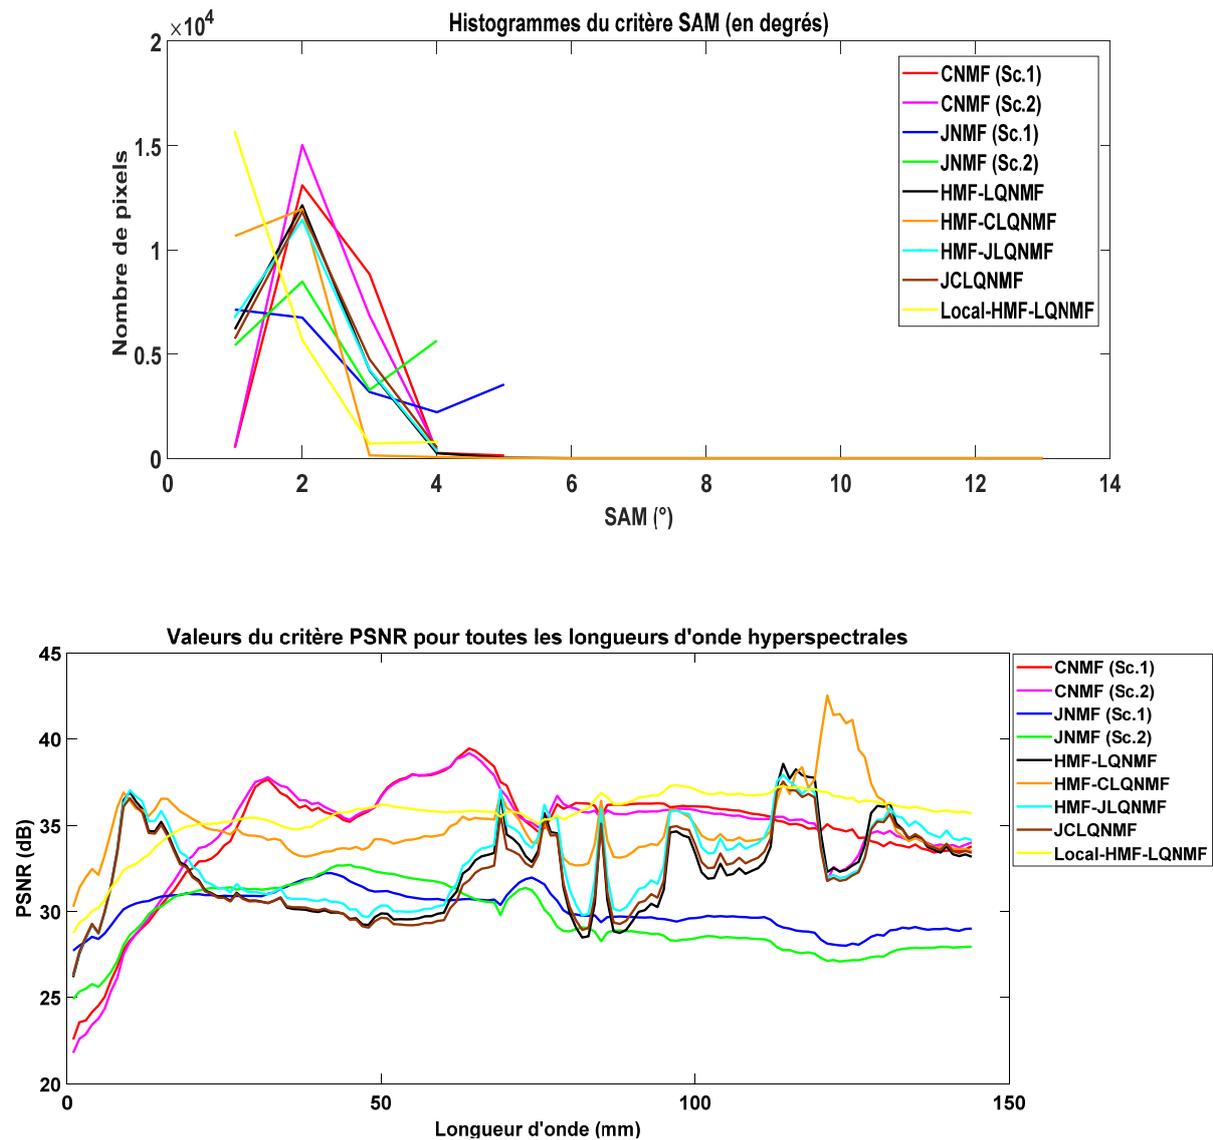


Figure 3.12 : Histogramme des valeurs du critère SAM (en degrés) et valeurs du critère PSNR (en décibels).

3.3.2.2. Résultats avec les données réelles

Dans cette section, sont présentés les résultats des tests effectués (Tableau 3.12 - Tableau 3.13) avec des données réelles (section 3.2.2.2) avec les méthodes proposées.

Notons ici que la méthode Local- HMF-LQNMF ne figure pas dans cette comparaison des résultats obtenus, du fait que nous ne disposons pas d'une vérité terrain associée à nos données réelles et de données DSM qui sont essentielles au fonctionnement de cette méthode

(pour la détection du modèle de mélange local et la méthode de démixage/fusion locale à utiliser).

Les tableaux ci-dessous montrent les résultats obtenus lors des tests effectués avec les méthodes proposées sur des données réelles. Dans l'ensemble, les méthodes de multisharpening proposées donnent des résultats assez proches avec des performances relativement meilleures pour la méthode CHMF-LQNMF proposée. De plus les résultats présentés dans ces tableaux confirment les bonnes performances de nos méthodes par rapport aux méthodes linéaires de la littérature (voir Tableaux 3.5-3.6).

Tableau 3.12 : Valeurs des coûts de calcul et des critères d'évaluation pour les données réelles: EO-1 Hyperion avec Landsat ETM +.

		Méthodes de fusion proposées basées sur la LQNMF			
		HMF-LQNMF	CHMF-LQNMF	JHMF-LQNMF	Multi-JCLQNMF
Temps (sec)		6.35	14.11	13.73	14.23
Critère	Valeur idéale				
D_λ	0	0.13	0.05	0.14	0.08
D_s	0	0.27	0.32	0.29	0.37
mQNR	1	0.64	0.64	0.60	0.58

Tableau 3.13 : Valeurs des coûts de calcul et des critères d'évaluation pour les données réelles: EO-1 Hyperion avec EO-1 ALI.

		Méthodes de fusion proposées basées sur la LQNMF			
		HMF-LQNMF	CHMF-LQNMF	JHMF-LQNMF	Multi-JCLQNMF
Temps (sec)		10.84	26.23	25.94	26.12
Critère	Valeur idéale				
D_λ	0	0.24	0.07	0.24	0.24
D_s	0	0.44	0.48	0.45	0.51
mQNR	1	0.43	0.48	0.42	0.37

3.4. Conclusion

Dans ce chapitre, nous avons présenté les performances obtenues avec les méthodes proposées pour la fusion des images hyperspectrale à haute résolution spectrale/faible résolution spatiale et multispectrale à haute résolution spatiale/faible résolution spectrale de milieux urbains. Ces méthodes, liées aux techniques de démixage spectrale linéaire-quadratique (LQSU), sont basées sur l'algorithme multiplicatif LQNMF.

Les résultats obtenus sur des données synthétiques et réelles sont satisfaisants et encourageants. Ils montrent que nos méthodes produisent de bonnes fidélités spectrale et spatiale globales pour le multisharpening des données hyperspectrales et dépassent de manière significative les méthodes de multisharpening linéaires de la littérature (JNMF et CNMF). Les méthodes développées sont faciles à mettre en œuvre, et les qualités élevées des données fusionnées obtenues peuvent certainement contribuer à l'identification et à la classification précise d'une région observée à une résolution spatiale plus fine.

Conclusion et perspectives

Dans cette deuxième partie, nous nous sommes consacrés à l'étude de la fusion des images de télédétection spatiale. Le but des travaux de cette partie est de développer des méthodes pour améliorer la résolution spatiale des images hyperspectrales tout en préservant l'information spectrale de ces dernières. La procédure adoptée était de fusionner une image hyperspectrale de haute résolution spectrale et une image multispectrale de haute résolution spatiale. Cette fusion est réalisée en combinant l'information spectrale issue des données hyperspectrales avec l'information spatiale issue des données multispectrales.

Dans le premier chapitre, nous avons présenté un état de l'art des principales méthodes de la littérature : tout d'abord sur les familles de méthodes de panchsharpening, qui consistent à fusionner des données panchromatiques avec des données multispectrales/hyperspectrales, puis sur les familles de méthodes de multisharpening, qui consistent à fusionner des données hyperspectrales avec des données multispectrales. Cette dernière étant l'axe de nos travaux, nous avons ainsi présenté quelques méthodes de multisharpening en nous focalisant davantage sur les méthodes basées sur la factorisation en matrices non-négatives.

