



HAL
open science

Méthodes de démixage et amélioration de résolution d'images hyperspectrales en sciences de l'univers : prise en compte de la variabilité spectrale

Salah Eddine Brezini

► **To cite this version:**

Salah Eddine Brezini. Méthodes de démixage et amélioration de résolution d'images hyperspectrales en sciences de l'univers : prise en compte de la variabilité spectrale. Instrumentation et méthodes pour l'astrophysique [astro-ph.IM]. Université Paul Sabatier - Toulouse III; Université des Sciences et de la Technologie d'Oran Mohamed-Boudiaf (Algérie), 2022. Français. NNT : 2022TOU30183 . tel-03969690

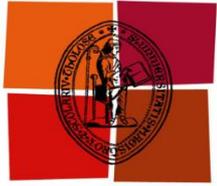
HAL Id: tel-03969690

<https://theses.hal.science/tel-03969690>

Submitted on 2 Feb 2023

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.



Université
de Toulouse

THÈSE

En vue de l'obtention du

DOCTORAT DE L'UNIVERSITÉ DE TOULOUSE

Délivré par :

l'Université Toulouse III – Paul Sabatier (France)

Discipline ou spécialité :

Informatique et Télécommunications

En cotutelle avec :

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

Présentée et soutenue par :

Salah Eddine BREZINI

Le 23 juin 2022

Titre :

Méthodes de démixtion et amélioration de résolution d'images hyperspectrales en sciences de l'univers. Prise en compte de la variabilité spectrale

JURY

Tarik ZOUAGUI	<i>Professeur USTO-MB(Algérie)</i>	Président
Karim ABED-MERAIM	<i>Professeur Université d'Orléans (France)</i>	Rapporteur
Nasreddine TALEB	<i>Professeur Université SBA (Algérie)</i>	Rapporteur
Hadria FIZAZI	<i>Professeur USTO-MB (Algérie)</i>	Examinatrice
Yannick DEVILLE	<i>Professeur UPS (France)</i>	Directeur de thèse
Moussa Sofiane KAROUI	<i>Directeur de Recherche CTS (Algérie)</i>	Directeur de thèse
Abdelaziz OUAMRI	<i>Professeur USTO-MB (Algérie)</i>	Co-directeur de thèse
Fatima Zohra BENHALOUCHE	<i>Maitre de Recherche A CTS (Algérie)</i>	Invitée

École doctorale : *MITT Mathématiques Informatique Télécommunications de Toulouse*

Unité de Recherche : *Institut de Recherche en Astrophysique et Planétologie (IRAP)*

THÈSE

En vue de l'obtention du Diplôme de Doctorat

Présentée par : Salah Eddine BREZINI

Intitulée

Méthodes de démixage et amélioration de résolution d'images hyperspectrales en sciences de l'univers. Prise en compte de la variabilité spectrale

Faculté : Génie Electrique

Département : Electronique

Domaine : Sciences et Technologies

Filière : Electronique

Intitulé de la Formation : Vision et Technologies de l'Information et de la Communication (VTIC)

Devant le Jury Composé de :

<i>Membres de Jury</i>	<i>Grade</i>	<i>Qualité</i>	<i>Domiciliation</i>
<i>Tarik ZOUAGUI</i>	<i>Prof.</i>	<i>Président</i>	<i>USTO MB, Algérie</i>
<i>Moussa Sofiane KAROUI</i>	<i>D.R.</i>	<i>Encadrant</i>	<i>CTS, Arzew, Algérie</i>
<i>Yannick DEVILLE</i>	<i>Prof.</i>	<i>Co-Encadrant</i>	<i>UPS Toulouse III, France</i>
<i>Abdelaziz OUAMRI</i>	<i>Prof.</i>	<i>Co-encadrant</i>	<i>USTO MB, Algérie</i>
<i>Karim ABED-MERAIM</i>	<i>Prof.</i>	<i>Examineur</i>	<i>Université d'Orléans, France</i>
<i>Hadria FIZAZI</i>	<i>Prof.</i>	<i>Examinatrice</i>	<i>USTO MB, Algérie</i>
<i>Nasreddine TALEB</i>	<i>Prof.</i>	<i>Invité</i>	<i>Université SBA, Algérie</i>
<i>Fatima Zohra BENHALOUCHE</i>	<i>M.R.A</i>	<i>Invitée</i>	<i>CTS, Arzew, Algérie</i>

Dédicaces

A ma Chère Mère, Merci pour tout.

A mon Père, pour le support et les sacrifices.

A mon Frère et ma Sœur.

A tous les gens qui me sont proches et chers.

Remerciements

Au terme de ce travail, je me dois de remercier l'ensemble des personnes associées à sa réalisation. Aussi, je tiens tout d'abord à remercier Dr. Moussa Sofiane Karoui et Prof. Yannick Deville, pour m'avoir proposé le sujet, pour le suivi et leur aide précieuse pour l'élaboration de cette thèse, les nombreux conseils et leurs disponibilités dans tous les domaines m'ont permis de mener à bien ce travail de recherche. Je tiens à remercier également Dr. Fatima Zohra Benhalouche pour sa participation à l'encadrement, ses conseils et son aide. Je remercie également mon co-directeur de thèse Prof. Abdelaziz Ouamri pour son aide.

Prof. Zouagui me fait l'honneur de présider le jury, à ce titre qu'il trouve l'expression de ma profonde reconnaissance. Les membres du jury, Prof. Nasreddine Taleb, Prof. Karim Abed-Meraim et Prof. Hadria Fizazi, qui ont acceptés de juger ce travail par leur participation au jury, je leur exprime ma reconnaissance pour l'honneur qu'ils me font. Les conseils et remarques constructives m'ont permis d'améliorer grandement la qualité de mes travaux et de ce mémoire.

Je tiens particulièrement à remercier l'Institut de Recherche en Astrophysique et Planétologie pour l'accueil et l'hospitalité lors des nombreux séjours effectués à Toulouse. Il m'est particulièrement agréable d'avoir une pensée pour l'équipe SISU de l'IRAP pour m'avoir accueilli chaleureusement en tant que doctorant. De plus, je ne peux oublier les doctorants Simon, Yohann et Mehdi, pour avoir partagé de nombreuses discussions enrichissantes.

De même, j'adresse ma profonde reconnaissance à l'équipe LSI de l'USTO pour m'avoir accueilli dans son laboratoire et aux doctorants pour les échanges fructueux.

Je tiens à remercier le Centre des Techniques Spatiales d'Arzew pour l'accueil et pour m'avoir fait bénéficier des données qui ont contribué dans l'élaboration de ce travail et les multiples échanges constructifs avec les différentes personnes. Je suis reconnaissant à l'Office National d'Etudes et de Recherches Aérospatiales pour avoir mis à ma disposition les données indispensables à cette recherche. Je remercie l'équipe du projet HypFom en particulier Prof. Mireille Guillaume pour m'avoir intégré dans le projet et pour les données, c'était un réel plaisir de travailler sur ce projet.

Ma reconnaissance et mes remerciements vont à mes enseignants, Prof. Loukil et Prof. Keche, qui ont contribué à ma formation à l'école doctorale. De même, j'associe mes remerciements au Prof. Hervé Carfantan pour le cours d'optimisation et de télédétection qu'il m'a dispensé et pour ses nombreux conseils pour la thèse.

Je ne peux oublier de remercier le Ministère de l'Enseignement Supérieur et de la Recherche Scientifique et le service des relations extérieures de l'USTO pour le support financier par l'octroi de la bourse Profas B+ qui m'a permis d'effectuer un séjour scientifique à l'IRAP. J'associe reconnaissances et remerciements à l'école doctorale VTIC de l'USTO et MITT de l'UPS pour l'accueil et l'hospitalité.

Résumé

Au cours de cette thèse, nous nous sommes intéressés aux traitements des images hyperspectrales de télédétection, plus précisément, à une problématique liée à qui est la faible résolution spatiale de ce type d'images. Cet aspect impacte directement le processus classificatoire, communément utilisé, car il est plus complexe de déterminer la proportion ou la superficie occupée par un matériau pur dans un pixel donné. Pour résoudre cette limitation, deux approches existent.

La première, nommée démixage spectral a pour objectif de séparer les composantes du pixel c'est-à-dire les matériaux purs et déterminer leurs proportions appelées aussi abondances. Le démixage spectral tire profit des techniques développées dans la filière de la Séparation Aveugle de Sources (SAS). La deuxième technique consiste à fusionner une image hyperspectrale avec une image multispectrale ou panchromatique, de la même région, pour incorporer l'information spatiale contenue dans ces deux types d'images afin d'aboutir à une image hyperspectrale avec une résolution spatiale de meilleure qualité. Parmi ces approches, plusieurs méthodes de fusion se basent sur le démixage spectral.

Le démixage spectral nécessite la connaissance de la loi régissant le mélange. La plus répandue représente un spectre observé dans un pixel par un mélange linéaire des spectres des matériaux présents dans le même pixel, ce cas de figure est nommé mélange linéaire instantané. Malgré sa simplicité de mise en œuvre, ce dernier reste limité par deux phénomènes fréquents, à savoir, la non-linéarité et la variabilité spectrale. En particulier, le modèle de mélange linéaire stipule que chaque matériau pur présent dans une scène est décrit par un même spectre dans la totalité de la scène observée. Cela n'est pas toujours valide à cause de certains phénomènes physiques. Dans ce cas précis, la notion de matériau pur doit être remplacée par la notion de classe de matériaux. Nous parlons alors de variabilité spectrale. Une partie de cette thèse traite cette problématique en intégrant la variabilité spectrale dans le démixage spectral.

Le travail de cette thèse s'inscrit dans cette configuration pour développer des méthodes tenant compte de la variabilité spectrale pour le démixage spectral dans la première partie. Ainsi trois méthodes ont été développées dans cette thèse en se basant sur un nouveau modèle de mélange proposé qui introduit la variabilité spectrale sous une forme additive. Les trois méthodes de démixage ont été développées en utilisant des algorithmes de factorisation en matrice non-négatives. Les résultats obtenus sont très prometteurs.

La deuxième partie de cette thèse a permis de développer des méthodes de fusion, intégrant le phénomène de la variabilité spectrale, pour combiner une image hyperspectrale et une autre image multispectrale, de la même zone observée. Dans cette optique, deux méthodes ont été développées et présentées dans la deuxième partie de ce manuscrit. Les tests effectués montrent l'importance de considérer le phénomène de la variabilité spectrale dans le processus de fusion.

Abstract

In this thesis, we focused on hyperspectral images processing and more precisely, about their limited spatial resolution. This limitation affects directly the classification process of this kind of images due to the fact that is more difficult to estimate the proportion and the area occupied by a pure material in an observed pixel. To overcome this limitation, two approaches are commonly used.

The first one is known as the spectral unmixing, which consists in unmixing an observed pixel in order to estimate the pure material spectra and their associated abundances. The spectral unmixing is based on methods developed in the fields of Blind Source Separation. The second approach consists in fusing a hyperspectral image with a multispectral or a panchromatic one, which covers the same observed area, in order to obtain a hyperspectral image with high spatial resolution. Some of fusion methods are based on the spectral unmixing.

The use of spectral unmixing requires the knowledge of the mixing model. The widespread model is the linear mixing model, which represents a pixel as a linear mixture of pure material spectra and their associated abundances. Despite its simplicity, this model is rather limited by some phenomena: the nonlinearity and the spectral variability. The linear mixing model assumes that each endmember is represented by the same spectrum in the whole image. However, such a hypothesis is no longer valid in many configurations. To overcome such constraints and avoid errors during the unmixing process, the concept of endmembers must be substituted by another one, which considers classes of endmembers. The main objective of this thesis is to incorporate the spectral variability in the spectral unmixing.

The first part of this manuscript is devoted to the spectral unmixing. Therefore, three methods are developed in this thesis based on a new introduced mixing model that integrates the spectral variability phenomenon within an additive manner. The three methods are based on nonnegative matrix factorization. The obtained results are encouraging.

The second part presents fusion methods integrating the spectral variability to merge a hyperspectral image and a multispectral one. To this end, two methods are developed. The conducted experiments show the importance to take into account the spectral variability phenomenon in the fusion process.

ملخص

خلال هذه الأطروحة، توجهنا لمعالجة الصور الفائقة الطيفية للاستشعار عن بعد. وتحديداً حول مشكلة انخفاض الدقة المكانية لهذا النوع من الصور الذي يؤثر بشكل مباشر على عملية التصنيف المتبعة، لأنه من الصعب تحديد حجم أو المساحة التي تشغلها الأشياء في بيكسل معين. ولفك هذا التقيد اتبعنا المقاربتين المذكورتين ادناه.

الأولى: والمسماة بالفك الطيفي، تهدف إلى فصل مكونات البيكسل وتحديد نسبها. تستفيد مقارنة الفك الطيفي من التقنيات المطورة في قطاع فصل المصادر.

فيما تتمثل التقنية الثانية في دمج صورة فائقة الطيفية مع صورة متعددة الأطياف أو شاملة، من نفس المنطقة، من أجل الحصول على صورة فائقة الطيف ذات دقة مكانية ذات جودة عالية. من بين هذه الأساليب هنالك العديد من طرق الادمج التي تعتمد على الفصل المكثف للمصادر. أثناء استعمال هذه الطريقة يجب معرفة القانون المسيطر على الخليط. يمثل الطيف الأكثر انتشاراً طيفاً يتم ملاحظته في البيكسل بواسطة خليط خطي من أطياف المواد الموجودة في البيكسل والمسمى الخليط الخطي اللحظي الذي على الرغم من بساطته إلا أن هذا الأخير يظل مقيد بظاهرتين، الا وهما التباين الطيفي واللاخطية. وعلى وجه الخصوص، ينص نموذج الخليط الخطي على أن كل مادة نقية موجودة في مشهد موصوفة بنفس الطيف في كامل المشهد المعين. لكن هذا ليس صحيحاً دائماً بسبب بعض الظواهر الفيزيائية. وبالتحديد في هذه الحالة يجب استبدال فكرة المادة النقية بمفهوم فئة المواد فهنا نحن نتحدث عن التباين الطيفي. لذلك هذه الأطروحة تدخل في حيز ادخال التباين في الفك الطيفي.

يلج الجزء الأول من هذه الأطروحة في منحى تطوير تقنيات مع مراعاة التباين الطيفي لفك الخليط الطيفي. لهذا تم إدراج ثلاث طرق مع الاعتماد على نموذج خليط جديد وادخال التباين الطيفي على شكل مضاف. تم تطوير طرق فك الخليط الثلاث باستخدام خوارزميات العوامل المصفوفية الغير سلبية. النتائج المتحصل عليها تبدو واعدة للغاية.

أتاح الجزء الثاني من هذه الأطروحة تطوير طرق دمج ظاهرة التباين الطيفي لصورة فائقة الطيف وصورة متعددة الأطياف. في هذا المنظور، تم تقديم طريقتين في الجزء الثاني من الأطروحة والتي أظهرت الاختبارات أهمية اعتبار ظاهرة التباين الطيفي في عملية الادمج.

Table des matières

Dédicaces	i
Remerciements.....	ii
Résumé.....	iii
Abstract	iv
ملخص	v
Table des matières	vi
Liste des figures	x
Liste des tableaux	xiv
Liste des acronymes.....	xvi
Notations.....	xx
Introduction générale.....	1
1. Imagerie de télédétection en observation de la Terre.....	2
2. Analyse d'images de télédétection et extraction d'informations	5
3. Problématique de la thèse.....	6
4. Plan de la thèse	7
<i>PARTIE I : Démélange spectral des images de télédétection spatiale</i>	<i>9</i>
Introduction	10
<i>Chapitre 1 : Séparation Aveugle de Sources (SAS) et Démélange Spectral....</i>	<i>12</i>
1.1. Introduction	13
1.2. Séparation Aveugle de Sources	13
1.3. Mélanges linéaires	15
1.3.1. Types de modèle de mélange	15
1.3.2. Modèle de mélange linéaire instantané dans la cadre des images de télédétection.....	17
1.4. Méthodes de démélange spectral pour le mélange linéaire instantané .	18
1.4.1. Méthodes basées sur l'analyse en composantes indépendantes et méthodes probabilistes	19
1.4.2. Méthodes géométriques de démélange spectral	19
1.4.3. Méthodes basées sur l'analyse en composantes parcimonieuses	22
1.4.4. Méthodes basées sur la factorisation en matrices non-négatives.....	23
1.4.5. Dimensionnalité intrinsèque de l'image.....	25
1.4.6. Limites du modèle de mélange linéaire.....	27

1.5. Méthodes de démixtion spectrale pour des mélanges non-linéaires	28
1.5.1. Méthodes de démixtion spectrale pour des modèles de mélange non-linéaires non-définis....	28
1.5.2. Méthodes de démixtion spectrale pour des modèles de mélange non-linéaires spécifiques....	29
1.6. Méthodes de démixtion spectrale pour le mélange linéaire avec prise en compte de la variabilité spectrale	30
1.6.1. Causes de la variabilité.....	30
1.6.2. Méthodes de démixtion spectrale prenant en compte la variabilité	32
1.7. Conclusion	37
<i>Chapitre 2 : Application d'une méthode, de la littérature, de démixtion linéaire avec prise en compte de la variabilité spectrale sur des données de fonds marins</i>	
	39
2.1. Introduction	40
2.2. Modèle mathématique de données.....	41
2.3. Méthode de la littérature testée	45
2.4. Données testées	47
2.5. Critère de performances.....	52
2.6. Résultats obtenus et discussion	52
2.6.1. Première étude.....	53
2.6.2. Deuxième étude.....	56
2.6.3. Troisième étude	59
2.7. Conclusion	61
<i>Chapitre 3 : Méthodes Proposées de Démixtion Spectrale Linéaire avec Prise en Compte de la Variabilité Spectrale</i>	
	63
3.1. Introduction	64
3.2. Modèle mathématique de données.....	65
3.3. Modèle de données introduit et méthodes proposées.....	66
3.3.1. Modèle de données introduit	66
3.3.2. Première méthode proposée	67
3.3.2.1. Algorithme à gradient projeté.....	68
3.3.2.2. Algorithme multiplicatif.....	69
3.3.3. Deuxième méthode proposée	71
3.3.3.1. Algorithme à gradient projeté.....	72
3.3.3.2. Algorithme multiplicatif.....	73
3.3.4. Troisième méthode proposée.....	74
3.3.4.1. Algorithme à gradient projeté.....	75

3.3.4.2. Algorithme multiplicatif.....	76
3.4. Conclusion.....	76
<i>Chapitre 4 : Tests et Performances.....</i>	78
4.1. Introduction.....	79
4.2. Données testées.....	80
4.2.1. Données synthétiques.....	80
4.2.2. Données réelles.....	82
4.3. Critères de performance.....	83
4.4. Résultats obtenus et discussion.....	84
4.4.1. Etude 1 : Comparaison des méthodes proposées.....	84
4.4.2. Etude 2 : Impact du bruit sur les trois méthodes proposées.....	91
4.4.3. Etude 3 : Impact de l'initialisation sur les méthodes proposées.....	94
4.4.4. Etude 4 : Comparaison avec des méthodes de la littérature.....	97
4.4.5. Etude 5 : Impact du bruit sur les méthodes.....	101
4.4.6. Etude 6 : Comparaison des performances avec les méthodes de la littérature sur une image réelle.....	102
4.5. Conclusion.....	105
Conclusion et perspectives.....	106
<i>PARTIE II : Fusion d'Images de Télédétection Spatiale.....</i>	108
Introduction.....	109
<i>Chapitre 1 : État de l'Art en Fusion d'Images de Télédétection Spatiale.</i>	111
1.1. Introduction.....	112
1.2. Hypothèses.....	112
1.3. Méthodes de Pansharpening.....	113
1.3.1. Méthodes à substitution de composantes.....	113
1.3.2. Analyse multirésolution.....	116
1.3.3. Méthodes variationnelles.....	119
1.3.4. Méthodes basées sur la Factorisation en Matrices Non-négatives.....	120
1.4. Méthodes de Multisharpening (Hypersharpening).....	120
1.4.1. Les méthodes bayésiennes.....	121
1.4.2. Méthodes basées sur la Factorisation en Matrices Non-négatives.....	121
1.4.3. Méthodes basées sur l'analyse en composantes parcimonieuses.....	125
1.5. Evaluation de la qualité.....	125
1.5.1. Interprétation visuelle.....	126

1.5.2. Analyse quantitative	126
1.6. Conclusion	129
<i>Chapitre 2 : Méthodes Proposées pour le Multisharpening</i>	130
2.1. Introduction	131
2.2. Rappel sur le modèle mathématique de données	132
2.3. Méthodes de multisharpening proposées	133
2.3.1. Première méthode proposée	133
2.3.2. Deuxième méthode proposée	135
2.4. Conclusion	137
<i>Chapitre3: Tests et Performances</i>	138
3.1. Introduction	139
3.2. Données testées	139
3.2.1. Données synthétiques	139
3.2.2. Données réelles.....	142
3.3. Résultats et discussions	143
3.3.1. Résultats sur le premier jeu de données synthétiques.....	144
3.3.2. Résultats sur le deuxième jeu de données synthétiques	147
3.3.3. Résultats sur les données réelles.....	150
3.4. Conclusion	153
Conclusion et perspectives.....	154
Conclusion Générale	155
Références bibliographiques	157
Publications scientifiques de l'auteur	173

Liste des figures

Introduction générale

Figure 1 :	Différents types de capteurs.	1
Figure 2 :	Même scène pour différentes résolutions spatiales.	2
Figure 3 :	Images avec des niveaux radiométriques différents.	3
Figure 4 :	Différence de résolution spectrale entre un capteur multispectral et hyperspectral.	4
Figure 5 :	Image panchromatique.	4
Figure 6 :	Image multispectrale.	5
Figure 7 :	Image hyperspectrale.	5

PARTIE I : Démélange spectral des images de télédétection spatiale

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

Figure 1.1 :	Application de la SAS dans le domaine de l'acoustique.	14
Figure 1.2 :	Configuration générale de l'application de la SAS.	15
Figure 1.3 :	Illustration d'un mélange spectral linéaire.	18
Figure 1.4 :	Représentation en deux bandes des observations contenues dans un simplexe constitué de trois matériaux.	20
Figure 1.5 :	Algorithme de N-FINDR.	21
Figure 1.6 :	Différents cônes englobant des données observées.	24
Figure 1.7 :	Mélanges non-linéaires : (a) réflexions multiples, (b) mélange intime.	27
Figure 1.8 :	Variabilité intra-classe dans une image hyperspectrale d'une zone urbaine.	28
Figure 1.9 :	Interaction de la lumière pendant l'acquisition d'un capteur.	31
Figure 1.10 :	Effet de l'atmosphère sur une image hyperspectrale : (a) lumière directement réfléchiée vers le capteur, (b) lumière diffusée par l'atmosphère et réfléchiée par le sol, (c) lumière réfléchiée directement par le sol et (d) lumière réfléchiée par des régions proches et diffusée par la suite.	32
Figure 1.11 :	Fonctionnement des méthodes basées sur les bundles.	34

Chapitre 2 : Application d'une méthode, de la littérature, de démixage linéaire avec prise en compte de la variabilité spectrale sur des données de fonds marins

Figure 2.1 :	Photons contribuant à la luminance ascendante à la subsurface.	42
Figure 2.2 :	Signatures spectrales des matériaux purs.	48
Figure 2.3 :	Variations de k_1 en fonction du pixel à une profondeur de 1.5m en eau claire.	48
Figure 2.4 :	Variations de k_2 en fonction du pixel à une profondeur de 1.5m en eau claire.	49
Figure 2.5 :	Variations de k_1 en fonction du pixel pour une profondeur variable d_i autour de $d_{ref} = 1.5 m$ avec $d_{max} = 0.05 m$.	50
Figure 2.6 :	Variations de k_2 en fonction du pixel pour une profondeur variable d_i autour de $d_{ref} = 1.5 m$ avec $d_{max} = 0.05 m$.	50
Figure 2.7 :	Cartes d'abondance pour les différents matériaux.	51
Figure 2.8 :	Jeu de spectres altérés par les différents paramètres de l'équation (2.7) pour la taxifolia.	51
Figure 2.9 :	Gain en % entre le SAM de l'IP-NMF et celui de la VCA selon les différents domaines de variation d_{max} autour de $d_{ref} = 1.5m$.	54
Figure 2.10 :	Spectres estimés pour tous les pixels de l'image pour la classe taxifolia.	55
Figure 2.11 :	Spectres estimés pour tous les pixels de l'image pour la classe substrat.	55
Figure 2.12 :	Spectres estimés pour tous les pixels de l'image pour la classe sable.	55
Figure 2.13 :	Spectres estimés pour tous les pixels de l'image pour la classe posidonie.	56
Figure 2.14 :	Gain en % entre le SAM de l'IP-NMF et celui de la VCA selon les différents domaines de variation d_{max} autour de $d_{ref} = 1.5m$.	57
Figure 2.15 :	Spectres estimés pour tous les pixels de l'image pour la classe taxifolia.	57
Figure 2.16 :	Spectres estimés pour tous les pixels de l'image pour la classe substrat.	58
Figure 2.17 :	Spectres estimés pour tous les pixels de l'image pour la classe sable.	58
Figure 2.18 :	Spectres estimés pour tous les pixels de l'image pour la classe posidonie.	58

Figure 2.19 :	Gain en % entre le SAM de l'IP-NMF et celui de la VCA selon les différents domaines de variation d_{max} autour de $d_{ref} = 7.5m$.	59
Figure 2.20 :	Spectres estimés pour tous les pixels de l'image pour la classe taxifolia.	60
Figure 2.21 :	Spectres estimés pour tous les pixels de l'image pour la classe substrat.	60
Figure 2.22 :	Spectres estimés pour tous les pixels de l'image pour la classe sable.	60
Figure 2.23 :	Spectres estimés pour tous les pixels de l'image pour la classe posidonie.	61

Chapitre 4 : Tests et Performances

Figure 4.1 :	Image hyperspectrale couvrant la zone de la campagne terrain.	80
Figure 4.2 :	Première bibliothèque spectrale (SL-1).	81
Figure 4.3 :	Deuxième bibliothèque spectrale (SL-2).	81
Figure 4.4 :	(a) Carte de classification contenant 4 matériaux. (b) Carte de classification contenant 5 matériaux. (c) Cartes d'abondance extraites de (a). (d) Cartes d'abondance extraites de (b).	82
Figure 4.5 :	Représentation RVB de l'image hyperspectrale réelle.	83
Figure 4.6 :	Répartition du SAM au niveau de chaque pixel pour l'image HI-1.	86
Figure 4.7 :	Spectres estimés des panneaux photovoltaïques pour l'image HI-1.	88
Figure 4.8 :	Répartition du SAM au niveau de chaque pixel pour l'image HI-2.	90
Figure 4.9 :	Spectres estimés des panneaux photovoltaïques pour l'image HI-2.	91
Figure 4.10 :	Variation du SAM en fonction du SNR pour l'image HI-3.	93
Figure 4.11 :	Variation du RMSE en fonction du SNR pour l'image HI-3.	94
Figure 4.12 :	Bibliothèque spectrale générée à partir de l'image HI-4.	95
Figure 4.13 :	Résultats de la classification de la bibliothèque spectrale pour l'image HI-4.	96
Figure 4.14 :	Répartition du SAM au niveau de chaque pixel pour l'image HI-5.	99
Figure 4.15 :	Répartition du SAM en fonction de la puissance du bruit pour l'image HI-3.	102
Figure 4.16 :	Cartes d'abondance des différentes méthodes pour l'image réelle.	104

PARTIE II : Fusion d'Images de Télédétection Spatiale

Chapitre 1 : État de l'Art en Fusion d'Images de Télédétection Spatiale

Figure 1.1 :	Application de l'IHS.	114
Figure 1.2 :	Fusion basée sur la transformée PCA.	115
Figure 1.3 :	Méthode de fusion basée sur la transformation de GS.	116
Figure 1.4 :	Algorithme de la fusion des images basé sur la transformée en ondelettes.	117
Figure 1.5 :	Décomposition pyramidale.	119
Figure 1.6 :	Fonctionnement de la CNMF.	123

Chapitre 3 : Tests et Performances

Figure 3.1 :	Image hyperspectrale de référence.	140
Figure 3.2 :	(a) Image HS-1. (b) Image MS-1.	141
Figure 3.3 :	(a) Image HS-2. (b) Image MS-2.	142
Figure 3.4 :	(a) Image hyperspectrale. (b) Image multispectrale.	143
Figure 3.5 :	Résultats en RVB de fusion des différents algorithmes pour le premier jeu de données synthétiques.	145
Figure 3.6 :	Résultats de fusion des différents algorithmes pour la bande spectrale $0.817 \mu m$ pour le premier jeu de données synthétiques.	146
Figure 3.7 :	Résultats en RVB de fusion des différents algorithmes pour le deuxième jeu de données synthétiques.	148
Figure 3.8 :	Résultats de fusion des différents algorithmes pour la bande spectrale $0.817 \mu m$ pour le deuxième jeu de données synthétiques.	149
Figure 3.9 :	Résultats en RVB de la fusion des différents algorithmes sur les données réelles.	151
Figure 3.10 :	Résultats de fusion des différents algorithmes pour la bande spectrale $0.815 \mu m$ pour données réelles.	152

Liste des tableaux

PARTIE I : Démélange spectral des images de télédétection spatiale

Chapitre 2 : Application d'une méthode, de la littérature, de démélange linéaire avec prise en compte de la variabilité spectrale sur des données de fonds marins

Tableau 2.1 :	Conditions et types de données pour les simulations réalisées.	53
Tableau 2.2 :	Valeurs moyennes du SAM (°) pour la première étude.	53
Tableau 2.3 :	Valeurs moyennes du SAM (°) pour la deuxième étude.	56
Tableau 2.4 :	Valeurs moyennes du SAM (°) pour la troisième étude.	59

Chapitre 4 : Tests et Performances

Tableau 4.1 :	Résultats des critères de performance sur HI-1.	85
Tableau 4.2 :	Résultats des critères de performance sur HI-2.	89
Tableau 4.3 :	Résultats du SAM en fonction du niveau de bruit pour l'image HI-3.	92
Tableau 4.4 :	Résultats du RMSE en fonction du bruit pour l'image HI-3.	93
Tableau 4.5 :	Résultats des critères en fonction de l'initialisation pour l'image HI-4.	96
Tableau 4.6 :	Résultats des critères de performance des méthodes proposées pour l'image HI-5.	98
Tableau 4.7 :	Résultats des critères de performance pour l'image HI-5.	98
Tableau 4.8 :	Résultats des critères de performance des méthodes proposées pour l'image HI-6.	100
Tableau 4.9 :	Résultats des critères de performance pour l'image HI-6.	100
Tableau 4.10 :	Résultats du SAM en fonction du bruit pour l'image HI-3.	101
Tableau 4.11 :	Résultats du RMSE en fonction de la puissance du bruit pour l'image HI-3.	102
Tableau 4.12 :	Résultats des critères de performance sur les données réelles des méthodes introduites.	103
Tableau 4.13 :	Résultats des critères de performance sur les données réelles.	103

PARTIE II : Fusion d'Images de Télédétection Spatiale

Chapitre 3 : Tests et Performances

Tableau 3.1 :	Bandes spectrales du capteur QuickBird.	140
Tableau 3.2 :	Bandes spectrales du capteur Landsat-8 OLI.	141
Tableau 3.3 :	Bandes spectrales du capteur EO-1 Advanced Land Imager.	142
Tableau 3.4 :	Valeurs des critères de performance sur le premier jeu de données synthétiques.	144
Tableau 3.5 :	Valeurs des critères de performance sur le deuxième jeu de données synthétiques.	147
Tableau 3.6 :	Valeurs des critères de performance sur les données réelles.	150

Liste des acronymes

ACI	Analyse en Composantes Indépendantes.
ACP	Analyse en Composantes Principales.
ACPa	Analyse en Composantes Parcimonieuses.
ADMM	Alternating Direction Method of Multipliers.
AEB	Automated Extraction Bundles.
ALI	Advanced Land Imager.
ALMM	Augmented Linear Mixing Model.
ALS	Alternating Least Square.
AMEE	Automated Morphological Endmember Extraction.
APC	Abundance Positivity Constraint.
ARSIS	Amélioration de la Résolution Spatiale par Injection de Structures.
ASC	Abundance Sum-to-one Constraint.
AVIRIS	Airborne Visible/ InfaRed Imaging Spectrometer.
BCI	Biophysical Composition Index.
BISPICE	Bilinear SParsity-Promoting Iterated Constrained Endmember.
BMI	Blind Mixture Identification.
BPT	Binary Partition Tree.
BSS	Blind Source Separation.
CNMF	Coupled Nonnegative Matrix Factorization.
COCHISE	COrrrection Code For Hyperspectral Images of remote sensing SENSors.
ELMM	Extended Linear Mixing Model.
EO-1	Earth Observer 1.
EQMN	Erreur Quadratique Moyenne Normalisée.
ERGAS	Erreur Relative Globale Adimensionnelle de Synthèse.
ExNMF	Extended Nonnegative Matrix Factorisation.
FCLS	Fully Constrained Least Square.
FMN	Factorisation en Matrices Non-négatives.

FMP	Factorisation en Matrices Positives.
FUSE	Fast fUision based on Sylvester Equation.
FuVar	Fusion with Spectral Variability.
GBM	Generalized Bilinear Model.
GIHS	Generalized Intensity Hue Saturation.
GLMM	Generalized Linear Mixing Model.
GS	Gram-Schmidt.
G-SOMP+	Generalization of Simultaneous Orthogonal Matching Pursuit.
HFC	Harsanyi, Farrand, and Chang.
HMF-IPNMF	Hyperspectral and Multispectral data Fusion based on Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation.
HS	Image Hyperspectrale.
HySime	Hyperspectral Subspace Identification by Minimum Error.
HySure	Hyperspectral Superresolution.
HYEP	Hyperspectral Imagery for Environmental Planning.
IAM	Identification Aveugle de Mélanges.
ICA	Independent Component Analysis.
ID	Intrinsic Dimension.
IHS	Intensity Hue Saturation.
IP-NMF	Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation.
JCNMF	Joint-Criterion Non-negative Matrix Factorization.
JCNMFV	Extension de la méthode Joint-Criterion Non-negative Matrix Factorization.
JNMF	Joint Nonnegative Matrix Factorization.
KFCLS	Kernel Fully Constrained Least Square.
LQ	Linéaire Quadratique.
LU	Local Unmixing.
LSU	Linear Spectral Unmixing.
MAP	Maximum à Postérieur.
MCMC	Monte Carlo Markov Chain.
MESMA	Multiple Endmember Spectral Mixture Analysis.
MJNMF	Multiplicative Joint Nonnegative Matrix Factorization.

MLMM	Multiplicative-tuning Linear Mixing Model.
MLP	Multi-Layer Perception.
MNF	Maximum Noise Fraction.
Modif ICA-NMF	Modified Independent Component Analysis for Initializing Nonnegative Matrix Factorization.
mQNR	Modified Quality with No Reference.
MS	Image Multispectrale.
MTF GLP HPM	Modulation Transfer Function Generalized Laplacian Pyramid with High Pass Modulation.
MTF GLP	Modulation Transfer Function Generalized Laplacian Pyramid.
MTF	Modulation Transfer Function.
MUSIC	Multiple Signal Classification.
MVC-NMF	Minimum Volume Constrained Nonnegative Matrix Factorization.
MVSA	Minimum Volume Simplex Analysis.
NDVI	Normalized Difference Vegetation Index.
NIIRS	National Imagery Interperability Rating Evaluation.
NMF	Nonnegative Matrix Factorization.
NMSE	Normalized Mean Square Error.
NWHFC	Noise-Whitening Harsanyi, Farrand, and Chang.
ONERA	Office National d'Etudes et de Recherches Aérospatiales.
OSOAA	Ordres Successifs Océan Atmosphère Avancé.
OSP	Sequential Quadratic Programming.
PAN	Image Panchromatique.
PBIM	Pixel Block Intensity Modulation.
PCA	Principal Component Analysis.
PLMM	Perturbed Linear Mixing Model.
PMF	Positive Matrix Factorization.
PPI	Pixel Purity Index.
PSF	Point Spread Function.
PSNR	Peak Signal to Noise Ratio.
QNR	Quality with No Reference.

RSB	Rapport Signal sur Bruit.
RMT	Random Matrix Theory.
RMSE	Root Mean Square Error.
SALSA	Split Augmented Lagrangian Shrinkage Algorithm.
SAM	Spectral Angle Mapper.
SAS	Séparation Aveugle de Sources.
SCA	Sparse Component Analysis.
SCLSU	Scaled Constrained Least Squares Unmixing.
SFIM	Smoothing Filter-based Intensity Modulation.
SID	Spectral Information Divergence.
SISAL	Simplex Identification via Split Augmented Lagrangian.
SMACC	Sequential Maximum Angle Convex Cone.
SNR	Signal to Noise Ratio.
SPICE	Sparsity-Promoting Iterated Constrained Endmember.
SRF	Spectral Response Function.
SU	Spectral Unmixing.
SUnSAL	Spectral Unmixing by Splitting and Augmented Lagrangian.
SVD	Singular Value Decomposition.
UIQI	Universal Image Quality Index.
UMBRA	Urban Material characterization in the sun and shade of Built-up structures and trees and their Retrieval from Airborne image.
UP-NMF	Unconstrained Pixel-by-Pixel Non-negative Matrix Factorization.
USGS	U.S. Geological Survey.
VCA	Vertex Component Analysis.
VMESMA	Virtual Multiple Endmember Spectral Mixture Analysis.

Notations

Symboles mathématiques

α	Scalaire.
x	Vecteur.
X	Matrice.
X^{-1}	Inverse de la matrice X .
I	Matrice identité.
$(.)^T$ ou $[.]^T$	Transposition (peut être appliquée à un vecteur ou à une matrice)
$Tr(.)$	Trace d'une matrice.
$Cov(.)$	Covariance d'une matrice.
$f(.)$	Fonction.
x_{ij} ou $[X]_{ij}$	(ij) -ème élément de la matrice X .
R^+	Ensemble des nombres réels positifs.
$[.]_+$	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.
$\ln(.)$	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 matricielle élément par élément.
\oslash	Division matricielle élément par élément.
ε	Terme ajouté au dénominateur d'un quotient, choisi positif et très petit pour éviter les divisions par zéro.

Introduction générale

La télédétection est définie comme « *l'ensemble des connaissances et techniques utilisées pour déterminer des caractéristiques physiques et biologiques d'objets par des mesures effectuées à distance, sans contact matériel avec ceux-ci* » [1]. Cette définition est considérée comme universellement admise.

La télédétection ou *Remote Sensing* est une discipline scientifique regroupant l'ensemble des connaissances et des différentes techniques destinées à l'observation, l'étude, l'analyse et l'interprétation permettant d'acquérir des informations sur un objet, une surface ou un phénomène étudiés sans contact direct avec l'objet. Dans le cadre de l'observation de la Terre considérée dans cette thèse, elle est basée sur des mesures et des images fournies à partir de capteurs embarqués sur des plates-formes aéroportées (avions ou drones) ou spatioportées [2-3].

Le capteur est un appareil qui détecte le rayonnement électromagnétique et ses variations [2]. Le choix du capteur installé sur une plate-forme de télédétection dépend de plusieurs paramètres comme les bandes spectrales dans lesquelles le capteur fonctionne qui vont définir le type d'images utilisées. En effet, à la base, les capteurs sont des radiomètres, c'est-à-dire ils permettent de mesurer l'énergie électromagnétique émise ou réfléchi, dans plusieurs bandes spectrales, par la cible. Ces mesures sont converties par la suite en image.

Dans le cadre de la télédétection en observation de la Terre, un capteur détecte trois sources d'énergies :

- solaire : le capteur détecte le rayonnement du soleil réfléchi par la Terre.
- terrestre : il détecte l'énergie émise par la Terre.
- énergie propre du capteur : le capteur émet un rayonnement et détecte sa réflexion.

Les capteurs détectant l'énergie solaire réfléchi et celle émise par la Terre sont dits capteurs passifs (voir figure 1). Ils utilisent l'énergie émise par le soleil et réfléchi par la Terre ou bien émise directement par la Terre comme dans le cas de l'énergie thermique. Le second type de capteur est nommé capteur actif (voir figure 1), il génère son propre rayonnement et mesure la réflexion de celui-ci par la cible [2]. Parmi les capteurs actifs, on peut citer le radar actif.

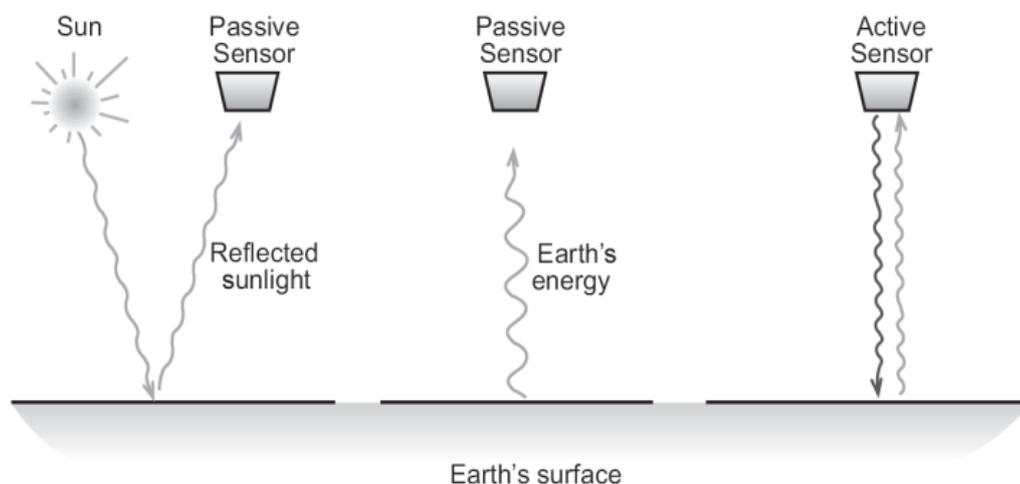


Figure 1 : Différents types de capteurs [2].

La télédétection dite moderne a pris naissance avec la photographie aérienne, dont la vue d'ensemble et verticale a permis la mise au point de méthodes de réalisation des cartographies et de surveillance de l'environnement et des ressources terrestres [2-3].

Actuellement, elle a acquis un caractère pluridisciplinaire par l'intégration des développements de la recherche spatiale, de la physique, de l'informatique pour représenter un outil performant pour étudier l'environnement et sa gestion dans de multiples domaines. Dans ce contexte, les techniques utilisées étant dans un rythme d'évolution rapide et permanent, les perspectives des domaines d'applications de la télédétection sont en constante croissance.

1. Imagerie de télédétection en observation de la Terre

Les images issues de la télédétection possèdent plusieurs caractéristiques importantes. Ces caractéristiques permettent d'étudier le contenu des images comme la forme des objets et leurs spectres. La résolution spatiale est une caractéristique essentielle de l'image. Elle représente le plus petit élément qui peut être distingué dans l'image, c'est-à-dire l'équivalent en dimension de chaque pixel en réalité.

La résolution spatiale est fondamentale dans la télédétection car elle permet d'extraire les propriétés géométriques des différents objets présents dans une image [3]. Parmi les critères du choix de la résolution spatiale, la dimension de la surface/phénomène à observer est fondamentale. Pour illustrer cet aspect la figure 3 illustre la même surface observée pour différentes résolutions spatiales.

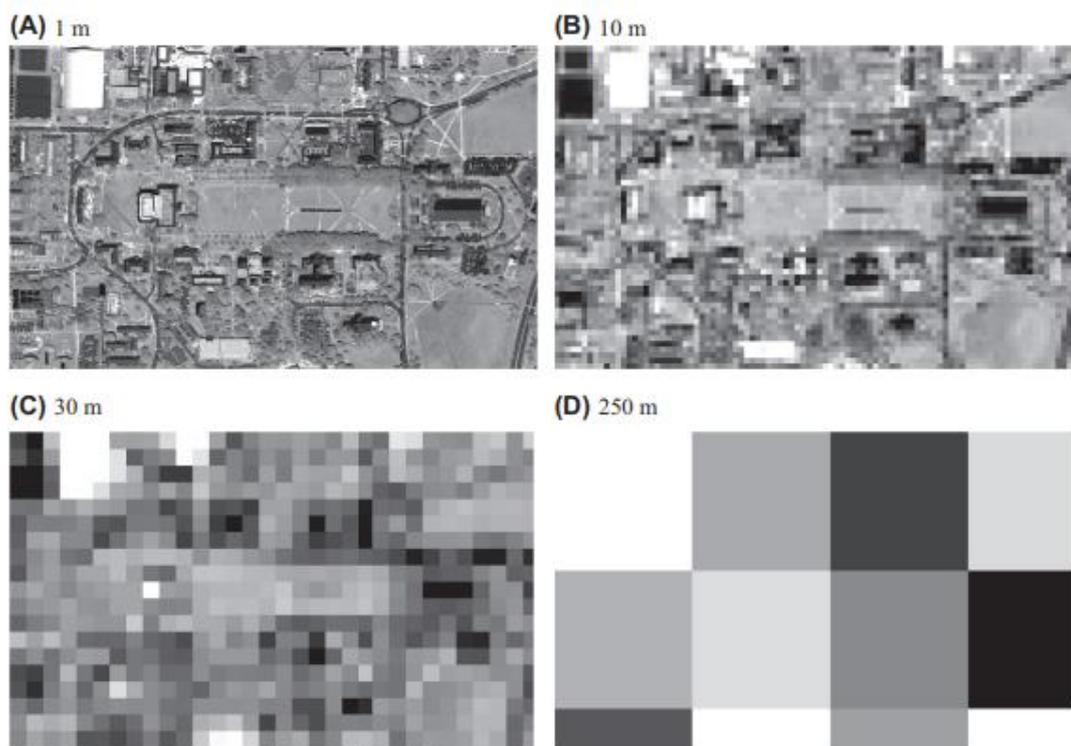


Figure 2 : Même scène pour différentes résolutions spatiales [4].

Introduction générale

Une autre caractéristique majeure est la résolution radiométrique : elle est liée à la capacité d'un capteur à distinguer la différence entre les niveaux d'énergie reçus [4]. Les différents niveaux de rayonnement sont convertis en données numériques. Pour améliorer la résolution radiométrique, il est nécessaire d'augmenter le nombre de bits comme illustré dans la figure 3.

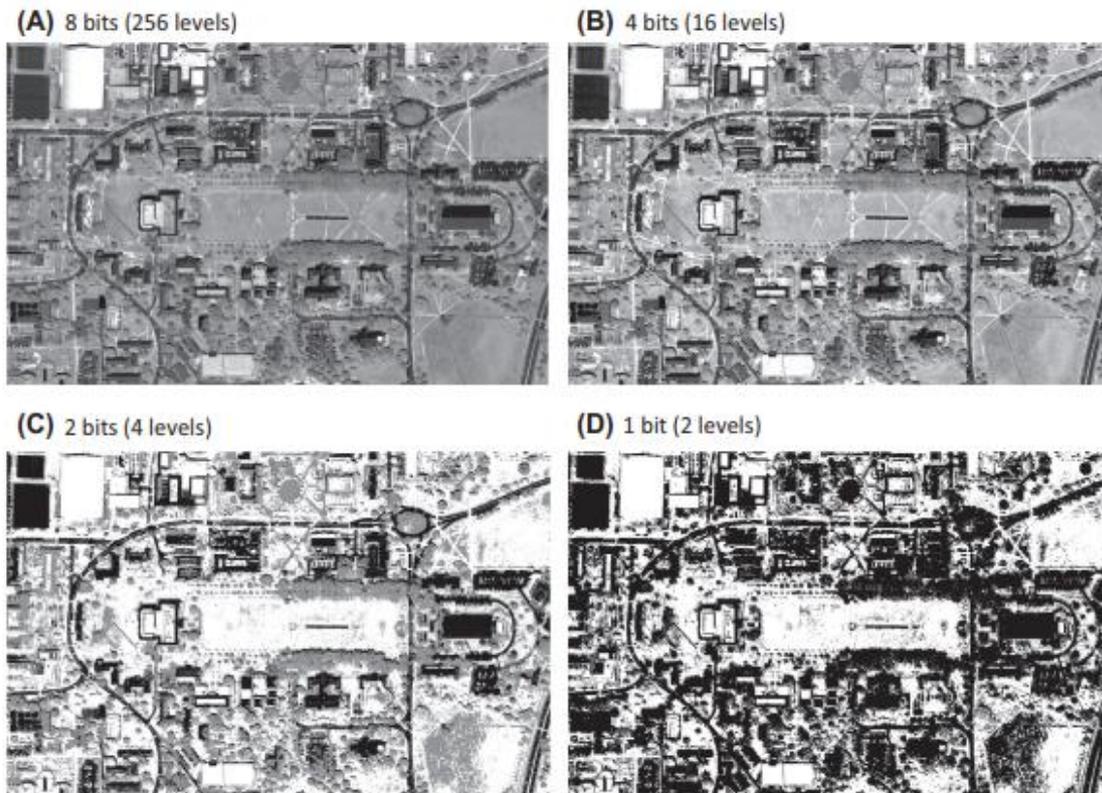


Figure 3 : Images avec des niveaux radiométriques différents [4].

De plus, un processus d'étalonnage (ou codage) est nécessaire pour associer à chaque niveau d'énergie du rayonnement une valeur numérique. Cette procédure est d'autant plus déterminante pour analyser les différentes images issues d'un même capteur.

L'autre intérêt de l'étalonnage est que les capteurs sont produits avec des matériaux identiques, néanmoins ils ne délivrent pas dans l'absolu la même réponse spectrale. En effet, nous pouvons relever de légères différences dans leurs sensibilités.

Par ailleurs, la résolution spectrale représente la capacité d'un capteur à pouvoir distinguer des énergies dans différentes longueurs d'onde [3]. Nous pouvons catégoriser les capteurs suivant la résolution spectrale en deux classes principales : les capteurs multispectraux couvrant une dizaine de bandes spectrales et hyperspectraux considérant une centaine de bandes spectrales et en plus contiguës.

Il existe plusieurs types d'images dans la télédétection. Le type est sélectionné en fonction de l'application et l'information que nous voulons extraire des images. Trois types d'images sont traitées dans la télédétection : panchromatique, multispectrale et hyperspectrale.

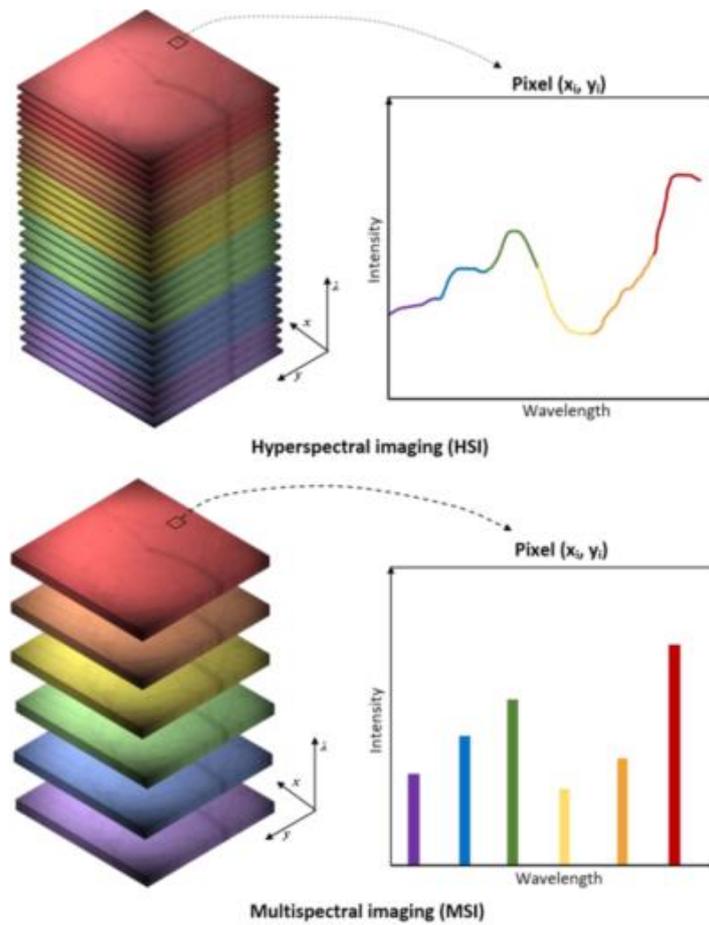


Figure 4 : Différence de résolution spectrale entre un capteur multispectral et hyperspectral [5].

Les images panchromatiques (voir figure 5) couvrent une seule bande spectrale et une seule mesure de réflectance est réalisée sur la bande traitée.



Figure 5: Image panchromatique [6].

Introduction générale

Les images multispectrales (voir figure 6), comme mentionné précédemment, possèdent plusieurs bandes spectrales, généralement une dizaine. L'exemple le plus simple de ce type d'image est l'image en couleur. Elle offre une certaine richesse spectrale, mais en contrepartie elle a une résolution spatiale moins fine que celle des images panchromatiques.



Figure 6: Image multispectrale [6].

Les images hyperspectrales contiennent des informations réparties sur plusieurs bandes spectrales généralement plus d'une centaine comme mentionné précédemment (voir figure 7).

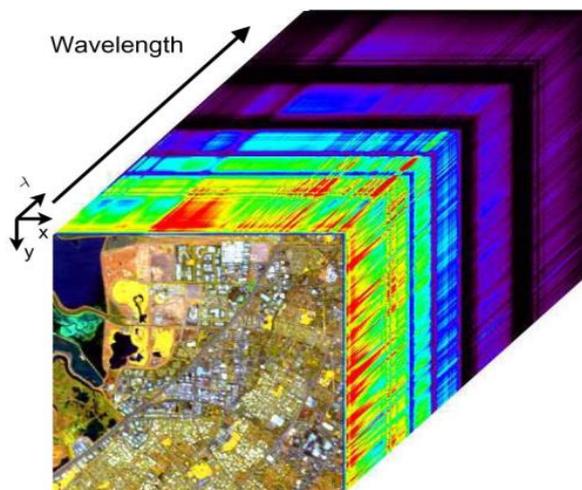


Figure 7: Image hyperspectrale [7].

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

Le processus de traitement et d'extraction d'informations des images de télédétection suit des étapes bien distinctes. L'acquisition des images est réalisée par les capteurs cités

précédemment dont le rôle est de transformer les signaux réels en valeurs numériques sous forme, généralement, d'images. Les différentes images obtenues par les plates-formes de télédétection sont sujettes à des erreurs d'ordres géométrique et/ou radiométrique. Ainsi, des corrections, qui représentent l'étape de prétraitement pour exploiter les informations contenues dans les images, sont nécessaires [2-3], [8].

Les erreurs géométriques sont produites par différents facteurs. Parmi les causes les plus notoires, nous pouvons relever :

- la rotation de la Terre durant l'acquisition de l'image,
- la variation de l'altitude de la plate-forme et sa vitesse,
- la courbure de la Terre,
- des problèmes liés au capteur.

Il existe plusieurs techniques pour corriger les problèmes géométriques. Le choix de la technique dépend principalement du type de la transformation voulue.

Dans la télédétection, le traitement radiométrique des images est primordial. Il permet d'améliorer l'image pour extraire des informations utiles présentes dans celle-ci. Le traitement consiste à restaurer et améliorer l'image en utilisant des outils mathématiques, en particulier ceux dérivés du traitement du signal.

Le traitement radiométrique a pour but de résoudre différents problèmes :

- la correction des erreurs dues aux singularités de la scène étudiée, la manière dont la scène est éclairée peut créer des problèmes comme les effets causés par la diffusion atmosphérique,
- l'amélioration des images pour mieux les interpréter par la suite dans une application ultérieure.

La dernière étape consiste à extraire les informations de l'image prétraitée. Deux grandes écoles sont considérées pour obtenir un produit final. La première approche nécessite l'intervention humaine, cette manière reste subjective et dépendante de l'opérateur humain. La deuxième méthodologie repose sur les techniques d'extraction d'informations automatisées. Les approches sont issues du traitement du signal et des images.

3. Problématique de la thèse

Le but du traitement des images de télédétection est d'extraire l'information contenue dans les images, qu'elle soit de l'ordre spatial ou spectral. En effet, ces informations permettent d'établir, par exemple, des cartes d'occupation des sols via le processus de classification. Les images multispectrales offrent un compromis approprié entre la résolution spectrale et spatiale. Cependant, certaines applications requièrent une résolution spectrale plus fine, l'exemple le plus concret étant la classification de la végétation du fait que nous pouvons distinguer par exemple entre une pelouse synthétique ou naturelle au niveau du domaine infrarouge. La solution la plus pertinente pour ce genre d'application est l'utilisation de l'imagerie hyperspectrale. Celle-ci présente une résolution spectrale fine. Néanmoins, cette richesse spectrale ne permet pas d'avoir une résolution spatiale de qualité pour distinguer les objets présents dans l'image car ces capteurs fonctionnent selon un compromis entre un rapport signal sur bruit et la résolution spatiale [9].

Cette limitation liée à la résolution spatiale engendre des images hyperspectrales avec des pixels mélangés. Plus précisément, le spectre observé au niveau d'un pixel est un mélange des spectres de plusieurs matériaux purs contenus au niveau du même pixel. Le terme communément évoqué dans cette situation est le mélange spectral ou *Spectral Mixing*. Cet aspect impacte directement le processus classificatoire, communément utilisé, car il est plus complexe de déterminer la proportion ou la superficie occupée par un matériau pur dans le pixel considéré.

Pour résoudre cette limitation, deux approches existent. La première a pour objectif de séparer les composantes du pixel (matériaux purs), cette technique est nommée démélange spectral ou *Spectral Unmixing* (SU) [8]. Le démélange spectral tire profit des techniques développées dans la filière de la Séparation Aveugle de Sources (SAS) ou *Blind Source Separation* (BSS) [11], [12]. La deuxième technique consiste à fusionner l'image hyperspectrale avec une image multispectrale ou panchromatique pour incorporer l'information spatiale contenue dans ces deux types d'images afin d'aboutir à une image hyperspectrale avec une résolution spatiale de bien meilleure qualité. Ce processus nécessite de disposer de deux images couvrant la même zone et idéalement acquises dans le même intervalle de temps. Parmi ces approches, plusieurs méthodes de fusion se basent sur le démélange spectral.