Le deuxième chapitre a été consacré à la description des méthodes mises en place dans cette thèse pour le multisharpening d'images de télédétection spatiale pour le cas particulier de données de milieux urbains. Dans ce chapitre, nous avons donc présenté le modèle mathématique de données, qui est le modèle linéaire-quadratique, puis nous avons présenté les méthodes de multisharpening développées dans le cadre de cette partie de thèse pour la fusion des données hyperspectrale et multispectrale de télédétection. Ces méthodes sont basées sur les techniques de démixage spectral conçues pour le modèle de mélange linéaire-quadratique et utilisent le principe de la factorisation en matrices non-négatives.

Dans le dernier chapitre, les performances des méthodes de multisharpening proposées ont été comparées aux performances de méthodes de la littérature. Les premiers tests ont été réalisés sur des données synthétiques issues d'une classification réelle de la couverture terrestre. Ces données ont été générées suivant le modèle de mélange linéaire-quadratique, tandis que les seconds tests ont été réalisés sur des données réelles qui représentent une partie de la zone urbaine d'Oran, en Algérie. Les résultats obtenus montrent que nos méthodes donnent généralement de meilleures performances en comparaison avec les résultats obtenus par des méthodes de la littérature, et cela pour les deux ensembles de données considérés.

Les résultats obtenus avec nos méthodes, pour le multisharpening de données hyperspectrales de milieux urbains, sont très satisfaisants et encourageants, ce qui nous permet d'envisager plusieurs perspectives :

- Validation de nos méthodes proposées sur d'autres données réelles de milieux urbains.
- Utiliser des données panchromatiques pour améliorer davantage le processus de multisharpening des données hyperspectrales.
- Tester notre méthode Local-HMF-LQNMF de multisharpening locale sur des données réelles.
- Utiliser les méthodes de démelange spectral proposées dans la première partie de la thèse pour réaliser le processus de multisharpening.

Conclusion générale

Dans ce travail de thèse nous avons développé des méthodes de "Démélange Spectral" et de "Fusion" d'images de télédétection spatiale de scènes de milieux urbains. Les méthodes proposées ont pour objectif de tenir compte de la nature particulière de ce type de scènes, à savoir les phénomènes de réflexions multiples dues à la présence de structures tridimensionnelles (3D).

Deux problématiques de la télédétection ont donc été abordées durant cette thèse :

Dans la première partie, nous avons étudié le démixage spectral non-supervisé, qui consiste à extraire d'une image de télédétection spatiale les spectres des composants purs présents dans l'image. Nous nous sommes particulièrement intéressés aux images hyperspectrales de scènes de milieux urbains. Les approches développées peuvent être considérées comme des approches dites de Séparation Aveugle de Sources (SAS).

Dans le premier chapitre de cette première partie, nous avons commencé par donner un état de l'art des méthodes de séparation de sources développées dans la littérature. Nous avons ainsi présenté les grandes catégories de méthodes de séparation conçues pour le cas de mélange linéaire, qui sont : l'Analyse en Composantes Indépendantes, l'Analyse en Composantes Parcimonieuses, la Factorisation en Matrices Non-négatives et les méthodes géométriques. Par la suite, nous avons présenté les méthodes non-linéaires les plus connues de séparation. Dans un second lieu, d'autres approches de séparation de sources dédiées principalement à l'imagerie de télédétection spatiale ont été présentées aussi bien pour le cas du modèle de mélange linéaire que pour le cas des mélanges non-linéaires.

Le second chapitre de cette première partie a été consacré à la description des méthodes développées dans le cadre du démixage spectral d'images hyperspectrales de milieux urbains. Tout d'abord, nous avons commencé ce chapitre par présenter notre modèle mathématique de données qui est le modèle bilinéaire/linéaire-quadratique. Ce modèle de mélange permet de tenir compte des interactions multiples entre les différents matériaux en présence de relief, ce qui est souvent le cas pour les images de scènes urbaines. Par la suite, les algorithmes développés pour le démixage spectral non-supervisé ont été présentés. Ces algorithmes sont basés sur la factorisation en matrices non-négatives, adaptée au modèle de mélange présent dans le type des données considéré.

Dans le troisième chapitre, les performances des algorithmes proposés ont été évaluées sur des données synthétiques. Les résultats obtenus montrent que les approches proposées offrent d'assez bonnes performances en termes d'extraction de spectres d'endmembers à partir d'images hyperspectrales de télédétection urbaine. De plus, ces résultats ont montré que les approches proposées offraient de meilleurs résultats que les méthodes de littérature testées.

La seconde partie de ce manuscrit a été consacrée à la fusion d'images de télédétection spatiale. Dans cette partie, nous avons ainsi présenté les méthodes développées pour la fusion des images hyperspectrale et multispectrale de scènes de milieux urbains, pour fournir une image fusionnée avec une haute résolution spatiale et spectrale.

Tout d'abord, nous avons commencé cette partie par donner un état de l'art des principales familles de méthodes de pansharpening, qui consiste à fusionner des données panchromatiques avec des données multispectrales ou hyperspectrales, puis sur les familles de méthodes de multisharpening, qui consistent à fusionner des données hyperspectrales avec des données multispectrales. Cette dernière étant l'axe de nos travaux, nous avons ainsi présenté quelques méthodes de multisharpening en nous focalisant davantage sur les méthodes basées sur la factorisation en matrices non-négatives.

Le deuxième chapitre, a été dédié à la description des méthodes proposées pour le multisharpening d'images de télédétection spatiale pour le cas particulier de données de milieux urbains. Dans ce chapitre, nous avons commencé par présenter le modèle de mélange de données qui est le mélange linéaire-quadratique. Par la suite, nous avons présenté les méthodes de multisharpening développées. Ces méthodes, basées sur le concept de démixage spectral sont conçues pour le modèle de mélange linéaire-quadratique et utilisent le principe de la factorisation en matrices non-négatives.

Dans le dernier chapitre, les méthodes de multisharpening développées ont été testées sur des données synthétiques et réelles, et leurs performances ont été comparées avec celles de méthodes de la littérature. À partir des résultats obtenus, nous pouvons conclure que les méthodes proposées sont très attractives pour la fusion des images hyperspectrale et multispectrale de télédétection spatiale.

Les travaux réalisés dans cette thèse ouvrent la voie à plusieurs perspectives, dont quelques-unes ont déjà été citées dans les conclusions propres à chaque partie, telles que :

-
- Validation de nos méthodes non-linéaires de démixage spectral sur d'autres jeux de données, en particulier sur des données réelles de milieux urbains, et test des performances de ces méthodes sur des données avec ou sans présence de pixels purs.
 - Validation des méthodes de multisharpening proposées sur d'autres données réelles, et éventuellement extension de ces méthodes pour la fusion de différents types d'images (panchromatiques, multispectrales et hyperspectrales).
 - Test de notre méthode Local-HMF-LQNMF de multisharpening locale sur des données réelles, et automatisation du choix du seuil utilisé pour la détection de la nature du modèle de mélange présent dans les zones de l'image étudiée.
 - Utilisation des méthodes de démixage spectral proposées dans la première partie de la thèse comme initialisation des méthodes de multisharpening développées dans la seconde partie.

Références bibliographiques

- [1] F. Bonn and G. Rochon, *Précis de télédétection: Principes et méthodes, Volume 1, 2*, illustrée ed., 1993.
- [2] P. Lier, C. Valorge, and X. Briottet, *Imagerie Spatiale : Des principes d'acquisition au traitement des images optiques pour l'observation de la Terre*: Cépadués, France, , 2008.
- [3] J. Gao, *Digital analysis of remotely sensed imagery*: McGraw-Hill, United States, 2009.
- [4] P. Comon, "Independent component analysis, a new concept " *Signal Processing*, vol. 36, pp. 287–314, 1994.
- [5] P. Comon and C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*: Academic Press, Oxford, UK, 2010.
- [6] Y. Deville, *Traitement du signal : signaux temporels et spatiotemporels – Analyse des signaux, théorie de l'information, traitement d'antenne, séparation aveugle de sources*: Ellipses Editions Marketing, Paris, 2011.
- [7] N. Keshava and J. F. Mustard, "Spectral Unmixing," *IEEE Signal Processing Magazine*, vol. 19, pp. 44-57, 2002.
- [8] J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader, and J. Chanussot, "Hyperspectral unmixing overview : Geometrical, statistical, and sparse regression-based approaches," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, pp. 354-379, 2012.
- [9] Y. Deville and L. T. Duarte, "An overview of blind source separation methods for linear-quadratic and post-nonlinear mixtures," presented at the International Conference on Latent Variable Analysis and Signal Separation, 2015.
- [10] I. Meganem, Y. Deville, S. Hosseini, P. Deliot, and X. Briottet, "Linear-Quadratic Blind Source Separation Using NMF to Unmix Urban Hyperspectral Images," *IEEE Transactions on Signal Processing*, vol. 62, pp. 1822-1833, 2014.
- [11] I. Meganem, P. Deliot, X. Briottet, Y. Deville, and S. Hosseini, "Linear-quadratic mixing model for reflectances in urban environments," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, pp. 544–558, 2014.
- [12] M. S. Karoui, Y. Deville, and S. Kreri, "Joint Nonnegative Matrix Factorization for Hyperspectral and Multispectral Remote Sensing Data Fusion," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing (WHISPERS), 2013.
- [13] M. S. Karoui, Y. Deville, F. Z. Benhalouche, and I. Boukerch, "Hypersharpener by Joint-Criterion Nonnegative Matrix Factorization," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, pp. 1660-1670, 2017.
- [14] J. Héroult, C. Jutten, and B. Ans, "Détection de grandeurs primitives dans un message composite par une architecture de calcul neuromimétique en apprentissage non supervisé," presented at the Groupe d'Etudes du Traitement du Signal et des Images (GRETSI), Nice, France, 1985.

-
- [15] K. Anand, G. Mathew, and V. Reddy, "Blind separation of multiple cochannel bpsk signals arriving at an antenna array," *IEEE Signal Processing Letters*, vol. 2, pp. 176–178, 1995.
- [16] A. Cichocki, R. Zdunek, and S. I. Amari, "New Algorithms for Non-Negative Matrix Factorization in Applications to Blind Source Separation," presented at the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) Toulouse, France, 2006, 2006.
- [17] Y. Deville, "Panorama des applications biomédicales des méthodes de séparation aveugle de sources," presented at the Groupe d'Etudes du Traitement du Signal et des Images (GRETSI), Paris, France, 2003.
- [18] P. Comon and C. Jutten, *Séparation de sources. Tome 1*, 2007.
- [19] C. Jutten and M. Babaie-Zadeh, "Source separation: principles, current advances and applications," presented at the Advanced Control and Diagnosis (ACD), Nancy, France, 2006.
- [20] A. Kachenoura, L. Albera, and L. Senhadji, "Séparation aveugle de sources en ingénierie biomédicale," *ITBM-RBM*, vol. 28, pp. 20-34, 2007.
- [21] Y. Deville, "Matrix Factorization for Bilinear Blind Source Separation: Methods, Separability and Conditioning," presented at the The European Signal Processing Conference (EUSIPCO) Nice, France, 2015.
- [22] Y. Deville, "Blind Source Separation and Blind Mixture Identification Methods (Encyclopedia of Electrical and Electronics Engineering)," ed: Hoboken, NJ, USA: Wiley, 2016, pp. 1–33.
- [23] M. S. Pedersen, J. Larsen, U. Kjems, and L. C. Parra, "A Survey of Convolutional Blind Source Separation Methods," Springer, Ed., ed, 2007, pp. 1–34.
- [24] S. Makino, T. W. Lee, and H. Sawada, *Blind speech separation*: Springer, Dordrecht, The Netherlands, 2007.
- [25] P. Comon and C. Jutten, *Séparation de sources 2 ; au-delà de l'aveugle et applications*: Hermès, 2007.
- [26] J. M. P. Nascimento and J. M. Bioucas-Dias, "Nonlinear mixture model for hyperspectral unmixing," presented at the Conference on Image and Signal Processing for Remote Sensing (SPIE), 2009.
- [27] C. Jutten and J. Karhunen, "Advances in nonlinear blind source separation," presented at the International Symposium on Independent Component Analysis and Blind Signal Separation (ICA), 2003.
- [28] C. Chaouchi, "Méthodes de séparation aveugle de sources non linéaires, étude du modèle quadratique," Thèse de l'Université Paul Sabatier, Toulouse III, 2011.
- [29] Y. Altmann, "Démélange non-linéaire d'images hyperspectrales," Thèse de l'Université Paul Sabatier, Toulouse III, 2013.
- [30] J. M. Bioucas-Dias and A. Plaza, "An overview on hyperspectral unmixing: geometrical, statistical, and sparse regression based approaches," presented at the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2011.

-
- [31] J. Plaza, E. M. T. Hendrix, I. Garcia, G. Martin, and A. Plaza, "On endmember Identification in Hyperspectral Images Without Pure Pixels: A Comparison of Algorithms," *Journal of Mathematical Imaging and Vision*, 2011.
- [32] M. Parente and A. Plaza, "Survey of geometric and statistical unmixing algorithms for hyperspectral images," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing (WHISPERS), Reykjavik, Iceland, 2010.
- [33] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*: Wiley Interscience, 2001.
- [34] S. Choi, A. Cichocki, H. M. Park, and S. Y. Lee, "Blind source separation and independent component analysis: a review," *Neural Information Processing - Letters and Reviews*, vol. 6, 2005.
- [35] K. H. Knuth, "A Bayesian approach to source separation," presented at the the First International Workshop on Independent Component Analysis and Signal Separation : ICA, 1999.
- [36] S. Moussaoui, D. Brie, A. Mohammad-Djafari, and C. Carteret, "Separation of nonnegative mixture of non-negative sources using a bayesian approach and MCMC sampling," *IEEE Transactions on Signal Processing*, vol. 54, pp. 4133–4145, 2006.
- [37] M. Babaie-Zadeh and C. Jutten, "A general approach for mutual information, minimizing and its application to blind source separation," *Signal Processing*, vol. 85, pp. 975-995, 2005.
- [38] S. Samadi, M. Babaie-Zadeh, C. Jutten, and K. Nayebi, "Blind source separation by adaptive estimation of score function difference," presented at the The 5th International Symposium on Independent Component Analysis and Blind Signal Separation, ICA 2004, Granada, Spain, 2004.
- [39] L. B. Almeida, "ICA of linear and nonlinear mixtures based on mutual information," presented at the International Joint Conference on Neural Networks, 2001.
- [40] D. T. Pham, "Mutual information approach to blind separation deconvolution," presented at the The European Signal Processing Conference (EUSIPCO) Antalya, Turkey, 2005.
- [41] D. T. Pham, "Mutual information approach to blind separation for stationary sources," *IEEE Transactions on Information Theory*, vol. 48, pp. 1935-1946, 2002.
- [42] M. Gaeta and J. L. Lacoume, "Estimateurs du maximum de vraisemblance étendus à la séparation de sources non gaussiennes," *Traitement du signal*, vol. 7, pp. 419–434, 1990.
- [43] D. T. Pham and P. Garat, "Blind separation of mixtures of independent sources through a quasi maximum likelihood approach," *IEEE Transactions on Signal Processing*, vol. 45, pp. 1712-1725, 1997.
- [44] D. T. Pham, P. Garat, and C. Jutten, "Separation of mixture of independent sources through a maximum likelihood approach," presented at the The European Signal Processing Conference (EUSIPCO) Brussels, Belgium, 1992.
- [45] A. Belouchrani and J.-F. Cardoso, "Maximum likelihood source separation for discrete sources," presented at the The European Signal Processing Conference (EUSIPCO) 1994.

-
- [46] R. Guidara, S. Hosseini, and Y. Deville, "Séparation aveugle de sources Markoviennes et non-stationnaires," presented at the Groupe d'Études du Traitement du Signal et des Images (GRETSI), Troyes, 2007.
- [47] J.-L. Lacoume, P. O. Amblard, and P. Comon, *Statistiques d'ordre supérieur pour le traitement du signal*: Masson, 1997.
- [48] A. Mansour and C. Jutten, "What should we say about the kurtosis," *IEEE Signal Processing Letters*, vol. 6, pp. 321–322, 1999.
- [49] A. Hyvärinen, "Fast and Robust Fixed-Point Algorithms for Independent Component Analysis," *IEEE Transactions on Neural Networks*, vol. 10, pp. 626–634, 1999.
- [50] J.-F. Cardoso and A. Souloumiac, "Blind beamforming for non gaussian signals," presented at the IEE Proceedings-F Radar and Signal Processing, 1993.
- [51] J.-F. Cardoso, "The three easy routes to independent component analysis: Contrasts and geometry," presented at the Independent Component Analysis (ICA), San Diego, 2001.
- [52] L. Tong, V. C. Soon, R. Liu, and Y. Huang, "AMUSE: a new blind identification algorithm," presented at the IEEE International Symposium on Circuits and Systems (ISCAS), New Orleans, Louisiana, USA, 1990.
- [53] A. Belouchrani, K. Abed-Meraim, J. F. Cardoso, and E. Moulines, "A Blind Source Separation Technique Using Second-Order Statistics," *IEEE Transactions on Signal Processing*, vol. 45, pp. 434-444, 1997.
- [54] A. Souloumiac, "Blind source detection and separation using second-order non-stationarity," presented at the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), Detroit, Michigan, USA, 1995.
- [55] D.-T. Pham and J.-F. Cardoso, "Blind separation of instantaneous mixtures of non stationary sources," *IEEE Transactions on Signal Processing*, vol. 49, pp. 1837–1848, 2000.
- [56] A. Jourjine, S. Rickard, and Ö. Yilmaz, "Blind separation of disjoint orthogonal signals Demixing N sources from 2 mixtures," presented at the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), 2000.
- [57] Ö. Yilmaz and S. Rickard, "Blind separation of speech mixtures via time-frequency masking," *IEEE Transactions on Signal Processing*, vol. 52, pp. 1830–1847, 2004.
- [58] F. Abrard and Y. Deville, "A time-frequency blind signal separation method applicable to underdetermined mixtures of dependent sources," *Signal Processing*, vol. 85, pp. 1389-1403, 2005.
- [59] Y. Deville and M. Puigt, "Temporal and time-frequency correlation-based blind source separation methods. part I : Determined and underdetermined linear instantaneous mixtures," *Signal Processing*, vol. 87, pp. 374–407, 2007.
- [60] D. Smith, J. Lukasiak, and I. Burnett, "A block-adaptative audio separation technique based upon time-frequency information," presented at the European Signal Processing Conference (EUSIPCO) Vienna, Austria, 2004.