Le démélange spectral nécessite la connaissance du modèle de mélange. Le plus répandu représente un spectre observé dans un pixel par un mélange linéaire des spectres des matériaux présents dans le pixel considéré [10]. Ce cas de figure est nommé mélange linéaire instantané. Malgré sa simplicité de mise en œuvre, ce dernier reste limité par deux phénomènes fréquents, à savoir, la variabilité spectrale [8], [13-14] et la non-linéarité [15]. Le cas le plus simple démontrant la non-linéarité est le cas des images hyperspectrales de zones urbaines où se produit le phénomène de réflexions multiples. Comme montré dans [16-17], il est primordial de prendre en compte la non-linéarité en considérant un modèle de mélange plus élaboré que le modèle de mélange linéaire instantané.

De plus, le modèle de mélange linéaire stipule que chaque matériau pur présent dans une scène est décrit par un même spectre dans la scène observée. Cela n'est pas toujours valide à cause de certains phénomènes physiques. Dans ce cas précis, la notion de matériaux purs doit être remplacée par la notion de classes de matériaux [18]. Nous parlons alors de variabilité spectrale ou variabilité intra-classe. Le travail de cette thèse s'inscrit dans cette configuration pour développer des méthodes tenant compte de la variabilité spectrale pour le démélange spectral dans la première partie et de la fusion dans une seconde partie.

4. Plan de la thèse

Le manuscrit est divisé en deux parties distinctes, la première partie est consacrée au démélange spectral. Le premier chapitre de cette partie présente les différentes notions fondamentales sur la SAS. En particulier, les différentes techniques issues de la SAS et se basant sur le modèle de mélange linéaire instantané sont exposées. Par la suite, les deux limitations de ce dernier sont introduites, à savoir, la non-linéarité et la variabilité spectrale. A ce titre, un état de l'art sur les approches traitant la variabilité spectrale est donné.

Introduction générale

Le deuxième chapitre de la première partie est dédié à une étude sur l'application d'une méthode de démixage spectral dans le cas d'images hyperspectrales décrivant des fonds marins. En effet, une analyse analytique démontre l'importance de prendre en considération la variabilité spectrale pour ce type de données afin d'en extraire les informations comme les spectres des matériaux présents.

Le troisième chapitre, toujours de la première partie, introduit les trois méthodes développées de démixage spectral tenant compte du phénomène de la variabilité spectrale. Pour chaque méthode, deux algorithmes sont déduits à partir d'une fonction de coût propre.

Le dernier chapitre de la première partie expose les résultats obtenus, sur des données synthétiques et réelles, par les trois méthodes proposées. Pour cela, les trois techniques sont comparées aux différentes méthodes récentes de la littérature considérant la variabilité spectrale.

La deuxième partie de la thèse concerne la fusion d'images de télédétection. Le premier chapitre de cette seconde partie est dédié à l'état de l'art sur la fusion. De plus, l'évaluation de la qualité des produits de fusion est abordée.

Le deuxième chapitre de cette deuxième partie présente les deux méthodes développées de fusion prenant en considération la variabilité spectrale. Pour chaque méthode l'aspect analytique est décrit dans un premier lieu. En effet, ce dernier montre comment la variabilité est intégrée dans le processus de fusion. Dans un second temps, les algorithmes des deux méthodes sont détaillés.

Le dernier chapitre de la seconde partie analyse les résultats des différents tests réalisés sur les données générées d'une manière synthétique et aussi sur des données réelles. Les deux méthodes sont comparées à différents techniques de fusion de la littérature.

***PARTIE I : Démélange spectral des images de
télédétection spatiale***

Introduction

Au cours de ces dernières années, l'intérêt porté à la Séparation Aveugle de Sources (SAS) a augmenté de manière considérable. La SAS consiste à estimer, à partir de très peu d'informations a priori sur les observations, qui sont des mélanges de signaux dits sources, d'une part, les paramètres du mélange, et d'autre part, l'ensemble de signaux sources. Cet aspect est essentiel dans le cadre des images de télédétection, en particulier celles hyperspectrales, où plusieurs informations sont extraites telles que les spectres de matériaux purs ainsi que leurs coefficients (appelés abondances dans une configuration standard) associés c'est-à-dire la proportion occupée par un matériau dans un pixel considéré. Ce processus est communément nommé démélange spectral. Dans cette optique plusieurs techniques ont été développées comme les méthodes basées sur : l'Analyse en Composantes Indépendantes (ACI), l'Analyse en Composantes Parcimonieuses (ACPa) et la Factorisation en Matrices Non-négatives (FMN). La majeure partie des méthodes appliquées à des images de télédétection sont fondées sur le Modèle de Mélange Linéaire. Cependant, ce dernier demeure limité par deux phénomènes qui sont la variabilité spectrale et la non-linéarité.

Dans cette première partie de la thèse, la problématique de la SAS est tout d'abord présentée. Par la suite, un état de l'art des méthodes de démélange spectral linéaire parmi les plus utilisées basées sur la SAS est introduit en soulignant les limites comme la non-linéarité et la variabilité spectrale qui constituent l'objet d'un traitement approprié. Une analyse succincte des méthodes non linéaires est donnée pour les modèles de mélange non linéaires non-définis et définis. Par ailleurs, un état de l'art, concernant les méthodes traitant la variabilité spectrale, constituant le sujet principal de cette thèse, est présenté. L'analyse sur la variabilité spectrale comporte deux parties distinctes, la première est consacrée aux origines physiques de la variabilité spectrale, à savoir, le changement d'illumination dans une scène imagée, les conditions atmosphériques et la variabilité intrinsèque. Concernant la deuxième partie, elle est dédiée aux différentes méthodes considérant la variabilité spectrale. Les approches présentées sont divisées en plusieurs catégories selon leur principe de fonctionnement.

Dans le deuxième chapitre, une analyse de fonds marins est considérée. En effet, un modèle de mélange a été introduit pour représenter les différents phénomènes se produisant dans une colonne d'eau. Une étude analytique démontre la possibilité d'appliquer le démélange spectral linéaire étendu au cas de la variabilité spectrale. Plus précisément, une méthode de la littérature : *Inertia-Constrained Pixel-By-Pixel Nonnegative Matrix Factorisation* (IP-NMF) est utilisée pour estimer la proportion des différents matériaux présents dans les fonds marins et en particulier les données contenues dans les colonnes d'eau présentant une bathymétrie différente pour chaque pixel d'une image hyperspectrale. Par ailleurs, l'IP-NMF est comparée à une méthode, nommée *Vertex Component Analysis* (VCA), ne prenant pas en considération la variabilité afin de mettre en valeur l'importance de ce phénomène.

La section finale comprenant le chapitre trois et quatre de cette première partie est dédiée aux trois méthodes, développées dans cette thèse, prenant en considération la variabilité spectrale. Plus précisément, elles sont basées sur un modèle paramétrique des données incluant la variabilité spectrale sous une forme additive. Pour chaque méthode, la FMN est utilisée avec deux algorithmes : un premier utilisant les gradients projetés, et le deuxième de type multiplicatif. Les trois méthodes sont comparées dans un premier temps pour montrer l'évolution du développement des trois techniques. Par la suite, elles sont comparées aux méthodes de la littérature récentes dans différentes configurations de variabilité spectrale. De plus, une étude de la robustesse au bruit est menée pour montrer l'efficacité des méthodes

proposées. Pour finir, une comparaison sur une image hyperspectrale réelle d'une zone urbaine est analysée.

Chapitre 1 : Séparation Aveugle de Sources (SAS) et Démélange Spectral

Chapitre 1

Séparation Aveugle de Sources (SAS) et Démélange Spectral

1.1. Introduction

L'objectif de ce chapitre est de présenter un état de l'art sur la séparation aveugle de sources (SAS) et son application aux images de télédétection spatiale. Cette thématique nécessite une connaissance appropriée de certaines notions fondamentales et des grandes familles de méthodes de SAS développées dans la littérature. Le plan de ce chapitre se décline sous la forme suivante.

Dans une première partie, la problématique de la SAS est formulée en présentant une introduction sur le sujet, son mécanisme de fonctionnement et le modèle associé de mélange le plus répandu, à savoir le modèle linéaire.

Le démélange spectral, en particulier celui hyperspectral, est traité dans une deuxième partie. Une attention particulière est consacrée au démélange hyperspectral linéaire. Une analyse détaillée permettant de comprendre les limites de ce modèle, à savoir la non-linéarité et la variabilité spectrale, est proposée. Il est à noter que la prise en compte du phénomène de la variabilité spectrale constitue le cœur des différentes méthodes développées dans cette thèse.

La troisième partie est dédiée à une synthèse sur les méthodes traitant la variabilité spectrale. Les causes de ce phénomène sont introduites et les différentes classes de techniques de SAS associées sont analysées avec leurs avantages et inconvénients. De plus, un bref aperçu des principales méthodes pour le démélange non-linéaire est donné. Ces approches sont regroupées en deux familles : les méthodes pour des modèles de mélange non-définis et celles pour des modèles de mélange définis.

1.2. Séparation Aveugle de Sources

Globalement, les signaux reçus par un capteur sont rarement identiques aux signaux émis par les sources, et ceci est dû à de nombreux phénomènes physiques qui peuvent se produire entre l'émission du signal et sa réception [11]. De plus, les signaux interagissent avec des signaux provenant d'autres sources si bien que ceux reçus sont en fait un mélange des différents signaux sources. Cette problématique (voir figure 1.1) est bien connue dans le monde du traitement de l'audio sous l'appellation "problème du cocktail" (*Cocktail Party Problem*).

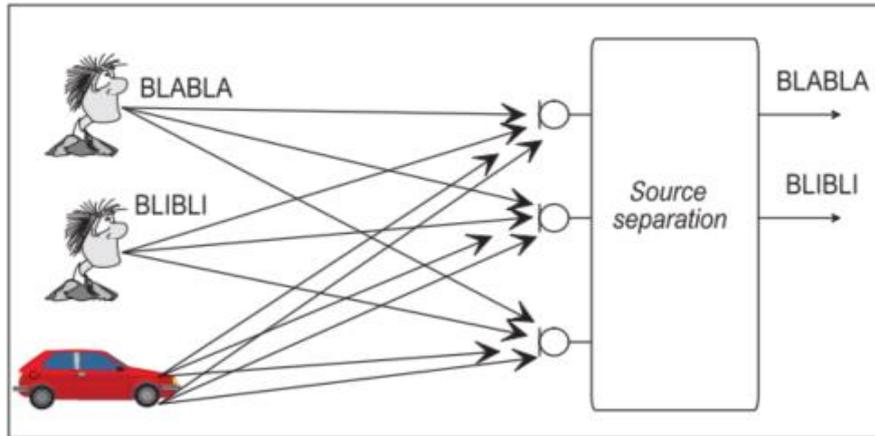


Figure 1.1: Application de la SAS dans le domaine de l'acoustique [12].

L'exemple le plus concret illustrant cette problématique est celui où deux orateurs parlent devant différents microphones en même temps : le signal reçu par le microphone d'indice i est un mélange des 2 signaux de parole émis. En effet, le signal observé x_i est composé de deux signaux sources s_j . Plus généralement, la manière dont les M signaux sources sont mélangés est déterminée par une fonction de mélange définie par la relation :

$$x_i = f(s_1, s_2, \dots, s_M) \quad (1.1)$$

C'est précisément le domaine d'application de la SAS. Elle permet dans le cas idéal avec peu d'information de retrouver les signaux sources (à certaines indéterminations près) à partir des observations. Le fonctionnement de la SAS est divisé en deux parties bien distinctes [12] :

- l'estimation du modèle de mélange ou fonction de mélange reliant les sources réelles ; cette opération est communément appelée Identification Aveugle de Mélanges (IAM) (*Blind Mixture Identification (BMI)*),
- l'estimation des sources à partir des observations.

D'une manière concrète, l'application de la SAS est en fait complexe et nécessite souvent des informations a priori, sinon les signaux sources risquent d'être estimés avec des indéterminations inacceptables. Ces dernières démontrent que l'ajout de contraintes sur les sources et/ou les paramètres de mélange pendant l'application de la SAS est nécessaire. En effet, ces contraintes permettent à la fois de réduire l'ensemble des solutions possibles du problème traité et de catégoriser les méthodes de la SAS en différentes classes (voir section 1.4). En particulier, dans le cadre du modèle de mélange linéaire instantané, ce dernier étant traité dans la section suivante, ces indéterminations sont :

- une permutation dans l'ordre des signaux sources estimés,
- des facteurs d'échelle sur ceux-ci.

Un autre élément essentiel pour l'application la SAS concerne le nombre M de sources présentes dans le mélange, ce nombre étant connu au préalable ou estimé. Selon la valeur de M par rapport au nombre N d'observations, il existe trois possibilités :

- $M = N$, le mélange est déterminé,
- $M > N$, le mélange est sous-déterminé, c'est le cas le plus complexe pour appliquer la SAS car il nécessite l'ajout de contraintes ou d'informations a priori sur les signaux sources et/ou les paramètres de mélange,

- $M < N$, le mélange est sur-déterminé, cette situation est la plus favorable pour utiliser la SAS car les informations contenues dans les observations facilitent l'estimation des signaux sources.

La figure 1.2 montre la configuration généralement adoptée dans la SAS. Les situations les plus fréquemment rencontrées correspondent aux conditions suivantes [12] :

- la nature du modèle de mélange ou la classe de fonction de mélange est supposée connue,
- les paramètres du modèle de mélange sont inconnus et estimés seulement à partir des observations x_i .

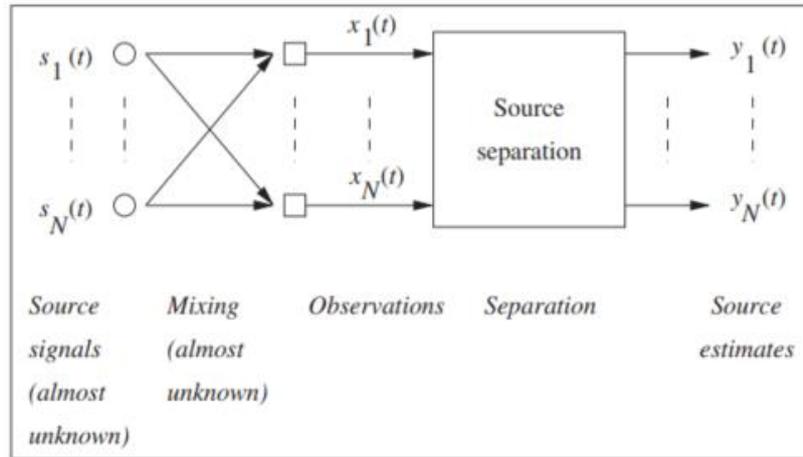


Figure 1.2 : Configuration générale de l'application de la SAS [12]

La connaissance du modèle de mélange, plus précisément le modèle mathématique décrivant les phénomènes physiques impliqués dans le mélange, est essentielle. Le modèle le plus étudié dans la littérature est celui du mélange linéaire qui constitue le thème de la partie suivante.

1.3. Mélanges linéaires

1.3.1. Types de modèle de mélange

Le modèle de mélange linéaire représente le cas dans lequel les observations sont représentées par un mélange linéaire des signaux sources. Il peut être divisé en 3 classes distinctes : linéaire instantané, atténuations et retards et convolutif.

- Mélange linéaire instantané

Ce modèle est le plus simple et le plus répandu, l'observation, notée x_i , est donnée par la relation :

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

où a_{ij} sont les coefficients de mélange et s_j une des sources à estimer.

Le terme instantané traduit le fait qu'à un instant donné t , x_i dépend uniquement des valeurs des sources s_j au même instant t . Les observations décrites par ce modèle peuvent être des observations à un instant dans le cas des signaux temporels monodimensionnels, à une position pour les signaux spatiaux bidimensionnels et une longueur d'onde si on utilise des spectres. Pour la suite du manuscrit, dans le cas du modèle de mélange linéaire instantané, les sources sont considérées comme étant des spectres. En effet, si les observations sont des images multispectrales ou hyperspectrales (voir figure 6 et figure 7 de l'introduction générale), le modèle peut être formulé suivant :

$$x_i = \sum_{j=1}^M a_{ij} s_j \quad (1.3)$$

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

L'équation (1.3) peut s'écrire sous forme matricielle toujours dans le cadre des images de télédétection :

$$X = AS \quad (1.4)$$

où $X = [x_1, \dots, x_p]^T \in R_+^{P \times L}$ est la matrice des observations, $S = [s_1, \dots, s_M]^T \in R_+^{M \times L}$ 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 contenant les coefficients de mélange. Le modèle de mélange linéaire instantané dans le cadre de la télédétection constitue l'objet d'une étude plus détaillée par la suite.

- Mélange linéaire à atténuations et retards

Dans ce modèle, les combinaisons des sources sont décalées dans le temps :

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

où l'élément t_{ij} représente le retard. Généralement ce modèle est utilisé dans la filière de l'audio où le temps de propagation d'un signal pour être reçu par un capteur doit être pris en considération.

- Mélange linéaire convolutif

Dans ce type de mélange, les observations représentent une somme de versions filtrées des signaux sources :

$$x_i(t) = \sum_{j=1}^M a_{ij} * s_j(t) \quad (1.6)$$

où le symbole $*$ indique l'opérateur de convolution. Une analyse plus détaillée et approfondie sur les modèles de mélange et leurs applications dans le cadre de la SAS est décrite dans [11] et [12].

1.3.2. Modèle de mélange linéaire instantané dans la cadre des images de télédétection

En télédétection spatiale, dite optique, les images, en particulier celles dénommées hyperspectrales (comme mentionné dans l'introduction générale), possèdent souvent une résolution spectrale fine qui permet une identification des matériaux (appelés aussi pôles de mélange) présents dans la scène observée. Elles sont composées d'un ensemble de pixels. Chacun de ces pixels porte une information relative à la surface de la Terre associée à ce pixel. Cette information par pixel représente un spectre.

Le cas élémentaire est celui où la zone de l'espace ou du sol associée au pixel considéré est composée d'une seule source. Dans cette configuration, le spectre mesuré pour ce pixel est directement égal au spectre représentant la source. Il permet ainsi d'identifier le type de source (ou matériau) présent dans ce pixel. Cependant, les données réelles sont souvent plus complexes que celles définies au préalable à l'aide d'une seule source par pixel ou plus précisément d'un pixel pur. La première cause est liée aux capteurs d'images hyperspectrales qui présentent une résolution spatiale limitée par les contraintes physiques. En effet, les capteurs fonctionnent selon un compromis entre une résolution spatiale satisfaisante et un bon rapport signal sur bruit, si bien que la zone associée à un pixel contient en réalité plusieurs sources.

Le spectre mesuré devient alors une combinaison (ou « mélange ») des spectres caractéristiques des sources mises en jeu dans ce pixel mélangé (appelé aussi mixel) (voir figure 1.3). Pour décrire ce pixel mélangé, le modèle le plus utilisé est celui du mélange spectral linéaire instantané (*Linear Spectral Mixing Model*) comme décrit dans (1.2). Il présente l'avantage majeur de la simplicité ; il permet de décrire un mixel observé dans l'image comme une combinaison linéaire des spectres des matériaux purs mis en jeu dans le mixel, pondérés par leurs abondances respectives (représentant la proportion occupée dans un pixel par un matériau). Ainsi l'observation x_i est formulée par [10] :

$$x_i = \sum_{j=1}^M a_{ij} s_j \quad i = 1, \dots, P \quad (1.7)$$

où $s_j \in R_+^{L \times 1}$ correspond aux spectres des matériaux purs composés de L bandes spectrales et a_{ij} les coefficients d'abondance.

L'abondance indique la proportion de surface occupée par un matériau j dans le pixel i . Pour cette raison, deux contraintes sont appliquées :

- la contrainte de non-négativité ou *Abundance Positivity Constraint* (APC) ; la surface occupée par un matériau au sol est nulle ou positive,

$$a_{ij} \geq 0 \quad j = 1 \dots M, i = 1 \dots P \quad (1.8)$$

- la contrainte de somme à un ou *Abundance Sum-to-one Constraint* (ASC) ; la somme des proportions de surface occupées par les matériaux est égale à 1.

$$\sum_{j=1}^M a_{ij} = 1 \quad i = 1 \dots P \quad (1.9)$$

Pour décrire l'ensemble des pixels de l'image, une formulation matricielle est adoptée :

$$X = AS \quad (1.10)$$

où $X \in R_+^{P \times L}$ est la matrice des observations, $A \in R_+^{P \times M}$ la matrice des abondances et $S \in R_+^{M \times M}$ la matrice des spectres.

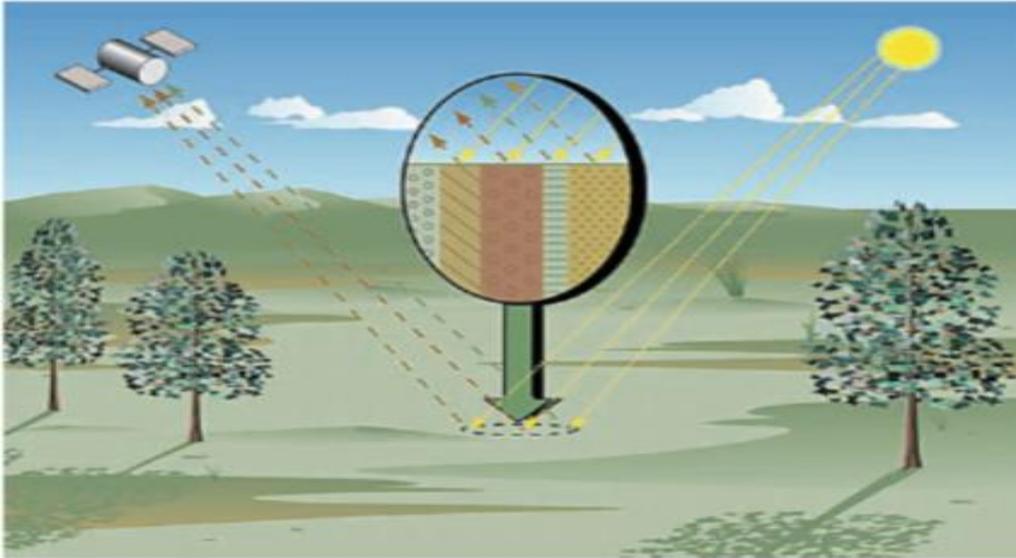


Figure 1.3 : Illustration d'un mélange spectral linéaire [19]

1.4. Méthodes de démélange spectral pour le mélange linéaire instantané

Les méthodes dites de "démélange spectral" (*Spectral Unmixing* (SU)) basées sur la SAS [11] et [12] ont pour objectif de traiter chaque spectre de pixel mesuré afin d'estimer les spectres des matériaux purs (appelés aussi *endmembers*) mis en jeu dans le mixel ainsi que les coefficients d'abondance associés.

La plupart des méthodes de démélange spectral linéaire ou *Linear Spectral Unmixing* (LSU) reposent sur l'hypothèse que chaque source est représentée exactement par le même spectre dans chacun des pixels de la scène. Cette partie est consacrée aux différentes méthodes dédiées au démélange spectral linéaire et leurs limites dans le cas d'images hyperspectrales décrites dans la section 1.4.6.

1.4.1. Méthodes basées sur l'analyse en composantes indépendantes et méthodes probabilistes

L'analyse en composantes indépendantes ou *Independent Component Analysis* (ICA) [20] est l'une des premières classes de méthodes apparues dans la SAS. Cette classe de méthodes est fondée sur l'hypothèse de l'indépendance statistique conjointe des signaux sources. Cependant l'ICA est difficilement applicable dans le cadre du démélange spectral. En supposant que les signaux sources de l'image représentent les spectres, ces derniers ne peuvent pas être statistiquement indépendants car plusieurs spectres sont corrélés, à titre d'exemple dans le cas de la végétation plusieurs spectres partagent les mêmes bandes d'absorption.

L'autre possibilité d'appliquer l'ICA dans le cadre du démélange spectral est de considérer les abondances comme étant les sources, de même que pour les spectres, les abondances sont statistiquement dépendantes du fait de la contrainte de somme à un.

Une étude comparative [21] a analysé l'impact et l'altération des méthodes basées sur l'ICA dans le cas d'un démélange spectral. Elle a démontré que l'ICA ne permet pas de retrouver la totalité des spectres pour chaque cas étudié et constitue donc une baisse de performance. Cette limite montre que l'ICA est difficilement applicable sur des images de télédétection.

Une version modifiée de l'ICA [22-23] nommée *Modified Independent Component Analysis for Initializing Non-negative Matrix Factorization* (Modif ICA-NMF) a été proposée. Cette version est utilisée comme initialisation de la *Non-negative Matrix Factorization* (NMF). La NMF est présentée en détail dans la section 1.4.4. Certaines variantes de l'ICA ont été développées pour traiter des signaux non-négatifs [24-25].

D'autres méthodes considèrent les propriétés statistiques des données. Dans [26], une méthode basée sur l'approche bayésienne a été introduite pour obtenir les abondances en respectant la contrainte de la somme-à-un. Une extension de cette technique introduite dans [27] permet d'extraire les spectres conjointement avec les abondances. Généralement, cette catégorie de méthodes est très coûteuse en terme de temps de calcul.

1.4.2. Méthodes géométriques de démélange spectral

Cet ensemble de méthodes repose sur l'hypothèse que les observations sont contenues dans une forme géométrique, dans le cas présent un simplexe. La figure 1.4 représente un simplexe composé de trois matériaux.

Les méthodes géométriques sont réparties en deux classes distinctes : les méthodes basées sur l'hypothèse de la présence d'un pixel pur (c'est-à-dire contenant un seul matériau) dans l'image et les méthodes applicables aussi en absence de pixels purs.

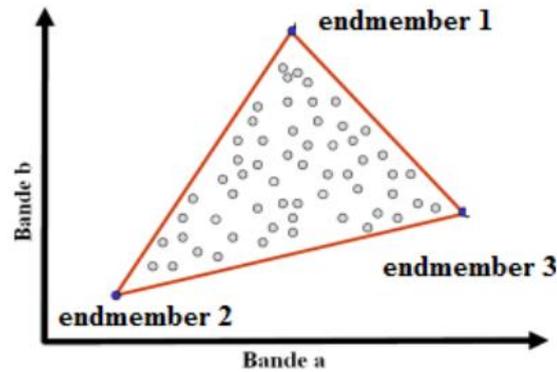


Figure 1.4 : Représentation en deux bandes des observations contenues dans un simplexe constitué de trois matériaux [28].

A. Méthodes avec existence de pixels purs

Cette classe de méthodes considère comme hypothèse de base la présence d'au moins un pixel pur (ou zone/région pure) dans une image, pour chaque matériau. Suivant cette hypothèse, les spectres des matériaux recherchés se situent au sommet du simplexe et le but est de les retrouver. Une synthèse détaillée de ces méthodes est décrite dans les références [10] et [29-30]. Dans cette partie, les principales méthodes sont présentées.

Pixel Purity Index (PPI) [31] : cet algorithme utilise le processus de blanchiment (*whitening*) via la technique dite de *Maximum Noise Fraction* (MNF) [32] pour réduire la dimensionnalité des données. Par la suite, un nombre conséquent de vecteurs aléatoires, nommés « skewers », sont générés. Les données composant l'image après réduction sont projetées suivant une direction bien définie par les skewers. Le point (pixel) qui se situe à l'extrémité de la projection est retenu. Le nombre de fois où un pixel est retenu est comptabilisé sous la forme d'un score.

Pour sélectionner les pixels les plus représentatifs d'un matériau recherché, l'utilisateur définit un seuil. Si le score obtenu par un pixel est supérieur à ce seuil, il est choisi comme représentant d'un matériau. Cependant malgré sa simplicité, la PPI présente certaines limites comme sa sensibilité au bruit lors de l'application de la MNF ou bien l'intervention humaine pour déterminer le nombre de matériaux et le critère (seuil) établi pour désigner les bons candidats parmi les pixels. Pour remédier à ces inconvénients, une version automatisée et rapide a été introduite dans [33].

N-FINDR [34] : comme la PPI, cette méthode commence par réduire la dimensionnalité en utilisant la MNF [32]. L'idée de base de N-FINDR est de générer de manière itérative un simplexe ayant le plus grand volume possible qui englobe les observations. Un ensemble de pixels, dont le nombre est égal au nombre de matériaux présents dans l'image, est sélectionné aléatoirement pour générer un simplexe, le volume de ce dernier est alors calculé (voir figure 1.5). Par la suite, un pixel est sélectionné aléatoirement pour remplacer un des pixels de l'itération précédente : si le nouveau volume du simplexe augmente, le pixel est retenu, dans le cas contraire il est rejeté. Ce processus est répété jusqu'à obtenir le volume maximal du simplexe.

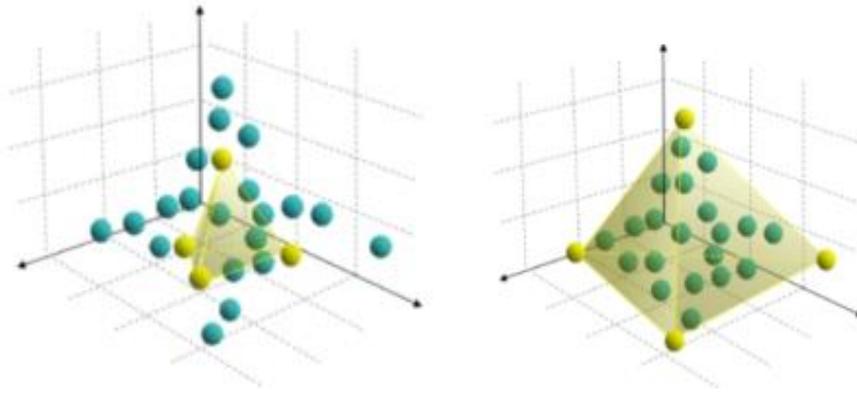


Figure 1.5 : Algorithmme N-FINDR [35]

SMACC (Sequential Maximum Angle Convex Cone) [36] : cette technique considère une représentation en cône convexe pour décrire les endmembers. A l'initialisation, un pixel est choisi et l'algorithme augmente en dimensions de façon itérative. A chaque fois qu'un pixel forme l'angle maximal par rapport au cône celui-ci est retenu comme représentant d'un matériau pur.

VCA (Vertex Component Analysis) [37] : la VCA estime dans un premier temps le rapport signal sur bruit (RSB) (*Signal to Noise Ratio* (SNR)) de l'image hyperspectrale. Si le bruit estimé est supérieur en terme de SNR au seuil établi, une projection des données est appliquée dans un sous-espace déterminé par la *Singular Value Decomposition* (SVD). Par la suite, les données sont normalisées en utilisant la *Projective Projection*. Cette dernière présente l'avantage d'être insensible aux facteurs d'échelle des données traitées. Cependant, elle a des inconvénients tels que sa sensibilité manifeste au bruit lors de la projection car celle-ci est inhérente à la méthode et peut amplifier le bruit déjà inclus dans l'image. Dans le cas où le bruit est inférieur au SNR établi (pour un fort bruit dans l'image) la projection est faite selon la *Principal Component Analysis* (PCA) ou l'Analyse en Composantes Principales (ACP) [38].

L'étape suivante consiste à générer des vecteurs aléatoires. Le premier matériau déterminé comme pur étant le point qui se situe à l'extrémité de la projection des données suivant la direction du premier vecteur aléatoire généré. Par la suite, le même processus est répété itérativement avec d'autres vecteurs aléatoires qui sont projetés avec la contrainte d'être orthogonaux au sous-espace couvert par l'endmember considéré dans l'itération précédente. La VCA demeure une méthode parmi les plus utilisées. Une de ses limites est la possibilité qu'un « outlier » (valeur aberrante) peut être confondu comme un matériau pur.

Les différentes méthodes citées sont présentées sous la forme d'une synthèse dans la référence [10].

B. Méthodes sans existence de pixels purs

Cette classe de méthodes part du principe de l'absence de pixels purs dans l'image [35]. La stratégie adoptée pour ces méthodes diffère de celles avec pixels purs ; plus précisément, cette classe de méthodes part d'un simplexe important en terme de volume et le fait décroître pour englober toutes les données. Cette classe impose la contrainte d'avoir un nombre minimal de pixels sur les facettes du simplexe. A cet effet, les méthodes ajoutent et adaptent différents paramètres de régularisation. Cependant, elles introduisent de nombreuses difficultés à savoir

comment gérer la présence de bruit dans l'image et certaines valeurs aberrantes (outliers) qui augmentent le volume du simplexe par rapport à un jeu de données en absence de bruit.

MVC-NMF (*Minimum Volume Constrained Non-negative Matrix Factorization*) [39] : cette méthode repose sur la Factorisation en Matrices Non-négatives (FMN) (*Nonnegative Matrix Factorization* (NMF)) (pour plus de détails sur la NMF voir section 1.4.4). La MVC-NMF ajoute à la NMF un terme de régularisation qui englobe les données dans le plus petit simplexe possible. De plus, il permet de ne pas inclure les pixels bruités ce qui constitue un autre avantage par rapport à une NMF classique sans contrainte.

MVSA (*Minimum Volume Simplex Analysis*) [40-41] : comme son nom l'indique, la MVSA a pour objectif d'obtenir le simplexe ayant le plus petit volume pour intégrer les données et détecter les matériaux purs. Pour cela, cette méthode optimise les équations de Kuhn-Tucker par la programmation quadratique du type *Sequential Quadratic Programming* (OSP) pour retrouver un minimum local satisfaisant. Si la présence du bruit ou de valeurs aberrantes dans le jeu de données est significative, la MVSA propose une étape finale en substituant la contrainte de positivité des abondances par une autre contrainte plus souple. Elle est définie par la fonction suivante $hinge(x) = 0$ si $x \geq 0$ et $-x$ si $x < 0$ pour être plus robuste au bruit, aux valeurs aberrantes (outliers) et aussi par rapport à une mauvaise initialisation.

SISAL (*Simplex Identification via Split Augmented Lagrangian*) [42] : la méthode applique le même principe que la MVSA mais diffère au niveau de l'étape d'optimisation en utilisant un algorithme de type lagrangien augmenté.

C. Estimation des abondances

Une fois les spectres connus, l'estimation des abondances revient à résoudre un problème de régression linéaire. Différentes méthodes se basent sur les moindres carrés comme la *Fully Constrained Least Square* (FCLS) [43]. La méthode FCLS applique les contraintes de somme à un et la positivité sur les abondances. D'autres méthodes peuvent être utilisées en connaissant les spectres comme SUnSAL (*Spectral Unmixing by Splitting and Augmented Lagrangian*) [44], elles sont détaillées dans la partie suivante. Il existe des classes de méthodes qui estiment conjointement les spectres ainsi que les abondances, parmi les classes les plus connues on peut citer les méthodes basées sur une approche statistique ou bien les techniques considérant la NMF constituant le sujet de la section 1.4.4.

1.4.3. Méthodes basées sur l'analyse en composantes parcimonieuses

Ces dernières années, plusieurs méthodes de démélange basées sur l'analyse en composantes parcimonieuses ou *Sparse Component Analysis* (SCA) [45] ont été développées. L'emploi récent de ces méthodes est favorisé par l'existence d'un nombre conséquent de bibliothèques spectrales comme *U.S. Geological Survey* (USGS) spectral library qui contient plus de 1300 spectres ou de mesures effectuées sur les scènes observées. Dans ce cas précis où la bibliothèque spectrale est disponible, l'une des manières les plus efficaces est de traiter le démélange spectral par les méthodes basées sur la parcimonie. Dans cette situation, le nombre de matériaux connus a priori dans la bibliothèque est plus grand que le nombre de matériaux réellement présents dans la scène. Une description plus détaillée de cette approche est présentée dans la référence [45].

Les méthodes basées sur la SCA s'appliquent sur les scènes de type damier où les matériaux couvrent une large zone dans l'image. Parmi les méthodes basées sur la SCA et utilisant des spectres connus au préalable, on peut citer SUnSAL [44] (*Spectral Unmixing by Splitting and*

Augmented Lagrangian). Une extension de cette technique est proposée dans celle qui intègre l'information spatiale SUnSAL-TV [45]. SUnSAL considère la technique dite *Alternating Direction Method of Multipliers* (ADMM) pour résoudre le problème d'optimisation en le décomposant en une séquence de problèmes plus simples à traiter. Comme mentionné précédemment, cette technique est employée pour estimer les abondances.

Cependant, l'utilisation d'un dictionnaire tirant profit des spectres connus au préalable peut induire un coût de calcul important surtout si le dictionnaire présente un nombre conséquent d'éléments. Pour réduire cette complexité, un algorithme basé sur la méthode appelée *Multiple Signal Classification* (MUSIC) [47] a été proposé. En effet, MUSIC permet dans ce contexte de sélectionner les composantes les plus pertinentes à sauvegarder dans les dictionnaires.

L'autre limitation de l'usage des dictionnaires réside dans les erreurs ou les pertes de performances car les spectres présents dans la scène traitée peuvent différer de ceux présents dans le dictionnaire à cause de différents phénomènes [48] ; ces erreurs sont nommées erreurs de non-correspondance (mismatching).

Récemment des méthodes ont été proposées [48] et [49] pour remédier à cette lacune. Ainsi, une variation des spectres est supposée décrite par une distribution gaussienne [48]. Une autre approche propose un dictionnaire adaptatif en laissant quelques bandes spectrales varier pour correspondre à la scène [49].

D'autres méthodes basées sur la SCA [51-52] utilisent un critère de corrélation ou bien de variance spatiale. Cependant, elles ne sont pas applicables sur toutes les images hyperspectrales, en particulier celles ayant une faible résolution spatiale où l'hypothèse de l'existence de pixels purs est délicate à vérifier. A cet effet, une méthode a été introduite dans [53] fondée sur la supposition que l'image contient des zones bi-sources, c'est-à-dire deux matériaux purs par zone.

1.4.4. Méthodes basées sur la factorisation en matrices non-négatives

Initialement connue sous le nom de Factorisation en Matrices Positives (FMP) ou *Positive Matrix Factorization* (PMF) [54], la NMF [55] est basée sur la positivité ou non-négativité des données traitées. Une attention particulière et plus de détails sont présentés par la suite sur la NMF. En effet, la configuration de positivité apparait bien adaptée au démélange spectral car les observations, les spectres et les abondances sont positifs.

La NMF permet de factoriser une matrice non-négative (positive) en deux matrices non-négatives (positives). Les algorithmes utilisant la NMF sont itératifs et ont pour objectif de minimiser une fonction de coût comme l'exemple suivant :

$$J = \frac{1}{2} \|X - AS\|_F^2, \text{ avec } A \geq 0 \text{ et } S \geq 0. \quad (1.11)$$

La fonction à minimiser est directement liée aux données dans l'équation (1.10). La norme la plus répandue est celle de Frobenius car elle est parfaitement adaptée aux données présentant un bruit décrit par une distribution gaussienne. Pour les bruits non gaussiens, la divergence de Kullback-Leibler [56] est plus appropriée. D'autres divergences existent comme celle de Bregman [57]. Pour les travaux de cette thèse la distance adoptée est celle de Frobenius.

L'inconvénient de la NMF est la non-unicité de sa solution car la décomposition en deux matrices n'est pas unique ; en effet, pour une matrice donnée Q inversible (vérifiant, ainsi que son inverse, la contrainte de non-négativité), nous avons la relation $X = AQQ^{-1}S$ qui implique une infinité de solutions. De plus, dans [58] il a été démontré que la contrainte de positivité à elle seule ne garantit pas une solution unique. En effet, une interprétation géométrique de la positivité des pixels d'une image est qu'ils appartiennent à un orthant positif. Le but de la NMF est de retrouver un cône englobant le nuage de points des données observées et situé dans l'orthant positif. D'après la figure 1.6, le cône n'est pas unique sans contraintes supplémentaires.

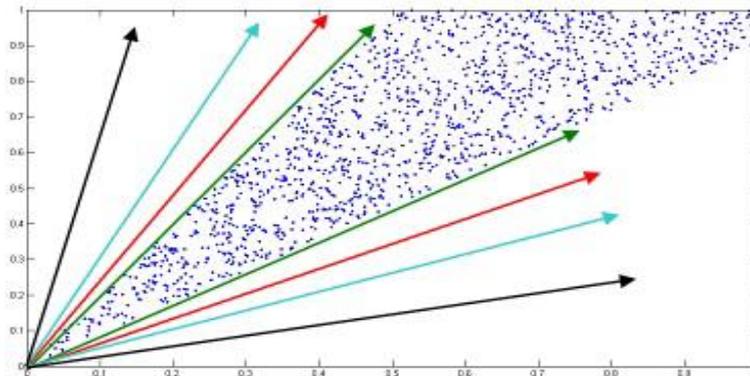


Figure 1.6 : Différents cônes englobant des données observées [59]

Par ailleurs, la NMF présente un problème d'optimisation, du fait qu'elle repose sur différents algorithmes qui assurent seulement une convergence vers un minimum local. Par conséquent, le point de convergence dépend de l'initialisation. L'autre limitation intrinsèque de la NMF et de la SAS en règle générale est le facteur d'échelle. Le cas le plus significatif montrant son impact est que si on multiplie une source par un facteur et on divise ses coefficients de mélange par ce même facteur le résultat reste identique.

Pour résoudre les problèmes de convergence liés à la NMF, différentes solutions existent :

- la normalisation [60] par la division des colonnes ou des lignes des matrices impliquées par la somme de leurs coefficients présente deux avantages : le premier est de réduire l'espace de solutions possibles et le second permet de résoudre les indéterminations liées au facteur d'échelle,
- l'initialisation [61-62], par rapport à laquelle la convergence de la NMF est très sensible, par exemple l'utilisateur peut tester la NMF pour plusieurs initialisations et retenir celle qui donne la fonction de coût la plus faible,
- l'addition de contraintes sur l'une ou les deux matrices à estimer pour réduire l'intervalle de solutions possibles, les contraintes les plus répandues sont celles de la parcimonie [63] dans le cas où la matrice à estimer contient une multitude de zéros ou bien la contrainte de lissage (smoothness) [64] pour rendre l'allure des variables contenues dans une matrice lisse,
- l'application d'un schéma multi-couches pour améliorer la convergence et éviter les minimums locaux [65].

Différents algorithmes ont été développés dans le cadre de la NMF, parmi les plus connus on peut citer les suivants.

Algorithme de gradient projeté [66] : cet algorithme considère le gradient projeté à chaque itération pour projeter les matrices dans l'espace des solutions possibles. Pour chaque mise à jour, les règles sont données par les équations suivantes :

$$A \leftarrow \left[A - \alpha_A \frac{\partial J}{\partial A} \right]_+, \quad (1.12)$$

$$S \leftarrow \left[S - \alpha_S \frac{\partial J}{\partial S} \right]_+, \quad (1.13)$$

où α_A et α_S sont des pas d'itération positifs fixés manuellement ou automatiquement pendant les mises à jour de A et S . $[\cdot]_+$ correspond à la projection sur \mathbb{R}^+ .

Algorithme multiplicatif [67] : proposé par Lee et Seung, il remplace les pas α_A et α_S par une écriture en fonction des matrices, plus précisément les éléments des matrices A et S sont mis à jour par des valeurs de pas d'adaptation différentes selon les éléments mis en jeu. Cet aspect présente l'avantage de ne pas fixer le pas comme dans l'algorithme à gradient. De plus, l'autre avantage réside dans les matrices A et S qui restent non-négatives (positives) pendant les itérations si elles sont initialisées par des valeurs non-négatives. Les règles multiplicatives sont :

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

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

où \odot représente l'opérateur de produit élément par élément et \oslash l'opérateur de division élément par élément. Une autre version de l'algorithme a aussi été introduite dans le cas où la fonction de coût à optimiser est la divergence de Kullback-Leiber.

Algorithme ALS [68] : l'algorithme dit *Alternating Least Square* (ALS) est basé sur les moindres carrés. A chaque itération, une matrice est mise à jour en fixant l'autre et inversement en calculant les moindres carrés. Pour respecter la positivité des matrices qui n'est pas considérée dans les moindres carrés, les valeurs négatives sont remises à 0 à chaque itération.

Différents algorithmes considérant la NMF ont été développés [69-71], une NMF a été proposée en intégrant des contraintes et des termes de pénalisation [69]. Pour plus de détails concernant les méthodes utilisant la NMF, on peut se référer à [60].

1.4.5. Dimensionnalité intrinsèque de l'image

Les méthodes de démélange spectral nécessitent généralement la connaissance a priori de la dimensionnalité intrinsèque (*Intrinsic Dimension* (ID)) de l'image traitée, en particulier pour les images hyperspectrales caractérisées par une grande dimensionnalité spectrale. Tout d'abord, il est fondamental de définir la ID d'une image hyperspectrale [72] : la ID des données observées X , composées d'une addition entre le signal S et le bruit B , est égale à la dimension du sous-espace vectoriel engendré par le signal S . Généralement, la ID correspond au nombre de signaux sources (dans le cas présent le nombre de pôles de mélange). D'autres définitions ont été formulées comme la dimension virtuelle définie par le nombre minimum de paramètres nécessaires pour réaliser un démélange spectral. Par ailleurs, le bruit impacte l'estimation de

la ID, en effet il est difficile de distinguer entre une valeur importante de bruit et une valeur faible d'un signal. Les différentes méthodes d'estimation de la ID et définitions sont rapportées dans [72].

Avant de présenter les techniques estimant la ID, il est nécessaire de noter que la définition d'un matériau reste subjective et dépend du cadre d'utilisation du démélange. Par exemple, dans un contexte bien défini, le but est de différencier plusieurs types de végétation alors que dans d'autres cas l'objectif est de distinguer la végétation par rapport à d'autres matériaux comme l'asphalte. Dans la partie suivante, les différentes méthodes développées dans la littérature pour estimer le nombre de pôles de mélange sont présentées.

Idéalement, l'une des approches les plus adéquates est de considérer une analyse des valeurs propres des matrices de covariance ou de corrélation. Elle permet de distinguer entre les valeurs propres du signal et du bruit [72]. Cependant dans la pratique, la distinction entre une valeur faible du signal et une valeur importante d'un bruit s'avère plutôt complexe. L'approche la mieux adaptée consiste alors à estimer le nombre de valeurs propres pertinentes à conserver pour retrouver une grande partie de l'information contenue dans l'image hyperspectrale. Dans cette optique, différentes méthodes ont été développées.

Harsanyi, Farrand, and Chang (HFC) [73] : cette classe de méthodes est basée sur le lemme de Neyman-Pearson pour déterminer si un élément du signal traité représente un signal ou un bruit. Originellement développée par Harsanyi, Farrand, and Chang, plusieurs méthodes ont été introduites dans [73] suivant cette approche. L'idée de base de cette catégorie de techniques est de comparer les valeurs propres des matrices de corrélation et de covariance. En effet, les valeurs propres permettent de décrire l'importance d'un élément en terme de variance ou d'énergie. Si un élément du signal ou un pixel dans notre cas, ne contient pas un signal source, les éléments des matrices des valeurs propres de covariance et de corrélation correspondant traduisent l'énergie du bruit présent. Dans ce cas précis, les valeurs propres sont supposées égales. Cependant en pratique cette différence entre ces deux valeurs n'est jamais égale à zéro, d'où la nécessité d'introduire un test basé sur un seuil. Une valeur de la différence supérieure au seuil implique la présence d'un signal source ou d'un pôle de mélange pour le cas des images de télédétection. Une extension de cette méthode consiste à appliquer un prétraitement (noise whitening) afin d'éviter que le bruit impacte les valeurs propres, cette méthode est nommée Noise-Whitening HFC (NWHFC).

Hyperspectral Subspace Identification by Minimum Error (HySime) [74] : tout d'abord cette méthode estime le bruit présent dans l'image ainsi que la matrice de corrélation associée au bruit en utilisant la régression linéaire multiple. Par la suite, le bruit est soustrait de chaque pixel de l'image afin de pouvoir estimer la matrice de corrélation du signal. Les vecteurs propres sont déduits à partir de cette dernière. La ID est obtenue en trouvant la valeur qui minimise l'erreur quadratique moyenne entre la projection de la matrice de corrélation des observations et la matrice de corrélation du bruit dans le sous-espace engendré par les vecteurs propres de la matrice de corrélation du signal.

Random Matrix Theory (RMT) [72] : la théorie des matrices aléatoires permet d'estimer le rang de la matrice de covariance.

Les méthodes ID nécessitent généralement l'estimation du signal de bruit présent dans l'image hyperspectrale. Récemment, deux études traitant cet aspect ainsi que l'impact du bruit dans l'estimation de pôles de mélange sont présentées dans [57] et [75].

1.4.6. Limites du modèle de mélange linéaire

D'après la section précédente, différentes méthodes peuvent être utilisées pour traiter le démélange. Elles sont principalement basées sur le modèle de mélange linéaire pour sa simplicité. Cependant, ce dernier est limité par deux facteurs importants : la non-linéarité et la variabilité spectrale, et ignorer ces deux aspects peut entraîner des erreurs pendant l'estimation des spectres. Par ailleurs, ces erreurs perturbent de manière conséquente l'estimation des abondances.

Le phénomène de non-linéarité se produit généralement dans les scènes en présence de diffusions multiples comme dans les scènes non-planes du type zones urbaines [16], [28], [67-78] et également dans le cas des mélanges intimes [79] (voir figure 1.7). Une synthèse succincte des travaux sur la non-linéarité est présentée dans la section 1.5 bien que ce phénomène ne constitue pas le sujet de cette thèse.

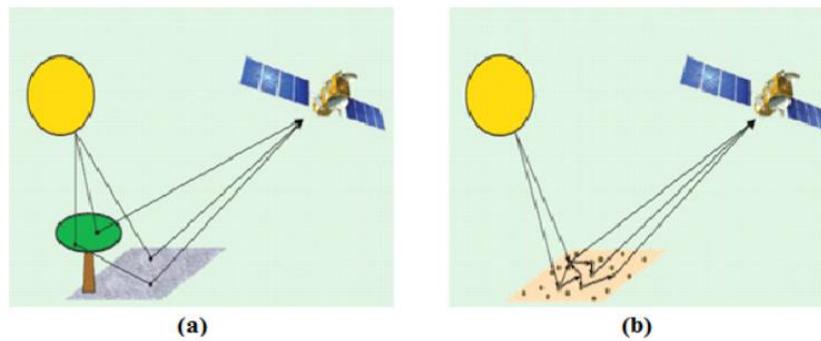


Figure 1.7 : Mélanges non-linéaires : (a) réflexions multiples, (b) mélange intime [28]

Le modèle de mélange linéaire standard stipule qu'une image hyperspectrale peut être reconstruite complètement à partir d'un seul spectre par matériau pur présent dans l'image. Cependant cela n'est pas toujours vérifié à cause de différents phénomènes physiques qui se produisent comme le changement d'illumination et de topographie dans la scène. Les conditions atmosphériques et la composition des matériaux peuvent entraîner la présence du phénomène dit de variabilité spectrale ou variabilité intra-classe. Pour mettre en évidence d'une manière détaillée cet aspect, une étude sur les zones urbaines [18], [80] a démontré ce phénomène illustré sur la figure 1.8. Les auteurs ont sélectionné plusieurs zones contenant des pixels purs de l'image et ont extrait plusieurs spectres manuellement. D'après cette figure, les spectres obtenus sont différents pour un même matériau. Ce résultat montre que pour appliquer le démélange spectral, la notion de matériaux purs doit être remplacée par la notion de classes de matériaux. La variabilité spectrale est le thème de cette thèse et dans la section 1.6 un état de l'art lui est consacré.

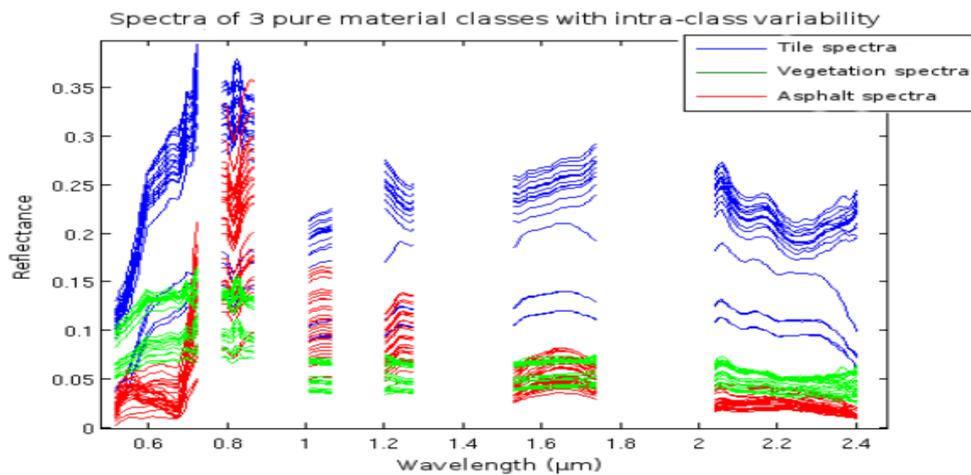


Figure 1.8 : Variabilité intra-classe dans une image hyperspectrale d'une zone urbaine [18].

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

La partie précédente a permis de présenter le mélange spectral linéaire et à l'évidence il ne peut s'appliquer à l'ensemble des cas réels. En effet, certains phénomènes de réflexion ne peuvent pas être interprétés par un modèle linéaire, comme le cas où la lumière reçue par un capteur interagit successivement avec plusieurs matériaux (au moins deux).

Les réflexions multiples se produisent généralement dans les scènes à surfaces très rugueuses ou des scènes avec un relief non plat comme dans le cas d'une scène urbaine. L'autre configuration de réflexions multiples est le mélange intime, c'est-à-dire que la réflexion se produit au niveau des particules comme dans les grains de sable. Dans ce cas bien précis, ce phénomène ne peut pas être ignoré et la solution alternative au modèle linéaire est l'utilisation d'un modèle non-linéaire qui apparaît plus adapté pour traiter une scène avec cette configuration.

Récemment, différentes méthodes ont été proposées pour résoudre le phénomène de non-linéarité même si le nombre de ces méthodes reste moins important que les méthodes de démixage linéaire à cause de la complexité de la modélisation des phénomènes de réflexion. Ces méthodes de démixage sont catégorisées en deux classes : les méthodes avec modèles non-linéaires non-définis et avec des modèles de mélange non-linéaires spécifiques.

1.5.1. Méthodes de démixage spectral pour des modèles de mélange non-linéaires non-définis

Ce type de mélange n'est basé sur aucun modèle physique ou aucun modèle de mélange bien défini au préalable. D'ailleurs, la plupart de ces méthodes considèrent plutôt les réseaux de neurones (ces méthodes ne nécessitant aucun a priori sur les modèles de mélange). Le but de cette partie est de présenter brièvement certaines de ces méthodes.

Une variante hybride [81] entre le démixage linéaire et non-linéaire est proposée :

- l'initialisation des endmembers est réalisée à partir de l'*Automated Morphological Endmember Extraction (AMEE)*,
- l'estimation des abondances utilise une méthode non-linéaire Perceptron Multicouche (*Multi-Layer Perceptron (MLP)*).

Une extension de N-FINDR, nommée *Simplex Volume Maximization*, est développée pour le cas non-linéaire [82]. Elle est effectuée en remplaçant la distance euclidienne pour mesurer le volume du simplexe dans la N-FINDR par une distance géodésique. D'autres variantes d'algorithmes appliquent une FCLS avec un noyau adaptatif KFCLS (*Kernel Fully Constrained Least Square*) [79], le noyau est introduit au niveau du critère à minimiser avec un paramètre ajustable lié au degré de la non-linéarité du mélange pour prendre en considération la non-linéarité. Cette technique permet d'estimer les abondances et de détecter les pixels contenant un mélange non-linéaire, en particulier dans le cadre d'un mélange intime. La KFCLS est une méthode supervisée nécessitant l'estimation des spectres au préalable.

Récemment, une approche a considéré un modèle de variables latentes de processus gaussien (*Gaussian Process Latent Variable Model (GPLVM)*) [83]. Elle estime les spectres ainsi que les abondances en supposant que chaque pixel est un mélange non-linéaire de matériaux contaminés par un bruit gaussien.

1.5.2. Méthodes de démélange spectral pour des modèles de mélange non-linéaires spécifiques

Récemment, différentes techniques ont été présentées pour traiter le phénomène de non-linéarité en se basant sur un modèle de mélange bien défini. Parmi ces modèles, on peut citer le bilinéaire et le linéaire quadratique [14], [28] et [76-78]. Le premier est un cas particulier du linéaire quadratique où les termes au carré sont absents. Leurs applications ont pour but d'intégrer les interactions entre différents matériaux en présence d'un relief dans la scène comme dans le cas des images urbaines ou les scènes avec de la végétation.

Une méthode [84] utilise un algorithme bayésien hiérarchique basé sur *Monte Carlo Markov Chain (MCMC)* pour résoudre le problème du modèle bilinéaire. Elle estime les abondances et nécessite la connaissance des endmembers présents dans l'image qui sont donnés par la VCA et requiert la présence de pixels purs dans l'image. Les performances et la robustesse de la méthode sont directement liées à la présence ou non de pixels purs dans l'image.

Une extension de l'algorithme *Sparsity-Promoting Iterated Constrained Endmember (SPICE)* est proposée pour traiter le modèle bilinéaire [85]. *Bilinear SPICE (BISPACE)* permet d'estimer les abondances et les spectres. L'extension réside dans l'étape de mise à jour des spectres ; chaque spectre est estimé en tenant compte des autres matériaux. D'autres travaux ont utilisé la NMF pour les deux modèles : le bilinéaire généralisé ou *Generalized Bilinear Model (GBM)* ou le linéaire quadratique (LQ).

Dans [17], les auteurs appliquent une NMF, plus précisément deux versions : le gradient (*Gradient Linear-Quadratic NMF*) et le multiplicatif (*Multi Linear-Quadratic NMF*). Pour plus de détails sur les modèles et les méthodes traitant la non-linéarité, une revue est présentée dans [15].