-
- [61] Y. Deville, D. Bisseur, M. Puigt, S. Hosseini, and H. Carfantan, "A time-scale correlation-based blind separation method applicable to correlated sources," presented at the The European Symposium on Artificial Neural Networks (ESANN) Bruges, Belgium, 2006.
- [62] S. Arberet, R. Gribonval, and F. Bimbot, "A robust method to count and locate audio sources in a stereophonic linear instantaneous mixture," presented at the International Conference on Independent Component Analysis and Blind Source Separation (ICA), Charleston, South Carolina, USA, 2006.
- [63] P. Paatero and U. Tapper, "Positive matrix factorization: A non-negative factor model with optimal utilization of error estimates of data values," *Environmetrics*, vol. 5, pp. 111–126, 1994.
- [64] D. D. Lee and H. S. Seung, "Learning the parts of objects by non-negative matrix factorization," *Nature*, vol. 401, pp. 788–791, 1999.
- [65] D. D. Lee and H. S. Seung, "Algorithms for Non-Negative Matrix Factorization," presented at the Advances in Neural Information Processing Systems, 2001.
- [66] D. L. Donoho and V. Stodden, "When does non-negative matrix factorization give a correct decomposition into parts?," presented at the Neural Information Processing Systems (NIPS), British Columbia, Canada, 2003.
- [67] M. S. Karoui, "Méthodes de séparation aveugle de sources et application à la télédétection spatiale," Thèse de l'Université Paul Sabatier Toulouse III et de l'Université des Sciences et de la Technologie USTO Oran, 2012.
- [68] P. O. Hoyer, "Non-negative sparse coding," presented at the IEEE Workshop on Neural Networks for Signal Processing, 2002.
- [69] S. Wild, J. Curry, and A. Dougherty, "Improving non-negative matrix factorizations through structured initialization," *Pattern Recognition*, vol. 37, pp. 2217–2232, 2004.
- [70] C. Boutsidis and E. Gallopoulos, "SVD based initialization : A head start for nonnegative matrix factorization," *Pattern Recognition*, vol. 41, pp. 1350 – 1362, 2008.
- [71] M. Rezaei, R. Boostani, and M. Rezaei, "An efficient initialization method for nonnegative matrix factorization," *Journal of Applied Science*, vol. 11, pp. 354–359, 2010.
- [72] H. Kim and H. Park, "Sparse non-negative matrix factorizations via alternating nonnegativity-constrained least squares for microarray data analysis," *Bioinformatics*, vol. 23, pp. 1495–1502, 2007.
- [73] Z. Chen, A. Cichocki, and T. M. Rutkowski, "Constrained non-negative matrix factorization method for EEG analysis in early detection of alzheimer's disease," presented at the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), 2006.
- [74] K. Drakakis, S. Rickard, R. D. Frein, and A. Cichocki, "Analysis of financial data using non-negative matrix factorization," *International Mathematical Forum*, vol. 3, pp. 1853–1870, 2008.
- [75] A. Cichocki, R. Zdunek, and S.-I. Amari. (2008) Nonnegative matrix and tensor factorization. *IEEE Signal Processing Magazine*. 142-145.

-
- [76] C.-J. Lin, "Projected gradient methods for non-negative matrix factorization," *Neural Computation*, vol. 19, pp. 2756–2779, 2009.
- [77] A. Cichocki and R. Zdunek, "Multilayer nonnegative matrix factorization using projected gradient approaches," *International Journal of Neural Systems*, vol. 17, pp. 431-446, 2007.
- [78] R. Zdunek and A. Cichocki, "Fast nonnegative matrix factorization algorithms using projected gradient approaches for large-scale problems," *Computational Intelligence and Neuroscience*, vol. 3, pp. 1-3, 2008.
- [79] C.-J. Lin, "Nonnegative matrix factorization based on alternating nonnegativity-constrained least squares and the active set method," *SIAM Journal in Matrix Analysis and Applications*, vol. 30, pp. 713–730, 2008.
- [80] P. Paatero and U. Tapper, "Least squares formulation of robust non-negative factor analysis," *Chemometrics and Intelligent Laboratory Systems*, vol. 37, pp. 23-35, 1997.
- [81] Y. Deville and L. T. Duarte, "An overview of blind source separation methods for linear-quadratic and post-nonlinear mixtures," presented at the 12th International Conference on Latent Variable Analysis and Signal Separation (LVA/ICA), Liberec, Czech Republic, 2015.
- [82] M. Krob and M. Benidir, "Blind identification of a linear-quadratic mixture: application to quadratic phase coupling estimation," presented at the IEEE Signal Processing Workshop on Higher-Order Statistics, 1993.
- [83] K. Abed-Meraim, A. Belouchrani, and Y. Hua, "Blind identification of a linear-quadratic mixture of independent components based on joint diagonalization procedure," presented at the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), Atlanta, GA, USA, 1996.
- [84] S. Hosseini and Y. Deville, "Blind separation of linear-quadratic mixtures of real sources using a recurrent structure," presented at the International Work-Conference on Artificial and Natural Neural Networks: Part II: Artificial Neural Nets Problem Solving Methods (IWANN), 2003.
- [85] S. Hosseini and Y. Deville, "Blind maximum likelihood separation of a linear-quadratic mixture," *Independent Component Analysis and Blind Signal Separation*, pp. 694–701, 2004.
- [86] C. Jutten and J. Herault, "Blind separation of sources, part I: An adaptive algorithm based on neuromimetic architecture," *Signal Processing*, vol. 24, pp. 1-10, 1991.
- [87] Y. Deville and S. Hosseini, "Recurrent networks for separating extractable-target nonlinear mixtures. Part I: non-blind configurations," *Signal Processing*, vol. 89, pp. 378–393, 2009.
- [88] Y. Deville and S. Hosseini, "Blind operation of a recurrent neural network for linear quadratic source separation: fixed points, stabilization and adaptation scheme," presented at the International conference on Latent variable analysis and signal separation, LVA/ICA, 2010.
- [89] F. Mokhtari, M. Babaie-Zadeh, and C. Jutten, "Blind separation of bilinear mixtures using mutual information minimization," presented at the IEEE International Workshop on Machine Learning for Signal Processing (MLSP), 2009.
- [90] F. Merrikh-Bayat, M. Babaie-Zadeh, and C. Jutten, "Linear-quadratic blind source separating structure for removing show-through in scanned documents," *International Journal on Document Analysis and Recognition*, vol. 14, pp. 319–333, 2011.

-
- [91] Y. Deville and S. Hosseini, "Blind identification and separation methods for linearquadratic mixtures and/or linearly independent non-stationary signals," presented at the International Symposium on Signal Processing and Its Applications (ISSPA), 2007.
- [92] L. T. Duarte, R. A. Ando, R. Attux, Y. Deville, and C. Jutten, "Separation of sparse signals in overdetermined linear-quadratic mixtures," presented at the International conference on Latent Variable Analysis and Signal Separation (LVA/ICA), 2012.
- [93] I. Meganem, "Méthodes de Séparation Aveugle de Sources pour l'imagerie hyperspectrale. Application à la télédétection urbaine et à l'astrophysique," Thèse de l'Université Paul Sabatier, Toulouse III, 2012.
- [94] D. Benachir, "Méthodes de séparation aveugle de sources pour le démixage d'images de télédétection," Thèse de l'Université Paul Sabatier, Toulouse III, 2014.
- [95] J. Boardman, "Automating spectral unmixing of AVIRIS data using convex geometry concepts," presented at the JPL, Summaries of the 4th Annual JPL Airborne Geoscience Workshop. Volume 1: AVIRIS Workshop, Washington, D.C., 1993.
- [96] M. E. Winter, "N-Findr: an algorithm for fast autonomous spectral end-member determination in hyperspectral data," presented at the SPIE conference on Imaging Spectrometry Denver, Colorado, USA, 1999.
- [97] J. Gruninger, A. J. Ratkowski, and M. L. Hoke, "The sequential maximum angle convex cone (SMACC) endmember model," in Algorithms for Multispectral, Hyperspectral and Ultraspectral Imagery," presented at the The International Society for Optical Engineering (SPIE), 2004.
- [98] J. M. P. Nascimento and J. M. B. Dias, "Vertex component analysis: a fast algorithm to unmix hyperspectral data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, pp. 898-910, 2005.
- [99] L. Miao and H. Qi, "Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, pp. 765-777, 2007.
- [100] J. Li and J. M. Bioucas-Dias, "Minimum volume simplex analysis : a fast algorithm to unmix hyperspectral data," presented at the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Boston, Massachusetts, USA, 2008.
- [101] J. M. Bioucas-Dias, "A Variable Splitting Augmented Lagrangian Approach to Linear Spectral Unmixing," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing (WHISPERS), Grenoble, France, 2009.
- [102] J. M. Bioucas-Dias and J. M. P. Nascimento, "Hyperspectral subspace identification," *IEEE Transactions on Geoscience and Remote Sensing (TGRS)*, vol. 46, pp. 2435-2445, 2008.
- [103] C.-I. Chang and Q. Du, "Estimation of number of spectrally distinct signal sources in hyperspectral imagery," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, pp. 608-619, 2004.
- [104] C.-I. Chang and D. C. Heinz, "Constrained subpixel target detection for remotely sensed imagery," *IEEE Transactions on Geoscience and Remote Sensing (TGRS)*, vol. 38, pp. 1144-1159, 2000.

-
- [105] D. C. Heinz and C.-I. Chang, "Fully constrained least-squares linear spectral mixture analysis method for material quantification in hyperspectral imagery," *IEEE Transactions on Geoscience and Remote Sensing (TGRS)*, vol. 29, pp. 529–545, 2001.
- [106] C. Theys, N. Dobigeon, J. Y. Tourneret, and H. Lantéri, "Linear unmixing of hyperspectral images using a scaled gradient method," presented at the IEEE-SP Workshop Stat. and Signal Processing (SSP), Cardiff, UK, 2009.
- [107] N. Dobigeon, S. Moussaoui, J.-Y. Tourneret, and C. Carteret, "Bayesian separation of spectral sources under non-negativity and full additivity constraints," *Signal Processing*, vol. 89, pp. 2657–2669, 2009.
- [108] J. Bayliss, J. A. Gualtieri, and R. F. Crompt, "Analyzing hyperspectral data with independent component analysis," presented at the SPIE AIPR Workshop: Exploiting New Image Sources and Sensors, Washington, DC, United States, 1997.
- [109] B. A. Pearlmutter and L. Parra, "A context-sensitive generalization of ICA," presented at the International Conference on Neural Information Processing, 1996.
- [110] J. Wang and C.-I. Chang, "Applications of independent component analysis in endmember extraction and abundance quantification for hyperspectral imagery," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, pp. 2601–2616, 2006.
- [111] J. M. P. Nascimento and J. M. Bioucas-Dias, "Does independent component analysis play a role in unmixing hyperspectral data ?," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, p. 175187, 2005.
- [112] D. Benachir, S. Hosseini, Y. Deville, M. S. Karoui, and A. Hameurlain, "Modified Independent Component Analysis for Initializing Non-negative Matrix Factorization : An approach to Hyperspectral Image Unmixing," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS), Gainesville, United States, 2013.
- [113] D. Benachir, S. Hosseini, Y. Deville, M. S. Karoui, and A. Hameurlain, "Modified Independent Component Analysis for Initializing Non-negative Matrix Factorization : An approach to Hyperspectral Image Unmixing," presented at the International Workshop on Electronics, Control, Modelling, Measurement and Signals (ECMS), Toulouse, France, 2013.
- [114] M. S. Karoui, Y. Deville, S. Hosseini, and A. Ouamri, "Blind spatial unmixing of multispectral images : New methods combining sparse component analysis, clustering and non-negativity constraints," *Pattern Recognition*, vol. 45, pp. 4263–4278, 2012.
- [115] M. S. Karoui, Y. Deville, S. Hosseini, and A. Ouamri, "Blind unmixing of remote sensing data with some pure pixels: Extension and comparison of spatial methods exploiting sparsity and nonnegativity properties," presented at the International Workshop on Systems, Signal Processing and their Applications (WoSSPA), Alger, Algérie, 2013.
- [116] M. S. Karoui, Y. Deville, S. Hosseini, and A. Ouamri, "Blind Unmixing of Hyperspectral Data With Some Pure Pixels: Spatial Variance-based Methods Exploiting Sparsity and Non-negativity Properties," in *Signal Processing: New Research*, G. R. Naik, Ed., ed: Nova Science, pp. 161–182.

-
- [117] M. S. Karoui, Y. Deville, S. Hosseini, and A. Ouamri, "A New Spatial Sparsity-Based Method For Extracting Endmember Spectra From Hyperspectral Data With Some Pure Pixels," presented at the International IEEE Geoscience and Remote Sensing Symposium (IGARSS) Munich, Germany, 2012.
- [118] R. N. Clark, G. A. Swayze, R. Wise, E. Livo, T. Hoefen, R. Kokaly, and S. J. Sutley. USGS digital spectral library splib06a, U. S. Geological Survey," Digital Data Series, 231 [Online]. Available: <http://speclab.cr.usgs.gov/spectral.lib06/>.
- [119] <http://www.tec.army.mil/hypercube>.
- [120] W.-K. Ma, J. M. Bioucas-Dias, N. G. T.-H. Chan, P. Gader, A. J. Plaza, A. Ambikapathi, and C.-Y. Chi, "A signal processing perspective on hyperspectral unmixing : insights from remote sensing," *IEEE Signal Processing Magazine*, vol. 31, pp. 67-81, 2014.
- [121] O. Eches, "Méthodes Bayésiennes pour le démixage d'images hyperspectrales," Thèse de l'Institut Polytechnique de Toulouse, 2010.
- [122] P. Huard and R. Marion, "Study of non-linear mixing in hyperspectral imagery - a first attempt in the laboratory," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing Evolution in Remote Sensing (WHISPERS), 2011.
- [123] J. Broadwater and A. Banerjee, "Mapping intimate mixtures using an adaptive kernel based technique," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS), 2011.
- [124] N. Dobigeon, J.-Y. Tourneret, C. Richard, J. C. M. Bermudez, S. McLaughlin, and A. O. Hero. (2014) Nonlinear unmixing of hyperspectral images: models and algorithms. *IEEE Signal Processing Magazine*. 82–94.
- [125] R. Heylen, D. Burazerovic, and P. Scheunders, "Non-linear spectral unmixing by geodesic simplex volume maximization," *IEEE Journal of Selected Topics in Signal Processing*, vol. 5, pp. 534-542, 2011.
- [126] H. Nguyen, C. Richard, P. Honeine, and C. Theys, "Hyperspectral image unmixing using manifold learning methods. derivations and comparative tests," presented at the IEEE Geosci. Remote Sens. (IGARSS), Munich, Germany, 2012.
- [127] G. Licciardi, X. Ceamanos, S. Doute, and J. Chanussot, "Unsupervised nonlinear spectral unmixing by means of NLPKA applied to hyperspectral imagery," presented at the IEEE Geosci. Remote Sens. (IGARSS), Munich, Germany, 2012.
- [128] J. Broadwater, R. Chellappa, A. Banerjee, and P. Burlina, "Kernel fully constrained least squares abundance estimates," presented at the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Barcelona, Spain., 2007.
- [129] J. Chen, C. Richard, and P. Honeine, "Nonlinear Unmixing of Hyperspectral Data Based on a Linear-Mixture/Nonlinear-Fluctuation Model," *IEEE Transactions on Signal Processing* vol. 61, pp. 480-492, 2013.
- [130] Y. Altmann, N. Dobigeon, S. McLaughlin, and J.-Y. Tourneret, "Nonlinear spectral unmixing of hyperspectral images using Gaussian processes," *IEEE Transactions on Signal Processing*, vol. 61, pp. 2442–2453, 2013.