1.6. Méthodes de démélange spectral pour le mélange linéaire avec prise en compte de la variabilité spectrale

Dans cette partie, les causes de la variabilité spectrale sont présentées ainsi que les différentes méthodes qui traitent cette problématique. Comme mentionné précédemment, les méthodes de démélange spectral linéaire stipulent qu'une image peut être reconstruite entièrement en considérant seulement un spectre pour chaque matériau présent dans l'image. Cependant, dans la plupart des cas, cette supposition n'est pas valable.

En effet, les signatures spectrales des matériaux peuvent varier d'un pixel à l'autre dans une image hyperspectrale pour différentes raisons comme le changement d'illumination dans la scène, les conditions atmosphériques et la composition intrinsèque des matériaux [9] et [13-14]. Dans ce contexte, la notion de matériaux est remplacée par la notion de classes de matériaux [18]. Ignorer la variabilité spectrale peut entraîner des erreurs dans le processus d'estimation des spectres et l'estimation des abondances.

Les méthodes traitant la variabilité spectrale peuvent être catégorisées en deux approches. La première analyse l'impact que peut avoir la variabilité spectrale sur la précision de l'estimation des abondances et ainsi diminuer cet impact. La deuxième a pour but d'estimer la variation de chaque classe de matériaux d'un pixel à l'autre dans l'image. L'ensemble des méthodes de démélange développées pour la variabilité considèrent la première approche. Par contre, peu de méthodes traitent la deuxième due à sa complexité. Cette thèse a pour but de traiter la variabilité spectrale pour estimer les abondances et en parallèle au niveau spectral pour estimer les différents spectres de matériaux purs présents dans chaque pixel de l'image traitée.

1.6.1. Causes de la variabilité

A- Changement d'illumination

Généralement le changement d'illumination d'un pixel à un autre d'une scène est causé par deux raisons principales : le changement de topographie, plus précisément l'acquisition des images de scènes non plates et la rugosité des matériaux présents dans la scène [14]. En effet, la réflectance est liée aux deux angles d'incidence et de vue du capteur. D'après la figure 1.9, on observe clairement que ces deux angles peuvent varier localement d'une position à une autre dans l'image et donc d'un pixel à un autre dans l'image. Ce phénomène introduit une variation de l'éclairement entre les zones bien éclairées de la scène et des zones ombrées [87]. Ainsi, suivant sa position dans une image la signature spectrale d'un matériau peut varier. En particulier, cet aspect est fortement présent dans le cas des scènes urbaines où un bâtiment peut engendrer des zones ombrées dans l'image. Plusieurs facteurs entrent en jeu dans le cas de changement d'illumination comme l'azimut du soleil ou bien les propriétés intrinsèques du matériau.

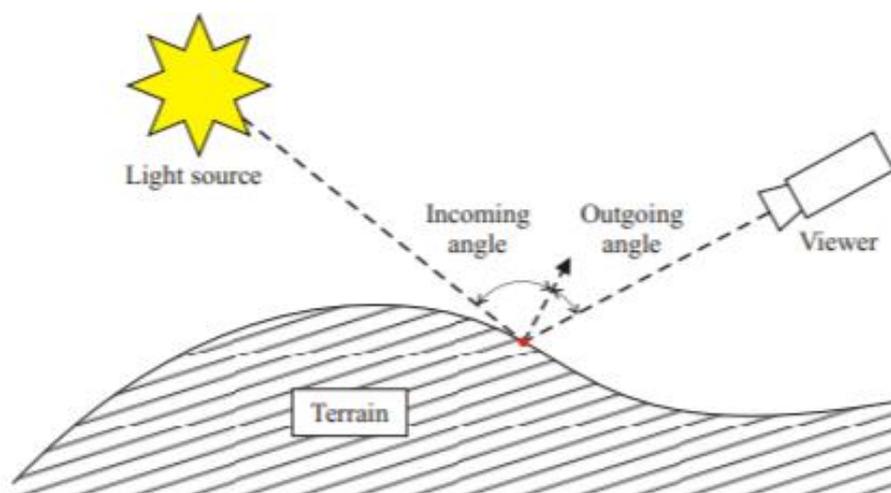


Figure 1.9 : Interaction de la lumière pendant l'acquisition d'un capteur [9].

Des modèles employés pour représenter ce phénomène comme celui de Hapke [88] donnent une interprétation complexe de ce phénomène. D'autres hypothèses, où par exemple seule la radiation incidente varie dans la scène, permettent de simplifier ce problème en considérant qu'un spectre en réflectance est multiplié par un facteur d'échelle constant au niveau du pixel. Plus précisément, dans chaque pixel on retrouve une version multipliée par un facteur des spectres d'origine. Les méthodes de démélange déduites de cette hypothèse sont traitées dans la section 1.6.2.3.

B- Conditions atmosphériques

Les conditions atmosphériques influent directement sur le traitement des images hyperspectrales pour différentes raisons comme l'absorption des radiations par l'eau ou la diffusion de la lumière causée par les aérosols. En effet, elles impactent directement les radiations transmises au niveau du capteur comme le montre la figure 1.10. Ainsi, les signatures spectrales d'un même matériau peuvent varier selon sa position dans l'image. Ce phénomène peut être atténué si nous appliquons des méthodes de correction.

Généralement, avant d'appliquer le démélange sur les images, les bandes spectrales présentant une forte absorption de l'eau sont supprimées. Par ailleurs, certains modèles physiques prenant en considération le capteur hyperspectral et les corrections atmosphériques des scènes étudiées permettent d'éliminer d'éventuelles distorsions des spectres reçus au niveau du capteur. Les méthodes traitant le problème des corrections atmosphériques sont classées en deux approches : les méthodes statistiques et les méthodes basées sur un modèle physique [89]. Les méthodes statistiques sont fondées sur les données a priori de la scène observée pour compenser cet aspect ; le but de cette classe de méthodes est de déterminer une relation entre le terrain et les signaux reçus par le capteur [89]. Les méthodes physiques sont plus robustes et développées sur des modèles mathématiques détaillés. Elles donnent une description plus complète de la diffusion et de l'absorption.

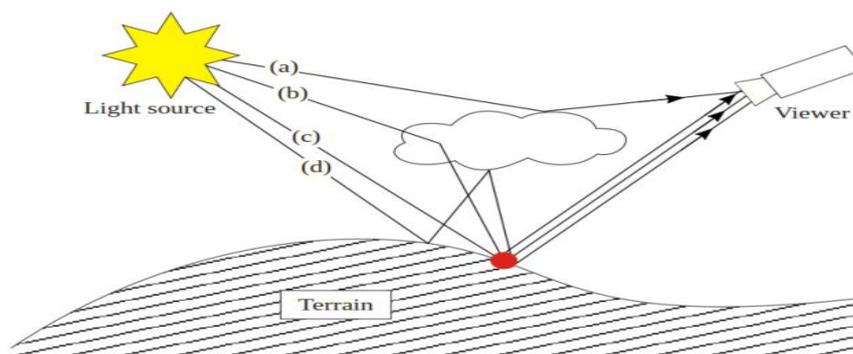


Figure 1.10 : Effet de l’atmosphère sur une image hyperspectrale : (a) lumière directement réfléchi vers le capteur, (b) lumière diffusée par l’atmosphère et réfléchi par le sol, (c) lumière réfléchi directement par le sol et (d) lumière réfléchi par des régions proches et diffusée par la suite [9].

C- Variabilité intrinsèque des matériaux

L’origine de cette variabilité est liée directement à la composition chimique et l’aspect physique des matériaux présents dans la scène. La végétation symbolise l’exemple type de cette variation spectrale. En effet, l’étude des scènes avec une forte présence de végétation à des fins de classification a montré qu’elle comporte une variabilité intrinsèque [90]. Cette variabilité intrinsèque est observée dans le domaine spectral 400-700 nm à cause de la concentration de chlorophylle qui varie entre les différents types de végétation et la concentration de caroténoïdes. Dans le proche infrarouge, elle est induite par la structure foliaire [90].

La variabilité intrinsèque demeure le type de variabilité le plus complexe à étudier et à modéliser car la variation n’est pas uniforme sur toutes les bandes spectrales. Une analyse et une synthèse sur les origines de la variabilité spectrale sont décrites dans les références [9] et [13-14]

1.6.2. Méthodes de démélange spectral prenant en compte la variabilité

1.6.2.1 Méthodes de démélange basées sur un dictionnaire spectral

Une manière de réaliser un démélange en prenant en compte la variabilité spectrale est de considérer un dictionnaire ou une bibliothèque spectrale (aussi nommée bundles) constitué de plusieurs signatures spectrales pour chaque classe de matériaux.

Plusieurs méthodes de démélange spectral utilisent cette approche et peuvent être classifiées selon la manière dont la bibliothèque est générée. En effet, il existe deux approches pour créer une bibliothèque. La première est de regrouper les spectres obtenus par des mesures sur le terrain à l’aide d’instruments. La deuxième technique extrait des signatures à partir de l’image pour laquelle l’application du démélange spectral est destinée en utilisant par exemple les méthodes géométriques citées dans la section 1.4.2. Chaque approche a ses avantages et ses inconvénients. Ces différentes méthodes sont présentées dans la partie suivante.

A. Méthodes utilisant une bibliothèque spectrale connue a priori

Parmi les premières méthodes traitant la variabilité spectrale, on peut citer la *Multiple Endmember Spectral Mixture Analysis* (MESMA) [91]. La méthode MESMA a été testée sur les montagnes de Santa Monica, Californie. Cette technique repose sur l’emploi d’une

bibliothèque spectrale connue a priori. MESMA part du principe qu'un pixel est initialement formé par une combinaison linéaire de deux signatures spectrales. MESMA recherche la meilleure combinaison possible entre un spectre de la bibliothèque spectrale et les abondances pour reconstruire ce pixel en se basant sur l'erreur de reconstruction. Plus précisément la méthode MESMA dans [91] emploie une bibliothèque constituée de 889 candidats, obtenus par une campagne terrain, pour former la combinaison de deux spectres par pixel de l'image. Pour des raisons de temps de calcul et de complexité, le nombre de candidats est réduit à 223 en enlevant par exemple les matériaux qui représentent moins de 0.001% de l'image considérée. Pour une partie de l'image, 14 candidats sont retenus pour représenter les classes de matériaux présents (sol, végétation non-photosynthétique et végétation verte) et considérés pour former les combinaisons. Les 14 matériaux ont été sélectionnés car ils couvrent une grande partie de l'image. Pour le reste de l'image, les 209 candidats restants sont considérés pour former les combinaisons restantes. Cependant dans [91], les pixels d'une partie restante de l'image ne peuvent pas être reconstruits seulement avec deux matériaux. Pour remédier à cela, 24 candidats sont choisis pour former des combinaisons de 3 matériaux possibles pour les pixels restants.

Le critère appliqué pour choisir la meilleure combinaison possible est l'erreur de reconstruction. D'autres critères peuvent être utilisés comme l'angle spectral (*Spectral Angle Mapper* (SAM)) [92]. Un des avantages de la méthode MESMA est sa flexibilité ; elle permet la variation des spectres au niveau de chaque pixel. Un autre avantage est une bonne reconstruction de l'image. Cependant, les performances de MESMA dépendent fortement de la qualité de la bibliothèque spectrale utilisée. L'inconvénient majeur de MESMA est le temps de calcul surtout dans le cas d'une image présentant un nombre important de pixels. Différentes méthodes ont été introduites afin de résoudre les problèmes de MESMA.

Une étude récente dont le but est de cartographier des zones méditerranéennes utilise la méthode MESMA. Dans ce cas, la bibliothèque spectrale a été construite à partir des données de l'instrument AVIRIS (*Airborne Visible/ Infrared Imaging Spectrometer*) et les spectres issus des images collectées par Landsat 5 TM. Pour réduire la complexité de calcul et la taille de la bibliothèque spectrale, la PPI a été appliquée pour sélectionner les matériaux les plus pertinents à retenir [93] en particulier des spectres issus des images de Landsat 5 TM. Une autre technique suit la même approche que la méthode MESMA à savoir trouver la meilleure combinaison possible entre un spectre et une abondance pour un pixel donné de l'image. Cependant cette méthode utilise l'optimisation de l'angle minimal pour estimer la reconstruction au niveau de chaque pixel [94]. La méthode MESMA et ses différentes variantes mènent à une bonne reconstruction de l'image quand la bibliothèque spectrale le permet. Comme mentionné précédemment, la méthode MESMA fonctionne avec des bibliothèques spectrales obtenues via des campagnes terrains ou extraites à partir d'images réelles. Un facteur important à prendre en considération pendant l'emploi de la méthode MESMA est qu'une signature spectrale d'un matériau acquise sous certaines conditions peut varier sur l'image pour laquelle on veut appliquer MESMA. De plus, il est primordial de prendre en compte les données traitées en terme de longueur d'onde et de nombre de bandes présentes dans l'image qui peuvent différer par rapport aux spectres contenus dans la bibliothèque spectrale. Pour compenser cet aspect, une classe de méthodes a été développée dans laquelle une bibliothèque spectrale est extraite directement des images hyperspectrales sur lesquelles un démélange est appliqué. La partie suivante est dédiée à cette catégorie de méthodes.

B. Méthodes utilisant une bibliothèque spectrale extraite de l'image traitée

L'autre manière d'utiliser les bibliothèques spectrales est de les extraire de l'image hyperspectrale directement. En effet, cette opération permet de construire une bibliothèque

spectrale ou bundles avec des signatures spectrales qui sont dans les conditions similaires aux pixels de l'image traitée contrairement à MESMA.

Dans ce sens, une stratégie a été proposée dans [95], la première étape consiste à réduire la dimensionnalité des données. Par la suite, les candidats retenus pour former le bundle sont obtenus en générant des simplexes qui englobent toutes les données. En effet les candidats retenus se situent à l'extrémité des simplexes. Pour des raisons de non-linéarité et de variabilité spectrale, l'initialisation de la méthode, qui génère le simplexe, est effectuée manuellement [96].

Pour remédier à cet aspect manuel, une technique simple nommée l'*Automated Extraction Bundles* (AEB) a été adoptée dans [97]. Le principe de base est de faire tourner les méthodes géométriques d'extraction de matériaux sur plusieurs parties de l'image choisies aléatoirement pour construire la bibliothèque spectrale. Vu l'aspect aléatoire de la méthode, une étape de clustering est nécessaire pour grouper les différents matériaux en différentes classes, généralement l'algorithme utilisé est le *k*-means. Le critère considéré peut être soit la distance euclidienne ou bien la distance spectrale, l'avantage de la dernière est son insensibilité aux changements d'illumination et donc aux facteurs d'échelle.

Malgré sa simplicité, l'AEB est fortement dépendante de la taille de la partie de l'image sélectionnée car elle impacte directement les méthodes d'extraction choisies. Pour estimer les abondances, l'AEB utilise soit la FCLS ou bien la méthode MESMA. La figure 1.11 montre le fonctionnement des méthodes qui utilisent les bundles pour réaliser le démélange.

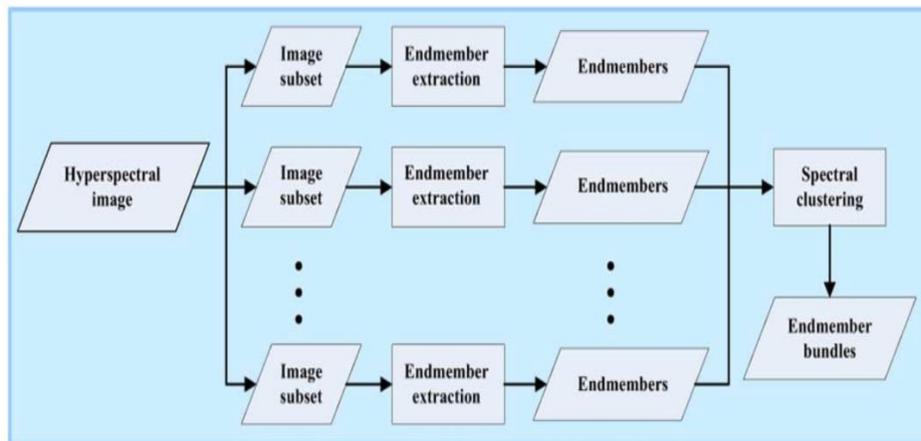


Figure 1.11 : Fonctionnement des méthodes basées sur les bundles [98].

Une autre approche [98] se base sur l'information spatiale de l'image pour générer les bundles. En effet, les matériaux purs dans les images hyperspectrales se situent généralement dans les zones homogènes de l'image et les mixels dans les zones de transition [99]. En considérant cette hypothèse, un indice d'homogénéité est calculé pour segmenter l'image en différentes régions et extraire les matériaux purs, le critère choisi pour calculer l'indice est la *Spectral Information Divergence* (SID). Comme pour l'AEB, le clustering est réalisé par l'algorithme *k*-means. Cependant, son utilisation pour classifier les différents candidats en prenant l'intégralité du spectre, à savoir toutes les bandes spectrales, n'est pas toujours optimale et peut mener à des erreurs dans la classification ; un matériau peut être en effet classifié dans la mauvaise classe. Dans plusieurs cas pratiques, la distinction entre les matériaux peut se faire seulement sur un nombre limité de bandes spectrales car ils sont corrélés dans la majorité des bandes. Pour surmonter cet aspect, une technique [100] divise l'image hyperspectrale dans le

domaine spectral en plusieurs images avec un nombre de bandes spectrales inférieur au nombre de bandes de l'image traitée.

Cette approche permet de différencier plus facilement les matériaux en considérant la variabilité inter et intra classe des matériaux. Par la suite, l'algorithme N-FINDR est appliqué pour extraire les matériaux du sous-ensemble d'images dans le domaine spectral extrait de l'étape décrite précédemment. Les matériaux sont alors regroupés dans une même bibliothèque spectrale. L'étape finale consiste à appliquer, le k -means sur cette bibliothèque spectrale pour classifier les spectres en considérant l'angle spectral comme approche. Par la suite, les indices obtenus par k -means sont considérés pour regrouper les spectres d'un point de vue global.

Les coefficients d'ondelettes [101] sont utilisés pour obtenir la classification des matériaux extraits. Tout d'abord, une transformation en ondelettes est appliquée sur l'image traitée. Cette transformation utilise les ondelettes de Haar, son avantage est l'insensibilité aux principales causes de la variabilité présentes dans l'image comme le changement d'illumination. Un filtre médian de 3×3 est donc utilisé pour réduire cet aspect. L'image est segmentée spatialement par la suite et les coefficients d'ondelettes les plus pertinents retenus pour représenter chaque sous-ensemble. Le critère est basé sur la *Deviation from Normality* (la comparaison entre la distribution des variables et une gaussienne avec la même variance et moyenne que les données). Plus cette valeur est élevée, plus le coefficient retenu montre une forte dissimilarité. Pour l'étape de classification, les coefficients les plus pertinents sont classifiés en différents bundles, en considérant la méthode d'apprentissage de la validation croisée et la méthode k -means.

1.6.2.2. Démélange local

L'une des approches pour gérer la variabilité spectrale de manière efficace est de considérer la variation des spectres dans une petite partie négligeable de l'image. L'idée de base de cette classe est de segmenter l'image hyperspectrale, d'appliquer un démélange local sur les différentes parties issues de la segmentation et de regrouper par la suite les spectres et les abondances de façon globale. Cette classe de méthodes est nommée démélange local (*Local Unmixing* (LU)).

L'une des premières approches basées sur le démélange local est une extension de MESMA, nommée la *Virtual MESMA* (VMESMA) [102]. Cette approche segmente l'image de façon manuelle et un démélange est appliqué sur les régions. A chaque itération de la VMESMA, la bibliothèque spectrale est mise à jour en intégrant manuellement de nouvelles signatures spectrales pour obtenir une estimation satisfaisante des abondances. Pour améliorer ce caractère trop supervisé de la VMESMA, une technique utilise une approche adaptative [99] au niveau du démélange local. Après l'extraction des spectres sur les différents segments de l'image, une étape de clustering est nécessaire pour regrouper les différents spectres et abondances au niveau global.

Une autre approche adaptative [103] au niveau spatial est proposée. L'estimation automatique des matériaux pour chaque pixel prend en considération le voisinage du pixel au lieu de prendre une image dans son ensemble. Cette méthode utilise deux métriques : la *Biophysical Composition Index* (BCI) et la *Normalized Difference Vegetation Index* (NDVI) pour extraire les possibles candidats au niveau local des classes de matériaux, en particulier les végétaux. Le choix de ces deux critères est motivé par deux aspects, premièrement la BCI est performante pour différencier les matériaux urbains en particulier entre un sol vierge couvert par aucun matériau et les surfaces imperméabilisées. Deuxièmement, la NDVI permet de distinguer les sols et des zones couvertes par plusieurs végétations. Par la suite, entre chaque

pixel cible et les candidats possibles, l'inverse de la distance euclidienne est calculée. Ainsi, les spectres présents dans chaque pixel sont générés comme étant une moyenne pondérée des spectres présents dans les pixels voisins. Finalement, un démélange linéaire est appliqué sur les spectres générés.

Une solution basée sur la *Binary Partition Tree* (BPT) est proposée dans [104]. Cette méthode utilise la BPT pour segmenter l'image en différentes régions. Un démélange local est appliqué en considérant l'erreur de reconstruction. Finalement, un critère de similarité est utilisé pour fusionner les différentes régions.

Les différentes méthodes citées considèrent toutes la même approche : diviser l'image en différents segments, estimer le nombre de matériaux et appliquer le démélange. Malgré leurs simplicités et la motivation d'un point de vue physique, le choix des régions et la manière de segmenter l'image impactent directement les performances du démélange spectral. Une revue plus détaillée de ce type de méthodes est proposée dans [9].

1.6.2.3. Modèle paramétrique

Récemment, différentes méthodes ont traité la variabilité spectrale en intégrant des termes supplémentaires dans le modèle de mélange. Ces termes traduisent la variabilité spectrale d'une part, et d'autre part ils permettent d'incorporer des termes de pénalisation et de contraintes pour gérer de manière plus efficiente la variabilité.

Le *Perturbed Linear Mixing Model* (PLMM) [105] considère le phénomène de variabilité sous forme additive en la formulant de la manière suivante :

$$X = SA + dS \quad (1.16)$$

où la matrice dS contient la perturbation additive au niveau de chaque pixel.

Les matrices des spectres S et de perturbations dS sont estimées de manière aveugle conjointement durant le démélange en utilisant l'ADMM pour résoudre le problème d'optimisation. Le fait d'estimer les deux matrices en parallèle augmente le nombre de paramètres à déterminer et le problème est non-convexe. A cet effet, différentes pénalisations sont introduites. La première consiste à appliquer une contrainte de douceur sur les abondances. La deuxième contraint la réduction du volume du simplexe en pénalisant la matrice des spectres. Enfin, la troisième limite les normes de la matrice dS pour obtenir une variabilité cohérente sur toute l'image. Le PLMM a été aussi considéré dans d'autres applications comme le traitement d'images hyperspectrales multi-temporelles.

Pour introduire la variabilité spectrale causée par le changement d'illumination, une stratégie a été proposée, et qui consiste à intégrer un facteur d'échelle. Cette méthode nommée l'*Extended Linear Mixing Model* (ELMM) [106] suppose que la matrice des spectres s'écrit sous la forme :

$$X = S(\psi \odot A) \quad (1.17)$$

où ψ contient les facteurs d'échelle au niveau des abondances et le symbole \odot représente la multiplication élément par élément. La matrice ψ permet aux spectres de varier au niveau de chaque pixel de l'image. L'ELMM est bien adapté pour la variabilité causée par les changements de topographie et d'illumination car il peut être déduit à partir d'approximations du modèle de Hapke. Afin d'améliorer l'ELMM et le rendre moins dépendant de l'initialisation

de la matrice S , une extension a été introduite dans [107], elle permet d'initialiser S en utilisant l'algorithme k -means sur les données observées. Le critère adopté pour le k -means est la distance angulaire ou l'angle spectral. L'autre avantage de cette extension est de pouvoir introduire la variabilité résultante de la composition intrinsèque des matériaux présents dans l'image.

Deux autres approches basées sur l'ELMM ont été développées récemment, nommées *Multiplicative-tuning Linear Mixing Model* (MLMM) [108] et *Generalized Linear Mixing Model* (GLMM) [109]. Elles apportent plus de flexibilité au ELMM en introduisant le facteur d'échelle sur les spectres à la place des abondances pour traiter des types de variabilité plus complexes. Plus précisément, ces algorithmes permettent à chaque bande spectrale de varier suivant :

$$X = (\psi \odot S)A \quad (1.18)$$

où ψ contient les facteurs d'échelle au niveau de chaque bande spectrale.

Un algorithme basé sur la NMF est utilisé [108] et un algorithme basé sur l'ADMM est considéré dans [109].

Pour traiter d'autres types de variabilité non considérés par l'ELMM, l'*Augmented Linear Mixing Model* (ALMM) a été proposé dans [110]. Dans l'ALMM, un dictionnaire a été ajouté pour décrire d'autres types de variabilité que celle traduite seulement par un facteur d'échelle. l'ALMM est défini par :

$$X = SA\psi + EB \quad (1.19)$$

où E représente le dictionnaire de variabilité spectrale et B les coefficients liés à cette matrice.

Une approche utilisant un modèle paramétrique nommée *Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation* (IP-NMF) [18] est détaillée exhaustivement et utilisée sur les données des fonds marins dans le chapitre suivant.

1.7. Conclusion

Dans ce chapitre, les principes fondamentaux de la SAS appliqués au démélange spectral dans le cadre d'images de télédétection ont été présentés. Dans une première partie, une description des principes de la SAS a été introduite ainsi que le modèle de mélange linéaire.

Par la suite, la problématique du démélange spectral a été formulée ainsi que les différentes méthodes développées pour son traitement. Les différentes techniques ont été divisées en plusieurs catégories selon leur fonctionnement. Par la suite, les limites du démélange spectral linéaire à savoir la non-linéarité et la variabilité spectrale ont été détaillées.

La deuxième partie a été consacrée aux différentes méthodes traitant la non-linéarité. Elles sont divisées en deux grandes catégories bien distinctes : celles basées sur les modèles de mélange non-linéaires non-définis et définis comme les modèles bilinéaire et quadratique.

Dans la troisième partie, la variabilité spectrale a été abordée. Tout d'abord, les causes de la variabilité ont été analysées, à savoir les changements d'illumination, les conditions atmosphériques et la variabilité intrinsèque des matériaux. De plus, les méthodes traitant la variabilité spectrale ont été présentées. Les différentes méthodes ont été regroupées en plusieurs classes selon leurs principes de fonctionnement.

Dans le chapitre suivant, une étude sur l'application d'une méthode de démélange d'images hyperspectrales sur des fonds marins est abordée ainsi que la manière de traiter la variabilité spectrale dans cette configuration.

Chapitre 2 : Application d'une méthode, de la littérature, de démixtion linéaire avec prise en compte de la variabilité spectrale sur des données de fonds marins

Chapitre 2

Application d'une méthode, de la littérature, de démixage linéaire avec prise en compte de la variabilité spectrale sur des données de fonds marins

2.1. Introduction

Les océans constituent une ressource incommensurable pour la planète et l'humanité. Les ressources marines fournissent à l'Homme de nombreuses richesses : la nourriture, l'eau, des matières premières et de l'énergie (marée, pétrole, gaz).

Ainsi, la connaissance des océans et des fonds marins devient une nécessité dans plusieurs domaines : économique, écologique, voire stratégique. A ce titre, le suivi de l'évolution et la surveillance des océans pour leur préservation et protection constituent un challenge d'intérêt général. Par ailleurs, les différentes campagnes sur cet espace impliquent des moyens humains et techniques souvent très coûteux par rapport aux étendues immenses des zones à surveiller. En fait, pour de telles applications les images de télédétection sont plus efficaces en terme de rapidité d'analyse. Dans ce contexte, l'utilisation des images de télédétection apparaît comme une solution pertinente.

Dans un premier temps, les capteurs multispectraux ont été considérés pour étudier les fonds marins. Cependant leur faible résolution spectrale introduit plusieurs inconvénients, en particulier la complexité d'extraction des données d'intérêt ou encore la séparation des informations présentes dans l'image, en particulier dans le cas des eaux peu profondes [111]. Par ailleurs, les images hyperspectrales offrent une meilleure précision dans cette configuration par leur haute résolution spectrale malgré leur moins bonne résolution spatiale.

Avec l'avènement des capteurs hyperspectraux, l'information contenue dans les images hyperspectrales est devenue riche et nécessite un développement de traitement de cette information en adéquation. Cette dernière est complémentaire à d'autres moyens communément utilisés, à savoir les sonars et les radars. En ce sens, les méthodes de démixage peuvent s'appliquer pour extraire le maximum d'informations des images hyperspectrales comme la bathymétrie et la qualité de l'eau [112-116].

Cependant, ces méthodes ne sont pas toujours évidentes à mettre en œuvre car le signal observé pour chaque pixel dans une zone côtière est affecté par plusieurs facteurs. Une des perturbations est causée par l'atmosphère qui implique une description et le support d'un modèle physique adaptés. Par ailleurs, les différents phénomènes de diffusion et de réflexion dans la colonne d'eau et la réflexion par des fonds marins sont des éléments fondamentaux à prendre en considération.

Une étude, récemment développée, réalisée sur la zone côtière de l'île de Porquerolles en France a permis d'analyser ces différents phénomènes physiques. Pour la modélisation du transfert radiatif des fonds marins, l'outil OSOAA (Ordres Successifs Océan Atmosphère Avancé) [117] a été utilisé. Plus précisément, l'étude du modèle radiatif et les données des fonds marins considérés dans ce chapitre ont été analysées dans le cadre du projet HypFom ANR-15ASTR-019 supervisé par l'Agence Nationale de la Recherche. Le but de ce projet est de développer des modèles et des méthodes avancées d'inversion, d'estimation et de séparation de sources pour la cartographie des fonds.

Dans ce chapitre, une méthode de démixage spectral tenant compte de la variabilité spectrale est appliquée pour traiter des images hyperspectrales de fonds marins sur la base du modèle de transfert radiatif proposé dans [112]. L'objectif est d'estimer la proportion des différents matériaux présents dans les fonds marins comme les algues. A cet effet, la méthode utilisée est l'*Inertia-Constrained Pixel-By-Pixel Nonnegative Matrix Factorisation* (IP-NMF) [18]. Plus précisément, la première partie de ce chapitre est consacrée à l'aspect analytique montrant la possibilité d'appliquer un démixage linéaire prenant en compte la variabilité au modèle de données propre à cette étude. La deuxième partie traite la prise en considération de la variabilité spectrale pour ce type de données et en particulier dans le cas où la bathymétrie des données varie à l'intérieur d'une même image. La troisième partie est dédiée aux tests réalisés dans plusieurs configurations pour évaluer la robustesse de la méthode considérée pour ces travaux.

2.2. Modèle mathématique de données

L'analyse des océans fournit des informations sur la composition des fonds marins, elles sont déterminées à partir de la radiance à la subsurface (c'est-à-dire juste en dessous de l'interface air-eau) mesurée à l'aide des observations de télédétection. De récentes études ont proposé des modèles paramétriques performants pour simuler la radiance des eaux peu profondes en fonction de l'interaction avec les hydrosols, de la profondeur et de la réflectance des fonds marins. Sur la base de ces modèles, des algorithmes ont été développés pour estimer les paramètres pour chaque pixel d'une image de télédétection [115], [117-120].

Dans cette partie, les expressions analytiques des grandeurs radiométriques sont formulées, en particulier la radiance ascendante à la subsurface de l'eau et les différents termes décrivant les effets de contiguïté dans la colonne d'eau, sur la base du modèle du transfert radiatif.

Le modèle est appliqué pour des eaux peu profondes, pour réduire les interactions et donc simplifier l'étude. Nous considérons un pixel situé sur le fond marin et son plus proche environnement constitué de pixels voisins. De plus, l'ensemble des phénomènes d'interaction entre le rayonnement et le fond marin s'effectue entièrement dans la colonne d'eau.

Le modèle radiatif traité dans cette partie est issu d'OSOAA introduit dans [117]. Il simule un champ de rayonnement, plus précisément l'intensité et le degré de polarisation (l'orientation du champ électrique ou magnétique dans le plan perpendiculaire à la propagation), sur la base de plusieurs paramètres, en particulier :

- l'interaction du rayonnement avec l'atmosphère, l'océan et le fond marin,
- l'agitation de la surface de la mer en particulier l'effet des vagues,
- la réflexion du signal par le fond marin,
- les aérosols variés rencontrés dans les milieux côtiers,
- les hydrosols.

Dans le cadre de cette étude, une première étape consiste à formuler analytiquement et interpréter toutes les interactions entre la cible observée et son environnement. Plus précisément, il s'agit de décrire les effets d'adjacence causés par le fond marin et la colonne d'eau sur le rayonnement au niveau de la subsurface. La figure 2.1 décrit les différentes interactions des photons reçus par le capteur en terme de la luminance ascendante à la subsurface.

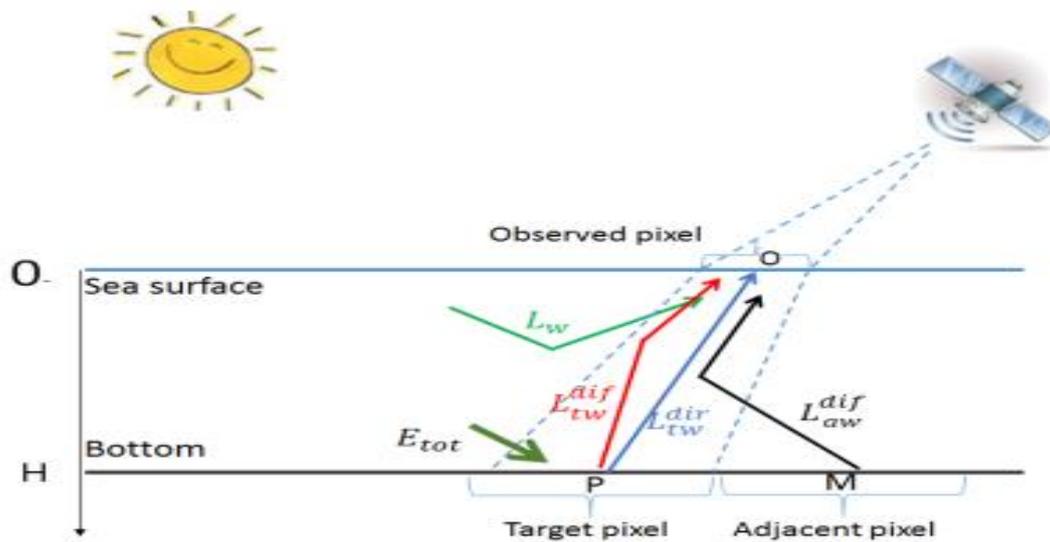


Figure 2.1 : Photons contribuant à la luminance ascendante à la subsurface [121].

Sur la figure 2.1, les différents termes représentent les grandeurs physiques suivantes [121] :

- E_{tot} : la luminance totale descendante au niveau du fond marin,
- L_{tw}^{dir} : la radiance ascendante directe au niveau de la subsurface après interaction avec le pixel cible,
- L_{tw}^{dif} : la radiance ascendante diffusée au niveau de la subsurface après interaction avec le pixel cible,
- L_{aw}^{dif} : la radiance ascendante diffusée au niveau de la subsurface après interaction avec l'environnement (pixel adjacent),
- L_w : la radiance ascendante diffusée au niveau de la subsurface de la colonne d'eau sans interaction avec le fond marin.

D'après la figure 2.1, le signal observé n'est pas seulement dépendant du pixel cible mais aussi des pixels voisins, la radiance subsurface, c'est à dire à la profondeur 0_- , peut être interprétée comme la contribution de trois grandeurs physiques prépondérantes L_{tw}^{dir} , L_{tw}^{dif} et L_{aw}^{dif} [121] :

$$L_{tot}(0_-) = L_{tw}^{dir}(0_-) + L_{env}^{dif}(0_-) + L_w(0_-), \quad (2.1)$$

où $L_{env}^{dif}(0_-) = L_{tw}^{dif}(0_-) + L_{aw}^{dif}(0_-)$.

Suivant les différents phénomènes physiques décrits, un modèle de mélange pour chaque pixel i observé dans la scène est établi d'après l'équation [113] :

$$x_i = k_{1,i} \odot (Sa_i) + k_{2,i} \odot (SAp_i), \quad (2.2)$$

où la matrice S contient les spectres des matériaux purs s_j dans chacune de ses colonnes et a_i les abondances pour le pixel considéré. L'opérateur \odot représente la multiplication élément par élément. Le vecteur spectral $k_{1,i}$ décrit les atténuations induites par l'eau sur le pixel observé i , pour les photons réfléchis directement par le fond marin. Le vecteur $k_{2,i}$ représente les atténuations causées par l'eau sur le pixel observé i pour les photons diffusés dans la colonne d'eau. Les deux quantités physiques sont déterminées au préalable à l'aide du modèle OSOAA [117] car elles sont supposées connues à l'initialisation de la méthode introduite dans la section 2.3. Pour le phénomène de réflexion directe, seul le pixel i est considéré, contrairement à la diffusion où l'environnement du pixel est également pris en compte.

Sa_i se développe selon une combinaison linéaire [113] :

$$Sa_i = \sum_{j=1}^J s_j a_{j,i}, \quad (2.3)$$

où J représente le nombre de matériaux présents dans l'image. SAp_i , qui représente l'effet d'adjacence, s'obtient en combinant linéairement les spectres s_j et les coefficients d'abondance contenus dans Ap_i . La quantité Ap_i s'interprète comme une abondance équivalente à la somme pondérée des proportions de matériaux purs $a_{j,n}$ présents dans le voisinage $V(i)$ du pixel observé i . Le terme SAp_i s'écrit sous la forme :

$$SAp_i = \sum_{j=1}^J \left[\sum_{n=1}^N p_{n,i} a_{j,n} \right] s_j, \quad (2.4)$$

où N correspond au nombre de pixels présents dans l'image. Le voisinage du pixel i est décrit par $p_{n,i}$ qui prend en considération le terme d'environnement δ ; avec $p_{n,i} = \frac{1-\delta_i}{N}$ si $n \in V(i)$ et $n \neq i$, $p_{n,i} = \delta_i$ si $n = i$ et $p_{n,i} = 0$ sinon.

Le paramètre δ_i varie en chaque pixel pour une profondeur non constante. De plus, il dépend aussi de la taille des pixels même si cette dernière est constante pour toutes les simulations considérées. Le deuxième terme de l'équation (2.2) peut être négligeable en comparaison avec le premier terme sauf dans le cas de fortes profondeurs.

Le modèle introduit dans (2.2) est traité en appliquant une méthode de démixage. En effet, il est possible de retrouver les spectres et les abondances même si les quantités $k_{1,i}$, $k_{2,i}$ et p_i sont inconnues. En intégrant (2.3) et (2.4), l'équation (2.2) devient :

$$x_i = k_{1,i} \odot \sum_{j=1}^J s_j a_{j,i} + k_{2,i} \odot \sum_{j=1}^J [\sum_{n=1}^N p_{n,i} a_{j,n}] s_j. \quad (2.5)$$

L'équation (2.5) peut être formulée suivant [116] :

$$x_i = \sum_{j=1}^J (a_{j,i} k_{1,i}) \odot s_j + \sum_{j=1}^J ([\sum_{n=1}^N p_{n,i} a_{j,n}] k_{2,i}) \odot s_j. \quad (2.6)$$

Une mise en facteur des termes s_j dans (2.6) permet d'obtenir [116] :

$$x_i = \sum_{j=1}^J (a_{j,i} k_{1,i} + [\sum_{n=1}^N p_{n,i} a_{j,n}] k_{2,i}) \odot s_j. \quad (2.7)$$

En comparant (2.7) au modèle linéaire standard, l'observation mesurée pour chaque pixel i reste une combinaison linéaire entre chaque matériau pur j avec différents paramètres de manière identique au modèle linéaire usuel.

Pour montrer le lien avec le modèle de mélange linéaire standard avec plus de détails, en supposant que le deuxième terme de l'équation (2.5) décrivant la diffusion soit négligé, nous obtenons alors :

$$x_i = \sum_{j=1}^J a_{j,i} (k_{1,i} \odot s_j). \quad (2.8)$$

Nous observons clairement que le modèle peut s'apparenter au modèle de mélange linéaire où chaque observation est une combinaison linéaire. Ainsi chaque spectre de réflectance mesuré au niveau d'un pixel i représente la somme des contributions pour chaque matériau j présent dans la scène, ces contributions sont décrites par les produits suivants :

- la première décrit les abondances d'une manière similaire au modèle de mélange linéaire classique et donc sans variabilité spectrale,
- la deuxième représente l'altération en amplitude des spectres s_j par $k_{1,i}$, plus précisément la modification de s_j est réalisée bande par bande avec $k_{1,i}$. De plus comme indiqué par les indices, le vecteur $k_{1,i}$ est directement lié au pixel considéré et donc pour chaque pixel de l'image traitée chaque matériau pur présent est décrit par une version différente. Cette configuration est proche de la variabilité intra-classe citée dans le premier chapitre et nécessite d'utiliser la notion de classes de matériaux.

D'un point de vue plus global en considérant l'équation (2.7) et en suivant la démarche décrite ci-dessus, nous observons que le spectre en réflectance mesuré pour un pixel i est une version de s_j altérée en amplitude par $k_{1,i}$ et $k_{2,i}$, en direction et en forme.

Au final, le but est d'estimer les spectres en réflectance altérés par les différents facteurs cités ci-dessus et de les comparer aux spectres de référence altérés eux aussi par les différents paramètres. Dans ce but, une méthode de démixage spectral récemment introduite est appliquée. En effet, comme montré précédemment le modèle peut être assimilé à un modèle linéaire plus précisément à un modèle linéaire étendu au cas de la variabilité spectrale où pour chaque pixel de l'image nous retrouvons une version différente des spectres des matériaux purs. Le choix de la méthode nommée *Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation* (IP-NMF) [18] est dicté par le fait que cette dernière est bien adaptée dans le cas présent avec la présence de variabilité intra-classe. En effet, l'IP-NMF permet d'extraire pour chaque pixel de l'image différents spectres pour chaque classe de matériau mis en jeu dans

l'image. De plus, cette méthode fonctionne de manière complètement aveugle et ne nécessite aucune information a priori sur les classes de matériaux présentes ou bien les coefficients de mélange. La section suivante est dédiée à la présentation de la méthode IP-NMF.

2.3. Méthode de la littérature testée

Dans le cadre de ce chapitre, une méthode de la littérature tenant compte de la variabilité spectrale dans le démixage spectral est considérée pour traiter le problème de SAS introduit dans (2.7). Cette méthode est l'IP-NMF [18]. L'intérêt de son application est d'une part le traitement des données dans le cas où aucune bibliothèque spectrale suffisamment consistante n'est disponible, et d'autre part l'étude des fonds marins dans notre cas où les matériaux sont sujets à une variation spectrale. Elle permet de retrouver de façon aveugle les contributions schématisées dans (2.7) en considérant la variabilité spectrale pendant l'application du démixage.

Dans cette partie, le modèle mathématique traitant la variabilité spectrale considérée pour cette étude et l'algorithme de la méthode sont présentés. La formulation mathématique pour chaque pixel x_i de l'image hyperspectrale est donnée par :

$$x_i = \sum_{j=1}^J a_{i,j} s_{j,i} \quad \forall i \in \{1, \dots, N\}, \quad (2.9)$$

où N représente le nombre de pixels de l'image et J le nombre de matériaux purs présents dans l'image. Ce modèle, contrairement au mélange linéaire classique, considère que pour chaque pixel i de l'image il existe un jeu, propre à ce pixel, de spectres purs associés à chacune des classes de matériaux purs. La contrainte de non-négativité des spectres $s_{j,i}$ et des abondances $a_{i,j}$ ainsi que celle de somme à un restent préservées.

Pour traiter la variabilité spectrale dans (2.9), la structure des variables impliquées doit être en adéquation. A cet effet, les notations suivantes sont adoptées [18] :

- la matrice S_i contenant l'ensemble des spectres purs associés au pixel x_i est introduite et formulée par $S_i = [s_{i,1}, \dots, s_{i,j}]^T$,
- la matrice $S = \begin{bmatrix} S_1 \\ \dots \\ S_N \end{bmatrix}$ contient l'ensemble des spectres sources de l'image,
- la matrice des abondances A est diagonale par blocs :

$$A = \begin{bmatrix} a_1^T & 0 \dots 0 & \dots & 0 \dots 0 \\ 0 \dots 0 & a_2^T & \dots & 0 \dots 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 \dots 0 & 0 \dots 0 & \dots & a_N^T \end{bmatrix}, \quad (2.10)$$

où $a_i = [a_{i,1}, \dots, a_{i,j}]^T$ est le vecteur des abondances associées à la matrice S_i .

Pour l'ensemble de l'image, la forme matricielle de (2.10) est donnée par [18] :

$$X = AS. \quad (2.11)$$

Par ailleurs, la fonction de coût est formulée par [18] :

$$J_{ipnmf} = \frac{1}{2} \|X - \tilde{A}\tilde{S}\|_F^2 + \mu \sum_{j=1}^J \text{Tr}(\text{Cov}(\tilde{S}_{a_j})), \quad (2.12)$$

où \tilde{A} et \tilde{S} représentent respectivement les matrices estimées de A et S . \tilde{S}_{a_j} correspond à la matrice contenant l'ensemble des spectres de la $j^{\text{ème}}$ classe de matériaux. Le terme $\mu \sum_{j=1}^J \text{Tr}(\text{Cov}(\tilde{S}_{a_j}))$ contrôle l'étalement des spectres à l'intérieur de chaque classe, plus précisément ce terme pénalise l'inertie des spectres. L'avantage d'introduire cette pénalisation est de restreindre seulement les spectres à l'intérieur d'une même classe et non pas un mouvement collectif des classes. De plus, les classes peuvent évoluer même dans le cas d'une mauvaise initialisation. Par ailleurs, μ gère l'inertie : plus μ est grand plus les spectres sont contraints de rester proches les uns des autres. Si $\mu = 0$, il n'existe pas de pénalisation des spectres et nous retrouvons le cas particulier de l'IP-NMF, à savoir *Unconstrained Pixel-by-Pixel NMF* (UP-NMF) [18].

L'IP-NMF utilise l'approche du gradient projeté pour minimiser la fonction de coût J_{ipnmf} . Ainsi, les expressions du gradient sont [18] :

$$\frac{J_{ipnmf}}{\partial \tilde{S}} = -\tilde{A}^T (X - \tilde{A}\tilde{S}) + \frac{2\mu}{N} (Id_{NJ} - \frac{1}{N}U)\tilde{S}, \quad (2.13)$$

$$\frac{J_{ipnmf}}{\partial \tilde{A}} = -(X - \tilde{A}\tilde{S})\tilde{S}^T, \quad (2.14)$$

où $U \in \mathbb{R}_+^{NJ \times NJ}$ est une matrice bloc dont chacun est composé d'une matrice identité Id .

L'IP-NMF considère les règles de mise à jour de l'algorithme de gradient projeté de la NMF. Cependant, la structure particulière des matrices entraîne des modifications mineures des règles de mise à jour. En particulier, la matrice des abondances \tilde{A} est mise à jour en considérant chaque vecteur \tilde{a}_i individuellement. Par ailleurs, il est possible de mettre à jour la matrice \tilde{A} de manière directe en fixant les zéros en dehors des blocs diagonaux à chaque itération. Pour la contrainte de la somme à un, à chaque itération les coefficients d'abondance sont normalisés. La contrainte de non-négativité est assurée par une comparaison entre chaque élément des matrices \tilde{A} puis \tilde{S} et un entier ε de valeur très petite. Au final, la valeur maximale est retenue. Le critère d'arrêt est soit de fixer le nombre d'itérations ou bien de vérifier si la différence entre le critère à optimiser lors de deux itérations successives est inférieure à un seuil préétabli ou en utilisant les deux critères en même temps. L'algorithme de l'IP-NMF est présenté ci-dessous [18].

Pour les tests réalisés, l'initialisation des spectres est assurée par la VCA [37] (voir chapitre précédent) tout en prenant en considération la structure particulière de \tilde{S} en dupliquant les spectres estimés. Les abondances initiales \tilde{A} sont obtenues en appliquant une FCLS [43] (voir chapitre précédent) entre l'image X et les spectres initiaux, les abondances sont agencées de manière identique à (2.10). Le paramètre μ est fixé à 150 sur la base d'études préliminaires réalisées sur des données synthétiques. En particulier, ces études ont démontré que les performances de l'IP-NMF sont en fait très peu sensibles à ce paramètre. De plus, suivant ces études le nombre d'itérations de l'IP-NMF est préétabli à 400.

Algorithme 1: Inertia-Constrained Pixel-By-Pixel Nonnegative Matrix Factorisation (IP-NMF).

1- Mise à jour de la matrice \tilde{S} .

$$\tilde{S}^{(i+1)} \leftarrow \tilde{S}^{(i)} + \alpha_{\tilde{S}} (\tilde{A}^{(i)T} (X - \tilde{A}^{(i)} \tilde{S}^{(i)}) - \frac{2\mu}{N} (Id_{NJ} - \frac{1}{N} U) \tilde{S}^{(i)})$$

$$\tilde{S}^{(i+1)} = \max(\tilde{S}^{(i+1)}, \varepsilon)$$

2- Mise à jour de la matrice \tilde{A} .

Pour $n = 1$ à N

$$\tilde{a}_n^{(i+1)T} \leftarrow \tilde{a}_n^{(i)T} + \alpha_{\tilde{A}} (x_n^T - \tilde{a}_n^{(i)T} \tilde{S}^{(i)}) \tilde{S}^{(i)T}$$

$$\tilde{a}_n^{(i+1)} = \max(\tilde{a}_n^{(i+1)}, \varepsilon)$$

3- Normalisation des coefficients de la matrice \tilde{A} .

Pour $n = 1$ à N

$$\tilde{a}_n^{(i+1)} \leftarrow \tilde{a}_n^{(i)} / \sum_{j=1}^J \tilde{a}_{nj}$$

2.4. Données testées

Le but de cette partie est de tester la méthode introduite sur des données synthétiques simulées à partir des données récoltées dans le cadre du projet HypFoM. Tout d'abord, l'intérêt de l'IP-NMF est de retrouver les abondances et les spectres, plus précisément les spectres altérés par les différents paramètres physiques décrits dans (2.7). Pour évaluer et comparer les performances de la méthode testée avec une méthode de démixage ne considérant pas la variabilité spectrale, les valeurs réelles des spectres sources, des abondances et des différents paramètres physiques mis en jeu dans chaque pixel de l'image sont connues au préalable. Le cadre ainsi défini permet d'étudier les performances de la méthode considérée par rapport aux valeurs de référence, plus précisément les spectres altérés comme décrit dans (2.7). Le protocole suivi pour les tests est de créer une image hyperspectrale suffisamment représentative d'une image obtenue par un capteur hyperspectral.

Premièrement pour créer ces images synthétiques, quatre spectres de matériaux purs obtenus par une campagne de terrain sont utilisés. Ils décrivent les signatures spectrales des matériaux suivants : taxifolia, sable, posidonie et substrat ; chacune d'elles contenant 31 bandes spectrales (voir figure 2.2). Le nombre de bandes reste limité car la simulation des différents paramètres physiques par le logiciel consomme un temps de calcul considérable à cause des nombreux facteurs considérés pour ce type de données [113].

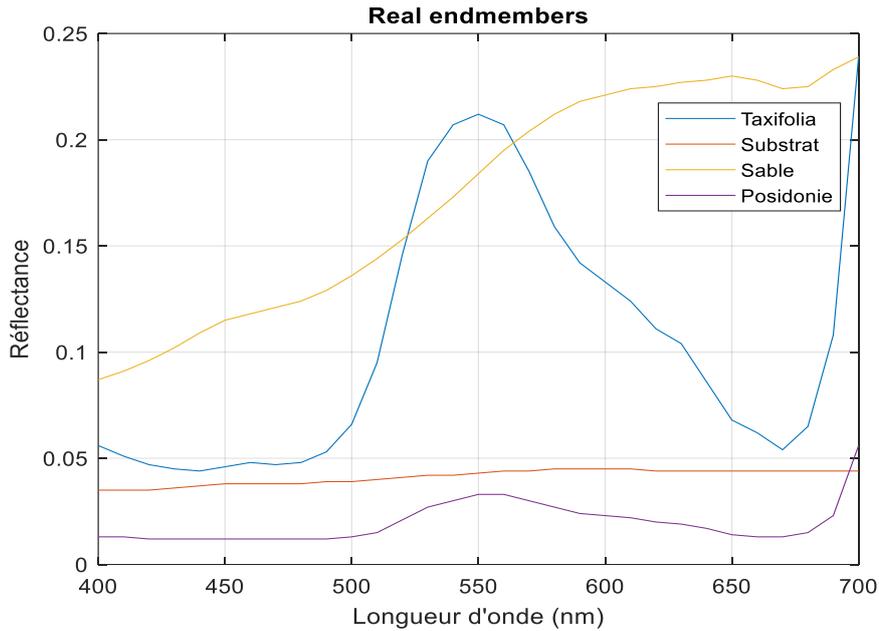


Figure 2.2 : Signatures spectrales des matériaux purs.

Dans une deuxième étape, les vecteurs k_1 et k_2 représentant les coefficients de transmission directe et diffuse de la colonne sont déterminés par le logiciel OSOAA [117]. Ces deux paramètres physiques dépendent de la profondeur et la qualité de l'eau. Les données, mises à disposition pour cette étude dans le cadre du projet HypFom, considèrent deux types d'eau : claire et standard. Les profondeurs mises à disposition pour simuler les données synthétiques correspondent à : 1, 2, 3, 4, 5 et 10 mètres. Sur un plan théorique, les valeurs des vecteurs k_1 et k_2 pour une profondeur donnée, sont supposées identiques pour tous les pixels. Cependant les simulations indiquent une légère variation illustrée sur les figures 2.3 et 2.4. Cette légère variation est due au fait que les deux termes dépendent de la composition des fonds marins par l'intermédiaire de l'éclairement au niveau du fond E_{tot} . Les figures 2.3 et 2.4 sont établies pour une profondeur constante de 1.5 m sur l'image.

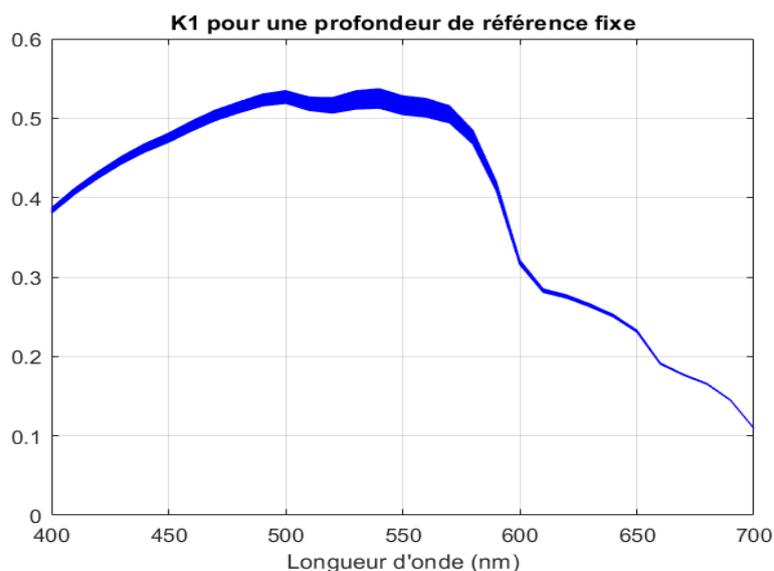


Figure 2.3 : Variations de k_1 en fonction du pixel à une profondeur de 1.5m en eau claire.

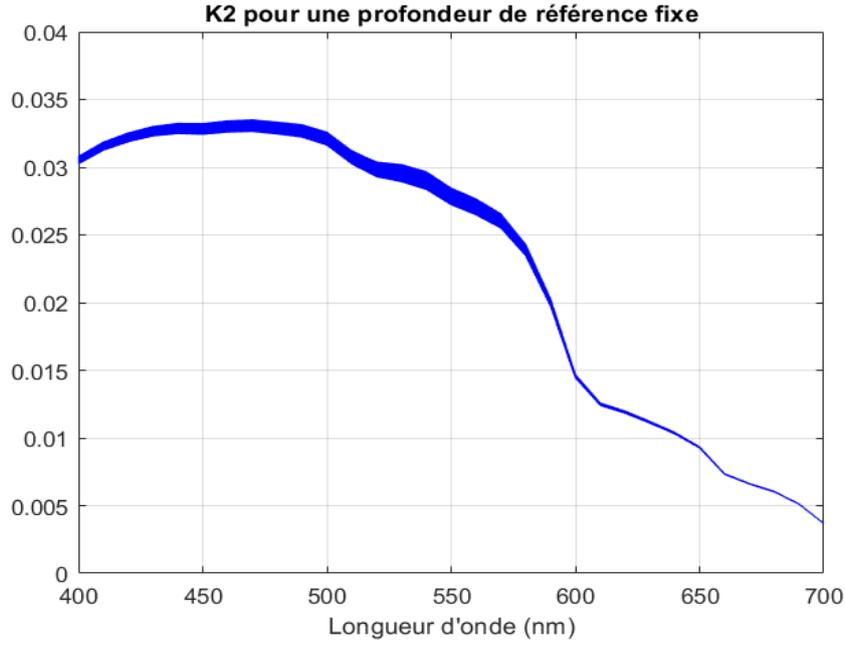


Figure 2.4 : Variations de k_2 en fonction du pixel à une profondeur de 1.5m en eau claire.

Le but de l'étude est de simuler des fonds marins de telle manière à obtenir de la variabilité spectrale pour tester l'IP-NMF, l'objectif étant de générer des données pour lesquelles chaque pixel à une profondeur différente par rapport aux autres pixels de l'image. Cette condition permet de simuler des données présentant de la variabilité spectrale. Les images générées considèrent des pixels avec des profondeurs variables autour d'une profondeur de référence à l'intérieur d'une même image. La profondeur de référence est notée d_{ref} , les vecteurs k_1 et k_2 sont adaptés à cet effet suivant une combinaison linéaire pondérée correspondant aux profondeurs les plus proches de la manière suivante [108] :

$$k_1(d_{ref}) = (0.5 - \alpha) * k_1(d_{ref}^-) + (0.5 + \alpha) * k_1(d_{ref}^+), \quad (2.15)$$

$$k_2(d_{ref}) = (0.5 - \alpha) * k_2(d_{ref}^-) + (0.5 + \alpha) * k_2(d_{ref}^+), \quad (2.16)$$

où d_{ref}^- et d_{ref}^+ représentent les profondeurs proches inférieure et supérieure. Ces profondeurs sont obtenues par OSOAA cité précédemment : 1, 2, 3, 4, 5 et 10 mètres. Le coefficient α est choisi selon la profondeur de référence considérée pour une simulation donnée, à titre d'exemple pour générer $d_{ref} = 1.5 m$, les profondeurs proches d_{ref}^- et d_{ref}^+ sont égales à 1 m et 2 m respectivement et $\alpha = 0$.