-
- [131] W. Fan, B. Hu, J. Miller, and M. Li, "Comparative study between a new nonlinear model and common linear model for analyzing laboratory simulated-forest hyperspectral data," *International Journal of Remote Sensing*, vol. 30, pp. 2951-2962, 2009.
- [132] B. Somers, K. Cools, S. Delalieux, J. Stuckens, D. V. d. Zande, W. W. Verstraeten, and P. Coppin, "Nonlinear hyperspectral mixture analysis for tree cover estimates in orchards," *Remote Sensing of Environment*, vol. 113, pp. 1183-1193, 2009.
- [133] J. M. P. Nascimento and J. M. Bioucas-Dias, "Learning dependent sources using mixtures of Dirichlet : Applications on hyperspectral unmixing," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS), 2009.
- [134] A. Halimi, Y. Altmann, N. Dobigeon, and J.-Y. Tourneret, "Nonlinear unmixing of hyperspectral images using a generalized bilinear model," *IEEE Transactions on Geoscience and Remote Sensing (TGRS)*, vol. 49, pp. 4153–4162, 2011.
- [135] C. Thomas, S. Doz, X. Briottet, and S. Lachérade, "AMARTIS v2: 3D Radiative Transfer Code in the [0.4; 2.5 μ m] Spectral Domain Dedicated to Urban Areas," *Remote Sensing*, vol. 3, pp. 1914-1942, 2011.
- [136] Y. Altmann, A. Halimi, N. Dobigeon, and J.-Y. Tourneret, "Supervised Nonlinear Spectral Unmixing Using a Postnonlinear Mixing Model for Hyperspectral Imagery," *IEEE Transactions Image Processing* vol. 21, pp. 3017-3025, 2012.
- [137] P. Gader, D. Dranishnikov, A. Zare, and J. Chanussot, "A sparsity promoting bilinear unmixing model," presented at the IEEE Workshop on Hyperstectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS), Shanghai, China, 2012.
- [138] A. Zare and P. Gader, "Sparsity promoting iterated constrained endmember detection in hyperspectral imagery," *IEEE Geosci. and Remote Sensing Letter*, vol. 4, pp. 446-450, 2007.
- [139] N. Yokoya, J. Chanussot, and A. Iwasaki, "Generalized bilinear model based nonlinear unmixing using semi-nonnegative matrix factorization.," presented at the IEEE Conf. Geosci. And remote sensing (IGARSS), 2012.
- [140] L. Jarboui, S. Hosseini, Y. Deville, R. Guidara, and A. B. Hamida, "New Unsupervised Method for Hyperspectral Image Unmixing Using a Linear-quadratic Model," presented at the IEEE ATSP, Sousse, Tunisia, 2014.
- [141] G. H. Golub and C. F. V. Loan, *Matrix Computations, Third Edition*: The Johns Hopkins University Press, 1996.
- [142] C.-I. Chang, "Spectral Information Divergence for Hyperspectral Image Analysis," presented at the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Hamburg, Germany, 1999.
- [143] A. M. Baldridge, S. J. Hook, C. I. Grove, and G. Rivera, "The ASTER Spectral Library Version 2.0," *Remote Sensing of Environment*, vol. 113, pp. 711-715, 2009.
- [144] C.-I. Chang, *Hyperspectral imaging techniques for spectral detection and classification*, 2nd ed., 2003.
- [145] R. Gomez, A. Jazaeri, and M. Kafatos, "Wavelet-based hyperspectral and multispectral image fusion," presented at the The International Society for Optical Engineering (SPIE), 2001.

-
- [146] L. Loncan, L. B. Almeida, J. M. Bioucas-Dias, X. Briottet, J. Chanussot, N. Dobigeon, S. Fabre, W. Liao, G. A. Licciardi, M. Simões, J.-Y. Tournieret, M. A. Veganzones, G. Vivone, Q. Wei, and N. Yokoya. (2015) Hyperspectral pansharpening: a review. *IEEE Geoscience and Remote Sensing Magazine*. 27-46.
- [147] C. Thomas, T. Ranchin, L. Wald, and J. Chanussot, "Synthesis of Multispectral Images to High Spatial Resolution: A Critical Review of Fusion Methods Based On Remote Sensing Physics," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 46, pp. 1301-1312, 2008.
- [148] L. Alparone, L. Wald, J. Chanussot, C. Thomas, P. Gamba, and L. Bruce, "Comparison of pansharpening algorithms: outcome of the 2006 GRS-S data-fusion contest," *IEEE Transaction on Geoscience and Remote Sensing (TGRS)*, vol. 45, pp. 3012–3021, 2007.
- [149] M. T. Eismann and R. C. Hardie, "Hyperspectral resolution enhancement using high-resolution multispectral imagery with arbitrary response functions," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, pp. 455-465, 2005.
- [150] F. Palsson, J. R. Sveinsson, M. O. Ulfarson, and J. A. Benediktsson, "Model-Based Fusion of Multi- and Hyperspectral Images Using PCA and Wavelets," *IEEE Transactions on Geoscience and Remote Sensing (TGRS)*, vol. 53, pp. 2652-2663, 2015.
- [151] Q. Wei, N. Dobigeon, and J.-Y. Tournieret, "Bayesian Fusion of Hyperspectral and Multispectral Images," presented at the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2014.
- [152] Q. Wei, J. M. Bioucas-Dias, N. Dobigeon, and J.-Y. Tournieret, "Hyperspectral and Multispectral Images Fusion Based on a Sparse Representation," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, pp. 3658-3668, 2015.
- [153] H. Song, B. Huang, K. Zhang, and H. Zhang, "Spatio-spectral fusion of satellite images based on dictionary-pair learning," *Journal Information Fusion*, vol. 18, pp. 148-160, 2014.
- [154] A. Cichocki, R. Zdunek, A. H. Phan, and S. I. Amari, *Nonnegative Matrix and Tensor Factorizations : Applications to Exploratory Multi-Way Data Analysis and Blind Source Separation*. Chichester, UK, 2009.
- [155] O. Berné, A. Tielens, P. Pilleri, and C. Joblin, "Non-negative matrix factorization Pansharpening of Hyperspectral data: An application to mid-infrared astronomy," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing (WHISPERS), Reykjavik, Iceland, 2010.
- [156] N. Yokoya, T. Yairi, and A. Iwasaki, "Coupled Nonnegative Matrix Factorization Unmixing for Hyperspectral and Multispectral Data Fusion," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, pp. 528-537, 2012.
- [157] G. Vivone, R. Restaino, G. Licciardi, M. D. Mura, and J. Chanussot, "MultiResolution Analysis and Component Substitution techniques for hyperspectral Pansharpening," presented at the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Quebec City, QC, Canada, 2014.
- [158] W. J. Carper, T. M. Lillesand, and R. W. Kiefer, "The Use of Intensity-Hue-Saturation Transformations for Merging SPOT Panchromatic and Multispectral Image Data," *Photogrammetric Engineering and Remote Sensing*, vol. 56, pp. 459–467, 1990.

-
- [159] P. S. C. Jr., S. C. Sides, and J. A. Anderson, "Comparison of Three Different Methods to Merge Multiresolution and Multispectral Data: Landsat TM and SPOT Panchromatic," *Photogrammetric Engineering and Remote Sensing*, vol. 57, pp. 265-303, 1991.
- [160] T. M. Tu, P. S. Huang, C. L. Hung, and C. P. Chang, "A fast intensity-hue-saturation fusion technique with spectral adjustment for IKONOS imagery," *IEEE Geoscience and Remote Sensing Letters*, vol. 1, pp. 309–312, 2004.
- [161] L. Fonseca, L. Namikawa, E. Castejon, L. Carvalho, C. Pinho, and A. Pagamisse, *Image Fusion for Remote Sensing Applications, Image Fusion and Its Applications*, 2011.
- [162] I. T. Jolliffe, *Principal Component Analysis*, 2 ed.: Springer-Verlag New York, 2002.
- [163] G. A. Licciardi, M. M. Khan, J. Chanussot, A. Montanvert, L. Condat, and C. Jutten, "Fusion of Hyperspectral and Panchromatic Images Using Multiresolution Analysis and Nonlinear PCA Band Reduction," presented at the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Vancouver, BC, Canada, 2011.
- [164] C. Laben and B. Brower, "Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening," US6011875 A, 1998.
- [165] B. Aiazzi, S. Baronti, F. Lotti, and M. Selva, "A comparison between global and contextadaptive pansharpening of multispectral images," *IEEE Geoscience and Remote Sensing Letters*, vol. 6, pp. 302–306, 2009.
- [166] B. Aiazzi, S. Baronti, and M. Selva, "Improving component substitution Pansharpening through multivariate regression of MS+Pan data," *IEEE Transaction on Geoscience and Remote Sensing (TGRS)*, vol. 45, pp. 3230–3239, 2007.
- [167] B. Aiazzi, S. Baronti, M. Selva, and L. Alparone, "Enhanced Gram-Schmidt spectral sharpening based on multivariate regression of MS and pan data," presented at the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Denver, CO, USA, 2006.
- [168] S. Rahmani, M. Strait, D. Merkurjev, M. Moeller, and T. Wittman, "An Adaptive IHS Pan-Sharpener Method," *IEEE Geoscience and Remote Sensing Letters*, vol. 7, pp. 746 - 750, 2010.
- [169] T. Ranchin and L. Wald, "Fusion of high spatial and spectral resolution images: the ARSIS concept and its implementation," *Photogrammetric engineering and remote sensing*, vol. 66, pp. 49–61, 2000.
- [170] J. G. Liu, "Smoothing filter based intensity modulation: a spectral preserve image fusion technique for improving spatial details," *International Journal of Remote Sensing*, vol. 21, pp. 3461-3472, 2000.
- [171] P. J. Burt and E. H. Adelson, "The Laplacian pyramid as a compact image code," *Transactions IEEE sur les communications*, vol. 31, pp. 532–540, 1983.
- [172] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, pp. 674–693, 1989.
- [173] L. Wald and T. Ranchin, "Comment: Liu 'Smoothing filter-based intensity modulation: A spectral preserve image fusion technique for improving spatial details,'" *International Journal of Remote Sensing*, vol. 23, pp. 593–597, 2002.