Suite à la création d'une profondeur de référence connue au préalable pour toutes les pixels de des images simulées, une profondeur aléatoire d_i pour chaque pixel, suivant une distribution uniforme, contenue dans un intervalle fixé au préalable compris entre $[d_{ref} - d_{max}, d_{ref} + d_{max}]$, est générée de manière synthétique. d_{max} est la limite de variation de la profondeur pixels autour de d_{ref} . Les deux vecteurs $k_{1,i}$ et $k_{2,i}$ sont calculés pour une profondeur d_i en utilisant une interpolation linéaire à partir des deux vecteurs k_1 et k_2 de référence pour deux profondeurs adjacentes déduites de (2.15) et (2.16). Pour illustrer cette démarche, les vecteurs $k_{1,i}$ et $k_{2,i}$ pour chaque pixel de l'image dans le cas d'une variation de la profondeur dans

l'image dans un intervalle de variation de $0.05 m$ autour d'une profondeur de référence $d_{ref} = 1.5 m$ pour une eau claire sont représentés dans les figures 2.5 et 2.6.

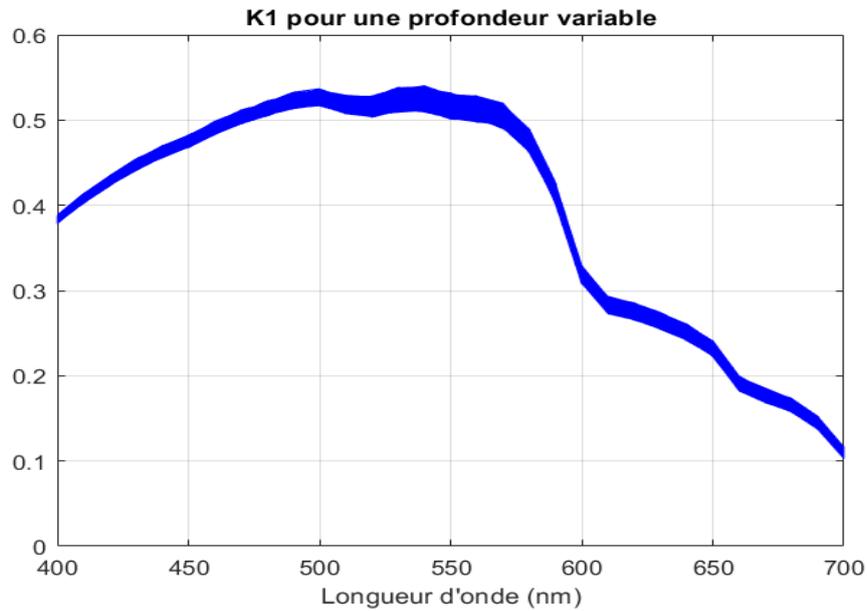


Figure 2.5 : Variations de k_1 en fonction du pixel pour une profondeur variable d_i autour de $d_{ref} = 1.5 m$ avec $d_{max} = 0.05 m$.

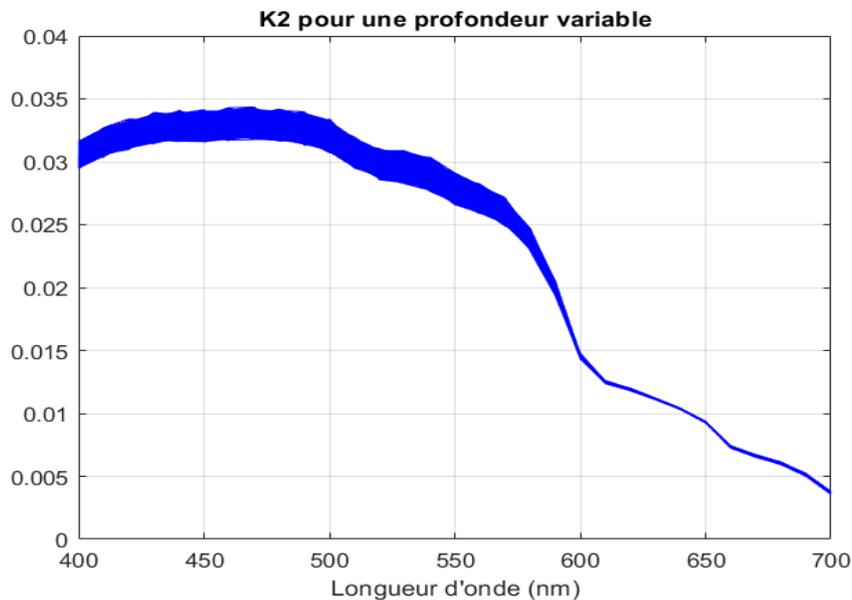


Figure 2.6 : Variations de k_2 en fonction du pixel pour une profondeur variable d_i autour de $d_{ref} = 1.5 m$ avec $d_{max} = 0.05 m$.

L'image hyperspectrale synthétique doit contenir des pixels mixtes, plus précisément chaque pixel de l'image contient un mélange de plusieurs matériaux. A cet effet, quatre cartes d'abondance sont générées aléatoirement pour chaque matériau pur considéré dans l'expérience. En particulier, elles ont été générées de telle sorte que chaque pixel de l'image

soit constitué au minimum de deux spectres purs. Ces cartes présentent une dimension de 100 lignes et 24 colonnes (ex : voir figure 2.7).

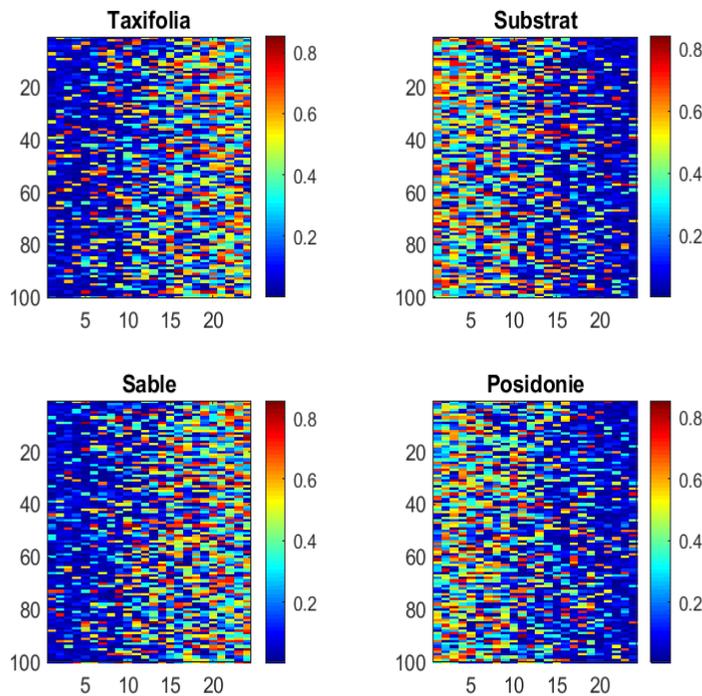


Figure 2.7 : Cartes d'abondance pour les différents matériaux.

Chaque spectre de l'image hyperspectrale synthétique est généré suivant (2.6) en prenant en considération les spectres des 4 matériaux purs, les vecteurs générés $k_{1,i}$ et $k_{2,i}$, les coefficients d'abondance du pixel traité et ses voisins. La figure 2.8 montre un jeu de spectres altérés de la classe Taxifolia avec les différents paramètres introduits dans l'équation (2.7).

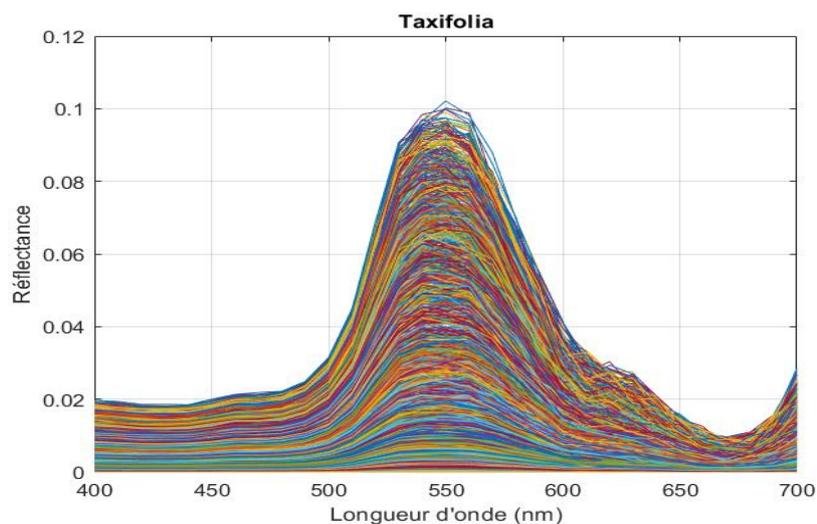


Figure 2.8 : Jeu de spectres altérés par les différents paramètres de l'équation (2.7) pour la taxifolia.

2.5. Critère de performances

Pour évaluer l'IP-NMF, l'approche suivante est adoptée : pour chaque pixel de l'image i et chaque matériau pur j , les informations disponibles sont :

- la valeur réelle de la contribution associée à chaque spectre qui représente les différents paramètres cités précédemment pour créer l'image synthétique,
- la valeur estimée, à un facteur d'échelle près, des contributions décrites dans (2.7).

La notion de facteur d'échelle est fondamentale dans le contexte des expérimentations proposées dans cette étude. En effet, elle est inhérente au problème de la séparation aveugle de sources, de plus l'estimation consiste à retrouver les spectres altérés à un facteur d'échelle près mais présentant la même direction que les spectres de référence. Ces derniers sont obtenus en considérant l'équation (2.7) et les vecteurs $k_{1,i}$ et $k_{2,i}$ générés aléatoirement pour chaque image simulée. Suivant ces deux propriétés, le critère le plus pertinent est l'angle entre les spectres estimés et les spectres de référence. A cet effet, le SAM (*Spectral Angle Mapper*) est considéré pour son insensibilité au facteur d'échelle [116]. Il est défini par :

$$SAM_{i,j} = \arccos \left(\frac{\langle r_{i,j}, \tilde{r}_{i,j} \rangle}{\|r_{i,j}\|_2 \cdot \|\tilde{r}_{i,j}\|_2} \right), \quad (2.17)$$

où $r_{i,j}$ et $\tilde{r}_{i,j}$ sont respectivement le spectre de référence et le spectre estimé du pixel i de l'image associés au matériau pur j de référence (utilisé pour la création des données synthétiques pour le pixel i), $\langle r_{i,j}, \tilde{r}_{i,j} \rangle$ étant le produit scalaire, $\|r_{i,j}\|_2$ et $\|\tilde{r}_{i,j}\|_2$ représentant les normes de $r_{i,j}$ et $\tilde{r}_{i,j}$.

Par la suite, le SAM est moyenné pour les quatre matériaux purs de l'image. Pour l'ensemble des cas étudiés, les résultats de l'IP-NMF sont comparés à ceux de la VCA, qui ne prend pas en considération la variabilité spectrale et donc le spectre estimé pour un matériau est unique pour toute l'image. Il est comparé à la contribution pour chaque matériau dans chaque pixel de l'image hyperspectrale, par la suite les valeurs de SAM sont moyennées pour l'ensemble des quatre matériaux.

2.6. Résultats obtenus et discussion

Dans cette partie, les différents tests réalisés et résultats sont présentés. La disponibilité des données et les conditions citées précédemment permettent d'effectuer un nombre conséquent de simulations. Plus précisément, trois études ont été effectuées pour tester la robustesse de la méthode utilisée pour différents types d'eau et de profondeur.

Les deux premières études consistent à mettre en valeur l'impact et la pertinence de prendre en considération la variabilité spectrale. Pour cela, la profondeur d_{ref} est fixée à 1.5 m pour les deux types d'eau claire et standard. Pour chaque type d'eau, cinq simulations sont réalisées pour d_{max} compris dans le domaine [0.05 m à 0.25 m] avec un pas de 0.05 m. La troisième étude a pour but d'évaluer la méthode testée pour une profondeur d_{ref} plus importante de 7.5 m, elle permet aussi de montrer la robustesse de la méthode considérée dans

des conditions avec la présence d'un bruit significatif dans les images simulées. Les différentes données et conditions sont résumées dans le tableau 2.1.

Etude	Type d'eau	Profondeur (d_{ref})(m)	Limites de variation (d_{max})(m)
1	claire	1.5	[0.05, 0.10, 0.15 0.20 et 0.25]
2	standard	1.5	[0.05, 0.10, 0.15 0.20 et 0.25]
3	claire	7.5	[0.05, 0.10, 0.15 0.20 et 0.25]

Tableau 2.1 : Conditions et types de données pour les simulations réalisées.

2.6.1. Première étude

La première configuration traitée considère une eau claire et une profondeur de référence $d_{ref} = 1.5 m$. Cinq simulations sont considérées pour différentes valeurs de d_{max} comprises dans les limites mentionnées dans le tableau 2.1. Le tableau 2.2 présente les résultats des valeurs moyennes du SAM obtenus par l'IP-NMF [18] et la VCA [37] pour les cinq simulations.

<i>Etude 1</i> <i>$d_{ref} = 1.5 m$</i> <i>Eau claire</i>	d_{max} (m)	IP-NMF	VCA
	0.05	<u>4.30</u>	4.58
	0.10	<u>3.90</u>	4.19
	0.15	<u>4.13</u>	4.52
	0.20	<u>3.96</u>	4.34
	0.25	<u>4.15</u>	4.73

Tableau 2.2: Valeurs moyennes du SAM ($^{\circ}$) pour la première étude.

Les valeurs moyennes du SAM montrent clairement, pour l'ensemble des configurations, que l'IP-MNF permet d'obtenir de meilleurs résultats que la VCA. En effet les valeurs numériques sont systématiquement inférieures. A titre d'exemple pour $d_{max} = 0.05m$, la valeur moyenne du SAM est de 4.30° pour l'IP-NMF et de 4.58° pour la VCA. Pour distinguer la différence entre ces deux résultats, le gain en pourcentage entre les valeurs de SAM de l'IP-NMF comparées aux valeurs de SAM de la VCA se révèle être un indicateur efficace. Le gain autour de la profondeur $d_{ref} = 1.5m$, i.e. $d_{max} = 0.05 m$, vaut 6.1% et donc la variabilité spectrale apparaît mineure.

Pour $d_{max} = 0.10 m$, le gain augmente par rapport à $d_{max} = 0.05 m$ et avec une valeur de 6.92 % . Cependant, ces gains restent contenus et limités par rapport à la VCA dans ces deux configurations car pour ces deux profondeurs la variabilité spectrale s'avère faible.

Une importante amélioration des performances de l'IP-NMF par rapport à la VCA est observée pour d_{max} plus grand. En effet, pour $d_{max} = 0.20 m$, le gain obtenu est de 8.76%

ce qui est en cohérence avec la supposition suivante : plus d_{max} augmente, meilleur est le comportement de l'IP-NMF en terme de performance avec un gain en SAM plus significatif entre l'IP-NMF et la VCA. Le résultat le plus conséquent pour la prise en considération de la variabilité spectrale est celui obtenu pour $d_{max} = 0.25 m$, en effet pour cette configuration le gain en terme de SAM est de l'ordre de 12.26%. Cette conclusion sur la performance de l'IP-NMF par rapport à la VCA pour la prise en compte de la variabilité spectrale sous le prisme du gain en terme de SAM est en adéquation avec l'hypothèse de départ. En effet, plus d_{max} augmente plus la variabilité spectrale devient prépondérante.

Le graphe de la figure 2.9, représente le gain en SAM de l'IP-NMF par rapport à la VCA pour les différents différentes valeurs de d_{max} mentionnés le tableau 2.2 autour de $d_{ref} = 1.5m$. La figure 2.9 montre clairement que plus la valeur de d_{max} augmente plus le gain de l'IP-NMF augmente.

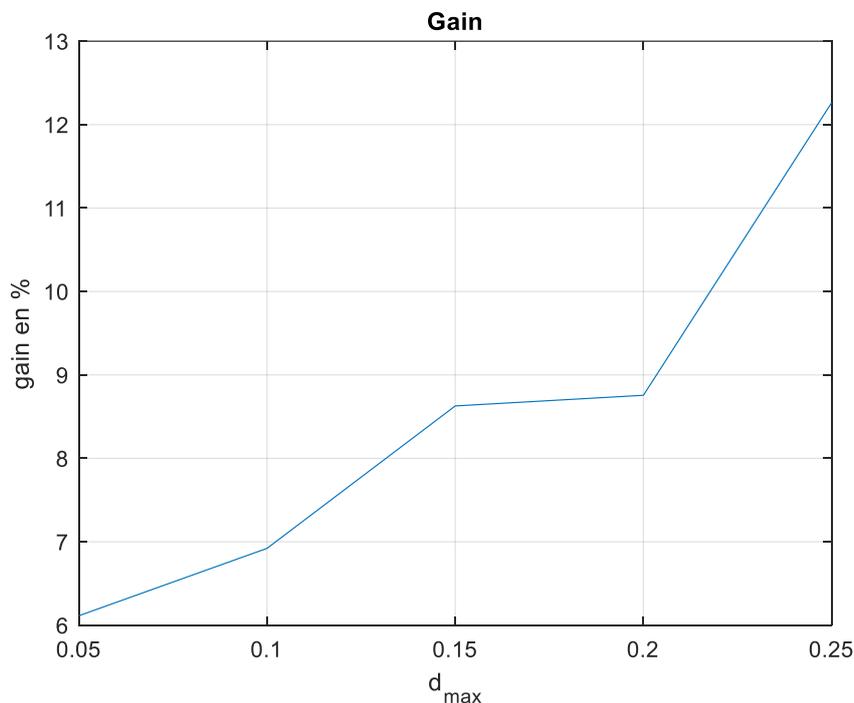


Figure 2.9 : Gain en % entre le SAM de l'IP-NMF et celui de la VCA selon les différents domaines de variation d_{max} autour $d_{ref} = 1.5m$.

Les spectres estimés, mesurés par la réflectance en fonction de la longueur d'onde, dans le cadre de la configuration $d_{max} = 0.25 m$ sont représentés dans les figures 2.10, 2.11, 2.12 et 2.13 pour les différentes classes de matériaux. Les figures se présentent sous une forme d'enveloppe, car chaque spectre est estimé pour chaque pixel de l'image montrant ainsi la présence de la variabilité spectrale dans cette image.

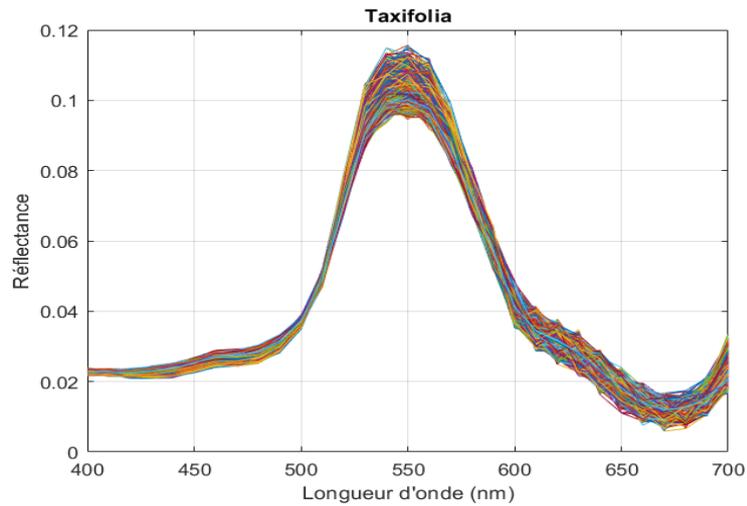


Figure 2.10 : Spectres estimés pour tous les pixels de l'image pour la classe taxifolia.

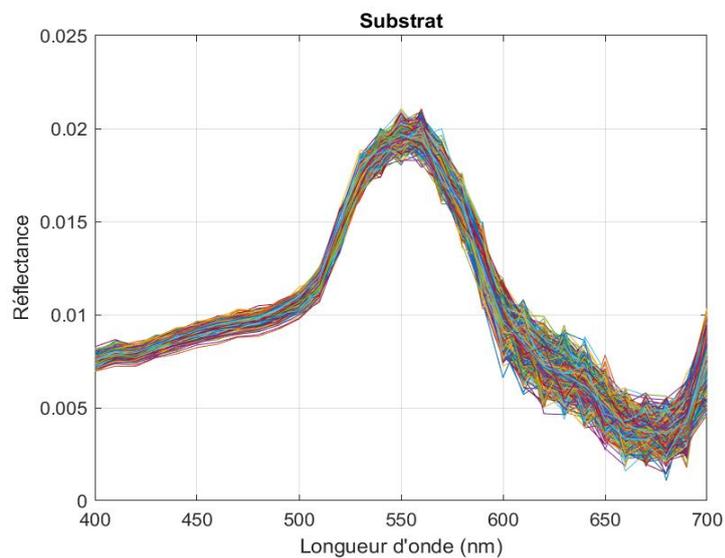


Figure 2.11 : Spectres estimés pour tous les pixels de l'image pour la classe substrat.

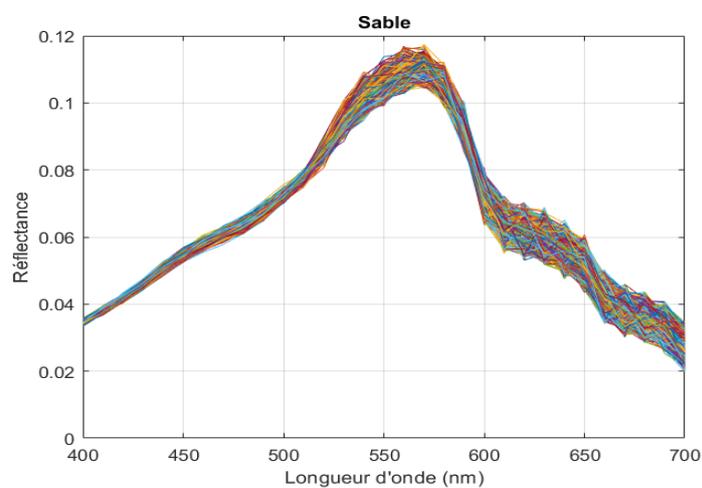


Figure 2.12 : Spectres estimés pour tous les pixels de l'image pour la classe sable.

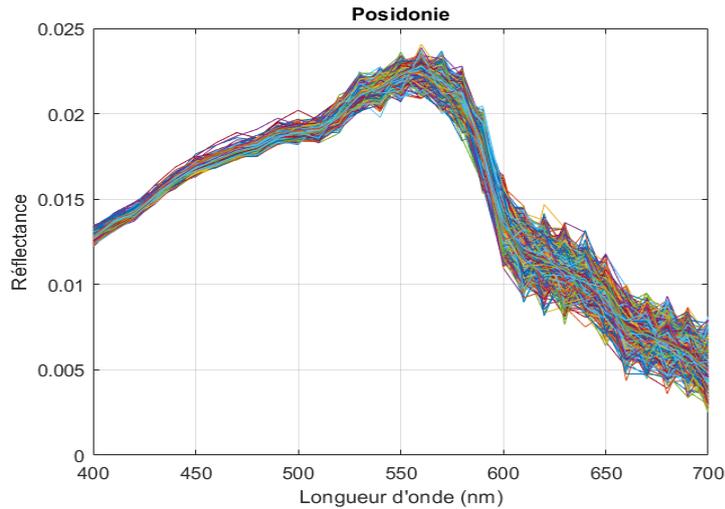


Figure 2.13 : Spectres estimés pour tous les pixels de l'image pour la classe posidonie.

2.6.2. Deuxième étude

La deuxième configuration est identique à la première mais appliquée pour un type d'eau standard. Les résultats des valeurs moyennes du SAM pour l'IP-NMF et la VCA sont reportés dans le tableau 2.3. D'après le tableau 2.3, nous notons clairement que l'IP-NMF présente des résultats plus performants que la VCA pour l'ensemble des simulations traitées. Les observations sont qualitativement similaires à la première étude, à la différence du comportement qui réside sur l'aspect quantitatif par rapport à la première étude. En effet, pour $d_{max} = 0.05m$ décrivant le domaine $[1.45m - 1.55m]$ autour de $d_{ref} = 1.5m$, la valeur moyenne du SAM obtenue par l'IP-NMF est de 3.75° et de 3.83° pour la VCA.

	d_{max} (m)	IP-NMF	VCA
Etude 2 $d_{ref} = 1.5 m$ Eau standard	0.05	<u>3.75</u>	3.83
	0.10	<u>3.02</u>	3.28
	0.15	<u>3.59</u>	4.02
	0.20	<u>3.90</u>	4.61
	0.25	<u>5.54</u>	6.53

Tableau 2.3: Valeurs moyennes du SAM ($^\circ$) pour la deuxième étude.

La figure 2.14 représente le gain en % entre les valeurs de SAM de l'IP-NMF et la VCA. Nous notons que pour $d_{max} = 0.05$, le gain absolu est égal à 2% traduisant une légère variabilité spectrale. Le gain absolu varie suivant une croissance brusque allant de 8% pour $d_{max} = 0.10 m$ jusqu'à atteindre 15% pour $d_{max} = 0.20 m$. Au delà de cette valeur de d_{max} , une crête est observée. L'ensemble de ces résultats souligne l'efficacité de la méthode pour traiter le phénomène de variabilité spectrale.

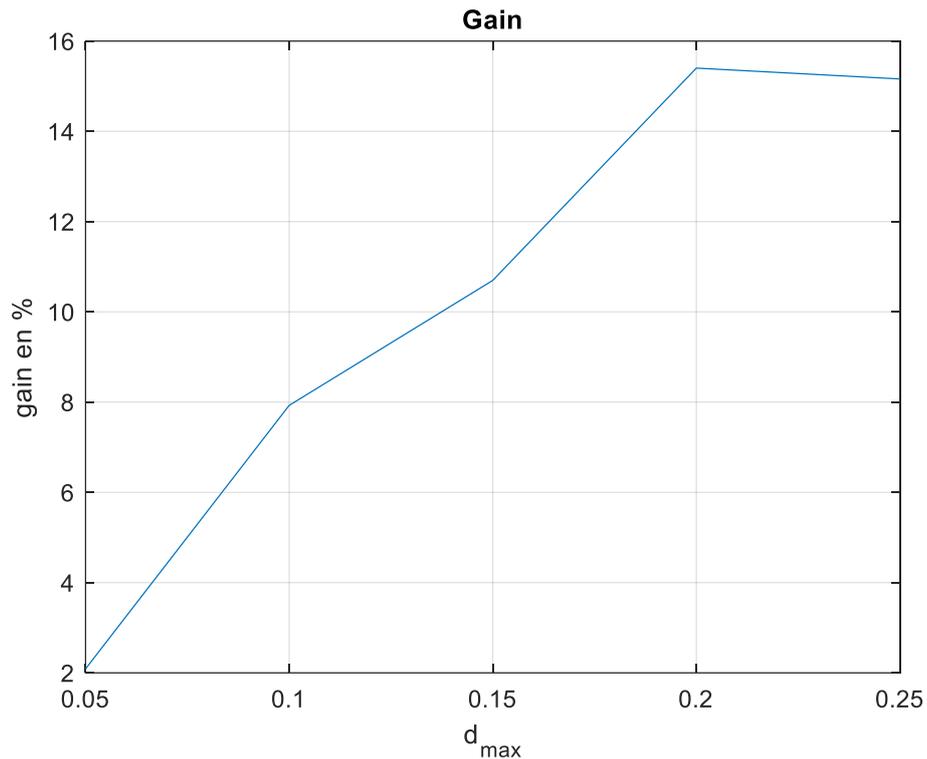


Figure 2.14 : Gain en % entre le SAM de l'IP-NMF et celui de la VCA selon les différents domaines de variation d_{max} autour $d_{ref} = 1.5m$.

Les spectres estimés pour chaque pixel de l'image dans le cadre de la configuration $d_{max} = 0.20 m$ sont représentées dans les figures 2.15, 2.16, 2.17 et 2.18. Elles montrent clairement le phénomène de variabilité pour les spectres estimés.

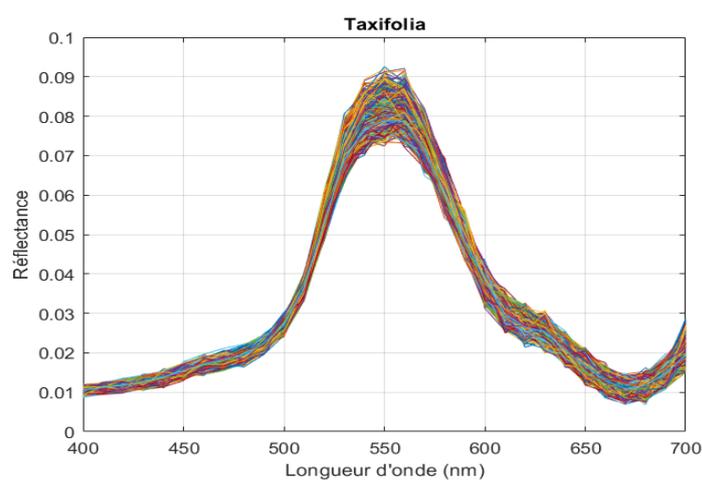


Figure 2.15 : Spectres estimés pour tous les pixels de l'image pour la classe taxifolia.

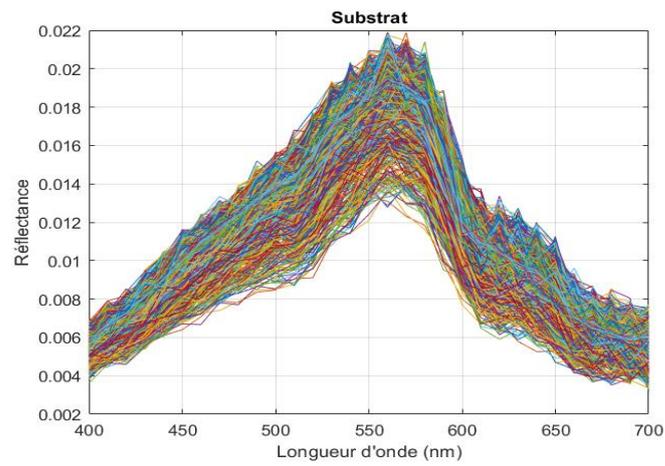


Figure 2.16 : Spectres estimés pour tous les pixels de l'image pour la classe substrat.

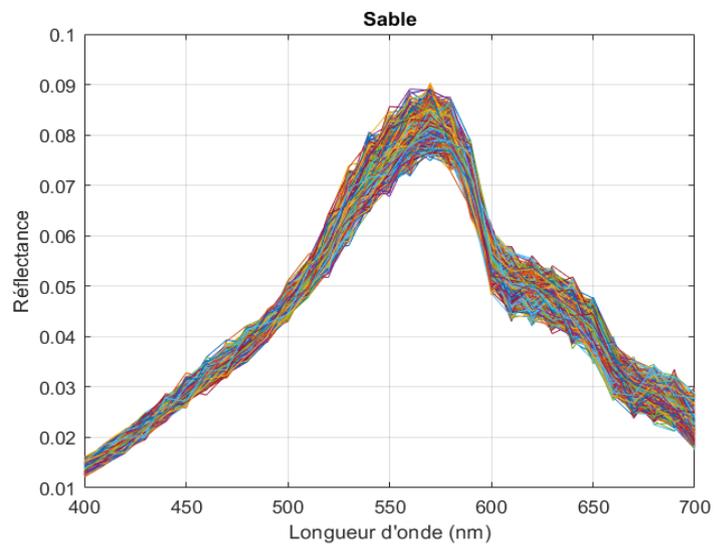


Figure 2.17 : Spectres estimés pour tous les pixels de l'image pour la classe sable.

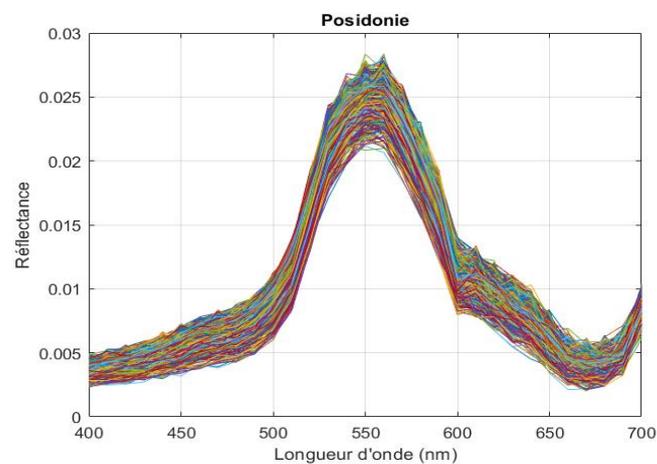


Figure 2.18 : Spectres estimés pour tous les pixels de l'image pour la classe posidonie.

2.6.3. Troisième étude

La troisième étude est réalisée pour évaluer l'IP-NMF dans des conditions de fonds marins avec une profondeur plus importante, à savoir 7.5 m au lieu de 1.5 m en eau claire. Une profondeur conséquente implique la présence d'un bruit plus significatif dans l'image et donc l'estimation des spectres devient problématique.

<p style="text-align: center;"><i>Etude 3</i> <i>$d_{ref} = 7.5\text{ m}$</i> <i>Eau claire</i></p>	$d_{max}\text{ (m)}$	IP-NMF	VCA
	0.05	<u>3.97</u>	4.03
	0.10	<u>4.75</u>	4.82
	0.15	<u>5.00</u>	5.18
	0.20	<u>5.32</u>	5.75
	0.25	<u>7.00</u>	7.44

Tableau 2.4: Valeurs moyennes du SAM ($^{\circ}$) pour la troisième étude.

Les résultats obtenus du SAM pour les deux méthodes IP-NMF et VCA sont reportés dans le tableau 2.4. Dans ce cas, l'IP-NMF reste toujours plus performante que la VCA en terme de valeur numérique du SAM. Le gain est décrit sur la figure 2.19. Nous notons un gain initial constant avec une valeur très faible de 1.5% pour $d_{max} = 0.10\text{ m}$. Cette valeur augmente avec d_{max} d'une manière abrupte jusqu'à atteindre un maximum de 7.5% pour $d_{max} = 0.20\text{ m}$ et diminue jusqu'à 6% pour $d_{max} = 0.25\text{ m}$. Les valeurs maximales atteintes sont de l'ordre de la moitié par rapport à celles de la deuxième étude. Cette conclusion est tout à fait cohérente et prévisible induite par la présence du bruit sur l'image.

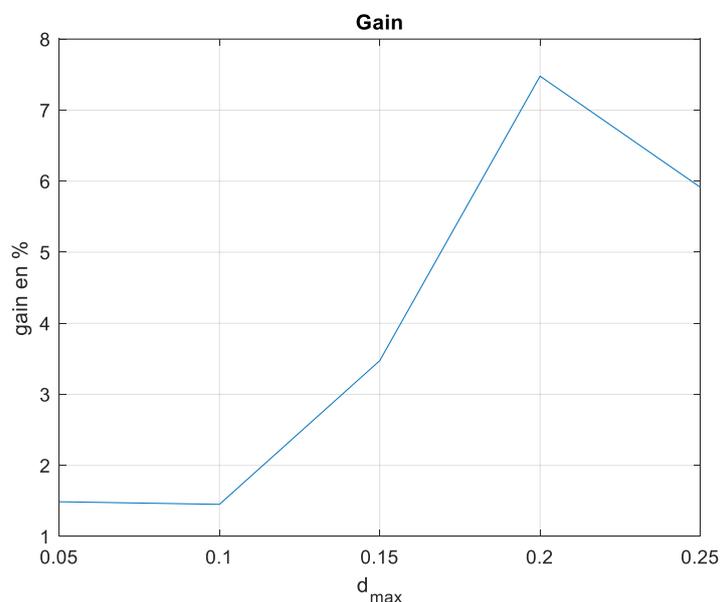


Figure 2.19 : Gain en % entre le SAM de l'IP-NMF et celui de la VCA selon les différents domaines de variation d_{max} autour $d_{ref} = 7.5\text{m}$.

Les spectres estimés dans le cadre de la configuration $d_{max} = 0.25 m$ sont représentés dans les figures 2.20 à 2.23. A noter que pour cette étude, la forme des spectres est différente par rapport aux études précédentes car les deux vecteurs k_1 et k_2 sont différents pour cette profondeur.

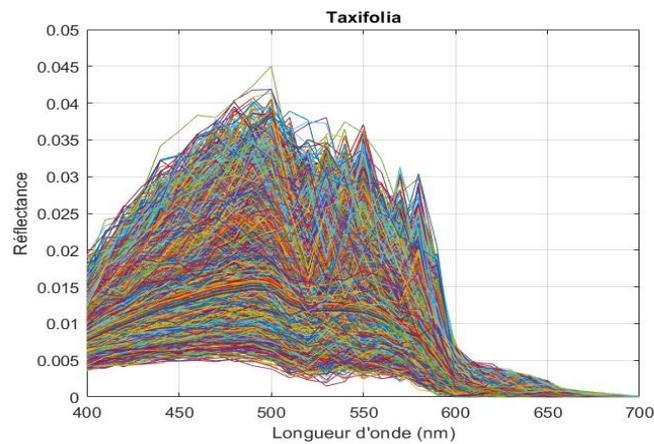


Figure 2.20 : Spectres estimés pour tous les pixels de l'image pour la classe taxifolia

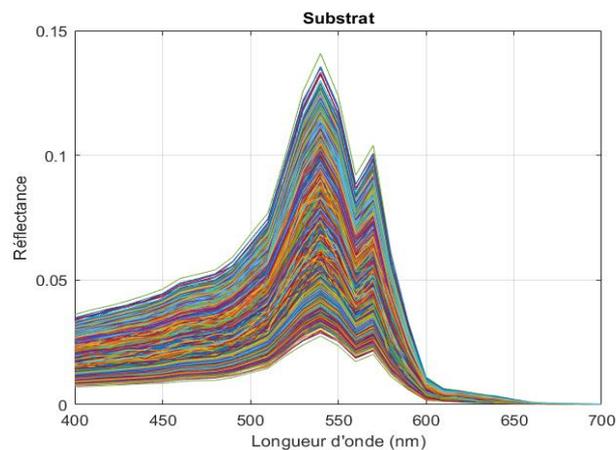


Figure 2.21 : Spectres estimés pour tous les pixels de l'image pour la classe substrat.

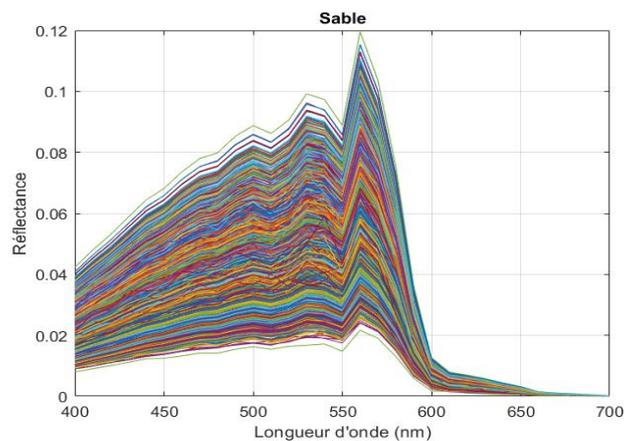


Figure 2.22 : Spectres estimés pour tous les pixels de l'image pour la classe sable..

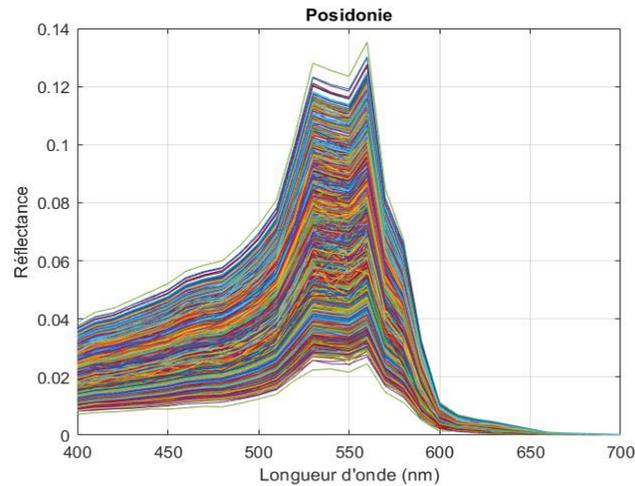


Figure 2.23 : Spectres estimés pour tous les pixels de l'image pour la classe posidonie.

2.7. Conclusion

Dans ce chapitre, une étude des fonds marins peu profonds a été réalisée en prenant en compte la variabilité spectrale sur la base d'un modèle de transfert radiatif. Dans ce modèle physique, récemment introduit, la luminance est déterminée à la subsurface en terme des contributions essentielles mettant en évidence les différents facteurs intervenant dans une colonne d'eau comme l'effet d'adjacence pour traiter un pixel cible et son environnement. Un développement analytique a permis d'introduire des simplifications pour réduire le modèle à un mélange linéaire classique en considérant certaines altérations causées par les fonds marins.

La deuxième partie a permis de démontrer qu'une méthode de démixage linéaire prenant en considération la variabilité spectrale, à savoir l'IP-NMF, est applicable pour ce type de données, elle permet d'extraire pour chaque pixel de l'image un spectre pour chaque classe de matériaux. Cette propriété s'avère intéressante en particulier pour le cas d'une image hyperspectrale avec des pixels correspondant à différentes profondeurs.

La troisième partie a été consacrée à la méthodologie suivie pour générer des données synthétiques mais réalistes en utilisant les différents paramètres tels que les matrices K_1 et K_2 contenant les atténuations de la colonne d'eau pour les termes directs et diffus pour chaque pixel de l'image observée. Cette méthode a été testée pour valider sa robustesse et sa fiabilité via sa performance par la comparaison des résultats obtenus avec ceux de la VCA qui ne prend pas en considération la variabilité spectrale.

A titre d'application, le fond marin considéré présente quatre matériaux purs : taxifolia, sable, posidonie et substrat. Le critère indiqué pour cette étude est le SAM, le choix de ce dernier étant justifié par son insensibilité aux facteurs d'échelles. Différentes simulations ont été réalisées, au total quinze simulations pour différents types d'eau, standard et claire, et différentes profondeurs, 1.5 m et 7.5 m. Ce nombre conséquent de simulations a pour but d'étudier la robustesse de l'IP-NMF selon plusieurs configurations.

Pour l'ensemble des simulations, il s'avère que les résultats obtenus par l'IP-NMF sont plus performants que ceux de la VCA. De plus, l'analyse du gain confirme nettement cette tendance même dans le cas de données fortement bruitées, c'est-à-dire en eau dite profonde. En effet, les

différents tests effectués ont montré que plus la profondeur de variation d_i est importante plus la performance de l'IP-NMF est meilleure comparée à la VCA.

Les perspectives envisagées, à partir de cette étude sur les fonds marins, sont à la fois multiples et motivantes. Dans un premier temps, l'étude peut être complétée par des simulations portant sur différentes configurations en fonction d'autres profondeurs pour obtenir une analyse plus fine des fonds marins. Un prolongement naturel de cette étude consiste à appliquer l'IP-NMF sur des données réelles et de comparer les résultats avec ceux d'autres méthodes de la littérature pour valider sa pertinence. Par ailleurs, les études des fonds marins ont toujours considéré l'hypothèse du fond marin plat, ainsi une généralisation serait indiquée en intégrant le phénomène de non-linéarité dans le processus d'estimation.

***Chapitre 3 : Méthodes Proposées de
Démélange Spectral Linéaire avec Prise
en Compte de la Variabilité Spectrale***

Chapitre 3

Méthodes proposées de démixage spectral avec prise en compte de la variabilité spectrale.

3.1. Introduction

Au cours de ces dernières années, les performances des capteurs de télédétection ont connu un développement considérable. En particulier, les capteurs hyperspectraux collectent des centaines, voire des milliers, de bandes spectrales allant du domaine du visible à celui de l'infrarouge. Par ailleurs, ces capteurs opèrent sur la base d'un compromis entre le rapport signal sur bruit (SNR) et la résolution spatiale. Cet arbitrage limite leur résolution spatiale et implique la présence de pixels mixtes (mixels) dans l'image c'est-à-dire que le spectre en réflectance observé pour un pixel est constitué d'un mélange de plusieurs matériaux purs ou endmembers présents. Dans ce contexte, le démixage spectral linéaire (LSU) constitue un outil standard pour estimer ces spectres de matériaux purs et les coefficients d'abondance associés.

Cependant comme mentionné dans le chapitre 1, l'hypothèse de départ de cette classe de méthodes, stipulant que chaque matériau pur est représenté par un seul spectre dans la totalité de la scène observée, n'est pas toujours valide. Le concept de matériaux doit être alors remplacé par de classes de matériaux pour éviter des erreurs pendant le processus de démixage, en particulier pour l'estimation des abondances. Ce phénomène est connu sous le nom de variabilité intra-classe spectrale.

Ce chapitre introduit les méthodes développées de démixage spectral, prenant en considération la variabilité spectrale dans cette thèse. En particulier, trois approches sont introduites pour tenir compte de ce phénomène. Elles sont toutes basées sur un modèle paramétrique et considèrent une factorisation en matrices non-négatives (NMF) pour l'estimation des spectres et des abondances composant l'image hyperspectrale, en utilisant les deux variantes multiplicatives et à gradient projeté. Dans une première partie, le modèle mathématique considéré des données est formulé. Il permet d'extraire pour chaque pixel de l'image hyperspectrale un jeu de spectres pour construire les classes de matériaux ainsi que les fractions d'abondances associées.

Dans la deuxième partie, la première méthode proposée est présentée. Elle est fondée sur un modèle paramétrique où la variabilité est intégrée au LSU de manière additive à l'aide de deux matrices contenant les coefficients permettant de gérer ladite variabilité spectrale, plus précisément en termes de variations supérieure et inférieure autour des spectres de référence.

En fonction du critère à optimiser déduit du modèle mathématique considéré, deux algorithmes sont développés pour la phase d'estimation.

La troisième partie concerne la présentation de la deuxième approche. Elle constitue une extension de la première méthode. En effet, cette technique considère une nouvelle fonction de coût dont l'intérêt majeur est de mieux gérer les structures des matrices traitées et en particulier celle des spectres. Cet aspect permet de simplifier la complexité du problème en réduisant la dimension de la matrice des spectres tout en respectant sa structure. Similairement à la première méthode, deux algorithmes associés à la nouvelle fonction de coût et basés sur la NMF sont proposés.

La dernière partie est consacrée à la troisième méthode développée. Elle introduit une fonction de coût étendue notamment par l'intermédiaire de deux nouveaux termes de pénalisation qui sont ajoutés à la fonction de coût de la deuxième méthode. Ils sont affectés de deux coefficients pour gérer la variabilité spectrale de manière plus efficace comparée aux deux premières méthodes.

3.2. Modèle mathématique de données

Dans cette partie, le modèle de données utilisé pour les trois méthodes proposées est présenté. Le modèle de mélange considéré dans les techniques LSU classiques est le modèle linéaire. Suivant ce dernier, le spectre de réflectance non-négatif observé, noté x_i , dans le pixel i de l'image de télédétection hyperspectrale, s'écrit sous la forme [80] :

$$x_i = \sum_{j=1}^M r_j c_{ji} \quad i = 1, \dots, P, \quad (3.1)$$

où $r_j \in R_+^{L \times 1}$ représente le spectre de réflectance non-négatif du j ème endmember. Chaque échantillon du spectre est inférieur ou égal à un. Le coefficient c_{ji} représente la fraction d'abondance non-négative du j ème endmember dans le pixel considéré i . P et L sont respectivement le nombre de pixels de l'image et le nombre de bandes spectrales, M étant le nombre d'endmembers.

Dans la présente étude, le phénomène de variabilité spectrale est pris en compte par l'intermédiaire du modèle de mélange de données étendu introduit dans [18]. Cette version étendue du modèle de mélange linéaire classique met en jeu un spectre différent dans chaque pixel pour chaque classe d'endmembers. Ainsi la notion de classe de matériaux est introduite et par conséquent le modèle (3.1) devient d'après [18] :

$$x_i = \sum_{j=1}^M r_{ij} c_{ji} \quad i = 1, \dots, P, \quad (3.2)$$

où $r_{ij} \in R_+^{L \times 1}$ décrit la version associée au pixel i pour la j ème classe de spectres de réflectance non-négatifs des endmembers. Chaque composante de ce vecteur est inférieure ou égale à un. Ce modèle constitue la base de travail pour les méthodes introduites dans cette thèse en intégrant la variabilité avec de nouvelles variables dans le modèle de données. L'écriture du modèle (3.2) sous forme matricielle pour l'ensemble des pixels de l'image hyperspectrale est donnée par :

$$X = RC, \quad (3.3)$$

où $X \in R_+^{L \times P}$ représente la matrice contenant les spectres en réflectance des pixels observés. Chacune de ses lignes correspond à une bande spectrale et chaque colonne à un spectre observé

au niveau des pixels. La matrice $R \in R_+^{L \times MP}$ contient les spectres d'endmembers. La matrice creuse $C \in R_+^{MP \times P}$ intègre les coefficients d'abondance et correspond à la transposée de la matrice creuse décrite précédemment pour l'IP-NMF dans (2.10) [18]. Par ailleurs, la structure de la matrice des spectres est identique à celle introduite dans le chapitre précédent dans la section 2.3, c'est-à-dire composée d'un jeu de spectres purs par pixel [80].

3.3. Modèle de données introduit et méthodes proposées

Dans le cadre de ce travail, trois approches de démixage hyperspectral sont développées. Elles considèrent un modèle paramétrique en intégrant de nouvelles variables dans le modèle de mélange linéaire étendu (3.2). Typiquement, leur rôle est de modéliser la variabilité spectrale. Plus précisément pour les trois méthodes, la variabilité est décrite de manière additive sans avoir à connaître la physique ou le type de variabilité présentes dans les images. Ainsi, ces méthodes adoptent une approche complètement aveugle. De plus, elles estiment de façon conjointe les spectres et les abondances, ce qui n'est pas le cas de toutes les méthodes traitant la variabilité spectrale. Par ailleurs, une attention particulière est portée à la variabilité spectrale. En effet, elle est traitée de façon locale et non pas globale sur le plan spectral, c'est-à-dire que toutes les méthodes développées dans ce chapitre permettent aux spectres de varier au niveau de chaque bande spectrale individuellement. Cette flexibilité est fondamentale pour aborder la variabilité de façon efficiente.

Cette partie est consacrée à la présentation des trois techniques. Pour chacune d'elles, une fonction de coût différente selon le modèle paramétrique est considérée. En particulier, suivant le modèle proposé, un critère à optimiser est utilisé afin d'estimer les classes des matériaux et ainsi extraire pour chaque pixel de l'image ainsi que les fractions d'abondance associées. Pour cela, des approches fondées sur la NMF [66] et [67] sont développées avec les deux variantes multiplicatives et à gradient projeté.

3.3.1. Modèle de données introduit

L'idée fondamentale du développement de cette technique consiste à prendre un jeu de spectres de référence, chaque spectre étant associé à une classe de matériaux purs, pour le faire varier bande par bande afin d'obtenir une version différente de chaque spectre pour chaque pixel de l'image. A cet effet, cette première méthode développée intègre deux variables dans le modèle (3.2), introduisant ainsi un nouveau modèle des données, qui permet de modéliser la variation des spectres de manière additive dans un intervalle autour des spectres de référence. Pour cela, les spectres r_{ij} dans (3.2) sont remplacés par :

$$r_{ij} = s_{1j} + \alpha_{ij} - \beta_{ij}, \quad (3.4)$$

où $s_{1j} \in R_+^{L \times 1}$ désigne le spectre de réflectance non-négatif de la j ème classe d'endmembers.

Dans le modèle proposé, les spectres d'endmembers contenus dans le premier pixel sont pris comme référence pour le phénomène de variabilité spectrale considéré. α_{ij} et β_{ij} représentent des vecteurs de variabilité contenant les coefficients non-négatifs pour la j ème classe d'endmembers associés au pixel i . Ces vecteurs permettent de réaliser une variation spectrale, dans tous les pixels, sur les spectres r_{ij} , par rapport aux spectres de référence s_{1j} , de manière additive. De plus, ces vecteurs délimitent respectivement les variations supérieure et inférieure

Partie I : CHAPITRE 3 : Méthodes proposées de démixage spectral avec prise en compte de la variabilité spectrale.

par rapport aux spectres de référence considérés s_{1j} . La substitution de l'expression de r_{ij} de (3.4) dans (3.2) permet d'obtenir :

$$x_i = \sum_{j=1}^M (s_{1j} + \alpha_{ij} - \beta_{ij}) c_{ji}. \quad (3.5)$$

Ainsi, pour tous les pixels de l'image, le modèle de mélange introduit s'exprime sous la forme matricielle suivante :

$$X = (S + A - B)C, \quad (3.6)$$

La matrice $S \in \mathbb{R}_+^{L \times MP}$ contient les spectres de référence, associés au premier pixel, dupliqués P fois :

$$S = \underbrace{[S_1 | S_1 | \dots | S_1]}_P. \quad (3.7)$$

Les matrices $A \in \mathbb{R}_+^{L \times MP}$ et $B \in \mathbb{R}_+^{L \times MP}$ contiennent respectivement les coefficients de variabilité supérieure et inférieure. Le premier bloc des matrices A et B contient des zéros pour ne pas impacter les spectres de référence, contenus dans le premier pixel de l'image, décrits par les équations suivantes :

$$A = [A_1 | A_2 \dots | A_P], \quad (3.8)$$

$$\text{avec } A_t \in \mathbb{R}_+^{L \times M} (t = 1, \dots, P), \text{ et } A_1 = 0^{L \times M}.$$

$$B = [B_1 | B_2 \dots | B_P],$$

$$\text{avec } B_t \in \mathbb{R}_+^{L \times M} (t = 1, \dots, P), \text{ et } B_1 = 0^{L \times M}. \quad (3.9)$$

3.3.2. Première méthode proposée

L'algorithme de démixage proposé est un algorithme de NMF appliqué pixel par pixel à l'image hyperspectrale. Son rôle est de modéliser la fonction de mélange de données définie par (3.6). Les variables impliquées, notées \tilde{S} , \tilde{A} , \tilde{B} et \tilde{C} , permettent d'estimer respectivement S , A , B et C . La présente méthode consiste à minimiser la fonction de coût définie par :

$$J = \frac{1}{2} \|X - (\tilde{S} + \tilde{A} - \tilde{B})\tilde{C}\|_F^2. \quad (3.10)$$

Le symbole $\|\cdot\|_F$ représente la norme de Frobenius.

En utilisant les propriétés établies d'après [122], les expressions du gradient pour les variables considérées, sous forme matricielle, de la fonction de coût sont données par :

$$\frac{\partial J}{\partial \tilde{S}} = -X\tilde{C}^T + \tilde{S}\tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T - \tilde{B}\tilde{C}\tilde{C}^T, \quad (3.11)$$

$$\frac{\partial J}{\partial \tilde{A}} = -XC^T + \tilde{S}\tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T - \tilde{B}\tilde{C}\tilde{C}^T, \quad (3.12)$$

$$\frac{\partial J}{\partial \tilde{B}} = XC^T - \tilde{S}\tilde{C}\tilde{C}^T - \tilde{A}\tilde{C}\tilde{C}^T + \tilde{B}\tilde{C}\tilde{C}^T, \quad (3.13)$$

$$\frac{\partial J}{\partial \tilde{C}} = -(\tilde{S} + \tilde{A})^T X + \tilde{B}^T X - \left(\tilde{B}^T (\tilde{S} + \tilde{A}) + (\tilde{S} + \tilde{A})^T \tilde{B} \right) \tilde{C} + (\tilde{S} + \tilde{A})^T (\tilde{S} + \tilde{A}) \tilde{C} + \tilde{B}^T \tilde{B} \tilde{C}, \quad (3.14)$$

où $(.)^T$ représente la transposée de la matrice. A titre de remarque, dans cette analyse la structure (3.7) de \tilde{S} n'est pas prise en considération contrairement aux deux méthodes qui sont introduites par la suite. Deux algorithmes sont appliqués, à savoir la version multiplicative et à gradient projeté.

3.3.2.1. Algorithme à gradient projeté

L'algorithme proposé étant basé sur la descente en gradient, en appliquant les étapes décrites dans [52] en calculant les expressions du gradient les règles de mise à jour sont données par les équations :

$$\tilde{S} \leftarrow \tilde{S} - \alpha_{\tilde{S}} \frac{\partial J}{\partial \tilde{S}}, \quad (3.15)$$

$$\tilde{A} \leftarrow \tilde{A} - \alpha_{\tilde{A}} \frac{\partial J}{\partial \tilde{A}}, \quad (3.16)$$

$$\tilde{B} \leftarrow \tilde{B} - \alpha_{\tilde{B}} \frac{\partial J}{\partial \tilde{B}}, \quad (3.17)$$

$$\tilde{C} \leftarrow \tilde{C} - \alpha_{\tilde{C}} \frac{\partial J}{\partial \tilde{C}}, \quad (3.18)$$

où $\alpha_{\tilde{S}}$, $\alpha_{\tilde{A}}$, $\alpha_{\tilde{B}}$ et $\alpha_{\tilde{C}}$ sont des pas d'adaptation positifs.

En raison de la structure creuse de la matrice \tilde{C} décrite dans (2.10), seuls les vecteurs contenus dans la diagonale sont mis à jour à chaque itération, les autres composantes étant fixées à 0. L'algorithme 2 présenté ci-dessous décrit les différentes étapes considérées. Après chaque itération, la matrice \tilde{C} est normalisée pour respecter la contrainte de la somme à un. Cette normalisation est réalisée en appliquant une division entre le coefficient d'abondance d'un matériau et la somme de l'ensemble des coefficients des matériaux présents dans le pixel traité.

Comme souligné précédemment, les $(P - 1)M$ dernières colonnes des sous-matrices de \tilde{A} et \tilde{B} définissent les variations autour de chaque colonne équivalente des sous-matrices de \tilde{S}_1 de \tilde{S} . Chaque élément de \tilde{S}_1 devant être inférieur ou égale à 1, en conséquence chaque élément des sous matrices de \tilde{A} et \tilde{B} doit satisfaire certaines contraintes pour réaliser une projection dans un intervalle compris entre 0 et 1. Suivant ce principe la quantité $\tilde{S} + \tilde{A} - \tilde{B}$ doit être comprise entre 0 et 1. En particulier, chaque élément \tilde{A}_t doit être borné pour ne pas dépasser 1 car la matrice \tilde{A} modélise la variabilité supérieure ainsi l'inégalité introduite ci-dessous dans (3.19) permet de satisfaire cette condition. De manière identique à \tilde{A} , la matrice \tilde{B} doit être limitée dans un intervalle afin que les spectres ne soient pas inférieurs à la valeur 0. Pour cela (3.20) est utilisée pendant les règles de mise à jour.

$$0^{L \times M} \leq \tilde{A}_t \leq \min(u^{L \times M}, 1^{L \times M} + \tilde{B}_t - \tilde{S}_t) \quad (3.19)$$

$$\begin{aligned} \forall t = 2 \dots P, \\ 0^{L \times M} \leq \tilde{B}_t \leq \min(v^{L \times M}, \tilde{A}_t + \tilde{S}_t) \\ \forall t = 2 \dots P, \end{aligned} \quad (3.20)$$

où u (respectivement v) correspond à la valeur maximale que peut atteindre chaque élément de la sous-matrice de \tilde{A} (respectivement \tilde{B}). Les valeurs considérées de u et v sont établies suivant les amplitudes des spectres dans les expérimentations.

Une dernière contrainte doit être considérée pour assurer de manière algorithmique, à chaque itération de la règle de mise à jour (3.15), que les $(P-1)M$ dernières colonnes des sous-matrices de \tilde{S} soient égales à la première sous-matrice décrite dans (3.7). Pour cela, à chaque itération, les spectres de référence associés au premier pixel sont dupliqués. Une telle contrainte est nécessaire pour garantir l'efficacité de la procédure dans l'estimation de la matrice de spectres \tilde{S} . Les spectres initiaux de référence \tilde{S} sont estimés par la VCA [37]. La première sous matrice initiale \tilde{S}_1 est dupliquée $P - 1$ fois pour obtenir la valeur initiale de la matrice \tilde{S} . De plus, chaque valeur initiale non-nulle de la matrice \tilde{C} est déterminée soit par la FCLS [43] ou soit égale à $1/M$. Un nombre maximum d'itérations prédéfini est considéré comme critère d'arrêt de l'algorithme proposé.

Algorithme 2

Entrée: Image hyperspectrale X .

1. Etape d'initialisation

- 1.1- Initialiser \tilde{S} à partir de X par la VCA.
- 1.2- Initialiser \tilde{C} avec des coefficients égaux à $1/M$ ou par FCLS.

2. Etape d'optimisation (jusqu'à obtenir la convergence)

- 2.1- Optimiser \tilde{S} en utilisant (3.15).
- 2.2- Optimiser \tilde{A} en utilisant (3.16).
- 2.3- Utiliser (3.19) pour contraindre \tilde{A} .
- 2.4- Optimiser \tilde{B} en utilisant (3.17).
- 2.5- Utiliser (3.20) pour contraindre \tilde{B} .
- 2.6- Optimiser \tilde{C} en utilisant (3.18).
- 2.7- Normaliser \tilde{C} avec : $\tilde{c}_p^{(i+1)} \leftarrow \tilde{c}_p^{(i)} / \sum_{j=1}^J \tilde{c}_{jp}$ pour $p = 1$ à P .
- 2.8- Dupliquer \tilde{S}_1 en utilisant (3.7) pour obtenir \tilde{S} .

Sortie: Jeu de spectres des matériaux purs pour chaque pixel de l'image hyperspectrale X et les fractions d'abondance pour chaque classe de matériaux.

3.3.2.2. Algorithme multiplicatif

L'algorithme proposé étant basé sur un gradient, la règle de mise à jour itérative suivante s'applique :

$$\theta \leftarrow \theta - \varphi_{\theta} \odot \frac{\partial J}{\partial \theta}, \quad (3.21)$$

où \odot est la multiplication élément par élément, θ décrit une des quatre matrices estimées \tilde{S} , \tilde{A} , \tilde{B} et \tilde{C} et φ_{θ} désigne une matrice de pas d'apprentissage. Pour garantir la contrainte de non-négativité des matrices estimées, une règle itérative et multiplicative est déduite, sur la base du gradient, de la manière suivante : d'après (3.11)-(3.14), les expressions du gradient de J en fonction de θ peuvent être formulées en terme de la différence de deux fonctions non-négatives telles que $\frac{\partial J}{\partial \theta} = \frac{\partial J^+}{\partial \theta} - \frac{\partial J^-}{\partial \theta}$. La fonction non-négative $\frac{\partial J^+}{\partial \theta}$ correspond aux termes de (3.11)-(3.14) précédés par un signe « + » et $\frac{\partial J^-}{\partial \theta}$ aux termes précédés par un signe « - », respectivement. Cette approche est utilisée car dans le cas présent les matrices considérées sont non-négatives. La contrainte de non-négativité peut être satisfaite par l'initialisation de θ par une valeur non-négative, le choix de φ_{θ} étant donné par :

$$\varphi_{\theta} = \theta \oslash \frac{\partial J^+}{\partial \theta}, \quad (3.22)$$

où \oslash symbolise la division élément par élément. La règle de mise à jour (3.21) devient :

$$\theta \leftarrow \theta \odot \frac{\partial J^-}{\partial \theta} \oslash \frac{\partial J^+}{\partial \theta}. \quad (3.23)$$

Pour rappel les matrices traitées dans (3.23) contiennent des éléments non-négatifs.

D'après (3.23) les règles de mise à jour pour les variables considérées, peuvent être formulées suivant :

$$\tilde{S} \leftarrow \tilde{S} \odot (X\tilde{C}^T + \tilde{B}\tilde{C}\tilde{C}^T) \oslash (\tilde{S}\tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T + \varepsilon), \quad (3.24)$$

$$\tilde{A} \leftarrow \tilde{A} \odot (X\tilde{C}^T + \tilde{B}\tilde{C}\tilde{C}^T) \oslash (\tilde{S}\tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T + \varepsilon), \quad (3.25)$$

$$\tilde{B} \leftarrow \tilde{B} \odot (\tilde{S}\tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T) \oslash (X\tilde{C}^T + \tilde{B}\tilde{C}\tilde{C}^T + \varepsilon), \quad (3.26)$$

$$\tilde{C} \leftarrow \tilde{C} \odot ((\tilde{S} + \tilde{A})^T X + (\tilde{B}^T(\tilde{S} + \tilde{A}) + (\tilde{S} + \tilde{A})^T \tilde{B}) \tilde{C}) \oslash (\tilde{B}^T X + (\tilde{S} + \tilde{A})^T (\tilde{S} + \tilde{A})\tilde{C} + \tilde{B}^T \tilde{B}\tilde{C} + \varepsilon), \quad (3.27)$$

où ε est une très petite quantité positive ajoutée à chaque dénominateur des règles de mise à jour (3.24)-(3.27) pour se prémunir d'éventuelles divisions par zéro. Pour l'initialisation des différentes matrices, la procédure utilisée pour l'algorithme à gradient projeté est aussi appliquée pour l'algorithme multiplicatif. Les différentes étapes de cet algorithme sont reportées dans l'Algorithme 3 ci-dessous.

Algorithme 3

Entrée: Image hyperspectrale X .

1. Etape d'initialisation

- 1.1- Initialiser \tilde{S} à partir de X par la VCA.
- 1.2- Initialiser \tilde{C} avec des coefficients égaux à $1/M$ ou par FCLS.

2. Etape d'optimisation (jusqu'à obtenir la convergence)

- 2.1- Optimiser \tilde{S} en utilisant (3.24).
- 2.2- Optimiser \tilde{A} en utilisant (3.25).
- 2.3- Utiliser (3.19) pour contraindre \tilde{A} .
- 2.4- Optimiser \tilde{B} en utilisant (3.26).
- 2.5- Utiliser (3.20) pour contraindre \tilde{B} .
- 2.6- Optimiser \tilde{C} en utilisant (3.27).
- 2.7- Dupliquer \tilde{S}_1 en utilisant (3.7) pour obtenir \tilde{S} .

Sortie: Jeu de spectres des matériaux purs pour chaque pixel de l'image hyperspectrale X et les fractions d'abondance pour chaque classe de matériaux.

3.3.3. Deuxième méthode proposée

La deuxième approche représente une extension de la première afin d'améliorer la gestion de la variabilité. En effet malgré la simplicité dans sa mise en œuvre, la première approche néglige d'une certaine manière les structures particulières des variables impliquées dans le modèle proposé de mélange notamment pour l'estimation des spectres. Elle ne prend pas en compte directement la structure particulière de la matrice S qui contient une répétition de S_1 . En fait, durant les règles de mise à jour utilisées dans l'algorithme de démixtion de la première méthode, une contrainte supplémentaire doit être prise en compte à chaque itération dans l'algorithme appliqué (la matrice S_1 est sauvegardée et répétée P fois durant chaque itération pour former la matrice des spectres décrite dans (3.7) pour appliquer la règle de mise à jour (3.24)). Cette approche n'est pas optimale d'un point de vue algorithmique.

Pour remédier à cet aspect, la deuxième méthode reformule le modèle proposé de mélange afin de préserver la structure particulière pour introduire de manière explicite la structure de la matrice des spectres et réduire les contraintes algorithmiques imposées pour en tenir compte. Par conséquent, dans la présente approche le modèle de données (3.6) est reformulé pour tenir en compte explicitement de cette structure particulière:

$$X = (S_1 K + A - B)C, \quad (3.28)$$

où la matrice $K \in \mathbb{R}_+^{M \times MP}$ contient la matrice identité, de dimension $M \times M$, répétée P fois sur des colonnes successives. L'introduction de K permet, d'une part, de gérer de manière simple la variabilité spectrale, et d'autre part, d'éviter dans les règles de mise à jour toute contrainte supplémentaire liée à la structure particulière de la matrice S .

Cette approche consiste à modéliser les données définies dans le modèle de mélange (3.28). Les variables impliquées sont \tilde{S}_1 , \tilde{A} , \tilde{B} et \tilde{C} qui estiment respectivement S_1 , A , B et C . La présente méthode a pour but de minimiser la fonction de coût définie par :

$$J = \frac{1}{2} \|X - (\tilde{S}_1 K + \tilde{A} - \tilde{B})\tilde{C}\|_F^2. \quad (3.29)$$

Comme pour la première méthode afin de minimiser (3.29), deux algorithmes de NMF sont considérés, à savoir à gradient projeté et multiplicatif. En combinant les propriétés présentées dans [114], les expressions du gradient dans un format matriciel, de la nouvelle fonction de coût sont formulées par :

$$\frac{\partial J}{\partial \tilde{S}_1} = -X\tilde{C}^T K^T + \tilde{S}_1 K \tilde{C} \tilde{C}^T K^T + \tilde{A} \tilde{C} \tilde{C}^T K^T - \tilde{B} \tilde{C} \tilde{C}^T K^T, \quad (3.30)$$

$$\frac{\partial J}{\partial \tilde{A}} = -X\tilde{C}^T + \tilde{S}_1 K \tilde{C} \tilde{C}^T + \tilde{A} \tilde{C} \tilde{C}^T - \tilde{B} \tilde{C} \tilde{C}^T, \quad (3.31)$$

$$\frac{\partial J}{\partial \tilde{B}} = X\tilde{C}^T - \tilde{S}_1 K \tilde{C} \tilde{C}^T - \tilde{A} \tilde{C} \tilde{C}^T + \tilde{B} \tilde{C} \tilde{C}^T, \quad (3.32)$$

$$\begin{aligned} \frac{\partial J}{\partial \tilde{C}} = & -(\tilde{S}_1 K + \tilde{A})^T X + \tilde{B}^T X - \left(\tilde{B}^T (\tilde{S}_1 K + \tilde{A}) + (\tilde{S}_1 K + \tilde{A})^T \tilde{B} \right) \tilde{C} + \\ & (\tilde{S}_1 K + \tilde{A})^T (\tilde{S}_1 K + \tilde{A}) \tilde{C} + \tilde{B}^T \tilde{B} \tilde{C}. \end{aligned} \quad (3.33)$$

3.3.3.1. Algorithme à gradient projeté

Les règles de mise à jour sont identiques aux règles définies dans (3.15) à (3.18) en prenant en considération les variables et la nouvelle fonction de coût introduites dans la deuxième méthode. Les règles de mise à jour sont données par les équations suivantes :

$$\tilde{S}_1 \leftarrow \tilde{S}_1 - \alpha_{\tilde{S}_1} \frac{\partial J}{\partial \tilde{S}_1}, \quad (3.34)$$

$$\tilde{A} \leftarrow \tilde{A} - \alpha_{\tilde{A}} \frac{\partial J}{\partial \tilde{A}}, \quad (3.35)$$

$$\tilde{B} \leftarrow \tilde{B} - \alpha_{\tilde{B}} \frac{\partial J}{\partial \tilde{B}}, \quad (3.36)$$

$$\tilde{C} \leftarrow \tilde{C} - \alpha_{\tilde{C}} \frac{\partial J}{\partial \tilde{C}}. \quad (3.37)$$

où $\alpha_{\tilde{S}_1}$, $\alpha_{\tilde{A}}$, $\alpha_{\tilde{B}}$ et $\alpha_{\tilde{C}}$ sont des pas d'adaptation positifs.

Similairement à la première méthode, seuls les vecteurs contenus dans la diagonale de la matrice \tilde{C} décrite précédemment sont mis à jour à chaque itération, les autres composantes étant fixées à 0. De plus, une normalisation des coefficients d'abondance identiques à la première méthode est nécessaire pour respecter la somme à un [18].

Dans la mesure où chaque élément de la matrice \tilde{S}_1 doit être inférieur ou égal à un, les contraintes suivantes s'appliquent suivant la même méthodologie décrite pour obtenir (3.19) et (3.20) à la différence que dans ce cas, on considère \tilde{S}_1 et non pas \tilde{S}_t :

$$0^{L \times M} \leq \tilde{A}_t \leq \min(\tilde{A}_t, u^{L \times M}, 1^{L \times M} + \tilde{B}_t - \tilde{S}_1) \quad (3.38)$$

$$\forall t = 2 \dots P,$$

$$0^{L \times M} \leq \tilde{B}_t \leq \min(\tilde{B}_t, v^{L \times M}, \tilde{A}_t + \tilde{S}_1) \quad (3.39)$$

$$\forall t = 2 \dots P,$$

où, comme pour la première méthode proposée, u (respectivement v) correspond à la valeur maximale que peut atteindre chacun des éléments de la sous-matrice de \tilde{A} (\tilde{B}) considérée. Comme pour la première méthode proposée, les valeurs de u et v sont fixées selon les valeurs moyennes en amplitude de chaque classe de matériaux considérée dans les tests.

La phase d'initialisation de cette seconde méthode proposée est la même que celle de la première méthode proposée.

La phase d'optimisation consiste à appliquer les règles de mise à jour des matrices considérées, jusqu'à atteindre la convergence, suivant les règles de mise à jour (3.34) -(3.37) et en considérant la méthode décrite dans [43] pour satisfaire la propriété de la somme à un de l'abondance. Un nombre maximum d'itérations est fixé au préalable, comme critère d'arrêt de l'algorithme proposé pour éviter un nombre conséquent d'itérations. L'algorithme 4 de la méthode proposée est détaillé ci-dessous.

Algorithme 4

Entrée: Image hyperspectrale X .

1. Etape d'initialisation

- 1.1- Initialiser \tilde{S}_1 à partir de X par la VCA.
- 1.2- Initialiser \tilde{C} avec des coefficients égaux à $1/M$ ou par FCLS..

1. Etape d'optimisation (jusqu'à obtenir la convergence)

- 2.1- Optimiser \tilde{S}_1 en utilisant (3.34).
- 2.2- Optimiser \tilde{A} en utilisant (3.35).
- 2.3- Contraindre \tilde{A} en utilisant (3.38).
- 2.4- Optimiser \tilde{B} en utilisant (3.36)
- 2.5- Contraindre \tilde{B} en utilisant (3.39).
- 2.6- Optimiser \tilde{C} en utilisant (3.37).
- 2.7- Normaliser \tilde{C} avec : $\tilde{c}_p^{(i+1)} \leftarrow \tilde{c}_p^{(i)} / \sum_{j=1}^J \tilde{c}_{jp}$ pour $p = 1$ à P .

Sortie: Jeu de spectres des matériaux purs pour chaque pixel de l'image hyperspectrale X et les fractions d'abondance pour chaque classe de matériaux.

3.3.3.2. Algorithme multiplicatif

Pour l'algorithme multiplicatif, la même approche que celle décrite ci-dessus (de la même manière que pour la première méthode proposée décrite dans (3.23)) est adoptée pour obtenir les règles de mise à jour suivantes :

$$\tilde{S}_1 \leftarrow \tilde{S}_1 \odot (X\tilde{C}^T K^T + \tilde{B}\tilde{C}\tilde{C}^T K^T) \oslash (\tilde{S}_1 K\tilde{C}\tilde{C}^T K^T + \tilde{A}\tilde{C}\tilde{C}^T K^T + \varepsilon), \quad (3.40)$$

$$\tilde{A} \leftarrow \tilde{A} \odot (X\tilde{C}^T + \tilde{B}\tilde{C}\tilde{C}^T) \oslash (\tilde{S}_1 K\tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T + \varepsilon), \quad (3.41)$$

$$\tilde{B} \leftarrow \tilde{B} \odot (\tilde{S}_1 K\tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T) \oslash (X\tilde{C}^T + \tilde{B}\tilde{C}\tilde{C}^T + \varepsilon), \quad (3.42)$$

$$\tilde{C} \leftarrow \tilde{C} \odot ((\tilde{S}_1 K + \tilde{A})^T X + (\tilde{B}^T (\tilde{S}_1 K + \tilde{A}) + (\tilde{S}_1 K + \tilde{A})^T \tilde{B}) \tilde{C}) \oslash (\tilde{B}^T X + (\tilde{S}_1 K + \tilde{A})^T (\tilde{S}_1 K + \tilde{A}) \tilde{C} + \tilde{B}^T \tilde{B} \tilde{C} + \varepsilon). \quad (3.43)$$

L'initialisation est identique, pour la matrice des spectres \tilde{S}_1 et des abondances \tilde{C} , à l'algorithme du gradient projeté c'est-à-dire en considérant la VCA [37] pour estimer les spectres et les valeurs initiales non-nulles de la matrice \tilde{C} sont fixées à $1/M$ ou bien obtenues en appliquant une FCLS [43].

Algorithme 5

Entrée: Image hyperspectrale X .

1. Etape d'initialisation

- 1.1- Initialiser \tilde{S}_1 à partir de X par la VCA.
- 1.2- Initialiser \tilde{C} avec des coefficients égaux à $1/M$ ou par FCLS.

2. Etape d'optimisation (jusqu'à obtenir la convergence)

- 2.1- Optimiser \tilde{S}_1 en utilisant (3.40).
- 2.2- Optimiser \tilde{A} en utilisant (3.41).
- 2.3- Contraindre \tilde{A} en utilisant (3.38).
- 2.4- Optimiser \tilde{B} en utilisant (3.42).
- 2.5- Contraindre \tilde{B} en utilisant (3.39).
- 2.6- Optimiser \tilde{C} en utilisant (3.43).

Sortie: Jeu de spectres des matériaux purs pour chaque pixel de l'image hyperspectrale X et les fractions d'abondance pour chaque classe de matériaux.

3.3.4. Troisième méthode proposée

D'après la partie précédente, la deuxième méthode présente l'avantage de prendre en considération la structure particulière de la matrice des spectres. Cependant, elle ne contraint pas de manière optimale l'amplitude de variation des spectres et plus précisément, la manière dont les coefficients contenus dans les matrices A et B évoluent par rapport aux spectres de référence. En effet les deux méthodes précédentes considèrent seulement les contraintes dans (3.19), (3.20), (3.38) et (3.39) pour gérer cet aspect.

L'une des possibilités est que ces coefficients augmentent significativement et conduit donc à une estimation erronée de la variabilité spectrale. Cette notion est non négligeable dans le cas de traitement des données réelles car elles peuvent contenir des outliers ou bien des matériaux rares. L'une des approches menant à une gestion efficiente de cet aspect est de pénaliser les

amplitudes des matrices A et B sans utiliser u et v . A cet effet, deux termes de pénalisation sont ajoutés à la fonction de coût (3.29) tels que

$$J = \frac{1}{2} \|X - (\tilde{S}_1 K + \tilde{A} - \tilde{B}) \tilde{C}\|_F^2 + \frac{\lambda_{\tilde{A}}}{2} \|\tilde{A}\|_F^2 + \frac{\lambda_{\tilde{B}}}{2} \|\tilde{B}\|_F^2. \quad (3.44)$$

Les deux derniers termes de (3.44) sont ajoutés comme termes de pénalisation pour limiter les normes de Frobenius des deux matrices \tilde{A} et \tilde{B} et contrôler l'amplitude des coefficients de variabilité. Par ailleurs, ces termes permettent d'obtenir une variabilité spectrale cohérente autour des spectres de référence \tilde{S}_1 pour chaque pixel. $\lambda_{\tilde{A}}$ et $\lambda_{\tilde{B}}$ sont des coefficients d'ajustement, qui n'ont pas nécessairement la même valeur, et qui gèrent respectivement les variabilités spectrales supérieure et inférieure. A titre de remarque, des valeurs plus élevées de $\lambda_{\tilde{A}}$ et $\lambda_{\tilde{B}}$ contraignent davantage les spectres estimés d'une classe de spectres afin de les maintenir proches du spectre de référence de cette classe contenue dans \tilde{S}_1 et donc de limiter l'amplitude de la variabilité.

D'après les propriétés présentées dans [122], les expressions du gradient de cette troisième de fonction de coût sont formulées par les expressions :

$$\frac{\partial J}{\partial \tilde{S}_1} = -X \tilde{C}^T K^T + \tilde{S}_1 K \tilde{C} \tilde{C}^T K^T + \tilde{A} \tilde{C} \tilde{C}^T K^T - \tilde{B} \tilde{C} \tilde{C}^T K^T, \quad (3.45)$$

$$\frac{\partial J}{\partial \tilde{A}} = -X \tilde{C}^T + \tilde{S}_1 K \tilde{C} \tilde{C}^T + \tilde{A} \tilde{C} \tilde{C}^T - \tilde{B} \tilde{C} \tilde{C}^T + \lambda_{\tilde{A}} \tilde{A}, \quad (3.46)$$

$$\frac{\partial J}{\partial \tilde{B}} = X \tilde{C}^T - \tilde{S}_1 K \tilde{C} \tilde{C}^T - \tilde{A} \tilde{C} \tilde{C}^T + \tilde{B} \tilde{C} \tilde{C}^T + \lambda_{\tilde{B}} \tilde{B}, \quad (3.47)$$

$$\frac{\partial J}{\partial \tilde{C}} = -(\tilde{S}_1 K + \tilde{A})^T X + \tilde{B}^T X - \left(\tilde{B}^T (\tilde{S}_1 K + \tilde{A}) + (\tilde{S}_1 K + \tilde{A})^T \tilde{B} \right) \tilde{C} + (\tilde{S}_1 K + \tilde{A})^T (\tilde{S}_1 K + \tilde{A}) \tilde{C} + \tilde{B}^T \tilde{B} \tilde{C}. \quad (3.48)$$

3.3.4.1. Algorithme à gradient projeté

Comme pour les deux premières méthodes, les règles de mise à jour sont données d'après [67] et identiques aux précédentes ((3.34) à (3.37)) mais en tenant compte de l'expression de la troisième fonction à optimiser. De manière similaire aux deux premières méthodes, seuls les vecteurs contenus dans la diagonale de la matrice \tilde{C} comme décrite précédemment sont mis à jour à chaque itération, les autres composantes étant fixées à 0. De plus, la procédure de normalisation est appliquée pour respecter la contrainte de la somme à un sur les abondances [18].

Dans la mesure où chaque élément de tous les spectres d'endmembers estimés doit être inférieur ou égal à un et supérieur ou égal à zéro, les éléments des sous-matrices considérés de \tilde{A} et \tilde{B} doivent tous obéir à des contraintes supplémentaires. Par conséquent, dans l'algorithme proposé, les contraintes (3.38) et (3.39) sont utilisées.

Les spectres hyperspectraux initiaux contenus dans la matrice \tilde{S}_1 et chaque valeur initiale non nulle de la matrice C sont fixés de manière identique aux deux méthodes précédentes. Un nombre maximal d'itérations est fixé comme critère d'arrêt de l'algorithme. L'algorithme à gradient projeté est identique à celui de l'algorithme 4.

3.3.4.2. Algorithme multiplicatif

Pour l'algorithme multiplicatif, l'approche décrite précédemment est considérée pour établir les règles de mise à jour:

$$\tilde{S}_1 \leftarrow \tilde{S}_1 \odot (X\tilde{C}^T K^T + \tilde{B}\tilde{C}\tilde{C}^T K^T) \oslash (\tilde{S}_1 K \tilde{C}\tilde{C}^T K^T + \tilde{A}\tilde{C}\tilde{C}^T K^T + \varepsilon), \quad (3.49)$$

$$\tilde{A} \leftarrow \tilde{A} \odot (X\tilde{C}^T + \tilde{B}\tilde{C}\tilde{C}^T) \oslash (\tilde{S}_1 K \tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T + \lambda_{\tilde{A}}\tilde{A} + \varepsilon), \quad (3.50)$$

$$\tilde{B} \leftarrow \tilde{B} \odot (\tilde{S}_1 K \tilde{C}\tilde{C}^T + \tilde{A}\tilde{C}\tilde{C}^T) \oslash (X\tilde{C}^T + \tilde{B}\tilde{C}\tilde{C}^T + \lambda_{\tilde{B}}\tilde{B} + \varepsilon), \quad (3.51)$$

$$\begin{aligned} \tilde{C} \leftarrow \tilde{C} \odot ((\tilde{S}_1 K + \tilde{A})^T X + (\tilde{B}^T (\tilde{S}_1 K + \tilde{A}) + (\tilde{S}_1 K + \tilde{A})^T \tilde{B}) \tilde{C}) \oslash (\tilde{B}^T X + \\ (\tilde{S}_1 K + \tilde{A})^T (\tilde{S}_1 K + \tilde{A}) \tilde{C} + \tilde{B}^T \tilde{B} \tilde{C} + \varepsilon). \end{aligned} \quad (3.52)$$

Pour l'initialisation des matrices des spectres et des abondances, une approche identique au gradient projeté est utilisée. L'algorithme multiplicatif est décrit ci-dessous.

Algorithme 6

Entrée: Image hyperspectrale X .

1. Etape d'initialisation

- 1.1- Initialiser \tilde{S}_1 à partir de X par la VCA.
- 1.2- Initialiser \tilde{C} avec des coefficients égaux à $1/M$ ou par FCLS.

2. Etape d'optimisation (jusqu'à obtenir la convergence)

- 2.1- Optimiser \tilde{S}_1 en utilisant (3.49).
- 2.2- Optimiser \tilde{A} en utilisant (3.50).
- 2.3- Contraindre \tilde{A} en utilisant (3.38).
- 2.4- Optimiser \tilde{B} en utilisant (3.51).
- 2.5- Contraindre \tilde{B} en utilisant (3.52).
- 2.6- Optimiser \tilde{C} en utilisant (3.43).

Sortie: Jeu de spectres des matériaux purs pour chaque pixel de l'image hyperspectrale X et les fractions d'abondance pour chaque classe de matériaux.

3.4. Conclusion

Dans le cadre de ce chapitre, trois méthodes de démixage spectral des images hyperspectrales de télédétection traitant la variabilité spectrale sont présentées. L'ensemble des méthodes se base sur un nouveau modèle de données paramétriques. En particulier, la variabilité spectrale est traduite sous forme additive en intégrant deux nouvelles variables matricielles dans le modèle linéaire étendu qui la gère. De plus, chaque méthode possède sa propre fonction de coût et utilise une NMF pour optimiser un critère bien défini. A cet effet, et

pour chaque méthode proposée, deux algorithmes sont appliqués à savoir à gradient projeté et multiplicatif.

Dans une première partie, le modèle mathématique des données considéré pour les trois méthodes a été introduit. Ce dernier est une version étendue du modèle linéaire classique et permet d'extraire pour chaque pixel de l'image hyperspectrale un jeu de spectres pour les différentes classes de matériaux ainsi que les fractions d'abondance. Il assure plus de flexibilité par rapport au modèle linéaire classique en intégrant la variabilité spectrale intra-classe et en intégrant cette dernière par le biais des deux matrices A et B .

Par la suite, les différentes méthodes sont détaillées et pour chacune d'elles un critère à minimiser différent est considéré. En effet, la première méthode proposée est fondée sur un critère intégrant deux matrices gérant les variations supérieure et inférieure autour des spectres de référence [123]. La deuxième technique constitue une extension de la première. En effet, elle tient en compte de manière approfondie des structures des matrices et en particulier celle des spectres [124]. Elle permet de réduire la dimension de la matrice des spectres. La dernière méthode ajoute deux nouveaux termes de pénalisation à la fonction de coût de la deuxième pour obtenir une variabilité spectrale plus contrainte autour des spectres de référence [125]. Dans le chapitre suivant, les tests et les résultats des trois méthodes proposées dans le cadre de cette thèse sont présentés.

Chapitre 4 : Tests et Performances

Chapitre 4

Tests et performances

4.1. Introduction

Dans le cadre de ce chapitre, les tests effectués et les différents résultats obtenus sur la base des trois méthodes proposées au chapitre précédent sont présentés pour une étude approfondie et une comparaison des performances de ces méthodes avec celles de la littérature. Les tests réalisés sont appliqués dans un premier temps sur des données synthétiques à partir de bibliothèques spectrales et de cartes d'abondance issues d'une classification des données réelles. Dans une deuxième étape, les expérimentations menées considèrent des données réelles.

Le chapitre est organisé de la manière suivante. La première partie concerne la présentation des différentes données traitées, en particulier la manière de générer des données synthétiques réalistes qui intègrent la variabilité spectrale à partir de spectres de matériaux de milieux urbains. Dans une deuxième partie, les critères adoptés pour évaluer les résultats des tests sont définis. Plusieurs critères de performances sont appliqués et considèrent les deux aspects, à savoir spectral et spatial. La troisième partie est consacrée à la présentation, la discussion et l'interprétation des résultats obtenus.

Ainsi, les résultats des tests réalisés sont développés en cinq parties bien distinctes. La première consiste en une comparaison, sur des données synthétiques, entre les trois méthodes proposées dans cette première partie du manuscrit. Elle permet de mettre en valeur le développement et l'amélioration entre les différentes approches proposées dans le chapitre précédent sur la base des critères de performances dans les domaines spatial et spectral. Cette analyse est déclinée en trois études séparées. La première concerne une comparaison entre les trois techniques sur une image synthétique. La deuxième porte sur la robustesse des différentes techniques introduites par rapport à plusieurs niveaux de bruit. En effet, cet aspect est primordial en vue d'appliquer les méthodes proposées à une image hyperspectrale réelle d'une zone urbaine. Ensuite, une étude sur l'impact de l'initialisation est réalisée montrant ainsi l'amélioration qui peut être obtenue par une meilleure optimisation de cette étape clé des algorithmes proposés.

Dans un second temps, une comparaison des résultats obtenus avec ceux des méthodes de la littérature traitant la variabilité spectrale est menée sur la base de tests sur des données synthétiques. Elle est effectuée en considérant : les techniques de la littérature intégrant le phénomène de la variabilité spectrale intrinsèque, les approches introduites dans cette thèse appliquant un modèle paramétrique des données. Dans une dernière partie, une comparaison des performances est discutée sur des données réelles afin d'évaluer la robustesse des méthodes proposées. Sur cette base, des perspectives pour l'application et le développement de ces méthodes sont suggérées.

4.2. Données testées

4.2.1. Données synthétiques

Pour les jeux de données synthétiques, deux bibliothèques spectrales sont considérées, chacune d'elle étant constituée de plusieurs signatures spectrales présentant le phénomène de variabilité intra-classe (plusieurs signatures spectrales sont disponibles pour un seul matériau). La première bibliothèque est construite via une campagne de terrain réalisée sur la ville de Toulouse (voir figure 4.1), plus précisément dans le cadre de la mission « The French Airborne UMBRA (*Urban Material characterization in the sun and shade of Built-up structures and trees and their Retrieval from Airborne image*) » conduite en 2012 [126-128].

Deux capteurs hyperspectraux Hypspec ont été utilisés pour collecter des signatures spectrales respectivement dans les domaines $[400\text{ nm} - 1000\text{ nm}]$ avec une résolution spatiale de 0.84 m et $[1000\text{ nm} - 2500\text{ nm}]$ avec une résolution spatiale de 1.6 m dans le cadre du projet HYPEP (*Hyperspectral Imagery for Environmental Planning*). Les données récoltées présentent 405 bandes spectrales. Après application des corrections atmosphériques, en enlevant les bandes d'absorption, le nombre de bandes spectrales en sortie est réduit à 214 [126-128]. Cette opération est réalisée à l'aide de la technique nommée *Correction Code for Hyperspectral Images of remote sensing Sensors* (COCHISE) [129]. Quatre matériaux décrivant un environnement urbain : panneau photovoltaïque, arbre, végétation et tuile sont considérés pour constituer la première bibliothèque spectrale notée « SL-1 » par la suite dans ce chapitre (voir figure 4.2). SL-1 est utilisée pour générer des images synthétiques contenant trois et quatre matériaux. Les signatures utilisées ont été fournies par l'Office National d'Etudes et de Recherches Aérospatiales (ONERA).



Figure 4.1 : Image hyperspectrale couvrant la zone de la campagne terrain [126].

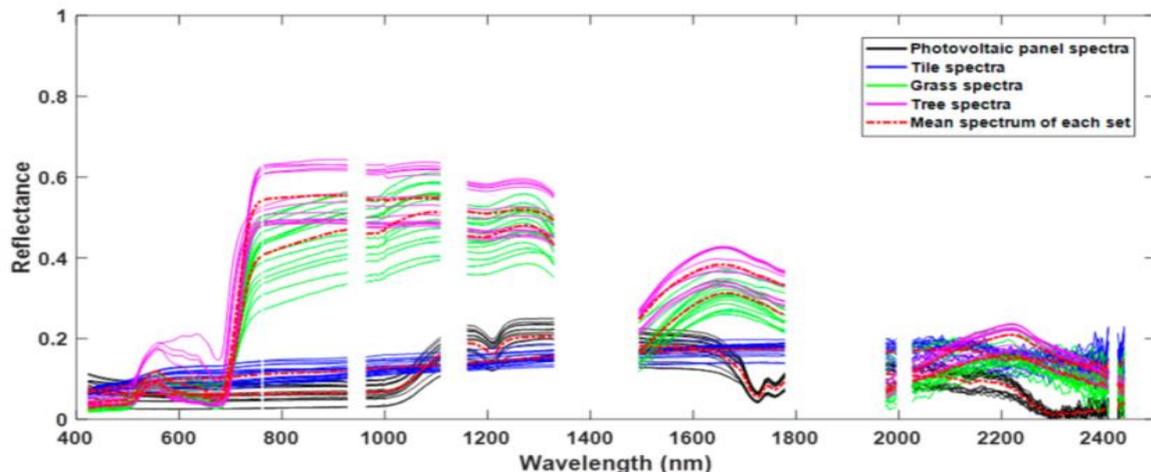


Figure 4.2 : Première bibliothèque spectrale (SL-1) [126].

La deuxième bibliothèque spectrale comprenant quinze matériaux est extraite à partir d'une image hyperspectrale d'une zone urbaine couvrant l'université de Houston et ses environs [30]. Les signatures spectrales ont été fournies avec l'image. Cette dernière présente une résolution spatiale de 2.5 m et 144 bandes spectrales s'étalant sur le domaine spectral $[380\text{ nm} - 1050\text{ nm}]$. Pour les tests menés sur les données synthétiques, cinq classes de matériaux (voir figure 4.3) sont sélectionnées parmi les quinze classes de matériaux fournis au préalable avec l'image hyperspectrale. Ainsi chaque classe est constituée de plusieurs signatures spectrales pour prendre en compte le phénomène de variabilité spectrale. Les cinq matériaux considérés sont : végétation, gazon artificiel, eau, chemin de fer et piste d'athlétisme. La notation « SL-2 » est adoptée pour cette seconde bibliothèque spectrale.

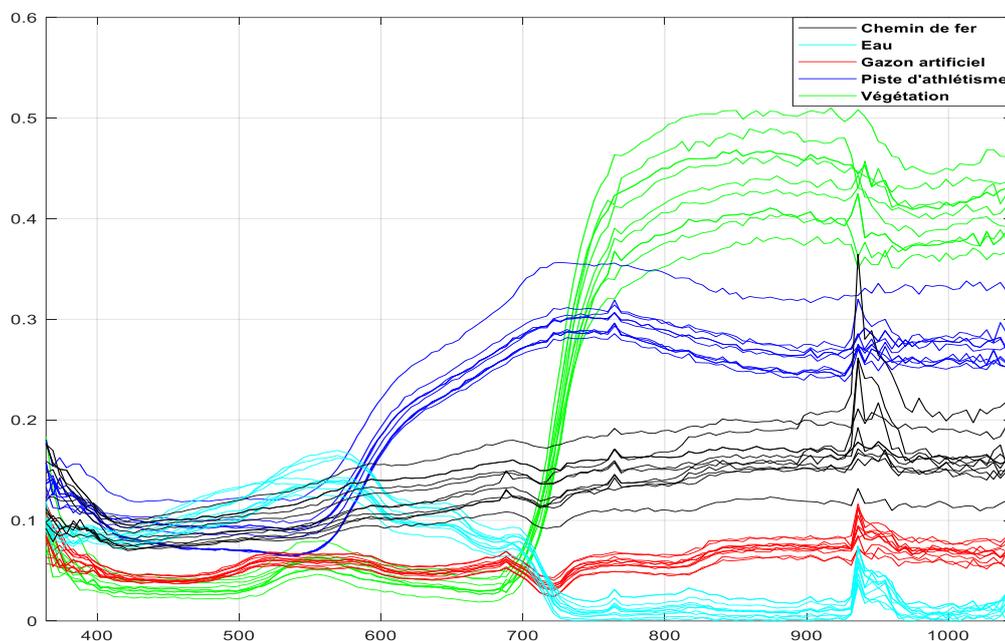


Figure 4.3 : Deuxième bibliothèque spectrale (SL-2).

Les cartes d'abondance linéaires utilisées, contenant respectivement trois, quatre et cinq matériaux pour la création des données synthétiques, sont générées à partir d'une classification d'une scène réelle urbaine comportant 90×90 pixels (voir figure 4.4). Les cartes traitées dans les expérimentations composées de 10×10 pixels sont obtenues en moyennant les valeurs de classification des pixels sur une fenêtre glissante de 9×9 pixels sans chevauchement pour créer des pixels mixtes. Cette procédure permet de simuler des données synthétiques réalistes [126]. A noter que pour la création des données présentant trois matériaux deux zones adjacentes de la carte à 4 matériaux sont fusionnées pour créer une seule zone.

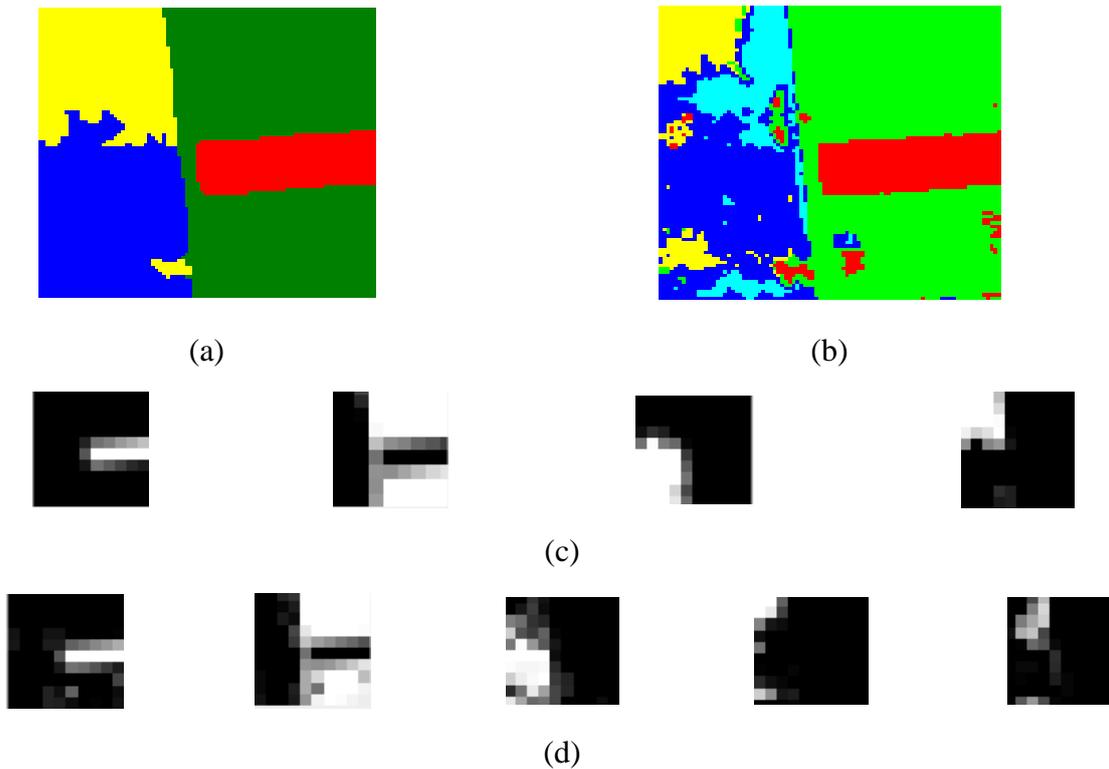


Figure 4.4 : (a) Carte de classification contenant 4 matériaux [126]. (b) Carte de classification contenant 5 matériaux. (c) Cartes d'abondance extraites de (a). (d) Cartes d'abondance extraites de (b).

4.2.2. Données réelles

Pour les tests sur données réelles, une partie de l'image hyperspectrale réelle acquise au-dessus du campus de l'université de Houston est considérée. Cette image est une référence très utilisée par la communauté pour tester la robustesse des différentes méthodes et en particulier celles traitant la variabilité spectrale [106]. La partie de l'image acquise au-dessus du Robertson stadium est composée de 105×108 pixels et de 144 bandes spectrales allant de 380 nm à 1050 nm . La figure 4.5 représente la version RGB de l'image réelle. Elle est constituée principalement de 4 matériaux : végétation, asphalte, toiture métallique et béton.



Figure 4.5 : Représentation RVB de l'image hyperspectrale réelle [106].

4.3. Critères de performance

Pour évaluer les tests sur données synthétiques, plusieurs critères de performances sont appliqués pour les aspects spectral et spatial. Ces critères se basent sur la comparaison entre les valeurs réelles des spectres et des abondances avec celles estimées par les différentes méthodes proposées. Ainsi pour le domaine spectral, trois critères sont retenus : le *Spectral Angle Mapper* (SAM), la *Spectral Information Divergence* (SID) et l'Erreur Quadratique Moyenne Normalisée ou *Normalized Mean Square Error* (NMSE). En effet, ils permettent de mesurer l'efficacité des trois méthodes à estimer les spectres de façon optimale en termes de forme et d'amplitude.

Spectral Angle Mapper (SAM)

Le SAM calcule des angles spectraux, il décrit la différence de forme entre les spectres estimés et les spectres de référence pour un pixel donné. Dans le présent cas, le SAM est déterminé pour chaque spectre d'une classe considérée avec son équivalent de référence pour un pixel ; cette éventualité est possible car les spectres de référence contenus dans le pixel sont connus au préalable. Par la suite, les valeurs de SAM obtenues sont moyennées sur l'ensemble des pixels. Le SAM moyen est défini par :

$$SAM_S = \frac{1}{PM} \sum_{i=1}^P \sum_{j=1}^M \arccos \left(\frac{\langle r_{ij}, \tilde{r}_{ij} \rangle}{\|r_{ij}\|_2 \cdot \|\tilde{r}_{ij}\|_2} \right), \quad (4.1)$$

où r_{ij} et \tilde{r}_{ij} représentent le spectre réel et le spectre estimé de la j ème classe de matériaux contenue dans le pixel i , $\langle r_{ij}, \tilde{r}_{ij} \rangle$ étant le produit scalaire, $\|r_{ij}\|_2$ et $\|\tilde{r}_{ij}\|_2$ représentant respectivement la norme L2 de r_{ij} et \tilde{r}_{ij} .

Spectral Information Divergence (SID)

Ce critère est basé sur la théorie de l'information, il détermine le degré de similarité entre deux spectres, comme pour le SAM, la SID est moyennée sur l'ensemble des pixels. Ce critère est formulé par :

$$SID_S = \frac{1}{PM} \sum_{i=1}^P \sum_{j=1}^M |r_{ij}^T \ln(r_{ij} \oslash \tilde{r}_{ij}) + \tilde{r}_{ij}^T \ln(\tilde{r}_{ij} \oslash r_{ij})|, \quad (4.2)$$

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

Erreur Quadratique Moyenne Normalisée Spectrale (*Normalized Mean Square Error* (NMSE_S))

Ce critère mesure la distance quadratique normalisée entre le spectre estimé et le spectre de référence par la relation :

$$NMSE_S = \frac{1}{PM} \sum_{i=1}^P \sum_{j=1}^M \frac{\|r_{ij} - \tilde{r}_{ij}\|_2}{\|r_{ij}\|_2}. \quad (4.3)$$

L'aspect spatial est fondamental pour évaluer la robustesse d'une méthode, en effet l'information spatiale traduite par les cartes d'abondance permet de connaître la proportion de chaque matériau dans un pixel et d'obtenir des cartes d'abondance fiables. La Racine de l'Erreur Quadratique Moyenne (*Abundance Overall Root Mean Square Error* (RMSE_A)) est calculée d'après :

$$RMSE_A = \frac{1}{P} \sum_{i=1}^P \sqrt{\frac{1}{M} \sum_{j=1}^M (c_{ji} - \tilde{c}_{ji})^2}, \quad (4.4)$$

où c_{ji} et \tilde{c}_{ji} décrivent respectivement les abondances réelles et estimées.

L'évaluation des performances des méthodes pour des données réelles est plus délicate à mettre en œuvre par rapport aux données synthétiques car la vérité terrain n'est pas toujours disponible dans la majorité des situations. Dans ce cas, les critères adoptés estiment l'erreur de reconstruction entre l'image estimée reconstruite, via la multiplication des matrices des spectres et des abondances estimées, avec les données réelles observées. Le premier critère concerne l'aspect spectral, à cet effet le SAM est calculé entre chaque spectre observé dans un pixel de l'image estimé avec le spectre observé dans le pixel correspondant dans l'image réelle. De plus, la RMSE entre le pixel reconstruit et réel, qui permet de mesurer la qualité de la reconstruction spectrale, est aussi calculée.

Pour estimer le degré performance dans le domaine spatial, une analyse visuelle des cartes d'abondance obtenues par les différents algorithmes est effectuée. En effet, chacune d'elles est comparée avec l'image réelle pour évaluer l'aspect spatial de chaque méthode.

4.4. Résultats obtenus et discussion

4.4.1. Etude 1 : Comparaison des méthodes proposées

La première étude est consacrée aux méthodes proposées dans le chapitre 3. Cette partie est dédiée à l'étude et à la comparaison détaillée de la manière dont chaque approche introduite

gère la variabilité intra-classe en se basant sur les critères de performances. Dans ce but, la bibliothèque « SL-1 » est choisie pour générer des données synthétiques réalistes incluant trois et quatre matériaux respectivement à l'aide des cartes d'abondance de 10×10 pixels citées précédemment.

La création des deux images synthétiques est réalisée de la manière suivante. Tout d'abord, une signature spectrale est sélectionnée aléatoirement pour chaque classe de matériaux présents dans la bibliothèque « SL-1 », parmi ses représentants. Par la suite, les signatures spectrales sont mélangées suivant le modèle de mélange linéaire à l'aide des fractions d'abondance pour créer chaque spectre de pixel de l'image hyperspectrale synthétique. Cette procédure permet de générer une image synthétique réaliste comportant de la variabilité intra-classe spectrale et de satisfaire la contrainte de la somme à un. Ce protocole est considéré également pour les autres données synthétiques par la suite. La première image hyperspectrale (HI-1) est constituée de trois matériaux : arbre, panneau photovoltaïque et tuile et la deuxième HI-2 comporte quatre matériaux : panneau photovoltaïque, arbre, végétation et tuile. Cette dernière permet d'étudier la manière dont les méthodes gèrent plus de variabilité spectrale.

Pour chaque méthode, les deux algorithmes proposés, multiplicatif (Multi) et à gradient projeté (Gradient), sont testés. Les méthodes 1, 2 et 3 sont décrites dans les sections 3.3.2, 3.3.3 et 3.3.4 respectivement. L'initialisation des spectres est réalisée en appliquant la VCA [37] à l'image hyperspectrale synthétique et celle des abondances en utilisant la FCLS [43] entre les spectres initiaux et l'image hyperspectrale. Pour chaque méthode, les structures particulières des matrices sont prises en considération à l'initialisation. Les matrices contenant les coefficients de variabilité A et B sont initialisées avec une valeur proche de zéro (ϵ de Matlab). Les coefficients de régularisation $\lambda_{\bar{A}}$ et $\lambda_{\bar{B}}$ sont déterminés de façon empirique pour optimiser les résultats en terme de qualité spatiale, cette approche est utilisée pour l'ensemble des tests suivants, les deux paramètres sont fixés à 0.2 pour HI-1 et à 0.25 pour HI-2. Les valeurs de u et v sont égales à 0.19 et 0.14 respectivement. Le nombre d'itérations est pris égal à 1000 pour l'ensemble des méthodes testées. Le processeur utilisé dans les expériences menées est un Intel (R) Core (TM) i5-8350U fonctionnant à 1,70 GHz, avec une capacité de mémoire de 16 Go. Les résultats de la première étude sont reportés dans le tableau 4.1.

		Méthodes de démixage proposées					
		Méthode 1		Méthode 2		Méthode 3	
		Multi	Gradient	Multi	Gradient	Multi	Gradient
Critère	Valeur Idéale						
SAM_S (°)	0	8.42	6.12	7.16	6.34	5.62	6.39
SID_S	0	3.35	2.66	2.98	2.62	2.68	2.44
$NMSE_S$ (%)	0	20.55	17.17	18.42	17.56	16.56	18.12
$RMSE_A$	0	0.102	0.093	0.089	0.095	0.061	0.095

Tableau 4.1 : Résultats des critères de performance sur HI-1.

En particulier, le tableau 4.1 met en valeur le gain obtenu sur la qualité spectrale entre les différentes méthodes. En effet, en comparant les algorithmes multiplicatifs des trois méthodes proposées, nous observons un gain considérable pour le SAM. A titre d'exemple, il évolue de 8.42° à 7.16° entre la première et la deuxième méthode. Par conséquent, la prise en

considération de la structure de la matrice des spectres s'avère primordiale. De plus, l'algorithme multiplicatif de la troisième méthode réalise un gain plus significatif pour atteindre la meilleure valeur du SAM de 5.62° . Pour les approches à gradient projeté, nous notons des valeurs de SAM satisfaisantes aux alentours de 6° et sensiblement similaires.

Pour mettre en évidence cet aspect du gain spectral, la figure 4.6 illustre les valeurs du SAM moyen au niveau de chaque pixel de l'image. Pour la première méthode multiplicative, les valeurs de ce critère sont plus élevées sur un nombre important de pixel par rapport aux autres méthodes sur l'ensemble de l'image. En particulier, nous relevons des valeurs entre 8° et 15° sur la majeure partie de l'image hyperspectrale. La deuxième méthode multiplicative présente des valeurs, toujours pour le SAM, plus faibles sur certains pixels de l'image que la première méthode avec cependant un nombre non-négligeable de pixels de l'image hyperspectrale dont la valeur du SAM est supérieure à 10° . La troisième méthode permet d'obtenir les plus faibles valeurs de SAM de cette comparaison. Par ailleurs, elles sont réparties de façon homogène sur l'intégralité de l'image conduisant à une meilleure fidélité spectrale par rapport aux autres méthodes. Ce résultat démontre l'intérêt de gérer à la fois la structure des matrices impliquées et les amplitudes des spectres estimés au niveau de chaque pixel.

Pour les algorithmes à gradient projeté, les valeurs numériques obtenues sont confirmées par la figure 4.6. En effet, les valeurs de SAM sont distribuées de manière homogène sur un nombre conséquent de pixels de l'image avec des valeurs comprises entre 5° et 6° et très peu de valeurs significatives supérieures à 10° .

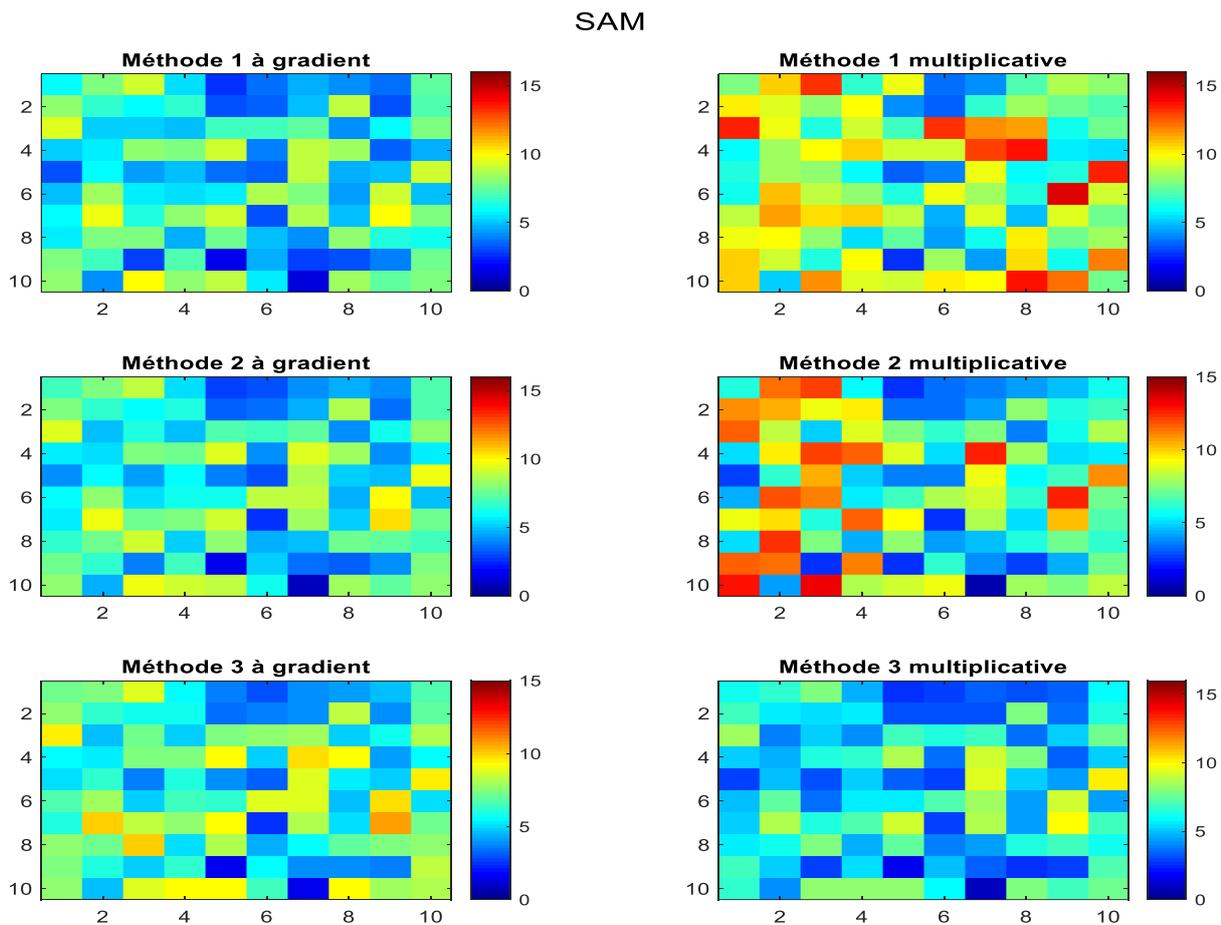


Figure 4.6 : Répartition du SAM au niveau de chaque pixel pour l'image HI-1.

Concernant le SID, nous observons que la première méthode dans sa version multiplicative mène à la plus grande valeur de 3.35 par rapport aux autres méthodes. La deuxième méthode dans sa version multiplicative améliore cet aspect avec une valeur du SID inférieure à 3 montrant l'importance de gérer la structure particulière de la matrice des spectres. De manière identique aux résultats du SAM, la troisième méthode permet d'atteindre la valeur la plus faible du SID, en particulier dans sa version à gradient projeté avec une valeur de 2.44. Par ailleurs, les différents algorithmes des trois méthodes proposées aboutissent à des valeurs de SID satisfaisantes.

De plus, les résultats du SAM et du SID sont confirmés par la troisième méthode (version multiplicative) qui présente également la valeur du NMSE la plus faible comparée aux autres méthodes, la seule inférieure à 17%, soulignant son efficacité à gérer d'une manière plus performante les amplitudes des spectres. De plus, l'introduction des termes de pénalisation joue un rôle prépondérant par rapport à la deuxième méthode sur la forme des spectres et de leurs amplitudes permettant de mieux traiter la variabilité spectrale.