-
- [174] M. G. Kim, I. Dinstein, and L. Shaw, "A Prototype Filter Design Approach to Pyramid Generation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 15, pp. 1233-1240 1993.
- [175] M. González-Audicana, X. Otazu, O. Fors, and A. Seco, "Comparison between Mallat's and the 'à trous' discrete wavelet transform based algorithms for the fusion of multispectral and panchromatic images," *Journal International Journal of Remote Sensing*, vol. 26, pp. 595-614, 2005.
- [176] K. Amolins, Y. Zhang, and P. Dare, "Wavelet based image fusion techniques-An introduction, review and comparison," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 62, pp. 249-263, 2007.
- [177] D. A. Yocky, "Image merging and data fusion by means of the discrete two-dimensional wavelet transform," *Journal of the Optical Society of America A: Optics, Image Science, and Vision*, vol. 12, pp. 1834-1841, 1995.
- [178] B. Garguet-Duport, J. Girel, J. M. Chassery, and G. Pautou, "The use of multiresolution analysis and wavelets transform for merging SPOT panchromatic and multispectral image data," *Photogrammetric Engineering and Remote Sensing*, vol. 62, pp. 1057-1066, 1996.
- [179] J. Zhou, D. L. Civco, and J. A. Silander, "A wavelet transform method to merge Landsat TM and SPOT panchromatic data," *International Journal of Remote Sensing*, vol. 19, pp. 743-757 1998.
- [180] J. Nunez, X. Otazu, O. Fors, A. Prades, V. Pala, and R. Arbiol, "Multiresolution-based image fusion with additive wavelet decomposition," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, pp. 1204 - 1211, 1999.
- [181] Y. Chibani and A. Houacine, "The joint use of IHS transform and redundant wavelet decomposition for fusing multispectral and panchromatic images," *International Journal of Remote Sensing*, vol. 23, pp. 3821-3833, 2002.
- [182] T. Ranchin, B. Aiazzi, L. Alparone, S. Baronti, and L. Wald, "Image fusion: the ARSIS concept and some successful implementation schemes," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 58, pp. 4-18, 2003.
- [183] G. Sapiro, *Geometric Partial Differential Equations and Image Processing*: Cambridge University Press, 2001.
- [184] T. Chan, J. Shen, and L. Vese, "Variational PDE models in image processing," *Notices of the AMS*, vol. 50, pp. 14-26, 2003.
- [185] G. Aubert and P. Kornprobst, *Mathematical Problems in Image Processing: Partial Differential Equations and the Calculus of Variations (Applied Mathematical Sciences) 2nd Edition*: New York, NY, USA: Springer-Verlag, 2009.
- [186] C. Ballester, V. Caselles, L. Igual, J. Verdera, and B. Rougé, "A variational model for P+XS image fusion," *International Journal of Computer Vision*, vol. 69, pp. 43-58, 2006.
- [187] M. A. Bendoumi, M. He, and S. Mei, "Hyperspectral image resolution enhancement using high-resolution multispectral image based on spectral unmixing," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, pp. 6574-6583, 2014.

-
- [188] J. Bieniarz, D. Cerra, J. Avbelj, P. Reinartz, and R. Müller, "Hyperspectral image resolution enhancement based on spectral unmixing and information fusion," presented at the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2011.
- [189] Y. Deville, *Blind Source Separation and Blind Mixture Identification Methods*: Wiley Encyclopedia of Electrical and Electronics Engineering, 2016.
- [190] N. Yokoya, C. Grohnfeldt, and J. Chanussot. (2017) Hyperspectral and Multispectral Data Fusion A comparative review of the recent literature. *IEEE Geoscience and Remote Sensing Magazine*. 29-56.
- [191] Q. Wei, N. Dobigeon, and J.-Y. Tourneret, "Bayesian fusion of multiband images," *IEEE Journal of Selected Topics in Signal Processing*, vol. 9, pp. 1117 -1127, 2015.
- [192] R. C. Hardie, M. T. Eismann, and G. L. Wilson, "MAP estimation for hyperspectral image resolution enhancement using an auxiliary sensor," *IEEE Transactions Image Processing*, vol. 13, pp. 1174–1184, 2004.
- [193] Y. Zhang, S. D. Backer, and P. Scheunders, "Noise-resistant wavelet based Bayesian fusion of multispectral and hyperspectral images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, pp. 3834 –3843, 2009.
- [194] G. Z. Rong, W. Bin, and Z. L. Ming, "Remote sensing image fusion based on Bayesian linear estimation," *Science in China Series F: Information Sciences*, vol. 50, pp. 227-240 2007.
- [195] M. S. Karoui, K. Djerriri, and I. Boukerch, "Pansharpening multispectral remote sensing data by multiplicative joint nonnegative matrix factorization," *International Journal of Remote Sensing*, vol. 37, pp. 805-818, 2016.
- [196] M. S. Karoui, I. Boukerch, and K. Djerriri, "Joint spatial variables nonnegative matrix factorization using constrained gradient method to pansharpen multispectral images," presented at the IEEE 12th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP), Bordeaux, France, 2016.
- [197] N. Farhi, M. S. Karoui, K. Djerriri, and I. Boukerch, "Pansharpening remotely sensed data by using Nonnegative Matrix Factorization and spectral-spatial degradation models," presented at the SPIE Image and Signal Processing for Remote Sensing, 2016.
- [198] N. Yokoya, T. Yairi, and A. Iwasaki, "Hyperspectral, multispectral, and panchromatic data fusion based on coupled non-negative matrix factorization," presented at the IEEE Workshop on Hyperspectral Image and Signal Processing (WHISPERS), Lisbon, Portugal, 2011.
- [199] D. J. Kim, Y. W. Park, and D. J. Park, "A Novel Validity Index for determination of the optimal number of clusters," *IEICE Transactions on Information and Systems*, vol. E84-D, pp. 281-285, 2001.
- [200] P. P. Gajjar, M. V. Joshi, A. Banerjee, and S. Mitra, "Decimation estimation and linear model-based super-resolution using zoomed observations," *Pattern Recognition and Image Analysis (Computer Science)*, vol. 4477, pp. 314–321, 2007.
- [201] <http://desktop.arcgis.com/fr/arcmap/10.3/manage-data/las-dataset/what-is-lidar-data-.htm>.

-
- [202] C. Debes, A. Merentitis, R. Heremans, J. Hahn, N. Frangiadakis, T. V. Kasteren, W. Liao, R. Bellens, A. Pizurica, S. Gautama, W. Philips, S. Prasad, Q. Du, and F. Pacifici, "Hyperspectral and LiDAR Data Fusion: Outcome of the 2013 GRSS Data Fusion Contest," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, pp. 2405-2418, 2014.
- [203] M. García, D. Riaño, E. Chuvieco, J. Salas, and F. M. Danson, "Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules," *Remote Sensing of Environment*, vol. 115, pp. 1369-1379, 2011.
- [204] A. Swatantran, R. Dubayah, D. Roberts, M. Hofton, and J. B. Blair, "Mapping biomass and stress in the Sierra Nevada using lidar and hyperspectral data fusion," *Remote Sensing of Environment*, vol. 115, pp. 2917-2930, 2011.
- [205] Z. Wang and A. C. Bovik, "A universal image quality index," *IEE Signal Processing*, vol. 9, pp. 81-84, 2002.
- [206] L. Wald, *Definitions and Architectures: Fusion of Images of Different Spatial Resolutions*: Presses de l'Ecole, Ecole des Mines de Paris, Paris, France, 2002.
- [207] L. Alparone, B. Aiazzi, S. Baronti, A. Garzelli, F. Nencini, and M. Selva, "Multispectral and Panchromatic Data Fusion Assessment Without Reference," *Photogrammetric Engineering & Remote Sensing*, vol. 74, pp. 193-200, 2008.

Publications scientifiques de l'auteur

Articles de revues internationales

M. S. Karoui, Y. Deville, **F. Z. Benhalouche**, and I. Boukerch, "Hypersharpener by Joint-Criterion Nonnegative Matrix Factorization," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, pp. 1660-1670, 2017.

F. Z. Benhalouche, M. S. Karoui, Y. Deville, and A. Ouamri, "Hyperspectral and multispectral data fusion based on linear-quadratic nonnegative matrix factorization," *Journal of Applied Remote Sensing*, vol. 11(2), pp. 025008-1-18, 2017.