Pour illustrer l'impact de la pénalisation sur les différentes méthodes, la figure 4.7 montre les spectres de la classe panneau photovoltaïque estimés par les algorithmes multiplicatifs des trois méthodes ainsi que la moyenne de chaque classe. La moyenne représente un indicateur visuel adéquat pour observer la manière dont la variabilité est gérée à l'intérieur de chaque classe.

En effet pour la première méthode, nous observons des distorsions au niveau des spectres estimés comparés aux spectres de références, en particulier entre la 60^{ème} et la 80^{ème} bande spectrale. De plus, on note clairement que les spectres estimés par la première technique présentent un étalement important par rapport à la moyenne de la classe. La deuxième méthode estime d'une meilleure façon la forme des spectres obtenus démontrant ainsi que la prise en considération de la matrice des spectres permet de les estimer de manière plus efficiente. Cependant, on relève également des distorsions sous forme de plusieurs pics d'amplitudes différentes au niveau de certains spectres toujours dans le même intervalle de bandes. La troisième méthode estime les spectres de manière plus efficiente comparée aux autres méthodes en termes de formes, en particulier entre la 60^{ème} et la 80^{ème} bande spectrale où les distorsions observées dans les résultats des deux premières méthodes sont moins notoires. La figure 4.7 montre clairement des formes plus cohérentes comparées aux spectres de référence dans l'ensemble du domaine spectral confirmant que les deux termes de pénalisation permettent d'être plus efficient en terme d'estimation des spectres.

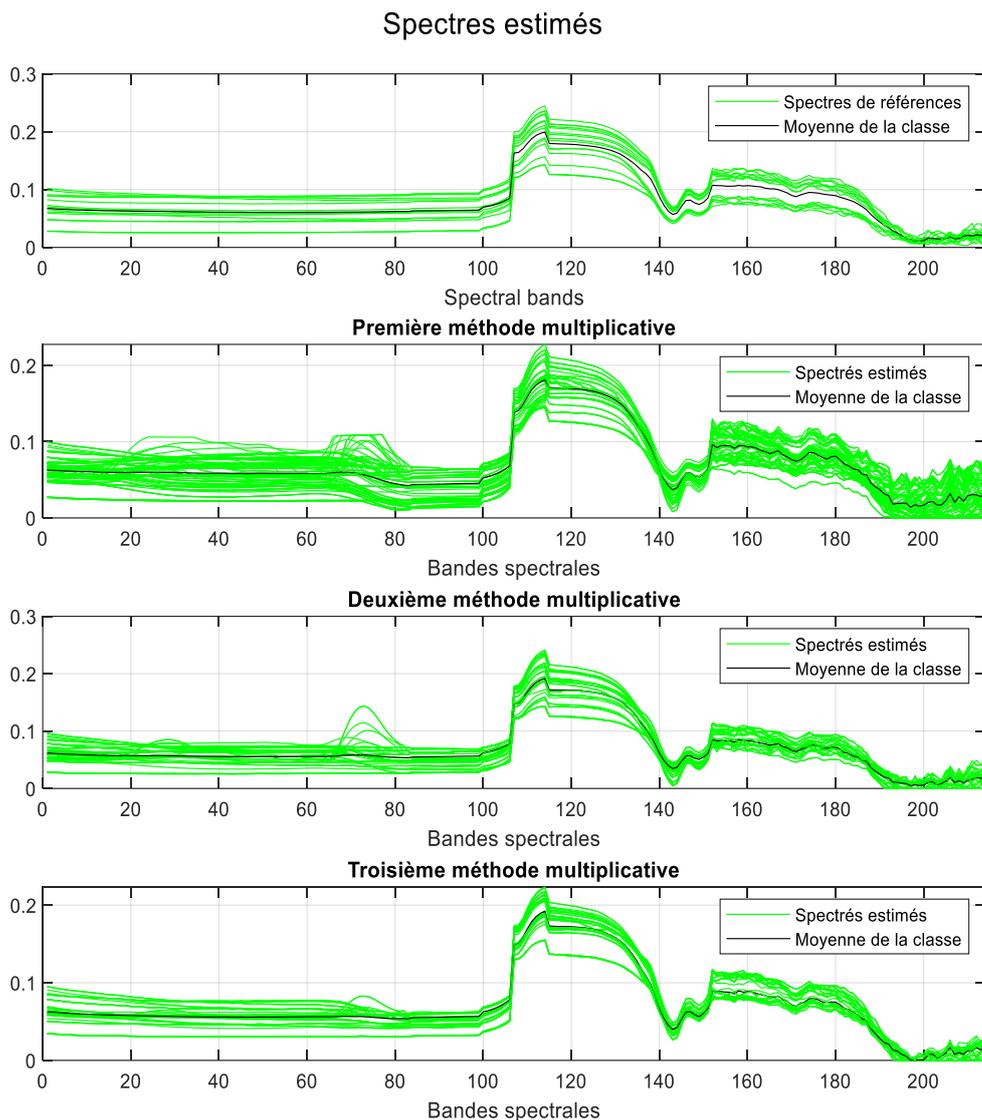


Figure 4.7 : Spectres estimés des panneaux photovoltaïques pour l'image HI-1.

Sur le plan spatial, une évolution appréciable entre les différentes méthodes est observée. En effet, en comparant la première méthode multiplicative à la seconde dans sa version multiplicative, l'amélioration en terme de reconstruction spatiale est notable passant de 0.102 à 0.089. Comme pour la reconstruction spectrale, l'algorithme multiplicatif de la troisième méthode permet d'obtenir la valeur de RMSE la plus faible de 0.061 indiquant que l'algorithme mène à une meilleure reconstruction spatiale et spectrale. Comme pour les critères spectraux, les trois algorithmes à gradient projeté produisent des valeurs de RMSE pratiquement identiques.

Le deuxième test sur l'image hyperspectrale HI-2 est réalisé pour analyser la manière dont les trois méthodes gèrent plus de variabilité spectrale en présence d'un plus grand nombre de classes dans l'image. A cet effet, quatre matériaux sont considérés : panneau photovoltaïque, arbre, végétation et tuile. Les résultats des tests sont reportés dans le tableau 4.2.

		Méthodes de démixage proposées					
		Méthode 1		Méthode 2		Méthode 3	
		Multi	Gradient	Multi	Gradient	Multi	Gradient
Critère	Valeur Idéale						
SAM_S (°)	0	11.53	6.10	6.85	6.01	5.50	6.00
SID_S	0	5.74	2.33	2.44	2.29	2.04	2.29
$NMSE_S$ (%)	0	30.21	17.87	19.01	17.88	16.89	17.91
$RMSE_A$	0	0.199	0.158	0.077	0.138	0.070	0.135

Tableau 4.2 : Résultats des critères de performance sur HI-2.

Comme pour la première image HI-1, les résultats d'après le tableau 4.2 mettent en évidence le gain sur l'aspect spectral entre les différentes méthodes. En effet la première méthode dans sa version multiplicative présente la valeur de SAM la plus élevée de 11.53°. Le gain est appréciable avec la deuxième méthode multiplicative de l'ordre de 5° avec une valeur de SAM de 6.85°. De plus, les versions à gradient projeté mènent dans l'ensemble à des résultats satisfaisants et équivalents en terme de qualité spectrale. Similairement à la première image, la troisième méthode dans sa version multiplicative mène à la valeur de 5.50°, soit la plus faible comparée aux valeurs obtenues par les autres approches proposées, et donc apparaît comme étant la plus performante. La figure 4.8 donne une idée plus précise de cette reconstruction spectrale en représentant les valeurs de SAM.

Le tableau 4.2 souligne le gain obtenu de NMSE entre les différentes méthodes proposées. D'après les résultats reportés, la première méthode multiplicative présente la valeur de NMSE la plus élevée de 30.21%. La deuxième méthode multiplicative améliore nettement cet aspect en gérant mieux les amplitudes des spectres estimés avec une valeur de NMSE de 19.01% dans sa version multiplicative. La troisième méthode multiplicative mène à la valeur de NMSE la plus faible de 16.89 % parmi celles proposées traduisant que la pénalisation des amplitudes permet d'estimer des spectres plus cohérents en termes d'amplitudes. Comme pour le SAM, les trois méthodes dans leur version à gradient projeté conduisent à des résultats satisfaisants de NMSE.

Concernant la SID, la première méthode multiplicative présente la valeur la plus élevée de 5.74 confirmant ainsi les résultats obtenus en termes de SAM et de NMSE. La deuxième méthode apporte un gain significatif avec une valeur de 2.44 démontrant que la gestion de la structure de la matrice des spectres améliore l'estimation des spectres. La troisième méthode permet d'atteindre la valeur de SID la plus faible (2.04) confirmant les résultats précédents. Les trois méthodes dans leurs versions à gradient projeté mènent pratiquement à des résultats identiques comme pour le SAM et le NMSE.

SAM

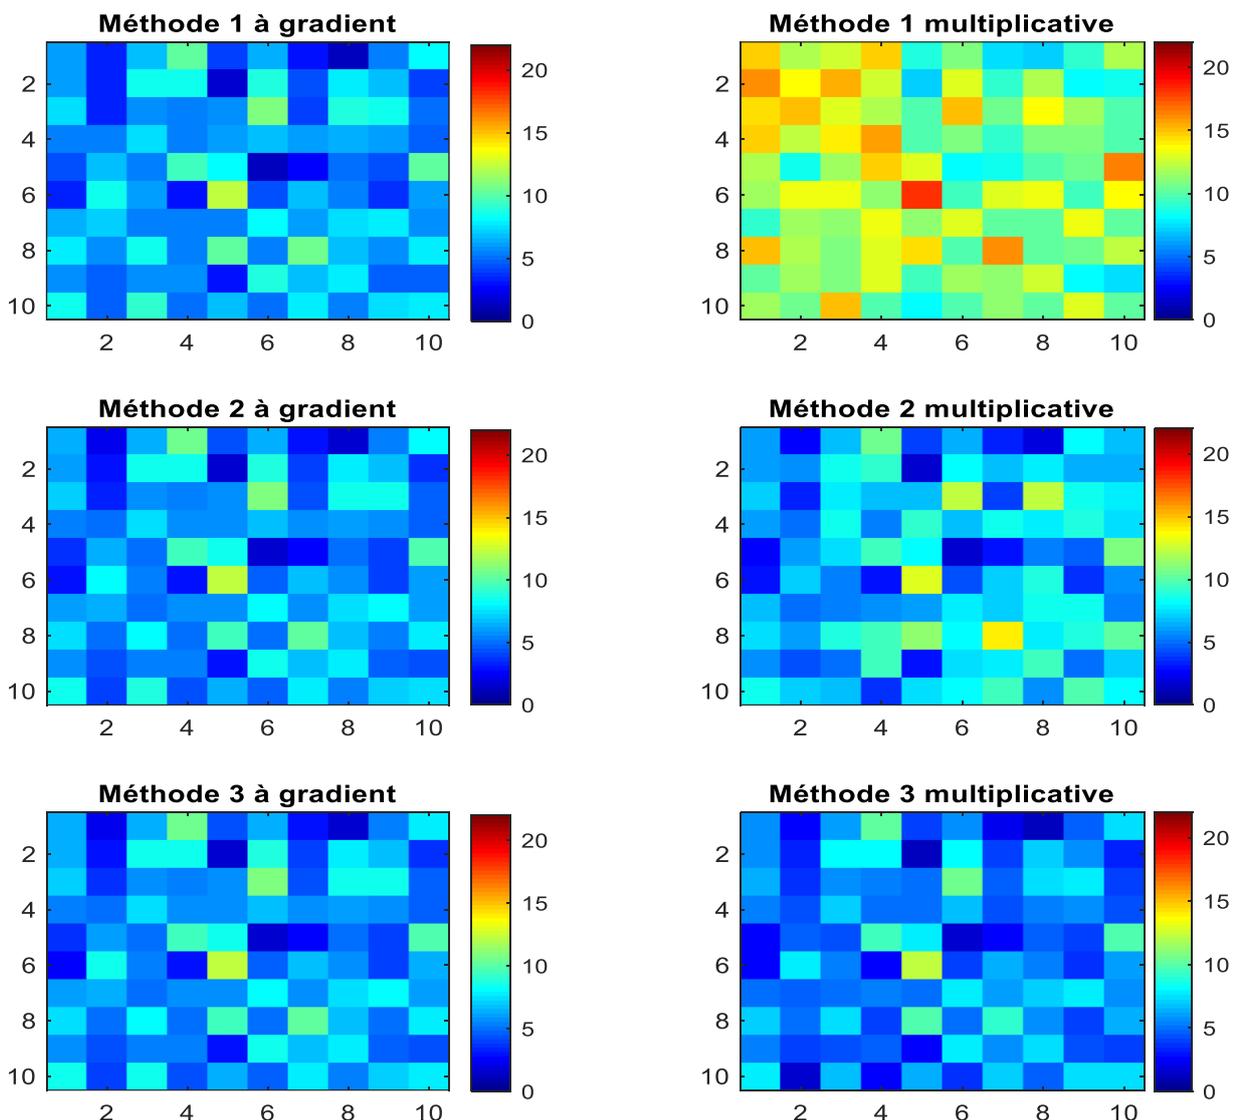


Figure 4.8 : Répartition du SAM au niveau de chaque pixel pour l'image HI-2.

Pour décrire la gestion des formes des trois méthodes multiplicatives, la figure 4.9 illustre les spectres estimés pour la classe panneau photovoltaïque et le spectre moyen pour chaque classe estimée ainsi que les spectres de référence de la classe photovoltaïque utilisée pour générer l'image HI-2. Comme pour l'image HI-1, la figure 4.9 indique clairement que la troisième méthode multiplicative estime les spectres les plus proches par rapport aux spectres de référence comparée aux deux autres méthodes.

Concernant l'aspect spatial, une amélioration significative entre les différentes méthodes multiplicatives proposées est notée avec une RMSE passant de 0.199 à 0.070. Ce gain met en évidence clairement que la prise en compte de la structure particulière de la matrice des spectres pendant les mises à jour impacte sensiblement l'estimation des abondances. Concernant les algorithmes à gradient projeté, on observe une amélioration entre les différentes méthodes.

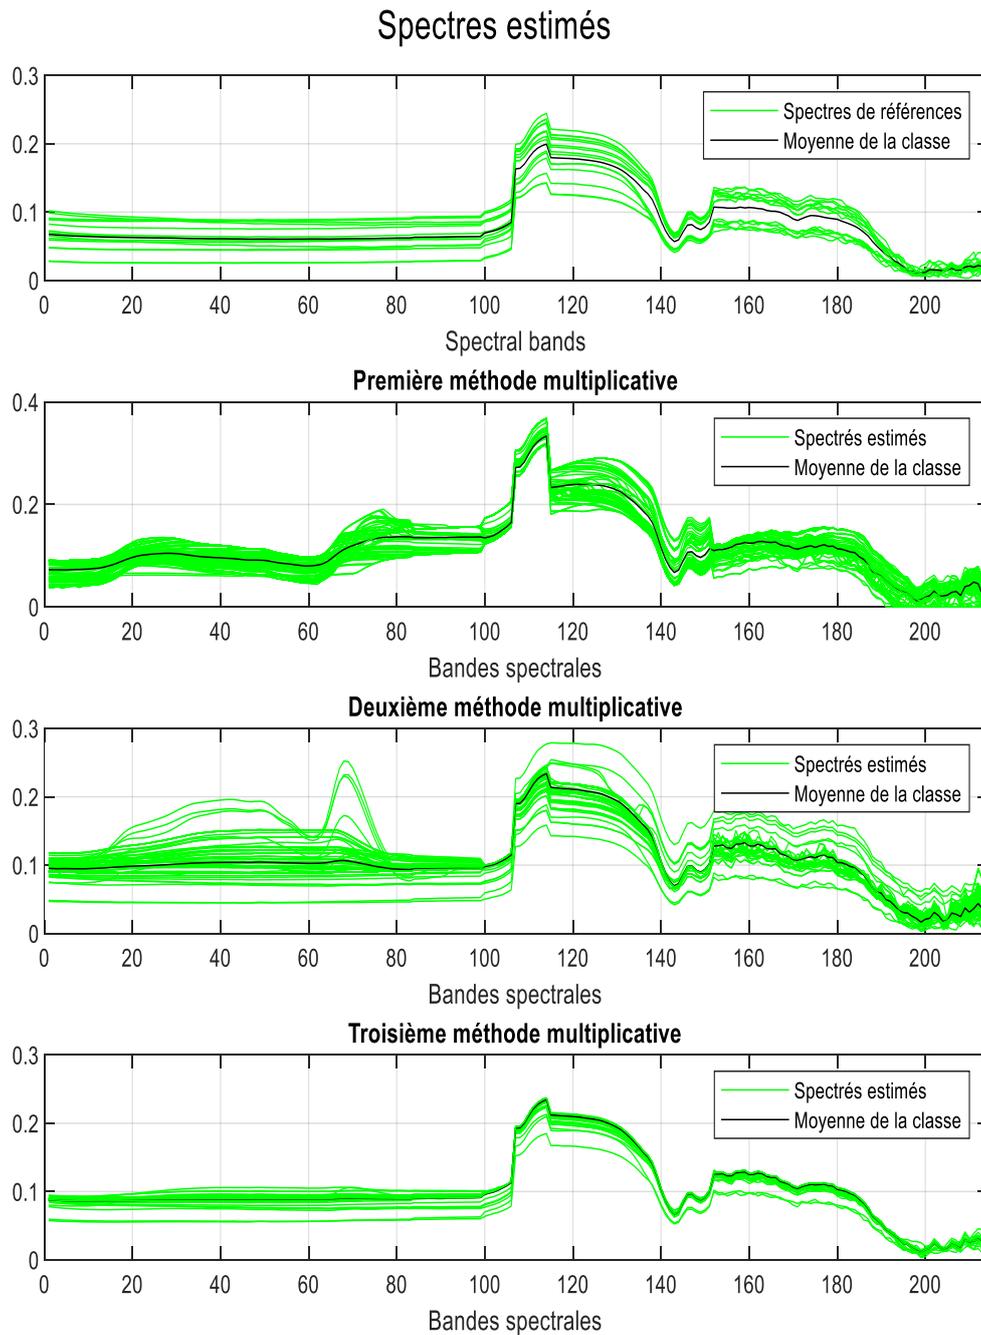


Figure 4.9 : Spectres estimés des panneaux photovoltaïques pour l'image HI-2.

4.4.2. Etude 2 : Impact du bruit sur les trois méthodes proposées

L'objectif de cette partie est d'analyser la robustesse au bruit des différentes méthodes introduites. En effet, l'étude de l'impact du bruit est fondamentale dans l'optique d'appliquer

des méthodes à des données réelles. Ces dernières peuvent présenter un fort bruit [110] ou bien des points aberrants d'où la nécessité d'étudier cet aspect. Pour conduire cette expérimentation, une image hyperspectrale HI-3 est générée de manière identique à HI-1, en sélectionnant aléatoirement une signature spectrale parmi les matériaux considérés pour la création de chaque pixel de l'image. La taille de HI-3 est identique à celle de HI-1, soit de 10×10 pixels. Par la suite, un bruit aléatoire gaussien est ajouté à l'image suivant la relation:

$$Y = X + B, \quad (4.5)$$

où Y est l'image hyperspectrale bruitée, X indique l'image hyperspectrale synthétique sans bruit et B représente le bruit gaussien.

Pour cette étude, quatre différents SNR sont appliqués : 15, 20, 25, et 30 dB. De plus, deux critères sont retenus : le SAM et la RMSE pour les deux aspects spectral et spatial respectivement. Le tableau 4.3 contient les différentes valeurs du SAM en fonction du bruit ajouté. Les coefficients de régularisation $\lambda_{\bar{A}}$ et $\lambda_{\bar{B}}$ sont fixés à 0.5 pour cette expérimentation pour les méthodes proposées.

	Méthodes de démixage proposées					
	Méthode 1		Méthode 2		Méthode 3	
	Multi	Gradient	Multi	Gradient	Multi	Gradient
SNR (dB)						
15	16.06	10.77	15.80	9.73	9.26	10.01
20	13.88	8.71	11.70	8.41	7.82	8.16
25	10.16	6.34	8.10	6.11	5.78	5.97
30	8.05	6.02	6.90	5.68	5.46	5.60

Tableau 4.3 : Résultats du SAM en fonction du niveau de bruit pour l'image HI-3.

Tout d'abord, nous observons que les valeurs de SAM augmentent avec l'intensité du bruit, ce résultat est prévisible car toutes les méthodes ont plus de difficultés à estimer les spectres avec un SNR plus faible. Pour la configuration avec un SNR de 15 dB, nous notons que les deux premières méthodes dans leurs versions multiplicatives atteignent les résultats les plus élevés en terme de SAM confirmant ainsi les résultats de la première étude, en particulier pour un environnement en présence d'un bruit élevé. De plus similairement à la première étude, la troisième méthode dans sa version multiplicative permet d'obtenir la plus faible valeur de SAM.

Pour 20 dB, la troisième méthode multiplicative permet d'atteindre la plus faible valeur de SAM dans cette configuration. La configuration à 25 dB montre que les méthodes donnent des résultats satisfaisants avec un gain important par rapport à 20 dB. Comme pour les deux premières configurations, la troisième méthode dans sa version multiplicative donne la valeur du SAM la plus faible. Pour un SNR de 30 dB, l'ensemble des méthodes mènent à des résultats satisfaisants Cette étude sur l'aspect spectral révèle clairement que la troisième méthode mène aux meilleurs résultats dans toutes les configurations considérées démontrant ainsi son efficacité et sa robustesse par rapport aux deux premières méthodes. Cela est confirmé par la figure 4.10 qui décrit les courbes de variation de chaque méthode en fonction du SNR montrant clairement que la troisième méthode dans sa version multiplicative est plus robuste au bruit.

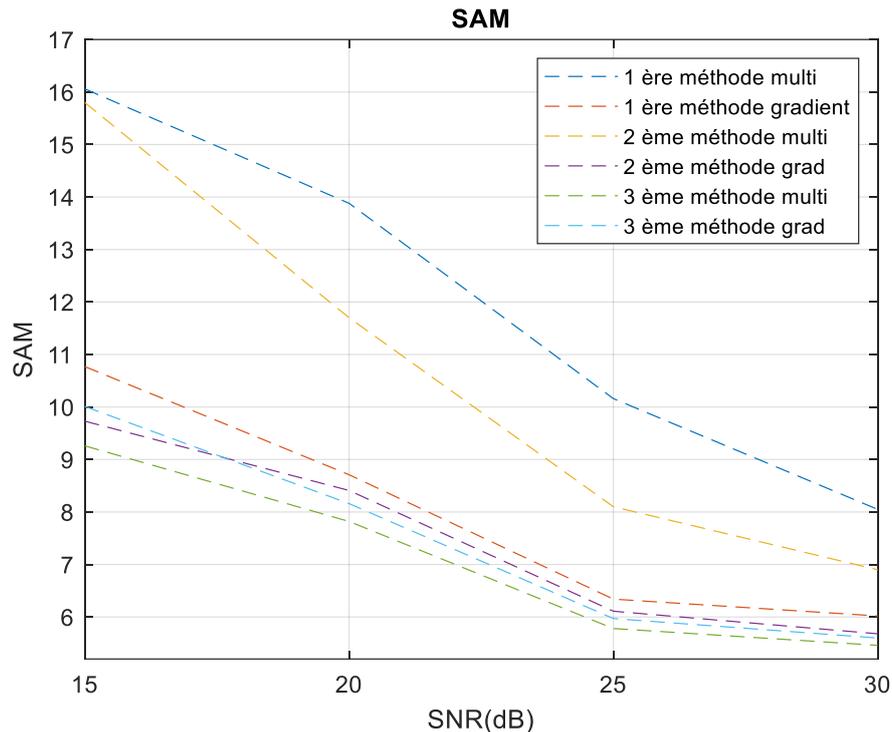


Figure 4.10 : Variation du SAM en fonction du SNR pour l’image HI-3.

Le tableau 4.4 présente les différentes valeurs du RMSE en fonction du bruit injecté dans l’image considérée. Nous observons que plus le bruit augmente plus les valeurs de ce critère deviennent élevées. Comme pour l’aspect spectral, la troisième méthode dans sa version multiplicative délivre les meilleures performances dans n’importe quelle configuration de bruit. Cette conclusion est illustrée par la figure 4.11.

SNR (dB)	Méthodes de démixage proposées					
	Méthode 1		Méthode 2		Méthode 3	
	Multi	Gradient	Multi	Gradient	Multi	Gradient
15	0.188	0.126	0.131	0.136	0.082	0.137
20	0.158	0.111	0.115	0.119	0.082	0.119
25	0.135	0.105	0.106	0.109	0.082	0.109
30	0.081	0.092	0.087	0.097	0.064	0.096

Tableau 4.4 : Résultats du RMSE en fonction du bruit pour l’image HI-3.

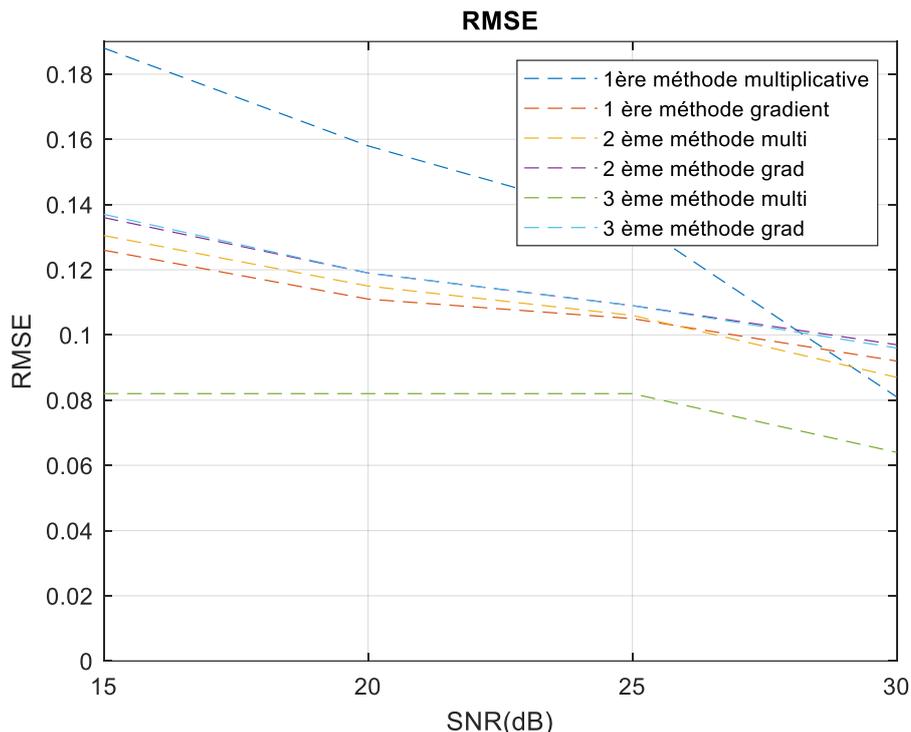


Figure 4.11 : Variation du RMSE en fonction du SNR pour l'image HI-3.

4.4.3. Etude 3 : Impact de l'initialisation sur les méthodes proposées

Les méthodes proposées sont toutes basées sur la NMF et donc dépendent fortement de l'initialisation. Ainsi une bonne initialisation des méthodes peut améliorer l'estimation des spectres et des abondances. En effet, une bonne initialisation permet d'avoir une amélioration effective par rapport à une NMF initialisée avec une méthode géométrique comme la VCA. Dans cette section, une étude démontrant l'importance de l'initialisation est menée. Elle a pour objectif de montrer que l'intégration d'une bibliothèque spectrale au niveau de l'initialisation impacte de manière significative les résultats des techniques proposées. Dans ce but, une image hyperspectrale HI-4 est créée de manière similaire à HI-1, c'est-à-dire composée de trois matériaux et de taille 10×10 pixels, en faisant une nouvelle sélection aléatoire des spectres.

Pour l'initialisation, les algorithmes appliquent généralement des méthodes géométriques linéaires ne considérant pas le phénomène de variabilité spectrale dans l'image or comme montré précédemment dans le chapitre 1, ce phénomène est fortement présent dans les images hyperspectrales. Le but consiste à intégrer d'une certaine manière la notion de variabilité spectrale via une l'utilisation d'une bibliothèque spectrale dans l'étape d'initialisation. A cet effet, une bibliothèque spectrale est générée à l'initialisation. Pour cela l'*Automated Extraction Bundles (AEB)* a été adoptée [97]. Le principe est de faire tourner les méthodes géométriques d'extraction de matériaux, dans le cas présent la VCA, sur plusieurs parties de l'image choisies aléatoirement pour construire la bibliothèque spectrale (voir figure 4.12). Cette approche a pour avantage d'être simple dans sa mise en œuvre et rapide en terme d'exécution. De plus, elle permet d'opérer complètement en aveugle en utilisant et en extrayant l'information spectrale présente dans l'image hyperspectrale traitée et ainsi en respectant la physique, c'est-à-dire

extraire les matériaux contenus dans l'image directement, et donc le type de variabilité présente dans l'image de l'image au lieu de considérer une bibliothèque préétablie.

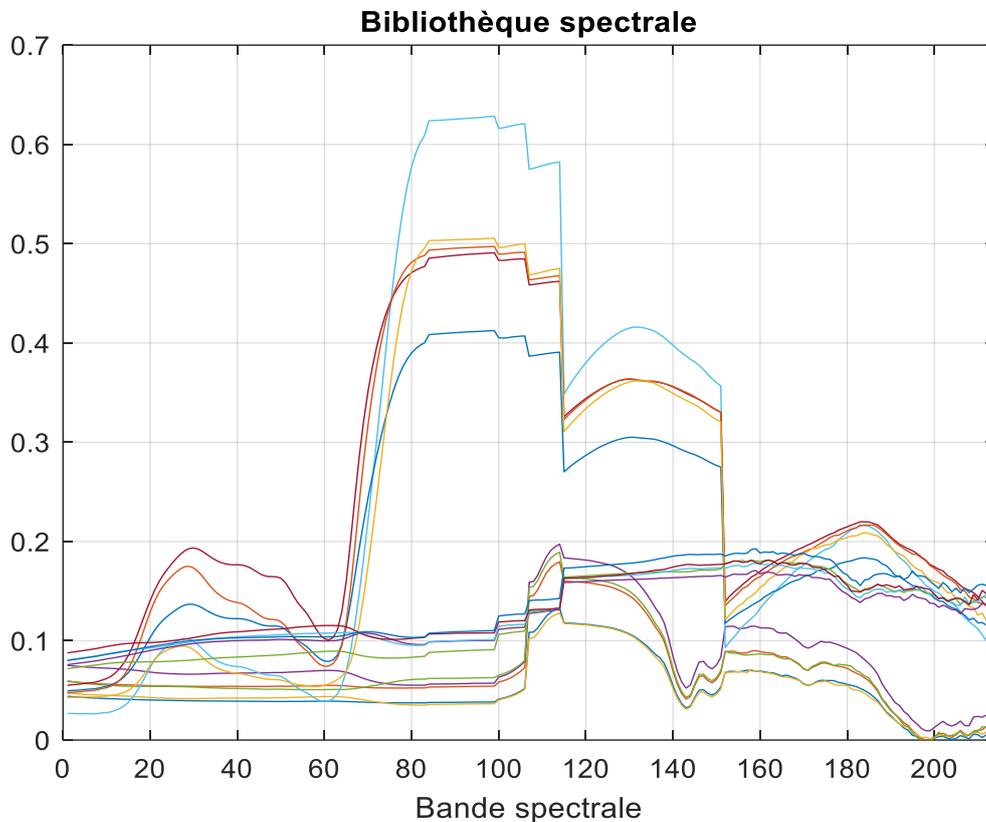


Figure 4.12 : Bibliothèque spectrale générée à partir de l'image HI-4.

Par la suite, une étape de clustering est nécessaire pour regrouper les différents matériaux en plusieurs classes, à l'aide de la méthode k -means. Par ailleurs, cette étape permet d'organiser l'ordre des spectres. Comme mentionné dans le chapitre 1, les méthodes de SAS sont généralement impactées par une permutation des spectres et c'est le cas en particulier dans cette configuration avec plusieurs exécutions de la VCA. La distance spectrale préétablie par MATLAB est appliquée comme critère de classification, son intérêt étant son insensibilité aux changements d'illumination et au facteur d'échelle [107]. Cette étape permet de diviser la bibliothèque spectrale en trois classes de matériaux comme le montre la figure 4.13. A noter que le nombre de classes doit être connu au préalable pour faire la classification. L'étape finale consiste à sélectionner le spectre médian de chaque classe comme initialisation de chacune d'elles. Le choix du spectre médian au lieu de la moyenne est dicté par le fait que si nous utilisons la moyenne et qu'un outlier est classifié dans une classe donnée, il peut impacter de façon sensible l'initialisation. Cet aspect est fondamental dans le cas de données réelles. L'initialisation proposée dans cette section est appliquée pour le cas des données réelles.

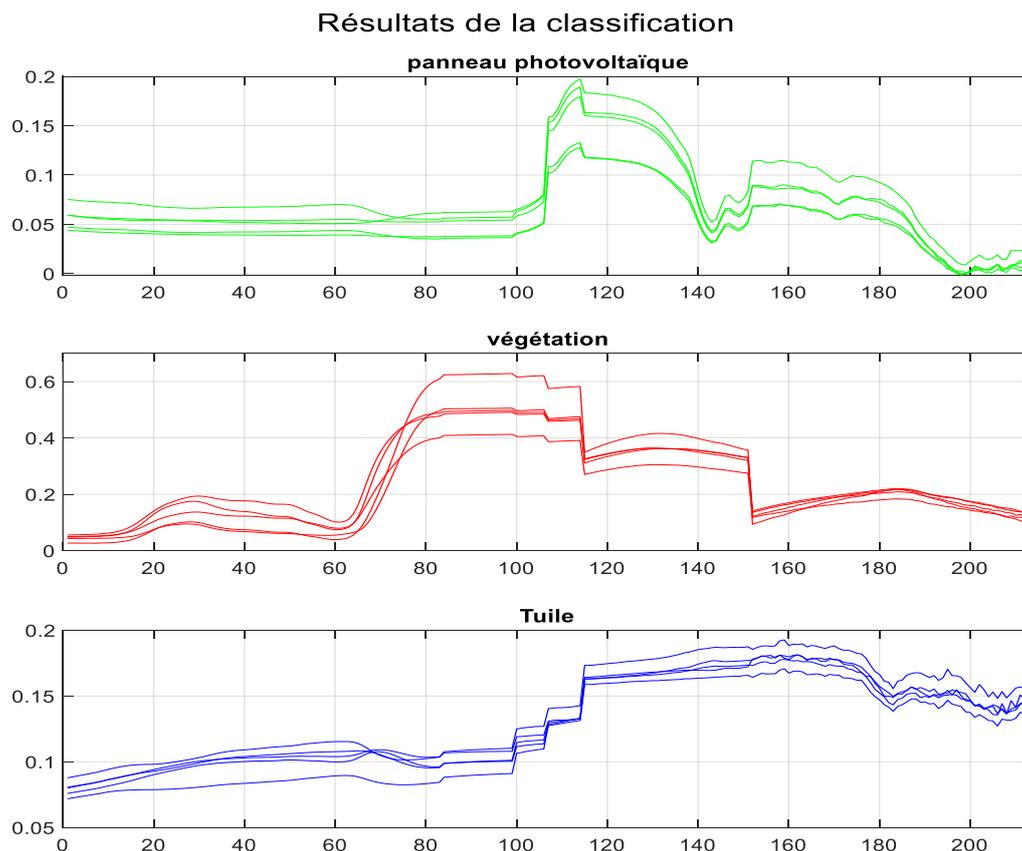


Figure 4.13 : Résultats de la classification de la bibliothèque spectrale pour l'image HI-4.

Le tableau 4.5 donne les résultats des méthodes proposées pour les deux initialisations : l'initialisation par VCA (a) et l'initialisation proposée (b). Les coefficients de régularisation $\lambda_{\bar{A}}$ et $\lambda_{\bar{B}}$ sont fixés à 0.4 pour cette étude.

		Méthodes de démelange proposées											
		Méthode 1				Méthode 2				Méthode 3			
		Multi		Gradient		Multi		Gradient		Multi		Gradient	
Critère	Valeur Idéale	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)
SAM_S (°)	0	9.36	8.30	6.61	6.12	8.96	7.50	6.68	6.11	6.72	5.90	6.60	6.09
SID_S	0	5.03	2.62	3.68	2.57	3.73	2.60	3.43	2.43	2.99	2.01	3.36	2.40
$NMSE_S$ (%)	0	27.40	20.65	24.99	18.48	27.19	18.89	26.00	17.02	23.52	16.39	26.10	17.07
$RMSE_A$	0	0.139	0.126	0.141	0.117	0.154	0.104	0.142	0.111	0.101	0.076	0.141	0.111

Tableau 4.5 : Résultats des critères en fonction de l'initialisation pour l'image HI-4.

4.4.4. Etude 4 : Comparaison avec des méthodes de la littérature

Cette étude est consacrée à la comparaison des méthodes proposées aux différentes méthodes récentes de la littérature traitant la variabilité spectrale de type intra-classe sur les données et les méthodes paramétriques. Plus précisément, l'étude est divisée en deux parties bien distinctes, la première est consacrée à la comparaison entre les méthodes introduites. Suivant cette comparaison, la méthode apportant les meilleures performances est retenue pour être comparée aux méthodes de la littérature dans une deuxième partie.

Les méthodes récentes de la littérature sélectionnées pour cette étude gérant la variabilité spectrale de manières différentes sont les suivantes :

- l'UP-NMF (*Unconstrained Pixel-by-Pixel NMF*) [18] est une extension de la NMF pour gérer la variabilité spectrale en utilisant les structures particulières des matrices des abondances et des spectres pour traiter la variabilité spectrale d'un point de vue spectral et spatial afin d'extraire des spectres au niveau de chaque pixel de l'image hyperspectrale traitée,
- l'IP-NMF (*Inertia-constrained Pixel-by-Pixel NMF*) [18] est une version étendue de l'UP-NMF en pénalisant la fonction de coût à l'aide de l'inertie des spectres comme montré dans le chapitre 2 pour améliorer l'aspect de l'estimation,
- l'ELMM (*Extended Linear Mixing Model*) [106] gère la variabilité au niveau spatial, c'est-à-dire pour chaque pixel de l'image hyperspectrale, il estime un facteur d'échelle constant sur toutes les bandes mais différent pour chaque matériau présent dans le pixel,
- le PLMM (*Perturbed Linear Mixing Model*) [105] considère la variabilité sur le plan spatial et spectral en estimant une perturbation du spectre de référence sous une forme additive pour chaque pixel de l'image,
- le GLMM (*Generalized Linear Mixing Model*) [109] est une extension du ELMM en considérant que le facteur d'échelle peut varier par bande spectrale pour gérer une variabilité plus complexe, plus précisément d'autres types de variabilité que celles décrites par un seul facteur d'échelle que l'ELMM,
- le MLMM (*Multiplicative-tuning Linear Mixing Model*) [108] considère la variabilité sous forme multiplicative pour chaque bande spectrale des spectres. De plus, il applique la structure de la matrice des abondances comme pour l'IP-NMF.

Pour l'initialisation de l'UP-NMF, l'IP-NMF et la troisième méthode proposée, la VCA [37] est considérée pour les spectres et la FCLS [43] pour les abondances. Concernant l'initialisation du PLMM, de l'ELMM et du GLMM, la VCA [37] est utilisée pour estimer les spectres initiaux et la SCLSU (*Scaled Constrained Least Square Unmixing*) [106] pour les abondances. La SCLSU est un cas particulier du ELMM où le facteur d'échelle est constant sur toutes les bandes spectrales et l'ensemble de matériaux présents dans l'image. Le choix de ne pas utiliser la méthode d'initialisation introduite dans l'étude 3 est dicté par le fait que les méthodes de la littérature utilisées n'ont pas été développées avec ce type d'initialisation. Ainsi toutes les méthodes traitées dans cette partie sont initialisées avec la même méthode pour avoir une indication appropriée sur les performances de chaque méthode.

Les différents paramètres de chaque méthode et le critère d'arrêt sont mis à la valeur indiquée par les auteurs des méthodes. Le nombre d'itérations est pris égal à 1000 pour chaque méthode. Les coefficients de régularisation $\lambda_{\bar{A}}$ et $\lambda_{\bar{B}}$ sont fixés de manière empirique à 0.2. Le premier test est réalisé sur une image hyperspectrale synthétique HI-5 créée de manière identique à l'image HI-1 avec les mêmes matériaux considérés et le même nombre de pixels dans l'image.

Pour HI-5, une nouvelle sélection aléatoire des matériaux considérés est réalisée. Les résultats des critères de performance sont reportés dans le tableau 4.6 pour les différentes méthodes.

		Méthodes de démixage proposées					
		Méthode 1		Méthode 2		Méthode 3	
		Multi	Gradient	Multi	Gradient	Multi	Gradient
Critère	Valeur Idéale						
SAM_S (°)	0	7.00	6.18	7.04	6.56	5.62	6.58
SID_S	0	2.32	2.01	2.30	2.27	1.95	2.28
$NMSE_S$ (%)	0	16.64	15.37	16.58	16.43	15.10	16.52
$RMSE_A$	0	0.072	0.094	0.071	0.087	0.068	0.087

Tableau 4.6 : Résultats des critères de performance des méthodes proposées pour l’image HI-5.

Le tableau 4.6 confirme les résultats des trois premières études. En particulier, nous observons que la troisième méthode par rapport aux autres méthodes proposées permet d’obtenir une meilleure reconstruction spectrale et spatiale avec un net gain en terme de SAM et donc comparée aux autres méthodes de la littérature.

		Méthodes						
		MLMM	UP-NMF	IP-NMF	PLMM	ELMM	GLMM	Proposée
Critère	Valeur Idéale							
SAM_S (°)	0	6.13	6.48	6.51	6.96	6.24	7.94	5.62
SID_S	0	2.00	2.31	2.30	2.06	2.04	2.70	1.95
$NMSE_S$ (%)	0	19.40	16.41	16.58	20.00	15.12	20.68	15.10
$RMSE_A$	0	0.071	0.073	0.073	0.49	0.076	0.077	0.068

Tableau 4.7: Résultats des critères de performance pour l’image HI-5.

D’après le tableau 4.7, d’un point de vue spectral, le GLMM atteint la valeur de SAM la plus élevée de 7.94° menant ainsi à une reconstruction spectrale moins performante par rapport aux autres méthodes. Le PLMM donne une meilleure fidélité spectrale, par rapport aux autres méthodes, avec un SAM de 6.96°. L’UP-NMF et l’IP-NMF permettent d’obtenir des valeurs similaires autour de 6.50°, soulignant qu’elles gèrent mieux la variabilité spectrale intra-classe. Le MLMM présente la valeur de SAM la plus faible par rapport aux autres méthodes de la littérature montrant son efficacité à gérer ce type de variabilité spectrale. Un gain significatif de SAM pour la méthode proposée est observé par rapport à toutes les méthodes de la littérature, elle aboutit à une valeur de 5.62°, démontrant sa capacité à gérer la variabilité intra-classe par rapport aux méthodes de la littérature testées. Ce résultat est confirmé par les autres critères spectraux. Pour mettre en évidence la qualité spectrale, la figure 4.14 illustre la répartition du SAM au niveau de chaque pixel de l’image. Elle montre globalement que la méthode proposée mène à la meilleure reconstruction en terme de SAM.

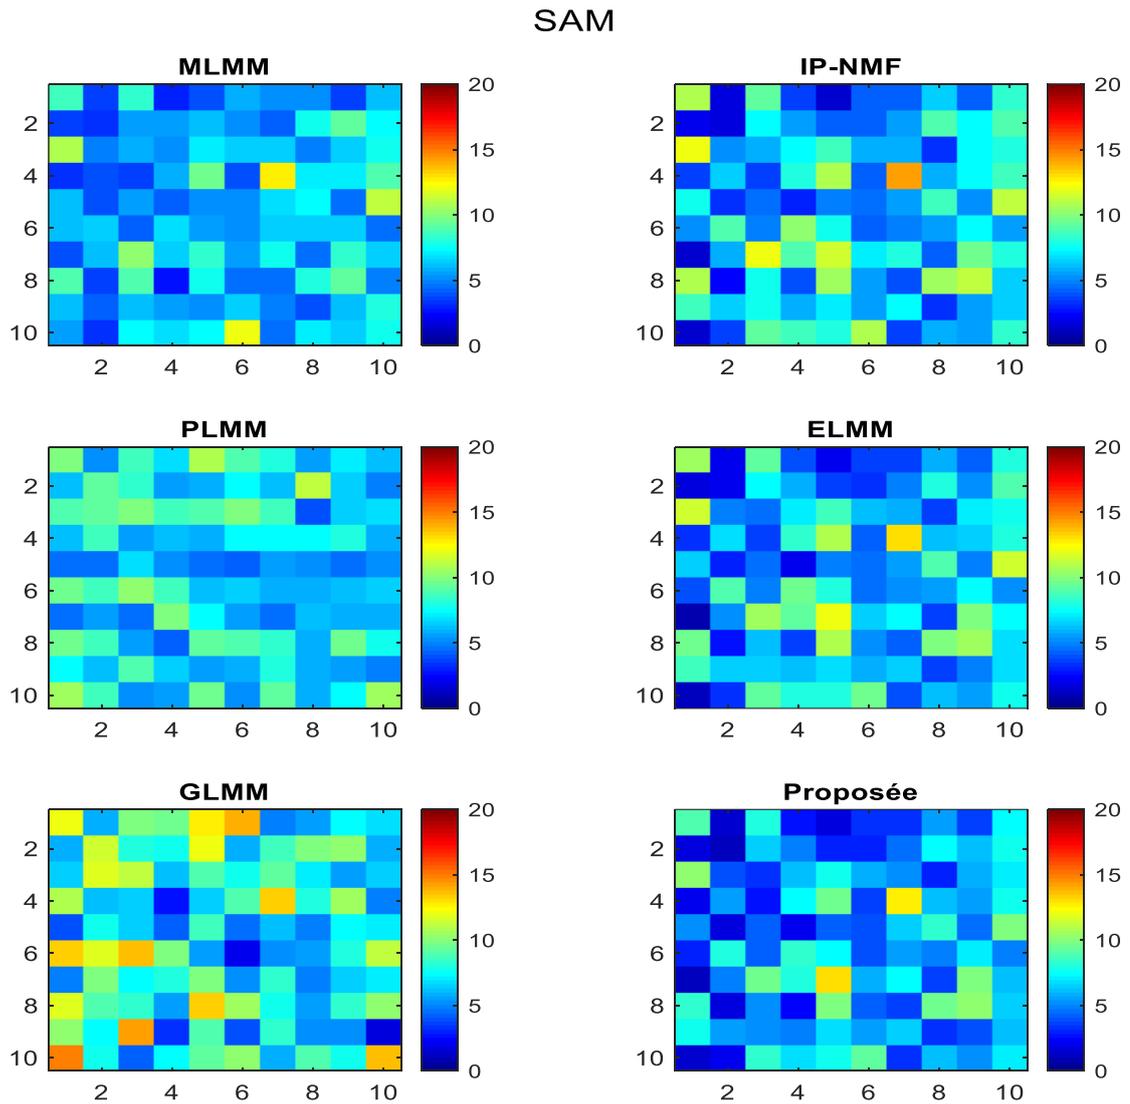


Figure 4.14 : Répartition du SAM au niveau de chaque pixel pour l’image HI-5.

Dans le domaine spatial, le PLMM mène à la valeur de RMSE la plus grande de 0.49. Pour les autres méthodes de la littérature testées, les valeurs de RMSE sont pratiquement identiques autour de 0.075 avec de meilleures valeurs pour le MLMM avec une valeur de 0.071. Comme pour l’aspect spectral, la méthode proposée produit la valeur la plus faible de 0.068 démontrant son efficacité à mieux gérer les deux aspects.

Le deuxième test réalisé a pour but d’étudier et d’analyser comment les différentes méthodes gèrent plus de variabilité intra-classe dans l’image. A cet effet, une image hyperspectrale synthétique HI-6 est créée, de taille 10×10 pixels et contenant cinq matériaux à partir de la bibliothèque spectrale « SL-2 » (voir figure 4.4.b). Cette configuration permet d’analyser les méthodes en présence d’une forte variabilité spectrale. Les résultats des critères de performance obtenus sont reportés dans le tableau 4.8. Les coefficients de régularisation $\lambda_{\bar{A}}$ et $\lambda_{\bar{B}}$ sont fixés à 0.2 pour cette expérimentation.

		Méthodes de démixage proposées					
		Méthode 1		Méthode 2		Méthode 3	
		Multi	Gradient	Multi	Gradient	Multi	Gradient
Critère	Valeur Idéale						
SAM_S (°)	0	4.94	4.60	4.97	4.65	4.52	4.64
SID_S	0	0.65	0.64	0.66	0.65	0.62	0.65
$NMSE_S$ (%)	0	12.66	12.04	12.69	12.07	11.89	12.07
$RMSE_A$	0	0.166	0.166	0.166	0.165	0.165	0.165

Tableau 4.8 : Résultats des critères de performance des méthodes proposées pour l’image HI-6.

Comme pour les différentes études précédentes, nous observons que la troisième méthode dans sa version multiplicative mène aux meilleurs résultats dans les domaines spatial et spectral. Pour cette raison, la dernière est retenue pour la comparaison avec les autres méthodes de la littérature.

		Méthodes						
		MLMM	UP-NMF	IP-NMF	PLMM	ELMM	GLMM	Proposée
Critère	Valeur Idéale							
SAM_S (°)	0	4.83	4.63	4.62	5.35	5.31	5.00	4.52
SID_S	0	2.65	0.63	0.63	0.86	3.43	0.71	0.62
$NMSE_S$ (%)	0	37.53	12.26	12.15	14.78	36.52	13.90	11.89
$RMSE_A$	0	0.165	0.165	0.165	0.37	0.23	0.21	0.165

Tableau 4.9 : Résultats des critères de performance pour l’image HI-6.

Sur le plan spectral d’après le tableau 4.9, le PLMM atteint la valeur plus élevée de SAM de 5.35° proche de celle obtenue par l’ELMM de 5.31°. Ces deux méthodes aboutissent à des reconstructions spectrales moins performantes comparées aux autres méthodes de la littérature. Le GLMM conduit à une meilleure valeur de SAM de 5.00°. Le MLMM améliore la valeur du SAM (4.83°). Par ailleurs, l’UP-NMF et l’IP-NMF apportent un gain significatif avec des valeurs quasi similaires autour de 4.60°, soulignant qu’elles gèrent de manière efficiente la variabilité intra-classe. La méthode proposée permet d’atteindre la meilleure reconstruction d’un point de vue spectral avec le SAM le plus faible de 4.52°. Ces observations sont confirmées par les valeurs de SID les plus faibles pour la méthode proposée ainsi que pour l’UP-NMF et l’IP-NMF. De plus, nous observons que les méthodes introduites dans leur globalité offrent de bien meilleurs résultats que les méthodes de la littérature en particulier comparées aux PLMM, ELMM et GLMM en termes de SAM et SID. Cela confirme que les méthodes proposées gèrent de manière plus efficiente l’aspect spectral dans une configuration avec une forte variabilité spectrale.

D'un point de vue spatial, le PLMM présente la valeur la plus élevée de RMSE de 0.37. Le GLMM et l'ELMM améliorent cet aspect avec des valeurs de RMSE de 0.21 et 0.23 respectivement. Comme pour l'aspect spectral, le MLMM, l'UP-NMF, l'IP-NMF et la méthode proposée produisent les meilleurs résultats avec des valeurs de RMSE de 0.165.

4.4.5. Etude 5 : Impact du bruit sur les méthodes

L'objectif de cette partie est d'analyser la robustesse des différentes méthodes testées aux bruits. A cet effet, l'image hyperspectrale HI-3 utilisée dans l'étude 2 est considérée avec des puissances de bruit identiques de 15, 20, 25, et 30 dB. Les résultats de la troisième méthode multiplicative proposée sont identiques à l'étude 2. De plus, deux critères sont retenus : le SAM et le RMSE, pour les deux aspects spectral et spatial respectivement. Le tableau 4.10 donne les différentes valeurs du SAM en fonction du niveau de bruit. Les coefficients de régularisation $\lambda_{\bar{A}}$ et $\lambda_{\bar{B}}$ sont fixés à 0.5 pour cette expérimentation pour la méthode proposée.

SNR (dB)	Méthodes						
	MLMM	UP-NMF	IP-NMF	PLMM	ELMM	GLMM	Proposée
15	11.59	11.59	9.48	9.91	10.39	11.00	9.27
20	10.06	8.94	7.93	8.70	8.28	8.65	7.82
25	8.09	6.03	6.03	6.69	5.95	6.12	5.76
30	7.37	5.87	5.88	7.06	5.45	5.56	5.43

Tableau 4.10 : Résultats du SAM en fonction du bruit pour l'image HI-3.

Comme pour l'étude 2, nous observons que plus le niveau de bruit augmente plus les valeurs de SAM sont élevées, ce résultat est prévisible car toutes les méthodes ont plus de difficultés à estimer les spectres. De plus nous notons que pour toutes les configurations la méthode proposée est plus robuste au bruit.

Pour illustrer les résultats du tableau 4.10, la figure 4.15 décrit les courbes de variations des performances de chaque méthode en fonction du bruit. Premièrement, cette figure montre que toutes les méthodes dans leur ensemble améliorent les performances avec la réduction du bruit sur l'image. De plus, elle démontre clairement que pour des puissances de bruit significatives de 15 et 20 dB, l'IP-NMF et la méthode proposée permettent d'obtenir les valeurs les plus faibles et demeurent robustes aux fortes valeurs de bruit. En conclusion, pour toutes les configurations, la méthode proposée présente les valeurs de SAM les plus faibles montrant ainsi sa robustesse aux différents bruits considérés.

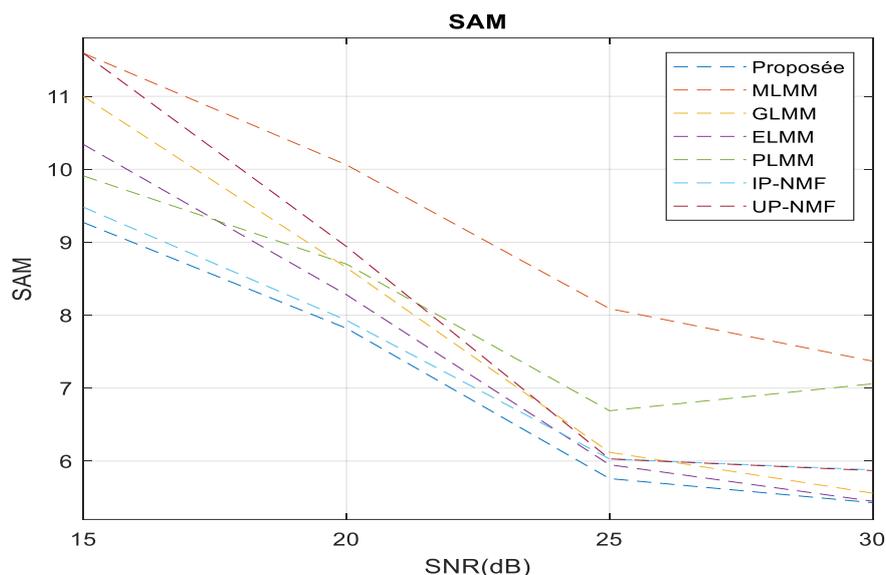


Figure 4.15 : Variation du SAM en fonction de la puissance du bruit pour l’image HI-3.

Le tableau 4.11 indique les valeurs du RMSE en fonction du bruit injecté dans l’image considérée. Nous observons aussi que plus le bruit augmente plus les valeurs de ce critère deviennent élevées. Comme pour l’aspect spectral, la troisième méthode proposée donne les meilleures performances en terme de qualité spatiale. Au vu des différents résultats de cette étude, la méthode proposée apparait la plus robuste sur les deux domaines spectral et spatial pour différentes configurations du bruit.

SNR (dB)	Méthodes						
	MLMM	UP-NMF	IP-NMF	PLMM	ELMM	GLMM	Proposée
15	0.122	0.116	0.116	0.51	0.089	0.104	0.082
20	0.112	0.101	0.101	0.50	0.088	0.091	0.082
25	0.112	0.089	0.089	0.50	0.097	0.084	0.081
30	0.086	0.068	0.068	0.49	0.086	0.066	0.063

Tableau 4.11 : Résultats du RMSE en fonction de la puissance du bruit pour l’image HI-3.

4.4.6. Etude 6 : Comparaison des performances avec les méthodes de la littérature sur une image réelle

Cette étude est consacrée aux tests de la méthode introduite et celles de la littérature sur données réelles (voir figure 4.5). Pour rappel, la vérité terrain n’est pas disponible pour l’image hyperspectrale réelle. Les critères utilisés portent sur la reconstruction de l’image, plus précisément ils sont calculés entre un pixel de l’image réelle et son homologue de l’image reconstruite estimée ainsi qu’une analyse visuelle des cartes d’abondance. L’image est constituée principalement de 4 matériaux : végétation, asphalte, toiture métallique et béton. A noter que les critères de reconstruction ne sont pas toujours fiables en terme d’indication car on peut estimer d’une mauvaise manière les spectres et les abondances et obtenir un bon produit des deux matrices.

Comme pour les données synthétiques, les paramètres des différentes méthodes sont fixés comme conseillé par les auteurs des différentes méthodes. Pour l’initialisation des spectres deux approches sont considérées :

- scénario (a) : une VCA en considérant le nombre exact de matériaux.
- scénario (b) : la procédure décrite dans l’étude 3 en considérant la méthode AEB et le spectre médian.

Pour les abondances, la SCLSU est appliquée pour : le PLMM, l’ELMM et le GLMM. Pour la méthode proposée, l’UP-NMF et l’IP-NMF, la FCLS est considérée en tenant compte de la structure particulière de la matrice des abondances. Les tests sont effectués sur un serveur de calcul scientifique car l’image est composée d’un nombre important de pixels impliquant une taille conséquente des matrices contenant les variables, en particulier pour l’UP-NMF, l’IP-NMF et la méthode proposée. Comme pour les données synthétiques, cette étude est divisée en deux parties bien distinctes. La première concerne les résultats obtenus pour les méthodes introduites dans cette thèse. La deuxième partie est consacrée à la comparaison de la meilleure méthode proposée en terme de performance avec les autres méthodes de la littérature. Le tableau 4.12 donne les résultats des méthodes proposées.

Méthodes de démixage proposées												
	Méthode 1				Méthode 2				Méthode 3			
	Multi		Gradient		Multi		Gradient		Multi		Gradient	
Scénario	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)
RMSE	0.0049	0.0062	0.0141	0.0062	0.0044	0.0033	0.0215	0.0119	0.0042	0.0009	0.0215	0.0119
SAM	1.32	1.37	1.82	0.90	1.18	0.99	3.39	2.33	1.13	0.06	3.39	2.33

Tableau 4.12 : Résultats des critères de performance sur les données réelles des méthodes introduites.

Comme pour les données synthétiques, la troisième méthode dans sa version multiplicative est meilleure en terme de performance. De plus, nous notons clairement que la méthode d’initialisation (b) est meilleure que (a).

Méthodes	MLMM		UP-NMF		IP-NMF		PLMM		ELMM		GLMM		Proposée	
Scénario	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)
RMSE	0.1803	0.1803	0.0223	0.016	0.0223	0.016	0.0052	0.0037	0.0033	0.0026	0.0005	0.0005	0.0042	0.0009
SAM	0.26	0.08	3.65	2.71	3.65	2.71	0.93	0.83	1.02	0.78	0.13	0.11	1.13	0.06

Tableau 4.13 : Résultats des critères de performance sur les données réelles.

D’après le tableau 4.13 contenant les résultats des différents critères de reconstruction obtenus par les méthodes testées, nous observons que le scénario (b) permet d’atteindre de meilleurs résultats pour toutes les méthodes de la littérature pour le RMSE ou le SAM. Ces résultats confirment ceux de l’étude 5 sur l’impact de l’initialisation sur les algorithmes de démixage. Pour le RMSE, le MLMM présente la valeur la plus élevée de l’étude. L’UP-NMF et l’IP-NMF améliorent cet aspect en obtenant des valeurs plus faibles par rapport au MLMM. Le PLMM mène à un gain significatif avec une valeur de 0.0037 pour le scénario (b). L’ELMM

gère mieux la variabilité spectrale que le PLMM. La méthode proposée et le GLMM atteignent les meilleures valeurs, en particulier pour le GLMM montrant ainsi que les deux méthodes gèrent mieux la reconstruction. Sur le plan de la reconstruction spectrale, l'UP-NMF et l'IP-NMF présentent les valeurs les plus élevées de SAM. L'ELMM et le PLMM gèrent mieux la reconstruction spectrale avec des valeurs nettement plus faibles de SAM. Le GLMM mène à des valeurs de SAM plus faibles montrant ainsi qu'il améliore les résultats du ELMM confirmant que la prise en compte de la variabilité bande par bande est plus efficace pour la reconstruction spectrale. Ce résultat est d'autant plus appuyé par le MLMM avec une valeur de SAM de 0.08. La méthode proposée présente la valeur de SAM la plus faible de 0.06 démontrant qu'elle gère mieux la reconstruction spectrale par rapport aux autres méthodes.

Pour valider ces résultats, les cartes d'abondance des 4 matériaux, pour chaque méthode testée dans le cas du scénario (b), sont illustrées sur la figure 4.16.

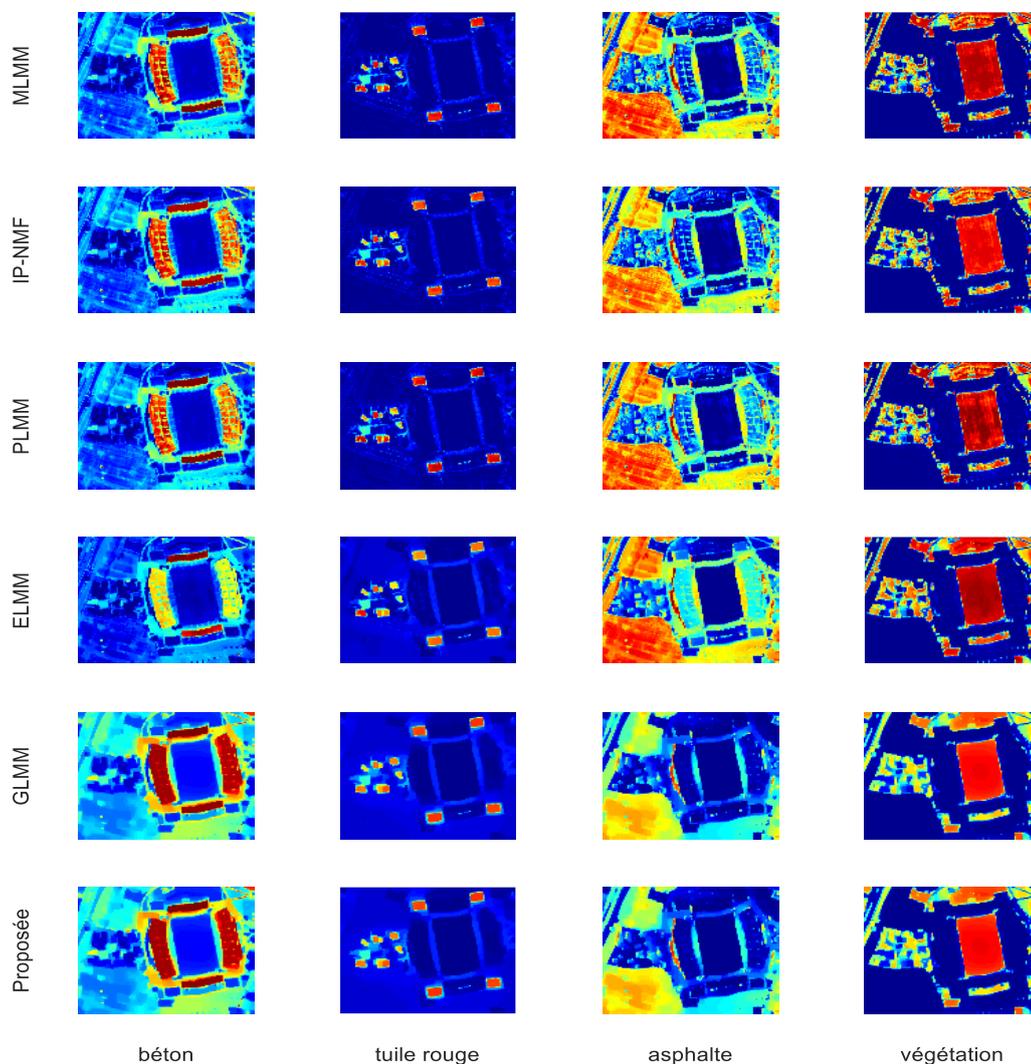


Figure 4.16 : Cartes d'abondance des différentes méthodes pour l'image réelle.

Nous observons globalement que les méthodes testées parviennent à détecter de manière satisfaisante les quatre matériaux. Cependant, nous remarquons au niveau des tribunes du stade la présence de pixels mixtes entre l'asphalte et le béton pour l'UP-NMF, l'IP-NMF, le PLMM et l'ELMM. Cet aspect est absent pour le GLMM et la méthode proposée, on note clairement que le stade est constitué seulement de béton. De plus, la méthode proposée et le GLMM estiment les spectres d'une meilleure manière, en particulier au niveau des lotissements proches du stade, par rapport aux autres méthodes pour lesquelles la tuile estimée est un mélange de tuile et d'asphalte.

4.5. Conclusion

Dans ce chapitre, une analyse comparative des différents tests des méthodes proposées dans le cadre de cette thèse et celles de la littérature récente prenant en compte la variabilité spectrale est présentée. Dans une première partie, les données synthétiques ainsi que la manière de les générer sont détaillées. De plus, l'image réelle considérée est introduite.

L'analyse a été divisée en plusieurs sections, la première étude a montré que la troisième méthode proposée dans sa version multiplicative obtient les meilleures performances parmi les méthodes introduites démontrant la consistance de tenir compte de la structure particulière de la matrice des spectres et les amplitudes de la variabilité spectrale en les pénalisant.

Ces résultats sont confirmés par l'étude de l'impact du bruit sur les différentes techniques pour laquelle la troisième méthode aboutit aux meilleurs résultats dans toutes les configurations. De plus, une étude sur l'impact de l'initialisation a démontré que considérer la variabilité spectrale, au niveau de l'initialisation, apporte un gain significatif sur la méthode proposée.

Au final, une étude incluant une image réelle a confirmé que la méthode proposée présente la meilleure reconstruction spectrale ainsi qu'une estimation satisfaisante des abondances comme montré par les cartes d'abondance obtenues.

Conclusion et perspectives

Cette partie de la thèse a été consacrée à la SAS appliquée au démixage spectral dans le cadre d'images de télédétection, en particulier celles hyperspectrales. Le premier objectif de ce travail de recherche a été de développer de nouvelles techniques et de les appliquer dans le cadre des images hyperspectrales présentant de la variabilité spectrale afin d'en extraire les spectres ainsi que les proportions des matériaux présents dans l'image hyperspectrale traitée.

Dans le premier chapitre de cette partie, la SAS a été présentée ainsi que le modèle de mélange linéaire. Par la suite, les différentes méthodes développées pour le traitement du démixage spectral ont été introduites. En particulier, le premier chapitre a exposé les limites du démixage spectral linéaire à savoir la non-linéarité et la variabilité spectrale. Une attention particulière a été portée à la variabilité spectrale constituant le sujet de cette thèse ainsi qu'aux causes de la variabilité spectrale à savoir les changements d'illumination, les conditions atmosphériques et la variabilité intrinsèque des matériaux. De plus, les méthodes traitant la variabilité spectrale ont été présentées en différentes catégories selon leurs principes de fonctionnement.

Dans le deuxième chapitre, une étude portant sur l'application d'une méthode de démixage d'images hyperspectrales à des fonds marins a été effectuée. L'IP-NMF a été appliquée pour estimer les spectres et les abondances dans le cas d'une colonne d'eau. En effet, ce second chapitre a permis de démontrer l'importance de la prise en considération de la variabilité spectrale dans le cas d'images hyperspectrales de fonds marins présentant une bathymétrie différente pour chaque pixel de l'image. Parmi les perspectives de cette étude, de nouvelles simulations d'images synthétiques pourront être considérées pour des profondeurs différentes non traitées dans cette thèse. L'autre extension de ce travail consiste à appliquer l'IP-NMF à des données réelles, en particulier des images hyperspectrales présentant des profondeurs différentes pour chaque pixel de l'image.

Dans le troisième chapitre, les trois méthodes de démixage spectral des images hyperspectrales de télédétection traitant la variabilité spectrale ont été introduites. Ces méthodes utilisent une approche paramétrique pour traiter la variabilité spectrale. En particulier, elle est traduite sous une forme additive en intégrant deux nouvelles variables par pixel dans le modèle linéaire étendu. De plus, chaque méthode considère une fonction de coût et utilise une FMN pour optimiser un critère bien défini. A cet effet, deux algorithmes sont introduits, à savoir, multiplicatif et à gradient projeté.

Le chapitre quatre a permis de réaliser une analyse comparative des différents tests des méthodes proposées dans le cadre de cette thèse et de celles de la littérature récente prenant en compte la variabilité spectrale. En effet, la première partie des tests a montré que la troisième méthode dans sa version multiplicative permet d'obtenir les meilleurs résultats.

La deuxième partie des résultats a été consacrée à l'étude des méthodes introduites, en particulier la troisième méthode dans le cadre de différentes configurations de variabilité spectrale. Sur l'ensemble des configurations relatives aux données synthétiques, la troisième méthode proposée mène aux meilleures performances comparées aux autres techniques de la littérature.

De plus, les résultats obtenus ont été confirmés par l'étude de l'impact du bruit sur les différentes techniques. En effet, la troisième méthode introduite aboutit aux meilleurs résultats dans n'importe quelle configuration de bruit. Par ailleurs, une étude de l'impact de l'initialisation a démontré que considérer la variabilité spectrale au niveau de l'initialisation apporte un gain significatif montrant ainsi l'utilité d'une initialisation adéquate.

La dernière étude considérant une image réelle a confirmé que la troisième méthode proposée présente la meilleure reconstruction spectrale ainsi qu'une estimation satisfaisante des abondances. Une des extensions envisagée est la pénalisation des abondances dans le cas où les images contiennent une certaine parcimonie dans les pixels traités en particulier dans le cas de données incluant un seul matériau dans certaines parties importantes de l'image. L'autre perspective concerne l'application de la troisième méthode à d'autres images hyperspectrales réelles pour mieux évaluer sa robustesse.

***PARTIE II : Fusion d'Images de Télédétection
Spatiale***

Introduction

Le développement continu des capteurs embarqués dans les satellites d'observation de la Terre permet une meilleure compréhension des différents phénomènes liés à notre environnement. En effet, ces capteurs passifs ou actifs délivrent une quantité considérable d'informations nécessaires à différentes applications. Les images issues de capteurs passifs entre autres ont pour but la distinction et la classification des objets présents dans une zone observée.

Les images obtenues par les capteurs passifs sont des images dites panchromatique, multispectrale et hyperspectrale. Ces trois types de données offrent chacune des caractéristiques différentes. En effet, une image panchromatique propose la meilleure résolution spatiale comparée aux deux autres, cependant elle ne délivre aucune information spectrale. L'imagerie multispectrale améliore cet aspect en proposant au maximum une dizaine de bandes au détriment d'une plus faible résolution spatiale. L'imagerie hyperspectrale présente la meilleure résolution spectrale avec des centaines de bandes spectrales, néanmoins la résolution spatiale est la plus faible des trois.

Les différentes applications dépendantes des images acquises des satellites d'observation de la Terre nécessitent à la fois une résolution spatiale fine pour distinguer les objets présents dans la zone couverte par les capteurs et une résolution spectrale de s aussi afin de mieux classifier et de connaître la nature des objets. Le processus, le plus naturel pour traiter cet aspect, est de combiner les différentes caractéristiques des trois types d'images afin d'obtenir une image possédant des résolutions spatiale et spectrale fines.

Dans un premier temps les techniques dites de pansharpening ont été développées. Elles consistent à fusionner des images panchromatiques et multispectrales/hyperspectrales afin de tirer profit de la richesse spatiale de la première et de la quantité d'informations spectrales de la deuxième. Le premier chapitre introduit le pansharpening. Les différentes méthodes déduites de cette approche sont classifiées selon leur principe de fonctionnement comme : les méthodes à substitution de composantes, l'analyse multirésolution, les méthodes variationnelles et les techniques basées sur la Factorisation en Matrices Non-négatives (FMN).

Avec la multiplication des capteurs hyperspectraux et multispectraux comme *Earth Observer 1* (EO-1) étant l'un des premiers satellites embarquant ces deux types de capteurs, à savoir, le *Advanced Land Imager* (ALI) pour la partie panchromatique/multispectrale et *Hyperion* pour l'aspect hyperspectral, différents algorithmes de multisharpening (appelés aussi algorithmes d'hypersharpener) ont été développés pour fusionner les images hyperspectrales avec les images multispectrales. Un état de l'art sur le multisharpening est présenté dans le premier chapitre.

Le processus de fusion est directement lié à plusieurs applications. Le but de la fusion est d'apporter un gain et une richesse supplémentaire aux images originales. Pour estimer cet apport ainsi que la fiabilité des différentes techniques, une évaluation de la qualité du produit fusionné s'impose. Actuellement, il existe deux grandes approches d'évaluation : l'approche basée sur l'analyse humaine et l'analyse quantitative. Ces deux approches se différencient par le fait que l'une est basée sur un opérateur et l'autre sur des métriques. La dernière partie du premier chapitre présente les généralités sur l'évaluation de la qualité.

Parmi les méthodes de multisharpening, plusieurs approches appliquent le démixage spectral linéaire et suivent la classe de techniques considérant la FMN. Ces méthodes estiment les spectres des matériaux purs présents dans l'image et les fractions d'abondance associées en réalisant un démixage spectral linéaire des données considérées. Cependant, dans certains cas en présence de certains phénomènes physiques, l'hypothèse qu'un matériau est représenté par une seule signature spectrale n'est pas toujours valide. Dans cette configuration, la variabilité spectrale doit être considérée.

Dans le deuxième chapitre, deux nouvelles méthodes de fusion sont introduites. Elles intègrent la variabilité spectrale dans le processus. La première utilise une approche de démixage spectral linéaire récente de la littérature traitant la variabilité spectrale : l'*Inertia-constrained Pixel-by-Pixel NMF* (IP-NMF) et nommée *Hyperspectral and Multispectral data Fusion based on IP-NMF* (HMF-IPNMF). La deuxième méthode représente une extension de la méthode de fusion *Joint-Criterion NMF* (JCNMF) multiplicative. Cette extension modifie le modèle mathématique de la JCNMF pour intégrer la variabilité spectrale. L'aspect théorique et les algorithmes de fusion sont détaillés dans ce chapitre.

Le troisième chapitre est dédié aux tests réalisés et les résultats obtenus sur données synthétiques et réelles. A cet effet les deux méthodes sont comparées à celles de fusion récentes de la littérature. Les différents tests sont appliqués à des données synthétiques et réelles avec présence de la variabilité spectrale. Les résultats basés sur des critères de performances spécifiquement dédiés aux deux types de données sont analysés.

*Chapitre 1 : État de l'Art en Fusion d'Images
de Télédétection Spatiale.*

Chapitre 1

Etat de l'art en fusion d'images de télédétection spatiale

1.1. Introduction

Ce chapitre est consacré à la présentation de l'état de l'art sur la fusion des images de télédétection issues de plusieurs capteurs différents : panchromatique, multispectral et hyperspectral.

Dans un premier temps, les hypothèses nécessaires pour l'utilisation des méthodes de la littérature et celles développées dans cette thèse sont détaillées ainsi que les corrections géométriques comme prétraitement afin d'appliquer la fusion d'images.

Dans une deuxième partie, les techniques de pansharpening qui consistent à fusionner des images panchromatiques et multispectrales/hyperspectrales sont introduites selon différentes classes de méthodes d'après les principes généraux ainsi que le mode de fonctionnement des approches citées. Les classes des approches traitées dans cette partie sont : les méthodes à substitution de composantes, l'analyse multirésolution, les méthodes variationnelles et les techniques basées sur la factorisation en matrices non-négatives.

La troisième partie est dédiée à l'état de l'art des algorithmes de multisharpening (appelés aussi algorithmes d'hypersharpener). En effet, ceux-ci ont été récemment introduits avec l'avènement d'un grand nombre de capteurs hyperspectraux. Parmi les méthodes réalisant le multisharpening, on peut citer celles utilisant l'approche bayésienne et celles basées sur l'analyse en composantes parcimonieuses. Il est à noter que les méthodes proposées dans cette thèse traitent cet aspect pour fusionner des images multispectrales et hyperspectrales en tenant compte du phénomène de la variabilité spectrale étudié dans la première partie de cette thèse.

Enfin, la dernière partie présente l'évaluation de la qualité du produit fusionné. A cet effet, il existe deux grandes écoles : une basée sur l'analyse humaine et l'autre sur l'analyse quantitative. Ces deux approches se différencient par le fait que l'une nécessite un opérateur humain et l'autre utilise des métriques.

1.2. Hypothèses

La plupart des méthodes de fusion d'images de télédétection admettent pour hypothèse de base que les images acquises par les deux capteurs couvrent la même scène dans le même intervalle de temps. Un écart entre le temps d'acquisition des deux images peut en effet entraîner des dissimilarités comme le changement de l'éclairage ou des paysages [28]. De plus,

des distorsions peuvent généralement apparaître, induites par les conditions atmosphériques et la réponse du capteur. Différentes étapes de prétraitement deviennent alors nécessaires, de l'ordre radiométrique ou géométrique [28]. L'autre point fondamental dans le processus de fusion est l'unité de mesure. Ainsi, les images doivent présenter la même unité physique, par exemple la réflectance ou la luminance [28].

1.3. Méthodes de Pansharpening

Le terme pansharpening [131] se réfère à la fusion des images panchromatiques et multispectrales/hyperspectrales. L'objectif est d'obtenir un produit de fusion qui intègre l'information spatiale substantielle de l'image panchromatique à l'information spectrale très fournie présente dans l'image multispectrale/hyperspectrale (comme mentionné précédemment une image hyperspectrale contient plus d'information spectrale). Ces dernières années, les techniques de pansharpening ont connu un développement considérable avec la disponibilité croissante des images de télédétection.

Avant d'entamer la description des méthodes de pansharpening, une notion fondamentale doit être tenue en compte. Elle est considérée comme un prétraitement nécessaire afin d'appliquer lesdites méthodes. En effet, les images multispectrale/hyperspectrale n'ont pas la même résolution spatiale que l'image panchromatique. Dans ce but, différentes techniques d'interpolation peuvent être utilisées comme la technique du plus proche voisin (*Nearest Neighbor*), l'interpolation bilinéaire (*Bilinear Interpolation*) ou l'interpolation cubique (*Cubic Convolution*), chaque méthode offrant des avantages et des inconvénients. Par exemple, le plus proche voisin donne les mêmes valeurs en sortie que les valeurs d'entrée et s'avère simple à implémenter. Son inconvénient réside dans le fait que certaines valeurs peuvent être dupliquées. Les interpolations bilinéaire et cubique réduisent l'effet d'escalier sur les images traitées, cependant les deux diminuent le contraste dans l'image et sont plus coûteuses en terme de temps de calcul [132].

Une étude comparative des différentes méthodes d'interpolation pour déterminer les plus adaptées dans le cadre de la télédétection est menée dans [133]. Une autre technique répandue dans la fusion d'images est la méthode 23-tap qui est basée sur un filtre passe bas [134].

Cette partie présente les différents algorithmes de pansharpening [131].

1.3.1. Méthodes à substitution de composantes

L'idée de base de cette classe de méthodes est de projeter l'image multispectrale/hyperspectrale dans un nouvel espace afin de séparer l'information spectrale de l'information spatiale. Cette séparation a pour but de remplacer l'information spatiale de l'image multispectrale/hyperspectrale par l'image panchromatique qui est plus riche en terme d'information spatiale. Cette partie est consacrée aux principales méthodes fondées sur cette approche.

Transformation Intensity Hue Saturation (IHS)

La transformée IHS (*Intensity Hue Saturation*) permet de projeter les différentes bandes qui constituent une image multispectrale, trois bandes dans le cas de l'IHS, dans un nouvel espace colorimétrique. Dans cette procédure, les informations spatiales et spectrales contenues dans

une image sont séparées. La transformation IHS contribue à l'amélioration des détails (l'information spatiale) présents dans l'image multispectrale et de la résolution spatiale des produits fusionnés. L'IHS change l'espace colorimétrique de l'image multispectrale traitée afin de séparer l'information spectrale de l'information spatiale [132]. La figure 1.1 illustre comment appliquer l'IHS.

L'information spatiale obtenue après conversion est décrite par le canal I (Intensity) et l'information spectrale est stockée dans les deux canaux H (Hue) et S (Saturation) contrairement à l'espace RGB. Un des avantages de l'espace IHS par rapport aux autres espaces colorimétriques est la possibilité d'intégrer des informations pertinentes avec un faible coût en termes de puissance de calcul et de simplicité d'implémentation [135].

L'un des problèmes majeurs rencontré par la transformée IHS reste la divergence spectrale entre l'image panchromatique et les différentes bandes composant les images à hautes résolutions spectrales qui engendre une détérioration du contenu spectral (colorimétrique) de l'image fusionnée [132]. L'une des solutions adoptées pour résoudre le problème de la distorsion spectrale est la prise en compte de la réponse spectrale du capteur utilisé pour l'acquisition des images à fusionner.

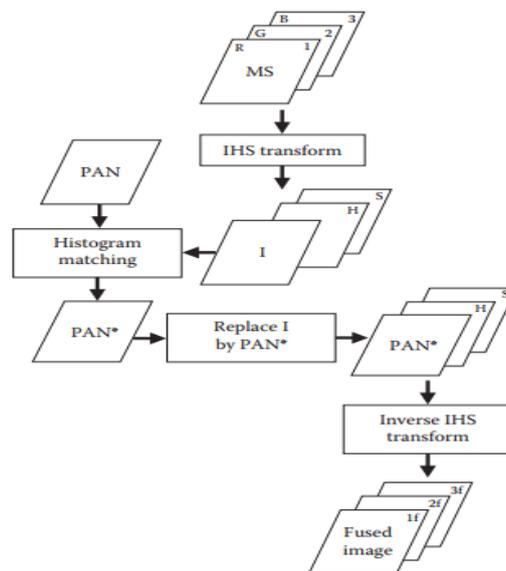


Figure 1.1 : Application de l'IHS [132].

Une autre technique employée est la *Fast IHS* ; elle s'applique généralement pour traiter un grand nombre d'informations de manière rapide et simple [136].

Un des inconvénients de la transformée IHS reste sa limitation en nombre de bandes d'entrée égal à trois. Pour remédier à cette lacune, la transformée IHS généralisée (GIHS) est considérée pour introduire un nombre plus conséquent de bandes d'entrée [137]. Récemment, une méthode basée sur la GIHS a été introduite dans le cadre de la fusion de zones comportant de la végétation [138].

Analyse en composante principale (ACP)

L'idée de base est d'appliquer une PCA (*Principal Component Analysis*) connue aussi sous le nom de transformation de *Karhunen-Loève* sur l'image multispectrale/hyperspectrale [139], la première composante principale étant remplacée par l'image panchromatique. En effet, cette

composante contient la majeure partie de l'information commune entre les bandes, c'est-à-dire l'information spatiale. Par la suite, une transformée PCA inverse est appliquée à l'image fusionnée pour la projeter dans l'espace d'origine de l'image multispectrale/hyperspectrale. La figure 1.2 montre la méthode de fusion basée sur la PCA [132].

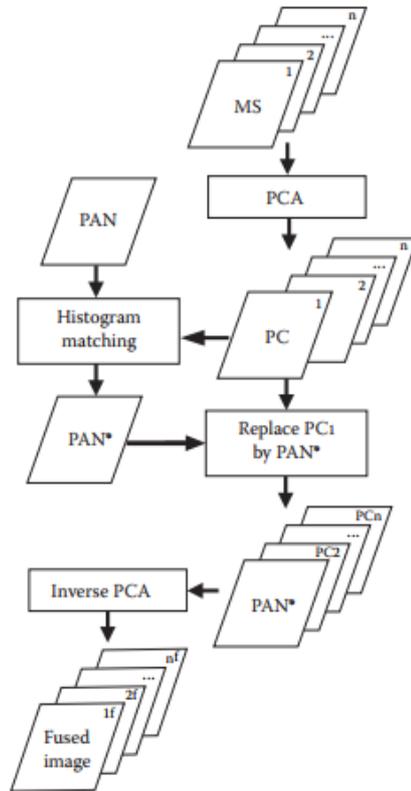


Figure 1.2: Fusion basée sur la transformée PCA [132].

L'intérêt de la PCA est la réduction de la redondance de l'information entre les différentes bandes; les bandes utilisées pour la fusion correspondent aux composantes principales dont les valeurs propres sont les plus grandes. En effet, la première composante principale comporte l'information commune à l'ensemble des bandes de l'image multispectrale/hyperspectrale. Cette propriété permet de réduire la redondance contenue dans une image. L'autre avantage de la PCA par rapport à l'IHS est la possibilité de traiter des images comportant plus de trois bandes.

Cependant, une des limites de la PCA est due aux différences radiométriques entre l'image panchromatique et la première composante, qui peuvent induire une perte d'information lors de la transformation inverse. Cette différence est généralement causée par la corrélation limitée entre les images panchromatiques et multispectrales/hyperspectrales, en effet le spectre de l'image panchromatique ne couvre pas toutes les bandes de l'image multispectrale/hyperspectrale. Pour surmonter cette difficulté et améliorer l'efficacité de la PCA, une variante a été développée : la PCA spatiale [140], qui consiste à diviser l'image en plusieurs parties et puis utiliser la PCA pour chacune d'elles.

Transformée Gram-Schmidt (GS)

Cette technique [132] est basée sur la transformée de *Gram-Schmidt* (GS) qui permet de construire une base orthonormée à partir d'un ensemble de vecteurs. Dans le cadre de la fusion

d'images, ces vecteurs sont les bandes des images traitées. Premièrement, une image panchromatique est synthétisée à partir de l'image multispectrale/hyperspectrale considérée. Par la suite, cette version synthétisée est ajoutée comme étant la première bande de l'image multispectrale/hyperspectrale (voir figure 1.3). Une transformée GS est considérée par la suite. L'image panchromatique remplace la première bande de l'image obtenue après transformation. L'étape finale consiste à appliquer une transformation GS inverse.

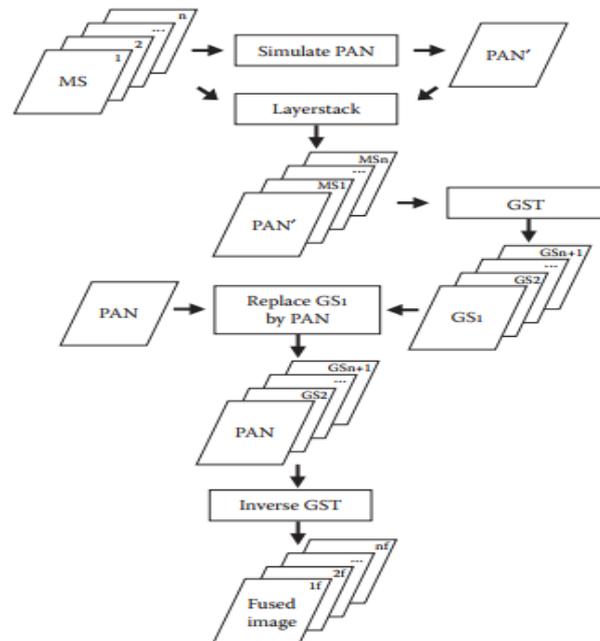


Figure 1.3: Méthode de fusion basée sur la transformation de GS [132].

Différentes techniques permettent de synthétiser l'image panchromatique à faible résolution. La première consiste à moyenner les bandes multispectrales, la deuxième applique un filtre passe bas et la dernière génère l'image synthétique en considérant la moyenne pondérée des bandes de l'image multispectrale/hyperspectrale avec des poids estimés par la minimisation de l'erreur quadratique moyenne. Récemment, une approche a considéré la matrice de covariance de l'image multispectrale/hyperspectrale pour créer une image synthétique [132].

1.3.2. Analyse multirésolution

Les techniques de fusion utilisant les hautes fréquences de l'image panchromatique, en les injectant dans l'image multispectrale/hyperspectrale, sont largement répandues. Les hautes fréquences sont extraites de la différence entre l'image panchromatique et sa version filtrée avec un filtre passe-bas. Ces différentes méthodes ont montré leur robustesse surtout dans le cas de la préservation de l'information spectrale. Dans la littérature, une autre appellation existe : Amélioration de la Résolution Spatiale par Injection de Structures (ARSIS) [142]. Différents algorithmes adoptant cette approche sont présentés dans cette partie.

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

La SFIM permet de mieux préserver l'information spectrale tout en améliorant les informations spatiales en comparaison avec d'autres techniques comme l'IHS [143]. La SFIM

correspond à une extension de la PBIM (*Pixel Block Intensity Modulation*) [144]. Elle module une image à haute résolution spatiale avec une image à faible résolution spatiale en considérant un bloc de pixels.

La SFIM applique une modulation entre l'image panchromatique et l'image panchromatique filtrée pour moduler l'image multispectrale/hyperspectrale à basse résolution. Elle est définie par :

$$IMAGE_{SFIM} = \frac{IMAGE_{LOW}IMAGE_{HIGH}}{IMAGE_{MEAN}}, \quad (1.1)$$

où $IMAGE_{LOW}$ représente l'image à faible résolution spatiale après ré-échantillonnage à la même résolution que l'image à haute résolution spatiale, $IMAGE_{HIGH}$ l'image à haute résolution spatiale et $IMAGE_{MEAN}$ désigne l'image moyennée à partir de $IMAGE_{HIGH}$ par un filtre considérant les pixels voisins. Les pixels voisins sont moyennés en appliquant un filtre dont le noyau dépend du rapport entre la résolution spatiale de l'image panchromatique et la résolution spatiale de l'image multispectrale/hyperspectrale.

Pour améliorer l'efficacité de la SFIM, une interpolation non linéaire est utilisée au lieu de l'interpolation bi-cubique lors du ré-échantillonnage de l'image multispectrale/hyperspectrale. Ce processus est nommé indusion [145]. L'intérêt est d'augmenter le nombre de détails injectés dans l'image et de réduire également les artefacts introduits dans l'image multispectrale/hyperspectrale par les interpolations linéaires comme le flou [145].

Transformation en ondelettes et variantes

La transformée en ondelettes transforme un certain nombre d'images en de nouvelles images, chacune d'elles présentant une résolution plus basse que la précédente. Cette démarche permet de séparer l'information spatiale entre deux images successives [146]. Les coefficients de la transformée en ondelettes décrivent la variation locale au niveau d'un pixel et ses voisins.

Le coefficient de l'ondelette est calculé pour chaque échelle et une localisation donnée. Il mesure la quantité de détails inclus pour cette position : en d'autre terme plus le coefficient est élevé, plus le nombre de détails est significatif. L'algorithme de la transformée en ondelettes est décrit dans la figure 1.4.

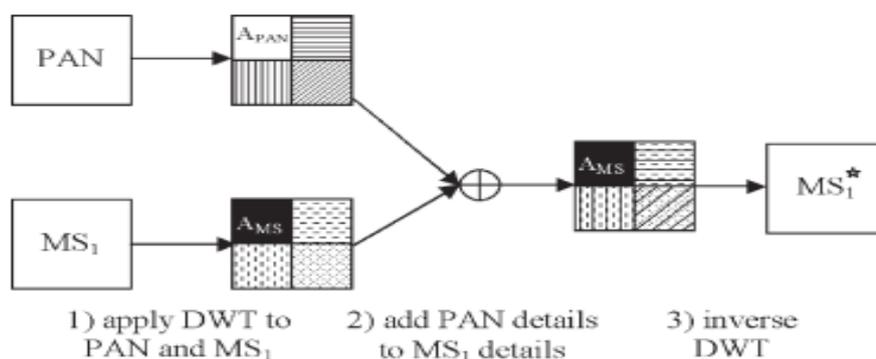


Figure 1.4: Algorithme de la fusion des images basé sur la transformée en ondelettes [147].

La transformée en ondelettes peut être appliquée en utilisant deux approches :

- l'algorithme de Mallat,

- l'algorithme à trous.

L'algorithme de Mallat est modélisé sous la forme d'une pyramide dont la base représente l'image originale et les différents niveaux décrivent les différentes approximations. Chacune d'elles correspond à un nombre de colonnes et de lignes qui est deux fois inférieur à celui de l'image précédente justifiant la schématisation sous forme pyramidale. Contrairement à l'algorithme de Mallat, l'algorithme à trous préserve le nombre de colonnes et de lignes. La meilleure représentation de l'algorithme à trous est sous forme d'un parallélépipède. Malgré les nombreux avantages de la transformée en ondelettes, l'inconvénient majeur de cette technique réside dans sa complexité en terme de calcul nécessitant l'utilisation de moyens conséquents [147].

Pour améliorer la qualité spatiale des images, une nouvelle approche multirésolution a été développée en utilisant la transformée en curvelettes. Elle est basée sur la transformée en ridgelettes correspondant à une transformée en ondelettes dans l'espace de Radon qui transforme des droites en points. Elle représente les contours d'une manière plus adéquate qui a pour effet l'amélioration de manière directe de la qualité spatiale. Ce gain est dû aux hautes fréquences qui décrivent les contours de l'image [148]. L'inconvénient majeur de la transformée en ridgelettes est l'impossibilité de représenter les formes curvilignes dans une image [149].

Pour surmonter cette difficulté, la transformée en ridgelettes est appliquée sur des blocs. Elle consiste à diviser l'image d'entrée en blocs carrés et à considérer une transformée en ridgelettes pour chaque bloc. L'idée de base de cette technique est de traiter localement les contours en utilisant des tailles de blocs très petites pour réduire l'impact des formes [150].

Une autre transformée est considérée dans l'approche multirésolution : la transformée en contourlettes qui peut être vue comme une transformée en curvelettes à la différence qu'elle utilise une pyramide laplacienne pour l'aspect multirésolution.

L'un des intérêts de la transformée en contourlettes par rapport à la transformée en ondelettes est de traiter les bords lisses de manière plus efficace. En effet, la transformée en ondelettes peut détecter les points de discontinuités dans l'image, cependant les contours lisses sont plus complexes à repérer surtout dans le cas d'une résolution fine [151].

Pyramide laplacienne

Cette catégorie de méthodes est basée sur la décomposition de la pyramide laplacienne [152]. En effet, la décomposition pyramidale est réalisée en appliquant un filtre gaussien pour obtenir une version filtrée de l'image panchromatique. La différence entre les différents niveaux (voir figure 1.5) de la pyramide est appelé le laplacien. L'information spatiale récupérée par le filtrage de l'image panchromatique est ajoutée à l'image multispectrale/hyperspectrale. Le filtre gaussien peut être ajusté à la fonction de transfert de modulation ou *Modulation Transfer Function* (MTF) [131] pour intégrer l'information spatiale présente dans l'image panchromatique. Les différentes méthodes qui intègrent la MTF sont : *MTF Generalized Laplacian Pyramid* (MTF GLP) ainsi que son extension *MTF GLP with High Pass Modulation* (MTF GLP HPM) [153].

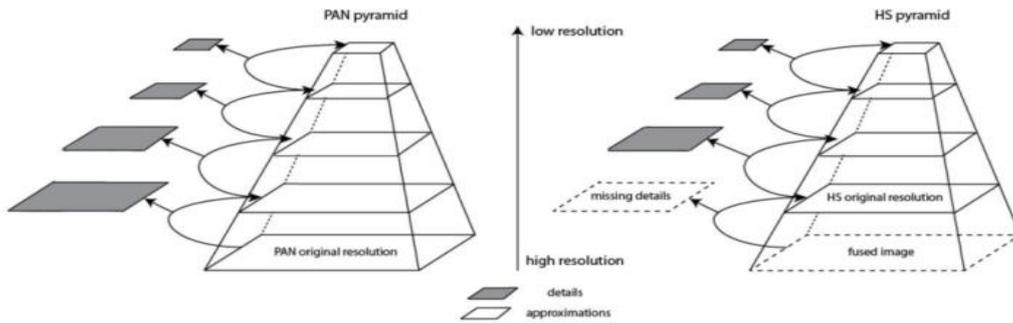


Figure 1.5: Décomposition pyramidale [154].

1.3.3. Méthodes variationnelles

Cette classe de méthodes peut être considérée similaire à l'approche de substitution de composantes. Cependant à la place de la substitution, une modulation est utilisée. Cette modulation est effectuée en multipliant chaque bande de l'image multispectrale/hyperspectrale avec l'image panchromatique, le résultat est divisé par la somme des bandes multispectrale/hyperspectrale.

Transformée de Brovey et Color Normalized

La transformée de Brovey [155] est une technique de fusion simple à mettre en œuvre. Elle est basée sur des opérations arithmétiques pour normaliser les bandes de l'image multispectrale/hyperspectrale d'entrée. La transformée de Brovey préserve la contribution spectrale de chaque pixel.

La transformée de Brovey reste limitée à trois bandes. Après l'application d'une normalisation, elle multiplie chaque pixel de l'image multispectrale/hyperspectrale à faible résolution spatiale avec chaque pixel de l'image panchromatique à haute résolution spatiale (PAN). L'ensemble est divisé par la somme des bandes multispectrales/hyperspectrales utilisées lors du processus de fusion [132].

La transformée de Brovey a été introduite à l'origine pour améliorer le contraste de l'image. Cependant dans cette technique, la moyenne et la dynamique ne sont pas ajustées. Cet aspect introduit des distorsions radiométrique et spectrale. La transformée "Color Normalized" est une généralisation de la transformée de Brovey pour un nombre de bandes d'entrée supérieur à trois bandes [132].

Méthode P + XS

La méthode P+XS a été développée pour améliorer la résolution spatiale des images multispectrales du satellite SPOT (XS) en intégrant l'image panchromatique (P). L'hypothèse de base est la corrélation entre les deux images, c'est-à-dire chaque bande de l'image fusionnée représente une combinaison linéaire des bandes spectrales de l'image multispectrale [156].

Pour plus de détails concernant les méthodes de pansharpening, des articles de synthèse sont présentés dans [1] et [157-159].

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

Récemment, différentes techniques ont utilisé le démixage spectral linéaire (*Linear Spectral Unmixing* (LSU)), voir le premier chapitre de la première partie de la thèse, pour réaliser du pansharpening. Plus précisément dans [160], les auteurs appliquent une approche basée sur la factorisation en matrices non-négatives (NMF) en considérant les règles de mise à jour multiplicatives (voir le premier chapitre de la première partie), nommée ExNMF pour (*Extended NMF*), afin d'estimer les spectres \tilde{S}_m et les abondances \tilde{A}_m de l'image multispectrale X_m , les abondances \tilde{A}_p et les spectres panchromatique \tilde{S}_p de l'image panchromatique X_p en optimisant la fonction de coût suivante :

$$\frac{1}{2} \|X_m - \tilde{A}_m \tilde{S}_m\|_F^2 + \frac{1}{2} \|X_p - \tilde{A}_p \tilde{S}_p\|_F^2, \quad (1.2)$$

Par la suite les abondances panchromatiques \tilde{A}_p sont fusionnées avec les spectres \tilde{S}_m . L'inconvénient majeur de l'ExNMF est qu'elle ne tient pas compte de la dégradation spatiale qui existe entre les abondances \tilde{A}_m de l'image multispectrale et les abondances \tilde{A}_p de l'image panchromatique. Pour remédier à cet aspect, une nouvelle fonction est introduite dans la nouvelle variante MJNMF (*Multiplicative Joint NMF*) [161] pour intégrer cette dégradation, plus précisément les abondances \tilde{A}_m sont formulées suivant :

$$\tilde{A}_m = \tilde{A}_p D \quad (1.3)$$

où D représente l'opérateur qui applique la dégradation spatiale.

Comme l'ExNMF, la MJNMF utilise les règles de mise à jour pour retrouver les abondances \tilde{A}_p et les spectres \tilde{S}_m afin de combiner les deux et d'obtenir le produit de fusion.

1.4. Méthodes de Multisharpning (Hypersharpning)

Avec le développement de l'instrumentation ces dernières décennies, le nombre de capteurs hyperspectraux a fortement augmenté. Une image hyperspectrale (HS) est issue d'un capteur qui est au minimum sensible à une centaine de bandes spectrales. Les images hyperspectrales contiennent une grande variété spectrale et une quantité d'informations spectrales considérable. La contrepartie de cette richesse spectrale est la faible résolution spatiale de ces images.

Au cours de ces dernières années, de nombreuses applications ont nécessité une haute résolution spectrale et spatiale d'où l'apparition des techniques de fusion des images multispectrales et hyperspectrales, ce processus est appelé multisharpning ou hypersharpning [162-163]. Il permet d'obtenir une identification de qualité et une classification précise des images observées.

Les premières techniques utilisées pour fusionner les images HS et multispectrales se basent sur les techniques citées précédemment dans la catégorie pansharpning comme multirésolution [164] et projection-substitution.

L'une des approches élaborées sur le schéma multirésolution consiste à réaliser une transformée en ondelettes à trois dimensions. L'application de cette dernière en 3D est réalisable car les points constituant les images hyperspectrales et multispectrales sont caractérisés par deux coordonnées spatiales représentant la localisation du pixel dans l'image et la dernière coordonnée décrivant le contenu spectral de l'image [165].

Pour obtenir un résultat en 3D, une transformée en ondelettes à 1D est appliquée au contenu spectral et une transformée en ondelettes à 2D est réalisée au niveau spatial. Les résultats de ces techniques sont directement liés au modèle d'injection des hautes fréquences (section 1.3.2).

L'une des méthodes utilisées pour réaliser l'hypersharping est fondée sur les méthodes projection-substitution comme par exemple la PCA. Typiquement la PCA est appliquée dans le cas présent pour réaliser la réduction de la dimensionnalité. Cette approche est intéressante car l'image hyperspectrale contient de nombreuses redondances [166].

Dans cette partie, les différentes méthodes de multisharping/hypersharping sont détaillées selon leur principe de fonctionnement.

1.4.1. Les méthodes bayésiennes

L'une des premières classes de méthodes traitant le multisharping repose sur les méthodes statistiques. La première technique développée en ce sens considère l'estimateur maximum a posteriori (MAP) [167]. Cette méthode initialement appliquée pour fusionner une image hyperspectrale et une image panchromatique peut être étendue pour fusionner une image hyperspectrale avec une image multispectrale. Elle apparaît adaptée dans le cas de présence de corrélation entre les images à fusionner. D'autres exemples existent dans la littérature basés sur l'approche statistique comme *Fast Fusion based on Sylvester Equation* (FUSE) [168]. Les résultats obtenus à l'aide des méthodes statistiques sont directement liés aux paramètres d'entrée comme dans le cas de FUSE où la *Spectral Response Function* (SRF) et la *Point Spread Function* (PSF) sont connues au préalable.

Une méthode a été introduite récemment qui suit l'approche bayésienne, cette technique nommée HySure pour *Hyperspectral Superresolution* [169]. Un des avantages de cet algorithme est son fonctionnement en aveugle, en effet les paramètres d'entrée comme la SRF sont estimés de manière complètement aveugle [169].

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

Ces dernières années, plusieurs techniques considérant le démixage linéaire ont été utilisées dans le processus de fusion. Plus précisément, ces méthodes sont fondées sur la factorisation en matrices non-négatives (NMF) présentée dans la première partie de la thèse. L'idée de base est d'appliquer une NMF à l'image hyperspectrale pour retrouver les spectres qui représentent l'information spectrale et à l'image multispectrale pour estimer les abondances (l'information spatiale). L'estimation peut être réalisée de manière alternée entre les images multispectrale et hyperspectrale ou conjointement. Dans l'étape suivante, les spectres et abondances estimés sont fusionnés pour obtenir une image hyperspectrale à haute résolution spatiale.

Dans la suite de la thèse, la notation suivante est adoptée pour décrire les images hyperspectrale et multispectrale :

$$X_h = A_h S_h, \quad (1.4)$$

$$X_m = A_m S_m, \quad (1.5)$$

où $X_h \in R_+^{P_h \times L_h}$ représente l'image hyperspectrale et $X_m \in R_+^{P_m \times L_m}$ l'image multispectrale. L_h (L_m) indique le nombre de bandes spectrales de l'image hyperspectrale (l'image multispectrale). P_h (P_m) représente le nombre de pixels de l'image hyperspectrale (l'image multispectrale). Les matrices $A_h \in R_+^{P_h \times M}$ et $A_m \in R_+^{P_m \times M}$ correspondent respectivement aux fractions d'abondance issues des images hyperspectrale et multispectrale. $S_h \in R_+^{M \times L_h}$ et $S_m \in R_+^{M \times L_m}$ sont respectivement les matrices des spectres d'endmembers hyperspectraux et multispectraux.

Coupled Non-negative Matrix Factorization (CNMF)

La CNMF [170] applique un démixage spectral (via une NMF) alterné et itératif entre l'image hyperspectrale et multispectrale afin d'estimer les spectres et les abondances des deux images. A cet effet, la CNMF utilise deux boucles, la première dite externe représente le nombre de fois où le démixage est appliqué de façon alternée entre l'image hyperspectrale et multispectrale [170]. La boucle interne correspond au nombre d'itérations de la NMF sur l'image hyperspectrale ou multispectrale.

Dans une première étape, la CNMF (voir figure 1.6) applique une NMF sur l'image X_h pour estimer les spectres \tilde{S}_h . L'initialisation de \tilde{S}_h est donnée par la VCA (voir partie 1 du manuscrit), une fois le nombre de matériaux M fixé. Chaque coefficient de la matrice des abondances \tilde{A}_h est initialisé par $1/M$.

Dans l'étape suivante, les matrices \tilde{S}_h et \tilde{A}_h sont mises à jour en utilisant les règles multiplicatives données par les relations :

$$\tilde{A}_h \leftarrow \tilde{A}_h \odot (X_h \tilde{S}_h^T) \oslash (\tilde{A}_h \tilde{S}_h \tilde{S}_h^T), \quad (1.6)$$

$$\tilde{S}_h \leftarrow \tilde{S}_h \odot (\tilde{A}_h^T X_h) \oslash (\tilde{A}_h^T \tilde{A}_h \tilde{S}_h), \quad (1.7)$$

$$\tilde{A}_m \leftarrow \tilde{A}_m \odot (X_m \tilde{S}_m^T) \oslash (\tilde{A}_m \tilde{S}_m \tilde{S}_m^T), \quad (1.8)$$

$$\tilde{S}_m \leftarrow \tilde{S}_m \odot (\tilde{A}_m^T X_m) \oslash (\tilde{A}_m^T \tilde{A}_m \tilde{S}_m). \quad (1.9)$$

où \odot représente la multiplication matricielle élément par élément et \oslash la division matricielle élément par élément.

Dans la deuxième étape (première itération de la boucle interne), la CNMF met à jour les matrices des abondances multispectrales \tilde{A}_m et des spectres multispectraux \tilde{S}_m . La matrice des spectres \tilde{S}_m est initialisée en dégradant spectralement la matrice \tilde{S}_h via la SRF du capteur

multispectral. Chaque coefficient de la matrice \tilde{A}_m est initialisé en tant que valeur constante $1/M$. Les deux matrices sont optimisées par (1.8) et (1.9).

Dans la troisième étape, la CNMF met à jour \tilde{S}_h et \tilde{A}_h en utilisant les équations (1.6) et (1.8). \tilde{A}_h est initialisée dans cette étape en appliquant une PSF gaussienne aux abondances \tilde{A}_m . Les étapes deux et trois sont répétées jusqu'à la convergence ou bien après avoir atteint le nombre maximal permis d'itérations de la boucle externe.

L'image issue de la fusion $X_f \in R_+^{P_m \times L_h}$ à haute résolution spatiale est obtenue en multipliant \tilde{A}_m par \tilde{S}_h :

$$X_f = \tilde{A}_m \tilde{S}_h. \quad (1.10)$$

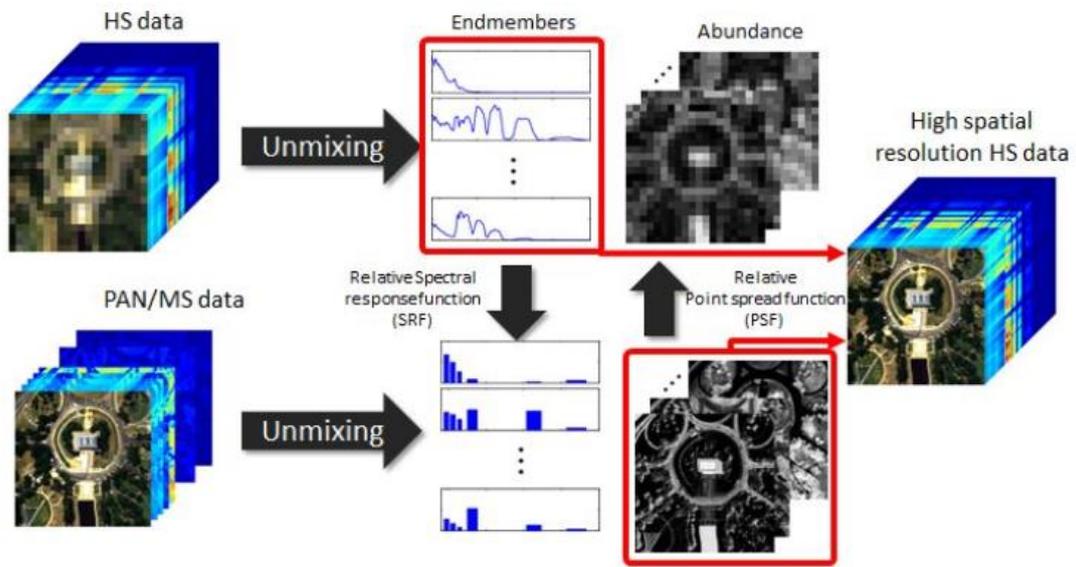


Figure 1.6: Fonctionnement de la CNMF [13].

Joint Non-negative Matrix Factorization (JNMF)

La JNMF [171] utilise comme la CNMF une NMF pour démêler X_h et X_m , cependant la JNMF démêle de façon simultanée ou conjointe contrairement à la CNMF. A cet effet, elle optimise la fonction de coût suivante :

$$\frac{1}{2} \|X_h - \tilde{A}_h \tilde{S}_h\|_F^2 + \frac{1}{2} \|X_m - \tilde{A}_m \tilde{S}_m\|_F^2. \quad (1.11)$$

Pour la phase d'optimisation, la JNMF considère les règles de mise à jour multiplicatives en ajoutant deux règles :

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

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

où \tilde{A}_{dm} et \tilde{A}_{uh} représentent respectivement la version sous-échantillonnée de \tilde{A}_m et celle sur-échantillonnée de \tilde{A}_h , α étant une valeur permettant de mettre à jour \tilde{A}_h et \tilde{A}_m de manière cohérente.

Comme initialisation, la JNMF considère SISAL (voir partie 1 de la thèse) pour \tilde{S}_h et la FCLS (voir partie 1 de ce manuscrit) pour \tilde{A}_h . La matrice des spectres \tilde{S}_m est initialisée en moyennant les échantillons de \tilde{S}_h sur les régions de longueurs d'onde utilisées dans l'image multispectrale. La matrice \tilde{A}_m des abondances multispectrales est déduite de \tilde{A}_h par sur-échantillonnage.

Pour l'optimisation des matrices \tilde{A}_h , \tilde{S}_h , \tilde{A}_m et \tilde{S}_m , les règles de (1.6) à (1.9) sont conjointement appliquées. Le critère de convergence d'arrêt adopté est le nombre d'itérations maximal. L'image fusionnée est obtenue suivant (1.10). L'avantage de la JNMF est sa rapidité de mise en œuvre par rapport à la CNMF tout en offrant de bonnes performances.

Une extension de la JNMF nommée *Joint-Criterion Nonnegative Matrix Factorization* (JCNMF) ajoute à la fonction de coût (1.11) un terme limitant la distance entre les abondances multispectrales et hyperspectrales [172]. La nouvelle fonction de coût s'écrit de la manière suivante :

$$J = \frac{\alpha}{2} \|X_h - \tilde{S}_h \tilde{A}_h\|_F^2 + \frac{\beta}{2} \|X_m - \tilde{S}_m \tilde{A}_m\|_F^2 + \frac{\gamma}{2} \|\tilde{A}_h - \tilde{A}_m D\|_F^2, \quad (1.14)$$

La JCNMF [172] se décline en deux variantes, la première pour les règles de mise à jour multiplicatives et la seconde le gradient projeté. La version à gradient projeté applique les règles de mise à jour suivantes :

$$\tilde{A}_h \leftarrow \tilde{A}_h - \alpha_{\tilde{A}_h} \frac{\partial J}{\partial \tilde{A}_h}, \quad (1.15)$$

$$\tilde{S}_h \leftarrow \tilde{S}_h - \alpha_{\tilde{S}_h} \frac{\partial J}{\partial \tilde{S}_h}, \quad (1.16)$$

$$\tilde{A}_m \leftarrow \tilde{A}_m - \alpha_{\tilde{A}_m} \frac{\partial J}{\partial \tilde{A}_m}, \quad (1.17)$$

$$\tilde{S}_m \leftarrow \tilde{S}_m - \alpha_{\tilde{S}_m} \frac{\partial J}{\partial \tilde{S}_m}, \quad (1.18)$$

Une attention particulière est portée à la version multiplicative dans le chapitre suivant. En effet, cette dernière constitue la base d'une nouvelle méthode proposée dans cette thèse.

Comme mentionné dans le chapitre 1 de la partie 1 de la thèse, l'une des limitations du modèle de mélange linéaire est la non-linéarité en particulier dans le cas d'images de zones urbaines. Dans cette optique, une méthode de fusion suivant cette approche a été développée [173] et présentée au chapitre suivant. Plus précisément, elle se base sur le modèle de mélange

linéaire quadratique et applique un démixage suivant ce modèle aux deux images X_h et X_m pour extraire les abondances multipectrales et les spectres hyperspectraux afin de les fusionner.

1.4.3. Méthodes basées sur l'analyse en composantes parcimonieuses

Différentes approches utilisent le principe d'analyse en composantes parcimonieuses comme dans [174]. Cette technique applique un algorithme d'apprentissage introduit dans [175] pour extraire les spectres de l'image hyperspectrale. Pour les abondances multispectrales, l'algorithme *Generalization of Simultaneous Orthogonal Matching Pursuit* (G-SOMP+) est considéré. Une autre méthode basée aussi sur l'approche parcimonieuse a été récemment proposée, cette technique utilise *Split Augmented Lagrangian Shrinkage Algorithm* (SALSA) pour résoudre le problème d'optimisation [176].

Pour plus de détails concernant les méthodes de multisharpening, une revue récente de ces méthodes est présentée dans [177].

1.5. Evaluation de la qualité

L'intérêt des différentes techniques de fusion est d'apporter un gain en termes d'informations par rapport aux images d'origine. En particulier dans le cas de la fusion d'une image multispectrale/hyperspectrale avec une image panchromatique, le but est d'améliorer l'information spatiale tout en préservant de manière optimale l'information spectrale présente dans l'image multispectrale/hyperspectrale originale.

Pour estimer si l'information supplémentaire obtenue par le processus de fusion permet d'obtenir une amélioration en termes de fidélité et de qualité, plusieurs types d'évaluation ont été mis en place au cours de ces dernières années.

Pour évaluer la qualité de la fusion, plusieurs métriques sont utilisées. Les métriques peuvent déterminer selon les différents cas la qualité spatiale, la qualité spectrale ou les deux à la fois. L'objectif des métriques est d'estimer la qualité des produits issus de la fusion ou de réaliser une comparaison entre les différentes techniques tout en restant précises et objectives.