Actes de conférences internationales avec comité de lecture

F. Z. Benhalouche, M. S. Karoui, Y. Deville, and A. Ouamri, "Hyperspectral Data Multi-sharpener based on Linear-Quadratic Nonnegative Matrix Factorization," presented at the *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Milano, Italy, 2015.

F. Z. Benhalouche, M. S. Karoui, Y. Deville, and A. Ouamri, "Local Hyperspectral Data Multi-Sharpener Based On Linear/Linear-Quadratic Nonnegative Matrix Factorization by Integrating Lidar Data," presented at the *SPIE Remote Sensing*, Toulouse, France, 2015.

F. Z. Benhalouche, Y. Deville, M. S. Karoui, and A. Ouamri, "Bilinear matrix factorization using a gradient method for hyperspectral endmember spectra extraction," presented at the *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Beijing, China, 2016.

F. Z. Benhalouche, Y. Deville, M. S. Karoui, and A. Ouamri, "Hyperspectral endmember spectra extraction based on constrained linear-quadratic matrix factorization using a projected gradient method," presented at the *IEEE International Workshop on Machine Learning for Signal Processing (MLSP)*, Vietri sul Mare, Italy, 2016.

F. Z. Benhalouche, M. S. Karoui, Y. Deville, I. Boukerch, and A. Ouamri, "Multi-sharpener hyperspectral remote sensing data by Multiplicative Joint-Criterion Linear-Quadratic Nonnegative Matrix Factorization," presented at the *IEEE International Workshop of Electronics, Control, Measurement, Signals and their Application to Mechatronics (ECMSM)*, 2017, pp. 1-6.

AUTEUR : Fatima Zohra BENHALOUCHE

TITRE : Méthodes de démixage et de fusion des images multispectrales et hyperspectrales de télédétection spatiale.

SOUTENANCE :

NATURE DE LA THESE : Thèse en cotutelle Franco-Algérienne.

PARTIE FRANÇAISE :

Université : Université Toulouse III - Paul Sabatier.

École Doctorale : Mathématiques, Informatique et Télécommunications de Toulouse.

Discipline ou spécialité : Signal, Image, Acoustique & Optimisation.

Unité de recherche : Institut de Recherche en Astrophysique et Planétologie.

Directeur de thèse : Yannick DEVILLE.

Encadrant : Moussa Sofiane KAROUI.

PARTIE ALGERIENNE :

Université : Université des Sciences et de la Technologie d'Oran - Mohamed Boudiaf.

Discipline ou spécialité : Techniques modernes de l'information et de la communication.

Laboratoire de recherche : Laboratoire Signaux et Images.

Directeur de thèse : Abdelaziz OUAMRI.

Encadrant : Moussa Sofiane KAROUI.

Méthodes de démélange et de fusion des images multispectrales et hyperspectrales de télédétection spatiale

Au cours de cette thèse, nous nous sommes intéressés à deux principales problématiques de la télédétection spatiale de milieux urbains qui sont : le "démélange spectral" et la "fusion".

Dans la première partie de la thèse, nous avons étudié le démélange spectral d'images hyperspectrales de scènes de milieux urbains. Les méthodes développées ont pour objectif d'extraire, d'une manière non-supervisée, les spectres des matériaux présents dans la scène imagée. Le plus souvent, les méthodes de démélange spectral (méthodes dites de séparation aveugle de sources) sont basées sur le modèle de mélange linéaire. Cependant, lorsque nous sommes en présence de paysage non-plat, comme c'est le cas en milieu urbain, le modèle de mélange linéaire n'est plus valide et doit être remplacé par un modèle de mélange non-linéaire. Ce modèle non-linéaire peut être réduit à un modèle de mélange linéaire-quadratique/bilinéaire. Les méthodes de démélange spectral proposées sont basées sur la factorisation matricielle avec contrainte de non-négativité, et elles sont conçues pour le cas particulier de scènes urbaines. Les méthodes proposées donnent généralement de meilleures performances que les méthodes testées de la littérature.

La seconde partie de cette thèse a été consacrée à la mise en place de méthodes qui permettent la fusion des images multispectrale et hyperspectrale, afin d'améliorer la résolution spatiale de l'image hyperspectrale. Cette fusion consiste à combiner la résolution spatiale élevée des images multispectrales et la haute résolution spectrale des images hyperspectrales. Les méthodes mises en place sont des méthodes conçues pour le cas particulier de fusion de données de télédétection de milieux urbains. Ces méthodes sont basées sur des techniques de démélange spectral linéaire-quadratique et utilisent la factorisation en matrices non-négatives. Les résultats obtenus montrent que les méthodes développées donnent globalement des performances satisfaisantes pour la fusion des données hyperspectrale et multispectrale. Ils prouvent également que ces méthodes surpassent significativement les approches testées de la littérature.

Mots-clés: Imagerie hyper/multispectrale, amélioration de la résolution spatiale/spectrale, démélange spectral linéaire-quadratique/bilinéaire, factorisation en matrices non-négatives linéaire-quadratique/bilinéaire, fusion de données.

Unmixing and fusion methods for remote sensing multispectral and hyperspectral images

In this thesis, we focused on two main problems of the spatial remote sensing of urban environments which are: "spectral unmixing" and "fusion". In the first part of the thesis, we are interested in the spectral unmixing of hyperspectral images of urban scenes. The developed methods are designed to unsupervisedly extract the spectra of materials contained in an imaged scene. Most often, spectral unmixing methods (methods known as blind source separation) are based on the linear mixing model. However, when facing non-flat landscape, as in the case of urban areas, the linear mixing model is not valid any more, and must be replaced by a nonlinear mixing model. This nonlinear model can be reduced to a linear-quadratic/bilinear mixing model. The proposed spectral unmixing methods are based on matrix factorization with non-negativity constraint, and are designed for urban scenes. The proposed methods generally give better performance than the tested literature methods.

The second part of this thesis is devoted to the implementation of methods that allow the fusion of multispectral and hyperspectral images, in order to improve the spatial resolution of the hyperspectral image. This fusion consists in combining the high spatial resolution of multispectral images and high spectral resolution of hyperspectral images. The implemented methods are designed for urban remote sensing data. These methods are based on linear-quadratic spectral unmixing techniques and use the non-negative matrix factorization. The obtained results show that the developed methods give good performance for hyperspectral and multispectral data fusion. They also show that these methods significantly outperform the tested literature approaches.

Keywords: Hyper/multispectral imaging, spatial/spectral resolution enhancement, linear-quadratic/bilinear spectral unmixing, linear-quadratic/bilinear nonnegative matrix factorization, data fusion, multi-sharpening.

طرق الفصل الطيفي ودمج صور الاستشعار عن بعد متعددة الأطياف و جد متعددة الأطياف

في هذه الرسالة، ركزنا على مشكلتين رئيسيتين للاستشعار عن بعد للبيانات الحضرية وهما : "الفصل الطيفي" و "الدمج".

في الجزء الأول من الأطروحة، إهتمنا بالفصل الطيفي لصور الاستشعار عن بعد جد متعددة الأطياف للبيانات الحضرية. تم تصميم طرق لاستخراج، بطريقة غير خاضعة للرقابة، أطياف المواد الموجودة في المكان المصور. في معظم الأحيان، تستند طرق الفك الطيفي (الطرق المعروفة باسم الفصل المكثف للمصادر) إلى نموذج الخلط الخطي. لكن عند دراسة مناظر طبيعية غير مسطحة، كما هو الحال في المناطق الحضرية، نموذج الخلط الخطي لا يصبح صالحا، ويجب أن يحل محله نموذج خلط غير خطي. يمكن تخفيض هذا النموذج الغير الخطي إلى نموذج خلط خطي/تربيعي/ثنائي خطي. تستند طرق فك الطيفي المقترحة على تحليل إلى مصفوفات غير سلبية، مصممة لمشاهد حضرية. الطرق المقترحة عموما تعطي أداء أفضل مقارنة مع الطرق التقليدية.

أما الجزء الثاني من هذه الأطروحة، فقد خصص لتنفيذ الأساليب التي تسمح بدمج صور متعددة الأطياف و جد متعددة الأطياف من أجل تحسين الدقة المكانية للصورة جد متعددة الأطياف، وذلك بدمج الدقة المكانية العالية للصور متعددة الأطياف و الدقة الطيفية العالية للصور جد متعددة الأطياف. الطرق المنفذة هي طرق مصممة لبيانات الاستشعار عن بعد الحضرية. تظهر النتائج التي تم الحصول عليها أن الأساليب المقدمة تعطي أداء جيد لدمج الصور متعددة الأطياف و الصور جد متعددة الأطياف. وتظهر أيضا أن هذه الأساليب تتفوق بشكل ملحوظ على الطرق التقليدية.

كلمات المفتاح : صور متعددة الأطياف و جد متعددة الأطياف، تعزيز القرار المكاني/الطيفي، الفصل الطيفي الغير خطي، طرق تحليل إلى المصفوفات الغير سلبية، دمج الصور.