Les métriques doivent se rapprocher le plus possible de la perception humaine. Pour cette raison, on distingue deux types d'évaluation:

- une basée sur l'interprétation visuelle humaine,
- une autre basée sur un ensemble de métriques appelée aussi analyse quantitative.

Afin de normaliser et d'évaluer la qualité d'un produit dans plusieurs cas, certains protocoles ont été élaborés, comme le protocole de Wald [178] et de Zhou [179]. Les protocoles définissent les propriétés que doivent présenter une image fusionnée idéalement [132].

Le protocole de Wald a établi deux propriétés ainsi, un produit fusionné doit être similaire le plus possible à [132] :

- l'image multispectrale si le produit est rééchantillonné avec une résolution spatiale plus basse, c'est-à-dire la même résolution spatiale que l'image multispectrale originale,

- l'image issue d'un capteur similaire prise avec une résolution spatiale fine,

La première propriété du protocole de Wald est dite propriété de cohérence, elle décrit la faculté que possède un produit provenant de la fusion de préserver le contenu original d'une image. Cette propriété traduit le fait que si on applique le processus inverse, c'est-à-dire en dégradant l'image fusionnée à la résolution spectrale de l'image multispectrale, on doit retrouver le même contenu en termes d'informations [180].

La dernière propriété stipule que le produit de la fusion doit comprendre toutes les caractéristiques de l'image multispectrale originale si celle-ci a été prise avec un capteur qui possède une meilleure résolution spatiale [180].

1.5.1. Interprétation visuelle

L'interprétation visuelle est l'une des techniques les plus utilisées pour déterminer la qualité de la fusion bien qu'elle soit subjective et qu'elle requière une connaissance approfondie du domaine de la part de l'opérateur humain.

La condition sine qua none pour aboutir à une bonne interprétation visuelle est d'opérer dans les mêmes conditions d'affichage pour les images originales et les images fusionnées. Un changement de conditions d'affichage peut introduire une incertitude significative menant à des résultats erronés par la suite.

Parmi les critères appliqués pour l'interprétation visuelle, on peut citer:

- la préservation de l'information spatiale comme la taille et la forme des objets,
- la préservation des spécificités spectrales dans chaque bande spectrale utilisée en visualisant l'apparence des objets dans chaque bande spectrale,
- la préservation des différentes caractéristiques spectrales de l'image en comparant la couleur du produit avec la couleur de l'image originale.

Pour estimer une image par la perception humaine, plusieurs échelles d'évaluation ont été proposées comme le NIIRS (*National Imagery Interperability Rating Evaluation*). Le NIIRS considère une échelle d'évaluation composée de dix niveaux qui varient entre 0 et 9; plus le NIIRS est élevé et plus l'interprétation de l'image devient simple [181].

Comme pour le NIIRS, l'opérateur peut introduire des niveaux de qualité pour évaluer la qualité de la fusion de l'image en se basant sur la perception ainsi que la connaissance de l'opérateur [182].

1.5.2. Analyse quantitative

L'analyse quantitative repose sur un modèle mathématique bien précis pour juger le produit de la fusion. Contrairement à l'opérateur humain, elle est objective et plus efficiente en terme de coût. Le but de l'analyse quantitative est de comparer la similarité entre les images d'entrée et les images de sortie en termes de contenu spatial et spectral.

L'analyse quantitative des différentes méthodes de fusion peut être réalisée avec une image de référence [178] ou sans image de référence (*Quality Without Reference*) [183]. L'image considérée comme référence est l'image multispectrale/hyperspectrale originale dégradée spatialement et spectralement, c'est-à-dire on applique un ré-échantillonnage dans le domaine spatial et spectral pour obtenir respectivement deux images, une à haute résolution spatiale et

une à haute résolution spectrale, cette approche est utilisée pour évaluer les méthodes de fusion introduites dans cette thèse.

Dans certains cas, l'évaluation est effectuée suivant des indices qui opèrent sans modification sur les images à fusionner. L'utilisation de ces indices offre la possibilité d'opérer sans image de référence. Un indice efficient d'évaluation doit être choisi de manière à déterminer la meilleure méthode pour extraire l'information spatiale de l'image panchromatique [184].

1.5.2.1. Analyse quantitative avec référence

Les indices présentés dans cette section sont utilisés par la suite pour évaluer la fusion entre une image hyperspectrale et une image multispectrale dans le cadre de données synthétiques.

Spectral Angle Mapper (SAM)

Le *SAM* est défini par :

$$SAM_i = \arccos \left(\frac{\langle x_i, \tilde{x}_i \rangle}{\|x_i\|_2 \cdot \|\tilde{x}_i\|_2} \right), \quad (1.19)$$

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, $\langle x_i, \tilde{x}_i \rangle$ dénote le produit scalaire, $\|x_i\|_2$ et $\|\tilde{x}_i\|_2$ représentent respectivement les normes de x_i et \tilde{x}_i . La valeur idéale du SAM est de 0.

Erreur Quadratique Moyenne Normalisée Spectrale (*Spectral Normalized Mean Square Error (NMSE_λ)*)

La $NMSE_{\lambda}$ est donnée par la relation :

$$NMSE_{\lambda_i} = \frac{\|x_i - \tilde{x}_i\|_2}{\|x_i\|_2}. \quad (1.20)$$

Une valeur faible de cet indice indique une meilleure reconstruction spectrale.

Erreur Quadratique Moyenne Normalisée (EQMN) (*Normalized Mean Square Error (NMSE_S)*)

La $NMSE_S$ est formulée par :

$$NMSE_{S_k} = \frac{\|X_{f_k} - \tilde{X}_{f_k}\|_2}{\|X_{f_k}\|_2}, \quad (1.21)$$

où X_{f_k} et \tilde{X}_{f_k} correspondent respectivement à la k -ième bande spectrale de l'image de référence et de l'image fusionnée.

La valeur idéale de cet indice est de 0.

Indice de Qualité d'Image Universel (*Universal Image Quality Index (UIQI)*)

L'*UIQI* [185] mesure la similarité entre l'image de référence et l'image fusionnée. Sa valeur est comprise entre -1 et 1. La valeur 1 traduit la meilleure qualité de reconstruction spatiale. Il

est déterminé pour chaque bande multispectrale/hyperspectrale. La valeur finale de l' *UIQI* est la moyenne des valeurs obtenues sur toutes les bandes multispectrale/hyperspectrale suivant :

$$UIQI(X_f, \tilde{X}_f) = \frac{4 \delta_{X_f \tilde{X}_f} \cdot \mu(X_f) \cdot \mu(\tilde{X}_f)}{(\sigma_{X_f}^2 + \sigma_{\tilde{X}_f}^2) (\mu(X_f)^2 + \mu(\tilde{X}_f)^2)}, \quad (1.22)$$

où $\delta_{X_f \tilde{X}_f}$ décrit la covariance entre l'image multispectrale/hyperspectrale de référence X_f et l'image hyperspectrale fusionnée \tilde{X}_f , $\sigma_{X_f}^2$ et $\sigma_{\tilde{X}_f}^2$ dénotent la variance de X_f et \tilde{X}_f respectivement et $\mu(X_f)$, $\mu(\tilde{X}_f)$ indiquent respectivement la moyenne des pixels de l'image de référence et de l'image fusionnée.

Rapport Signal / Bruit (*Peak Signal to Noise Ratio (PSNR)*)

Le *PSNR* s'écrit sous la forme [172] :

$$PSNR_k = 20 \times \log_{10} \left(\frac{\max(X_{fk})}{RMSE_k} \right). \quad (1.23)$$

$$RMSE_k = \sqrt{\frac{1}{P} \sum_{i,j} (X_{fk} - \tilde{X}_{fk})^2}. \quad (1.24)$$

$RMSE_k$ est l'erreur quadratique moyenne, où P représente le nombre de pixels de l'image hyperspectrale à haute résolution spatiale.

Une plus grande valeur du *PSNR* signifie une meilleure reconstruction spatiale.

Erreur Relative Globale Adimensionnelle de Synthèse (*ERGAS*)

Elle détermine la différence et la distorsion entre deux images comme suit [177]:

$$ERGAS = \frac{100}{r} \times \sqrt{\frac{1}{L} \sum_{l=1}^L \left(\frac{RMSE_k}{\mu(X_{fk})} \right)^2}, \quad (1.25)$$

où r représente le rapport entre la résolution spatiale de l'image hyperspectrale à faible résolution spatiale et celle de l'image hyperspectrale fusionnée, L est le nombre de bandes de l'image hyperspectrale.

Une plus faible valeur d'*ERGAS* traduit un meilleur produit de fusion.

1.5.2.2. Analyse quantitative sans référence

Cette section est dédiée aux critères utilisés pour les données réelles dans cette thèse, ainsi le critère modified *Quality with No Reference (mQNR)* [172] est considéré au lieu du *QNR* standard [183]. L'intérêt du *mQNR* réside dans l'utilisation des indices de distorsion spectrale (D_λ) et spatiale (D_s). Le domaine des indices *mQNR*, D_λ et D_s est compris dans l'intervalle [0,1]. Une valeur plus élevée de *mQNR* correspond à une qualité plus élevée de la reconstruction spectrale et spatiale. Une plus petite valeur obtenue pour la distorsion spectrale D_λ ou spatiale D_s signifie une meilleure reconstruction spectrale ou spatiale respectivement. Le *mQNR* est donné par :

$$mQNR = (1 - D_\lambda)^\sigma (1 - D_s)^\rho, \quad (1.26)$$

où σ et ρ sont des exposants entiers (fixés à 1 pour les tests réalisés).

L'indice de distorsion spectrale D_λ est formulé par :

$$D_\lambda = \sqrt[\omega]{\frac{1}{L_h(L_h-1)} \sum_{j=1}^{L_h} \sum_{r=1, r \neq j}^{L_h} \left| \text{UIQI}(\tilde{X}_{f_j}, \tilde{X}_{f_r}) - \text{UIQI}(X_{h_j}, X_{h_r}) \right|^\omega}, \quad (1.27)$$

où ω est un exposant entier positif (égal à 1 pour les tests effectués). X_{f_*} dénote une bande spectrale de l'image fusionnée et X_{h_*} une bande spectrale de l'image hyperspectrale respectivement.

L'indice de distorsion spatiale D_s est estimé de la manière suivante. Un sous-indice est calculé par la méthode décrite dans [183] entre une bande multispectrale et hyperspectrale, à noter que les bandes hyperspectrales n'intégrant pas le domaine spectral de l'image multispectrale considérée ne sont pas traitées. Une moyenne est ensuite calculée pour l'ensemble des sous-indices pour déterminer D_s .

1.6. Conclusion

Dans ce chapitre, les méthodes de fusion des images de télédétection ont été analysées. Dans la première partie les hypothèses de ces méthodes ont été présentées à savoir la même physique et le temps d'acquisition proche de la même scène observée.

Par la suite, les principales méthodes de pansharpening ont été détaillées avec leurs avantages et inconvénients. Les techniques traitées dans cette partie ont été catégorisées dans différentes classes selon leur principe de fonctionnement.

Dans la troisième partie, les principales méthodes de multisharpening ou hypersharpening ont été introduites. Une attention particulière a été apportée aux méthodes utilisant la NMF, cette dernière étant la base des méthodes de fusion développées dans cette thèse.

La dernière partie a été consacrée aux différents types d'évaluation, l'une basée sur la perception humaine. L'autre type d'évaluation est l'analyse quantitative. Cette dernière est divisée en deux écoles : l'une consiste à utiliser une image de référence pour réaliser l'évaluation et l'autre sans passer par une image de référence.

Dans le chapitre suivant, les méthodes proposées dans le cadre de cette thèse sont présentées. Pour chaque méthode le critère à optimiser ainsi que les algorithmes utilisés sont détaillés. En particulier, deux méthodes développées pour intégrer la variabilité spectrale dans le processus de multisharpening sont introduites.

Chapitre 2 : Méthodes Proposées pour le Multisharpening

Chapitre 2

Méthodes proposées pour le multisharpening

2.1. Introduction

L'observation de la Terre et la connaissance de notre environnement ont connu une avancée décisive ces dernières années avec l'acquisition d'un grand nombre de données délivrées par des capteurs hyperspectraux et multispectraux. En particulier, les données obtenues via les capteurs hyperspectraux avec une multitude de bandes spectrales, qui s'étalent d'une centaine jusqu'à des milliers de bandes, permettent de réaliser une classification précise des matériaux présents dans l'image en donnant une information spectrale très détaillée.

Cependant, ces images hyperspectrales restent limitées en résolution spatiale contrairement aux images multispectrales. Dans ce contexte, l'objectif consiste à améliorer la résolution spatiale des images hyperspectrales en exploitant l'information spatiale présente dans l'image multispectrale de la même scène tout en préservant le plus possible l'information spectrale de l'image hyperspectrale.

Différentes techniques ont été développées, dans un premier temps dans le cadre du pansharpening (voir le chapitre précédent), pour affiner la résolution spatiale des images hyperspectrales ou multispectrales en utilisant l'information d'une image panchromatique. Ces méthodes ont été étendues pour appliquer la fusion entre les images hyperspectrales et multispectrales. Cette extension est connue sous les noms de multisharpening ou hypersharpening.

Les méthodes de multisharpening représentent une nouvelle conception de la manière de traiter le processus de fusion en combinant l'information spectrale de l'image hyperspectrale et l'information spatiale de l'image multispectrale. Plusieurs approches récemment introduites se basent sur le démixage linéaire (LSU) et utilisent l'approche de la factorisation en matrices non-négatives (NMF) comme mentionnée dans le chapitre précédent. Ces méthodes estiment les spectres des matériaux purs présents dans l'image et les fractions d'abondance associées en appliquant un démixage spectral linéaire sur les données considérées.

Dans ce chapitre, deux nouvelles méthodes de fusion sont présentées, fondées sur la NMF et intégrant la variabilité spectrale pendant la fusion en introduisant la notion de classe de matériaux dans ce processus. La première méthode repose sur une approche de démixage linéaire récente de la littérature traitant la variabilité spectrale : l'*Inertia-constrained Pixel-by-Pixel NMF* (IP-NMF) [18] et nommée *Hyperspectral and Multispectral data Fusion based on IP-NMF* (HMF-IPNMF). Dans une première étape, le modèle mathématique des données

considérées pour le développement de la HMF-IPNMF est présenté. Par la suite, l'algorithme appliqué pour fusionner les données est détaillé.

La deuxième méthode est une extension de la *Joint-Criterion NMF* (JCNMF) [172], qui exploite un modèle de dégradation spatiale entre les deux images hyperspectrale et multispectrale. Cette extension consiste à modifier le modèle mathématique de ladite méthode pour intégrer la variabilité spectrale. Le nouveau modèle inspiré de celui de l'IP-NMF (voir la première partie de la thèse) ainsi que l'algorithme associé sont présentés dans la deuxième partie de ce chapitre.

2.2. Rappel sur le modèle mathématique de données

La première technique d'hypersharpening développée dans le cadre de ces travaux utilise la méthode de démixage dite IP-NMF [18]. Cette technique considère un modèle de mélange linéaire étendu (voir chapitre 2 de la partie 1) afin d'intégrer la variabilité spectrale. Dans le cadre des présentes recherches, une image observée, notée $X \in \mathbb{R}_+^{P \times L}$, est modélisée suivant un format matriciel par :

$$X = AS. \quad (2.1)$$

Chaque ligne de la matrice X correspond à un spectre présent dans un pixel de l'image traitée et chaque colonne à une bande spectrale de cette image. P et L indiquent respectivement le nombre de pixels et le nombre de bandes spectrales de l'image.

De plus, la matrice $A \in \mathbb{R}_+^{P \times LN}$ contient les fractions d'abondance et la matrice $S \in \mathbb{R}_+^{PN \times L}$ est composée de l'ensemble des spectres des matériaux purs dépendants des pixels. N est le nombre des classes de matériaux purs présents dans la zone imagée. La matrice A , diagonale par bloc, se présente sous la forme suivante [18] :

$$A = \begin{bmatrix} a_1^T & 0 \dots 0 & \dots & 0 \dots 0 \\ 0 \dots 0 & a_2^T & \dots & 0 \dots 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 \dots 0 & 0 \dots 0 & \dots & a_P^T \end{bmatrix}, \quad (2.2)$$

où $a_i = [a_{i1}, \dots, a_{iN}]^T$ est l'élément du N -ième vecteur colonne qui contient les fractions d'abondance associées au spectre contenu dans le i -ième pixel observé, $[\cdot]^T$ décrit le vecteur/matrice transposé. Par ailleurs, la matrice S contenant l'ensemble des spectres purs présents dans toute l'image (un jeu de spectres purs par pixel) est composée de P blocs [18]:

$$S = \begin{pmatrix} S_1 \\ \dots \\ S_P \end{pmatrix}. \quad (2.3)$$

Les structures particulières des matrices des spectres S et des abondances A permettent d'estimer pour chaque pixel de l'image X un jeu de spectres pour chaque classe de matériaux. Ces deux structures sont utilisées pour la suite de cette partie, en particulier pour la deuxième méthode proposée [18].

2.3. Méthodes de multisharpening proposées

2.3.1. Première méthode proposée

La première méthode proposée est la HMF-IPNMF. Elle présente l'avantage d'utiliser l'IP-NMF pour estimer les spectres, ce qui permet de retrouver les spectres hyperspectraux de manière plus efficiente que les méthodes classiques de fusion de la littérature basées sur le modèle de mélange linéaire (LSU). Contrairement à la CNMF [170] et à la JCNMF [172] qui appliquent un démélange de façon alternée ou bien conjointe sur l'image hyperspectrale X_h et l'image multispectrale X_m , la HMF-IPNMF adopte une stratégie séquentielle simple. Elle se décline en trois étapes.

A. Étape d'estimation des spectres de l'image hyperspectrale

La première étape de la méthode consiste à sur-échantillonner spatialement l'image hyperspectrale originale à basse résolution spatiale, notée $X_h \in \mathbb{R}_+^{P_h \times L_h}$, pour obtenir une image sur-échantillonnée $X_z \in \mathbb{R}_+^{P_m \times L_h}$ qui a la même résolution spatiale que l'image multispectrale notée $X_m \in \mathbb{R}_+^{P_m \times L_m}$. La méthode considérée pour réaliser le sur-échantillonnage est la méthode appelée 23-tap [53], d'autres algorithmes peuvent être utilisés comme celui du plus proche voisin ou l'interpolation bilinéaire comme indiqué dans le chapitre 1.

Par la suite, l'image hyperspectrale de haute résolution spatiale obtenue par sur-échantillonnage est démélangée à l'aide de l'algorithme IP-NMF [18]. Plus précisément, cette procédure de démélange permet d'aboutir à une matrice $\tilde{S}_z \in \mathbb{R}_+^{P_m \times L_h}$ contenant les spectres hyperspectraux à estimer. Cette matrice est obtenue en optimisant la fonction de coût [18] :

$$J_{ipnmf} = \frac{1}{2} \|X_z - \tilde{A}_z \tilde{S}_z\|_F^2 + \mu \sum_{c=1}^N \text{Tr}(\text{Cov}(\tilde{S}_{z_c})), \quad (2.4)$$

où la matrice $\tilde{S}_{z_c} \in \mathbb{R}_+^{P_m \times L_h}$ contient l'ensemble des spectres hyperspectraux des matériaux purs estimés de la c -ième classe [18]. $\tilde{A}_z \in \mathbb{R}_+^{P_m \times P_m^N}$ est la matrice contenant les fractions d'abondance à haute résolution spatiale sur-échantillonnées (avec une structure identique à (2.2)). $\|\cdot\|_F$ désigne la norme de Frobenius, $\text{Tr}(\cdot)$ et $\text{Cov}(\cdot)$ représentent respectivement la trace et la covariance. L'algorithme de l'IP-NMF (mentionné dans le chapitre 2 de la partie 1) est utilisé pour estimer les spectres hyperspectraux.

Pour l'initialisation des spectres $\tilde{S}_z^{(0)}$, la méthode VCA [37] (voir première partie du manuscrit) est appliquée à l'image X_z . Les spectres obtenus par la VCA sont dupliqués P_m fois pour former $\tilde{S}_z^{(0)}$. Les abondances $\tilde{A}_z^{(0)}$ sont initialisées par une régression linéaire. Plus précisément, pour chaque pixel de l'image, la FCLS [43] (voir première partie de la thèse) est appliquée à X_z en utilisant $\tilde{S}_z^{(0)}$ pour obtenir $\tilde{A}_z^{(0)}$. La FCLS garantit les deux contraintes de non-négativité et de somme à un.

B. Etape de l'estimation des fractions abondance à haute résolution spatiale

La deuxième étape de l'approche proposée consiste à estimer, pixel par pixel, les fractions d'abondance à haute résolution spatiale, contenue dans la matrice $\tilde{A}_m \in \mathbb{R}_+^{P_m \times P_m^N}$ définie similairement à l'équation (2.2). La HMF-IPNMF n'applique pas une NMF sur l'image pour estimer les abondances multispectrales. En effet, cette estimation est réalisée en utilisant une simple régression par le biais de la méthode FCLS. Elle est appliquée à l'image multispectrale

X_m et en considérant la matrice des spectres de l'image multispectrale, notée $\tilde{S}_m \in \mathbb{R}_+^{P_m N \times L_m}$. La matrice \tilde{S}_m , qui n'est pas mise à jour au cours de cette deuxième étape, est obtenue à partir de la matrice $\tilde{S}_z^{(0)}$ estimée dans la première étape en la dégradant spectralement. La dégradation est obtenue en utilisant la SRF connue ou estimée à partir du capteur multispectral considéré.

L'utilisation de la SRF est essentielle pendant le processus de fusion, en particulier l'aspect physique de l'hypersharpening. En effet, il existe deux raisons principales pour introduire la SRF [186] :

- préserver la cohérence physique des bandes fusionnées car on ne peut inclure des bandes spectrales du capteur hyperspectral que si elles se chevauchent avec celles du capteur multispectral,
- la fusion a pour objectif d'obtenir une image d'un capteur idéal avec la même résolution spectrale que le capteur hyperspectral et la même résolution spatiale que le capteur multispectral d'où la nécessité d'inclure la SRF du capteur hyperspectral.

C. Etape de fusion

La troisième étape permet de générer les images hyperspectrales à haute résolution spatiale \tilde{X}_f en recombinaison des matrices obtenues \tilde{A}_m et \tilde{S}_z par la relation :

$$\tilde{X}_f = \tilde{A}_m \tilde{S}_z. \quad (2.5)$$

Les différentes étapes de la HMF-IPNMF sont résumées dans l'algorithme suivant

Algorithme 7 : Hyperspectral and Multispectral data Fusion based on IP-NMF (HMF-IPNMF).

Entrée: Image hyperspectrale X_h et image multispectrale X_m .

1- Initialisation

- 1.1 Sur-échantillonnage de X_h pour obtenir X_z avec l'algorithme 23-tap.
- 1.2 Initialisation de $\tilde{S}_z^{(0)}$ avec la VCA.
- 1.3 Initialisation de $\tilde{A}_z^{(0)}$ à partir de X_z et $\tilde{S}_z^{(0)}$ avec la FCLS.
- 1.4 Agencement de $\tilde{A}_z^{(0)}$ et $\tilde{S}_z^{(0)}$ comme dans (2.2) et (2.3) respectivement.

2- Estimation de \tilde{S}_z avec l'IP-NMF.

3- Obtention de \tilde{S}_m en dégradant spectralement \tilde{S}_z avec la SRF.

4- Estimation de \tilde{A}_m pour chaque pixel de X_m en utilisant la FCLS entre \tilde{S}_m et X_m .

5- Fusion de \tilde{A}_m et \tilde{S}_z pour obtenir \tilde{X}_f selon (2.5).

Sortie : Image fusionnée \tilde{X}_f

2.3.2. Deuxième méthode proposée

La deuxième méthode proposée est une extension de la JCNMF multiplicative nommée JCNMFV. La JCNMF [172] est une technique de fusion qui applique un démélange simultané sur les images X_h et X_m afin d'estimer les spectres de l'image hyperspectrale \tilde{S}_h et les abondances de l'image multispectrale A_m .

La JCNMF peut être vue comme une extension de la *Joint NMF* (JNMF) [171], elle intègre deux règles de mise à jour supplémentaires qui considèrent les versions sous-échantillonnée et sur-échantillonnée des abondances à haute et faible résolutions spatiales. Elles sont obtenues à l'aide de l'algorithme des k -plus proches voisins (k -nearest-neighbors) [172]. Ces deux règles de mise à jour ne découlent pas directement du critère considéré, elles permettent aux abondances à haute et faible résolutions spatiales d'être estimées de manière consistante.

Comme la HMF-IPNMF, cette version étendue de la JCNMF doit adapter les tailles des matrices mises en jeu dans la fusion afin que le démélange simultané des images X_h et X_m soit réalisé. A cet effet, la matrice des spectres \tilde{S}_h est utilisée pour générer une matrice étendue $\tilde{S}_{k_m} \in \mathbb{R}_+^{L_h \times P_m N}$. Cette opération est nécessaire pour effectuer la multiplication avec les abondances multispectrales par la suite. En effet, le nombre de pixels présent dans l'image hyperspectrale n'est pas identique à celui de l'image multispectrale. Pour cela une duplication des sous-matrices de \tilde{S}_h est effectuée en prenant en considération le ratio entre les images X_m et X_h pour obtenir \tilde{S}_{k_m} . De plus, la duplication est réalisée en tenant compte de la position des pixels dans X_h avec leurs homologues X_m .

Dans sa première version, la JCNMF a été développée pour fusionner conjointement les deux images X_h et X_m , à cet effet la JCNMF optimise la fonction de coût suivante :

$$J = \frac{\alpha}{2} \|X_h - \tilde{S}_h \tilde{A}_h\|_F^2 + \frac{\beta}{2} \|X_m - \tilde{S}_m \tilde{A}_m\|_F^2 + \frac{\gamma}{2} \|\tilde{A}_h - \tilde{A}_m D\|_F^2, \quad (2.6)$$

où $\|\cdot\|_F$ est la norme de Frobenius. α , β et γ représentent des coefficients, égaux au nombre inverse du nombre d'éléments des variables considérées dans chaque norme de Frobenius à savoir X_h , X_m et \tilde{A}_h [172]. La matrice D permet de réaliser la dégradation spatiale (blurring-decimation) entre l'image multispectrale et hyperspectrale. Elle peut être interprétée comme la *Point Spread Function* (PSF) du capteur hyperspectral, dans cette étude une PSF gaussienne est considérée. Cette matrice est estimée au début de l'algorithme avec des filtres gaussiens [172].

L'extension de cette méthode consiste à remplacer la structure des matrices \tilde{A}_h et \tilde{A}_m par celle décrite dans (2.2). Elle permet de manière efficiente de prendre en considération la variabilité spectrale pendant l'optimisation. De plus, les matrices \tilde{S}_h et S_m sont agencées à l'identique de (2.3). Ainsi pour chaque pixel des deux images, un jeu de spectres est estimé afin d'obtenir une classe de spectres pour chaque matériau.

La JCNMF est un algorithme multiplicatif qui utilise les règles décrites par les relations [172] :

$$\tilde{S}_h \leftarrow \tilde{S}_h \odot ((X_h A_h^T) \oslash (\tilde{S}_h \tilde{A}_h \tilde{A}_h^T + \epsilon)), \quad (2.7)$$

$$\tilde{A}_h \leftarrow \tilde{A}_h \odot ((\alpha \tilde{S}_h^T X_h + \gamma \tilde{A}_m D) \oslash (\alpha \tilde{S}_h^T \tilde{S}_h \tilde{A}_h + \gamma \tilde{A}_h + \epsilon)), \quad (2.8)$$

$$\tilde{S}_m \leftarrow \tilde{S}_m \odot ((X_m A_m^T) \oslash (\tilde{S}_m \tilde{A}_m \tilde{A}_m^T + \epsilon)), \quad (2.9)$$

$$\tilde{A}_m \leftarrow \tilde{A}_m \odot ((\beta \tilde{S}_m^T X_m + \gamma \tilde{A}_h D^T) \oslash (\beta S_m^T \tilde{S}_m A_m + \gamma A_m D D^T + \epsilon)), \quad (2.10)$$

où \odot et \oslash correspondent respectivement à la multiplication et à la division élément par élément. ϵ est ajouté au dénominateur afin d'éviter une éventuelle division par zéro durant les mises à jour. Ces règles de mise à jour restent applicables et pertinentes dans le processus considéré si les éléments des matrices \tilde{A}_m et \tilde{A}_h correspondant à des zéros dans (2.2) sont initialisés avec des valeurs nulles (voir chapitre 1 de la première partie de la thèse).

Pour la contrainte de somme à un, l'approche introduite par la FCLS [43] est adoptée. Le critère d'arrêt de l'algorithme est de vérifier si la différence entre le critère à optimiser lors de deux itérations successives est inférieure à un seuil préétabli noté *thresh* [42] :

$$\left| \frac{J^{(t)} - J^{(t+1)}}{J^{(t)}} \right| \leq \text{thresh}, \quad (2.11)$$

où t correspond à l'itération. De plus, pour se préserver d'un nombre excessif d'itérations, ce nombre maximal d'itération est fixé au préalable.

La dernière étape consiste à fusionner les matrices obtenues \tilde{A}_m et \tilde{S}_{k_m} pour obtenir les images hyperspectrales à haute résolution spatiale \tilde{X}_f suivant :

$$\tilde{X}_f = \tilde{S}_{k_m} \tilde{A}_m. \quad (2.12)$$

Pour l'initialisation des matrices des spectres $\tilde{S}_h^{(0)}$, la même approche que pour la HMF-IPNMF est utilisée, c'est-à-dire appliquer la VCA [37] sur l'image X_h , pour obtenir $\tilde{S}_h^{(0)}$. Pour les abondances hyperspectrales $\tilde{A}_h^{(0)}$, la FCLS est appliquée entre l'image hyperspectrale X_h et les spectres hyperspectraux initiaux $\tilde{S}_h^{(0)}$. Par ailleurs, les différentes matrices $\tilde{S}_h^{(0)}$ et $\tilde{A}_h^{(0)}$ sont organisées suivant (2.2) et (2.3).

Les spectres de l'image multispectrale $\tilde{S}_m^{(0)}$ sont déduits des spectres de l'image hyperspectrale $\tilde{S}_h^{(0)}$ en utilisant la SRF du capteur multispectral considéré dans les expériences. Les abondances initiales sont estimées en appliquant une FCLS entre chaque pixel de l'image multispectrale X_m et en utilisant les spectres correspondant dans $\tilde{S}_m^{(0)}$.

Algorithme 8 : Extension de la méthode Joint-Criterion NMF (JCNMFV)

Entrée: Image hyperspectrale X_h et image multispectrale X_m .

1- Initialisation

1.1 Adaptation de la taille de \tilde{S}_h .

1.2 Initialisation de $\tilde{S}_h^{(0)}$ avec la VCA.

1.3 Initialisation de $\tilde{A}_h^{(0)}$ à partir de X_h et $\tilde{S}_h^{(0)}$ avec la FCLS.

1.4 Obtention de $\tilde{S}_m^{(0)}$ en dégradant spectralement $\tilde{S}_h^{(0)}$ avec la SRF.

1.5 Initialisation de $\tilde{A}_m^{(0)}$ à partir de X_m et $\tilde{S}_m^{(0)}$ avec la FCLS.

1.6 Agencement de $\tilde{A}_h^{(0)}$ et $\tilde{S}_h^{(0)}$ comme (2.2) et (2.3) respectivement.

1.7 Agencement de $\tilde{A}_m^{(0)}$ et $\tilde{S}_m^{(0)}$ comme (2.2) et (2.3) respectivement.

2- Optimisation

2.1 Optimisation de \tilde{S}_h avec (2.7).

2.2 Optimisation de \tilde{A}_h avec (2.8).

2.3 Optimisation de \tilde{S}_m avec (2.9).

2.4 Optimisation de \tilde{A}_m avec (2.10).

3- Fusion de \tilde{A}_m et \tilde{S}_h pour obtenir \tilde{X}_f selon (2.12).

Sortie : Image fusionnée \tilde{X}_f .

2.4. Conclusion

Dans ce chapitre, les deux méthodes de fusion d'images de télédétection développées dans le cadre de cette thèse ont été présentées. Dans un premier temps, le modèle mathématique des données est détaillé. Par la suite les deux méthodes de multisharpening prenant en considération la variabilité spectrale pendant la fusion ont été proposées : *Hyperspectral and Multispectral data Fusion based on IP-NMF* (HMF-IPNMF) [187] et extension de la méthode appelée *Joint-Criterion NMF* (JCNMF). Ainsi les étapes et l'algorithme de la HMF-IPNMF sont définis. Dans une troisième partie, l'extension de la méthode *Joint-Criterion NMF* (JCNMF) [188] est présentée. En particulier, l'adaptation pour considérer le phénomène de variabilité spectrale est formulée. Enfin, l'algorithme de la JCNMF multiplicative étendue est introduit.

Chapitre 3: Tests et Performances

Chapitre 3

Tests et Performances.

3.1. Introduction

Dans ce chapitre, les tests réalisés et les résultats obtenus à partir des deux méthodes de fusion développées, la HMF-IPNMF et l'extension de la JCNMF, sont présentés et comparés à ceux de méthodes de fusion récentes de la littérature. Les différents tests sont appliqués à des données synthétiques et réelles avec présence de la variabilité spectrale. Le chapitre est organisé de la manière suivante.

La première partie est dédiée à l'introduction des données utilisées dans le cadre de cette étude, en particulier les données synthétiques issues d'une image réelle. Leur création est basée sur le protocole de Wald [48] en considérant les caractéristiques physiques simulées telles que la réponse spectrale des capteurs considérés.

La dernière partie analyse les résultats obtenus sur les deux jeux de données synthétiques et sur les images réelles en se basant sur les critères ainsi qu'une étude visuelle des résultats des produits de la fusion. L'ensemble des résultats est discuté par une comparaison détaillée avec ceux d'autres méthodes sur la base des critères de performances.

3.2. Données testées

3.2.1. Données synthétiques

Deux jeux de données synthétiques sont considérés pour les tests effectués. Ils sont générés à partir d'une image hyperspectrale réelle de haute résolution spectrale et spatiale. Plus précisément, un sous-ensemble d'une image hyperspectrale REF (voir figure 3.1) est utilisé pour créer ces données synthétiques. Il est composé de 7 classes de matériaux avec variabilité spectrale.



Figure 3.1 : Image hyperspectrale de référence.

Ce sous-ensemble d'image est constitué de 100×100 pixels et de 144 longueurs d'onde couvrant le domaine spectral $0,38 - 1,05 \mu m$. A partir de cette image de référence, deux jeux de données synthétiques sont créés suivant le protocole de Wald [1,48]. Ce dernier a pour principe de base d'obtenir deux images synthétiques dégradées spectralement et spatialement respectivement à partir d'une image réelle à haute résolution spectrale et spatiale. Le produit de la fusion entre les deux images synthétiques est comparé à l'image de référence en appliquant des critères de performance.

Le premier jeu est constitué d'une image multispectrale (MS-1) et d'une image hyperspectrale (HS-1) (voir figure 3.2). L'image MS-1 de haute résolution spatiale et de faible résolution spectrale est obtenue en dégradant l'image REF spectralement en utilisant la SRF du satellite QuickBird pour aboutir à 4 bandes spectrales correspondant aux domaines spectraux reportés dans le tableau 3.1.

QuickBird	Bandes spectrales (μm)
	0,45 – 0,52 (bleu)
	0,52 – 0,60 (vert)
	0,63 – 0,69 (rouge)
	0,76 – 0,90 (proche infrarouge)

Tableau 3.1 : Bandes spectrales du capteur QuickBird [199].

L'image HS-1 de faible résolution spatiale et de haute résolution spectrale de 50×50 pixels est générée en dégradant spatialement l'image REF avec un facteur deux par un filtre Gaussien assimilé à une PSF du capteur hyperspectral considéré [172]. L'utilisation de la SRF et de la PSF permettent de générer des images synthétiques réalistes en intégrant les caractéristiques physiques des capteurs adoptés pour la simulation des données [177].



Figure 3.2 : (a) Image HS-1. (b) Image MS-1.

Le deuxième jeu de données est composé de l'image multispectrale à haute résolution spatiale MS-2 et de l'image hyperspectrale HS-2 à haute résolution spectrale (voir figure 3.3). L'image MS-2 est créée en dégradant spectralement l'image REF pour obtenir une image à 5 bandes spectrales, à cet effet la SRF de Landsat-8 Operational Imageur terrestre (OLI) est appliquée. Elle couvre les domaines reportés dans le tableau 3.2.

Landsat-8 OLI	Bandes spectrales (μm)
	0,43 – 0,45 (aérosol)
	0,45 – 0,51 (bleu)
	0,53 – 0,59 (vert)
	0,64 – 0,67 (rouge)
	0,85 – 0,88 (proche infrarouge)

Tableau 3.2 : Bandes spectrales du capteur Landsat-8 OLI [190].

L'image HS-2 à haute résolution spectrale est générée en dégradant spatialement l'image REF avec un facteur 4 en utilisant une PSF Gaussienne pour obtenir une image de 25×25 pixels. Le but de ce jeu de données est de comprendre comment les méthodes gèrent un ratio plus significatif entre l'image hyperspectrale et multispectrale.



(a) (b)

Figure 3.3 : (a) Image HS-2. (b) Image MS-2.

3.2.2. Données réelles

Pour les données réelles, deux images hyperspectrale et multispectrale, radiométriquement corrigées et géométriquement recalées, sont considérées. Les deux images ont été acquises au même instant et à la même date (3 mars 2003) [172] (voir figure 3.4). Elles couvrent une partie de la zone urbaine d’Oran (Algérie). L’image hyperspectrale de taille de 30×30 pixels est obtenue par le capteur Earth Observing-1 (EO-1) Hyperion. Elle présente une résolution spatiale de 30 m et elle est composée de 7 matériaux. Elle est constituée de 125 bandes spectrales, après avoir enlevé des bandes spectrales à faible rapport signal/bruit ainsi que les bandes spectrales non-calibrées et chevauchantes, à partir du cube de données d’origine de 242 bandes spectrales [172].

L’image multispectrale à haute résolution spatiale acquise par le capteur EO-1 Advanced Land Imager (ALI) (voir figure 3.4). Elle est caractérisée par une taille de 90×90 pixels, une résolution spatiale de 10 m et 9 bandes spectrales [172]. Les bandes sont comprises dans les domaines spectraux reportés dans le tableau 3.3.

EO-1 Advanced Land Imager	Bandes spectrales (μm)
	0,433 – 0,453
	0,450 – 0,515
	0,525 – 0,605
	0,630 – 0,690
	0,775 – 0,805
	0,845 – 0,890
	1,200 – 1,300
	1,550 – 1,750
	2,080 – 2,350

Tableau 3.3 : Bandes spectrales du capteur EO-1 Advanced Land Imager [191].

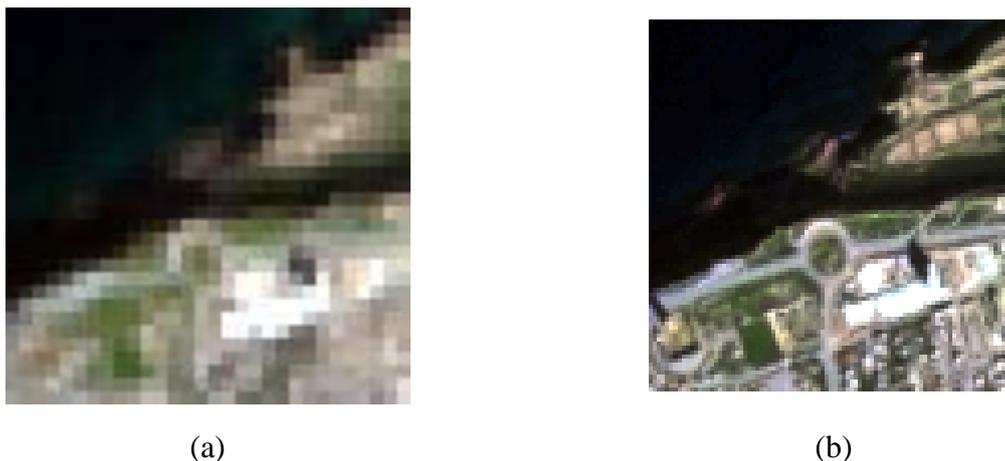


Figure 3.4 : (a) Image hyperspectrale. (b) Image multispectrale [61].

3.3. Résultats et discussions

Dans cette partie les méthodes de multisharpening développées dans cette thèse, à savoir la HMF-IPNMF et l'extension de la JCNMF (notée JCNMFV pour le reste du chapitre), sont testées sur les données synthétiques et réelles décrites ci-dessus. Pour ces études, différentes méthodes de la littérature sont considérées, à savoir :

- *Coupled Nonnegative Matrix Factorization (CNMF)* [170],
- *Hyperspectral Superresolution (HySure)* [169],
- *Fusion with spectral Variability (FuVar)* [192],
- *Smoothing Filter based Intensity Modulation (SFIM)* [143],
- *Joint NMF (JNMF)* [171].

Trois méthodes sont basées sur le démelange spectral : la CNMF, la HySure, la FuVar et la JNMF. Les méthodes CNMF et HySure ne prennent pas en compte le phénomène de variabilité spectrale, alors que la technique FuVar le considère.

La CNMF et la HySure sont appliquées à travers deux scénarios. Dans le premier (scénario (a)), ces différentes méthodes sont utilisées en considérant exactement le nombre de matériaux purs. Ce dernier est déterminé manuellement ($N=7$ pour les jeux de données synthétiques et l'image réelle) tandis que dans le second (scénario (b)) elles sont appliquées en tenant compte du nombre obtenu par la HySime [74] (voir première partie du manuscrit). Pour les deux données synthétiques, le nombre de matériaux estimé par HySime est égal à 18. Concernant les données réelles, le nombre de matériaux estimés est de 38. Le scénario (b) permet plus de flexibilité pour ces méthodes, pour tenir compte de la variabilité spectrale, bien qu'elles ne soient pas développées à cet effet. La FuVar et la HMF-IPNMF appliquent le nombre exact de matériaux.

Pour la HMF-IPNMF, le nombre maximal d'itérations utilisées dans l'algorithme IP-NMF est de 100. De plus, le paramètre μ de l'équation (2.2) du chapitre précédent est égal à 30. Le

nombre d'itérations est mis égal à 10 pour la JCNMFV. Pour la CNMF le nombre d'itérations est fixé à 100 pour la boucle interne et à 3 pour la boucle externe. Les paramètres des autres méthodes sont pris comme conseillé par leurs auteurs. Les méthodes basées sur le démélange sont initialisées avec la VCA pour les spectres et la FCLS pour les abondances.

Pour information, le processeur utilisé dans les expériences menées est un Intel (R) Core(TM) i5-8350U fonctionnant à 1,70 GHz, avec une capacité de mémoire de 16 Go.

3.3.1. Résultats sur le premier jeu de données synthétiques

Les résultats obtenus sur le premier jeu de données synthétiques ainsi que les différents temps de calcul sont reportés dans le tableau 3.4.

		HMF-IPNMF	JCNMFV	FuVar	SFIM	CNMF		HySure		JNMF	
						(a)	(b)	(a)	(b)	(a)	(b)
Temps (s)		500.02	1275	298.27	2.77	1.78	2.50	3.02	8.76	1.30	2.45
Critère	Valeur Idéale										
SAM (°)	0	3.37	2.80	4.66	3.38	4.47	3.60	3.81	3.77	3.48	3.33
$NMSE_{\lambda}$ (%)	0	8.19	9.93	13.60	14.87	15.45	13.73	9.52	9.57	14.81	13.76
$NMSE_S$ (%)	0	8.69	14.77	19.17	19.45	14.59	12.40	11.10	10.45	15.52	16.02
$PSNR$ (dB)	∞	34.10	34.85	28.91	28.45	29.13	31.85	33.05	33.29	29.77	30.01
$UIQI$	1	0.9746	0.9485	0.9212	0.9105	0.9272	0.9534	0.9710	0.9741	0.9237	0.9299
$ERGAS$	0	6.59	9.28	13.01	12.58	8.88	7.97	7.20	6.66	9.67	10.20

Tableau 3.4 : Valeurs des critères de performance sur le premier jeu de données synthétiques.

D'après le tableau 3.4, nous observons d'un point de vue spectral que les méthodes JNMF et HySure dans les deux configurations mènent à des résultats performants. Plus précisément, nous notons une valeur de $NMSE_{\lambda}$ pour HySure plus faible comparée à celle de la CNMF et de la FuVar. La JNMF améliore la HySure en terme de SAM avec une valeur de 3.33° . La JCNMFV produit le meilleur résultat en terme de SAM avec une valeur de 2.80° . Pour le $NMSE_{\lambda}$, la HMF-IPNMF aboutit à la valeur la plus faible de 8.19 indiquant ainsi que la prise en compte de la variabilité spectrale dans le processus de fusion est fondamentale pour une meilleure reconstruction spectrale.

Pour l'aspect spatial, la HySure permet d'obtenir la meilleure valeur de $UIQI$ et du $PSNR$ par rapport aux méthodes de la littérature traduisant ainsi son efficacité. La HMF-IPNMF permet d'obtenir les meilleures performances globalement pour les meilleures valeurs des critères spatiaux : $NMSE_S$, l' $ERGAS$ et l' $UIQI$. La figure 3.5 montre les résultats de la fusion des différents algorithmes.

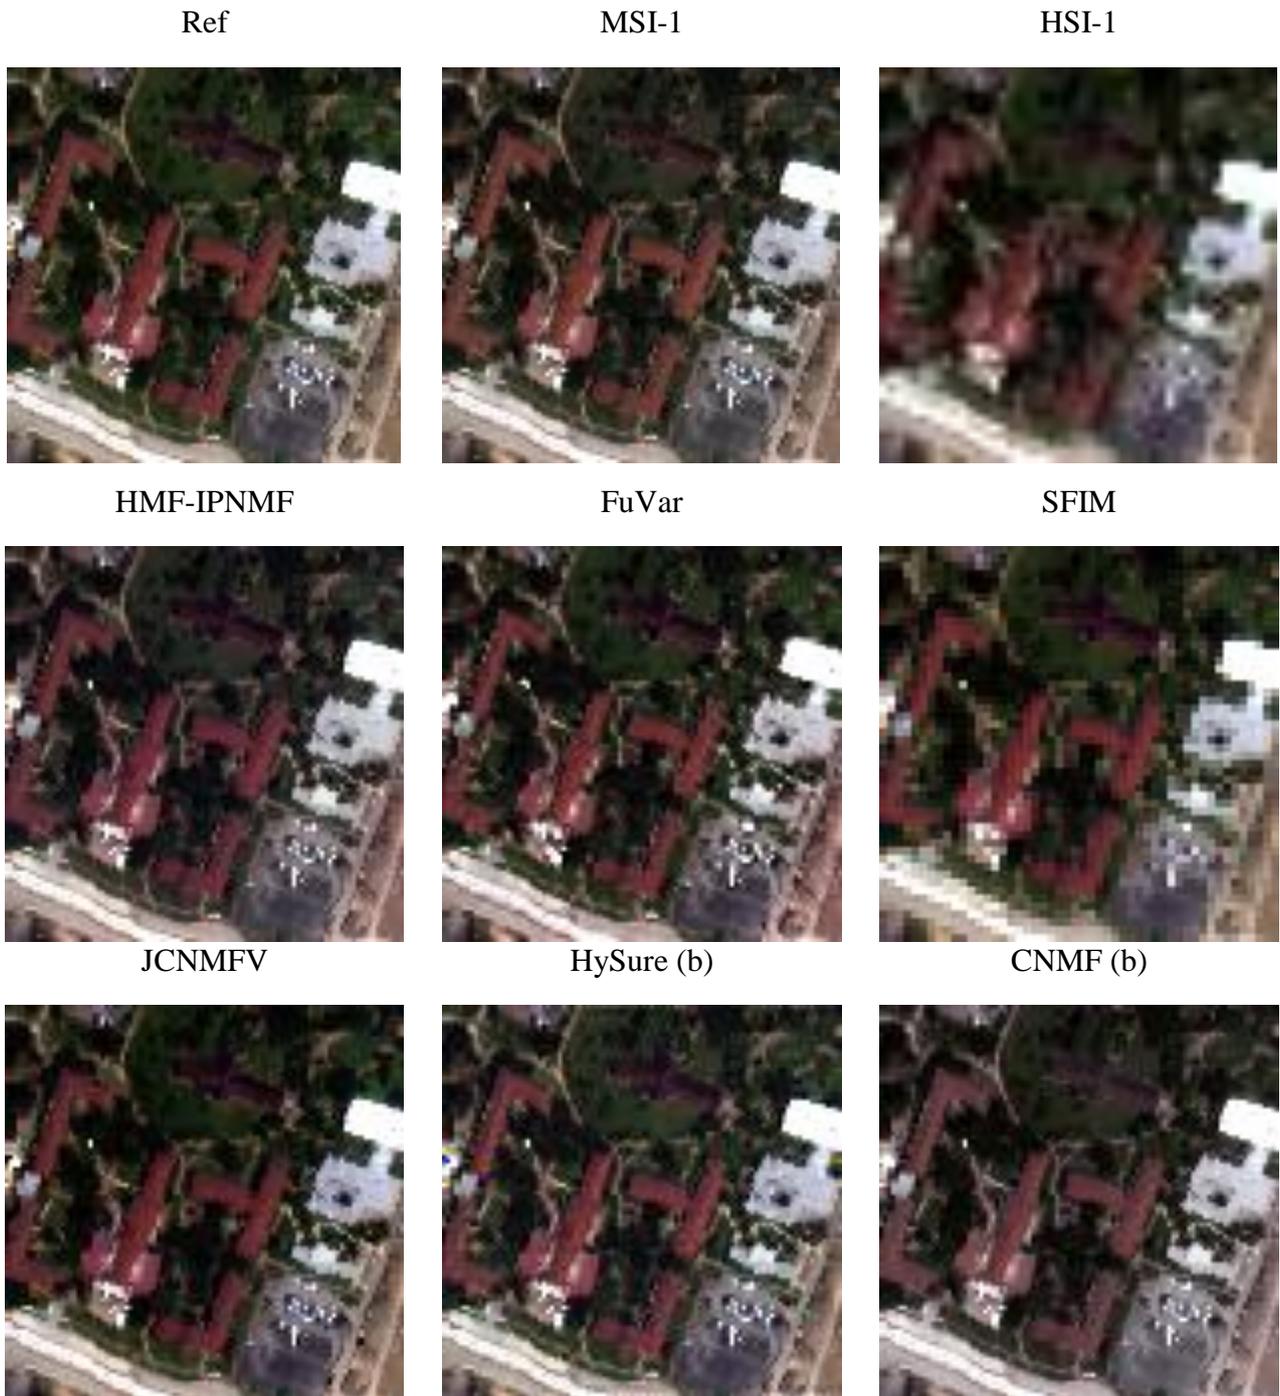


Figure 3.5 : Résultats en RGB de fusion des différents algorithmes pour le premier jeu de données synthétiques.

Pour montrer plus en détails le gain en terme de qualité spatiale et spectrale des deux méthodes proposées, la figure 3.6 illustre les résultats obtenus pour la bande spectrale $0.817 \mu m$. Nous observons clairement que les deux techniques introduites mènent à une meilleure reconstruction spatiale en particulier pour la HMF-IPNMF.

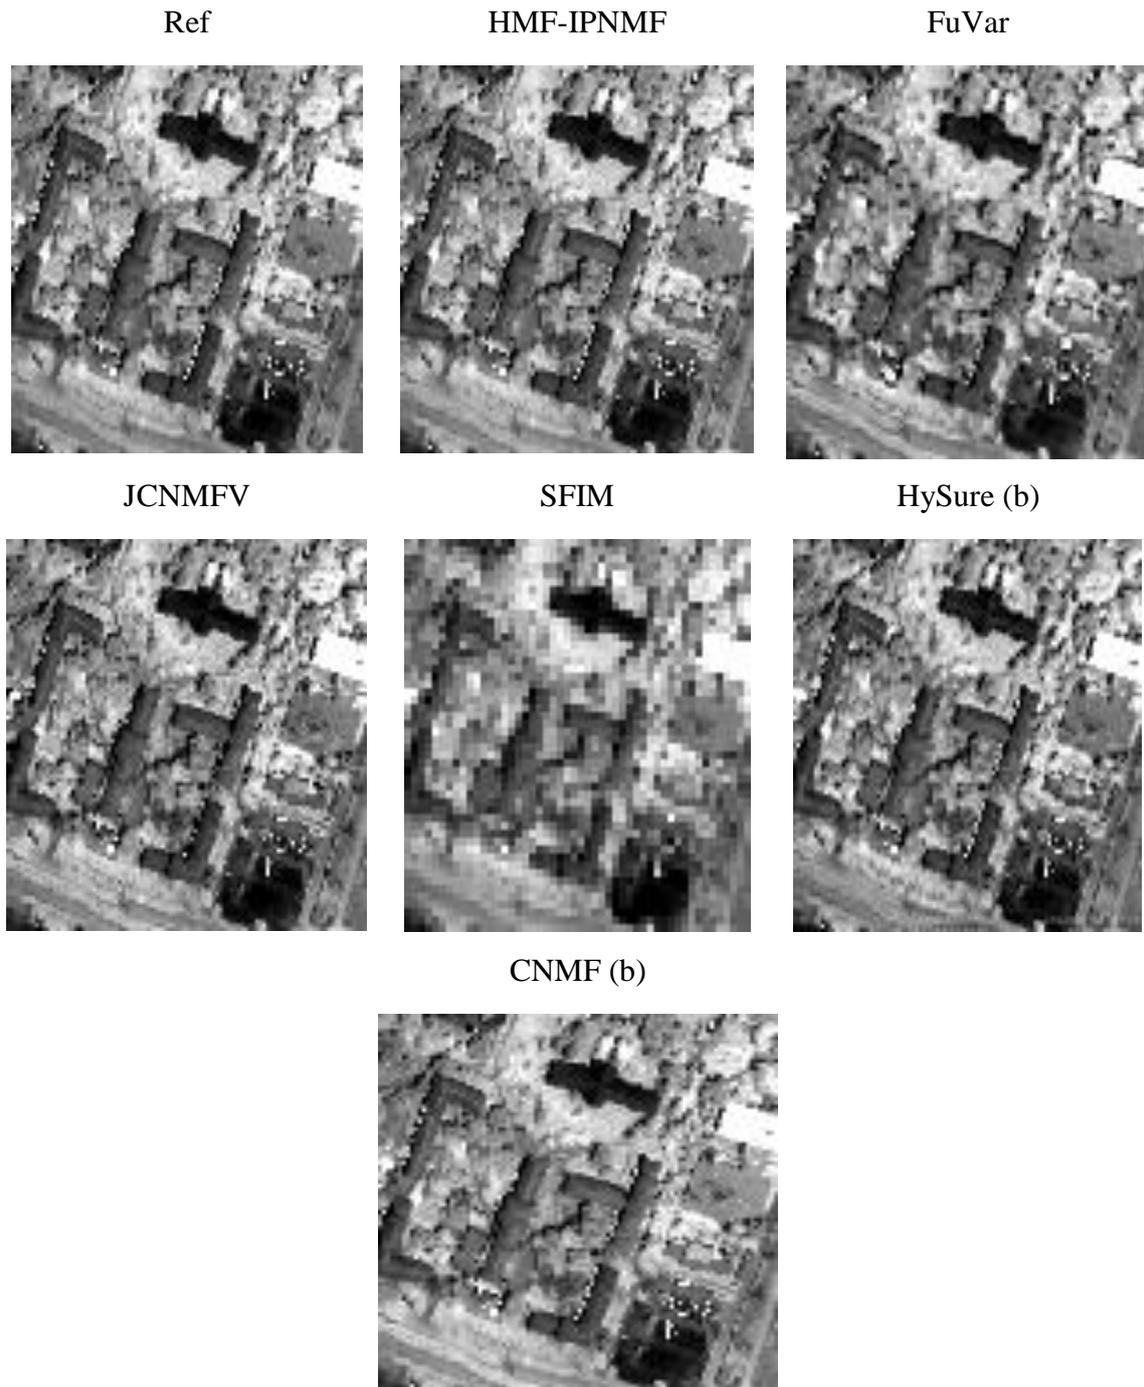


Figure 3.6 : Résultats de fusion des différents algorithmes pour la bande spectrale $0.817 \mu m$ pour le premier jeu de données synthétiques.

Concernant le temps de calcul, les trois méthodes considérant la variabilité spectrale consomment un temps plus important que les autres méthodes car elles prennent en considération le phénomène de variabilité spectrale impliquant plus de variables à gérer.

3.3.2. Résultats sur le deuxième jeu de données synthétiques

Le tableau 3.5 présente les résultats des différentes méthodes ainsi que les temps de calcul obtenus sur le deuxième jeu de données synthétiques.

		HMF-IPNMF	JCNMFV	FuVar	SFIM	CNMF		HySure		JNMF	
						(a)	(b)	(a)	(b)	(a)	(b)
Temps (s)		466.98	989.16	379.36	2.89	0.72	1.20	3.04	10.34	0.94	2.14
Critère	Valeur Idéale										
SAM (°)	0	2.65	3.29	4.35	2.75	3.74	3.64	4.50	4.20	3.69	3.49
$NMSE_\lambda$ (%)	0	4.97	12.25	16.08	7.26	14.97	6.72	10.15	9.15	15.02	15.94
$NMSE_S$ (%)	0	6.99	16.57	20.83	10.45	23.93	8.69	12.12	10.70	19.46	18.47
$PSNR$ (dB)	∞	37.57	33.79	28.04	34.36	26.89	36.09	32.34	33.48	28.46	28.69
$UIQI$	1	0.9819	0.9376	0.9058	0.9712	0.8255	0.9763	0.9652	0.9715	0.8876	0.8989
$ERGAS$	0	2.66	5.12	6.76	3.96	7.82	3.32	3.94	3.54	6.40	5.85

Tableau 3.5 : Valeurs des critères de performance sur le deuxième jeu de données synthétiques.

D'après le tableau 3.5, la HMF-IPNMF conduit aux meilleurs résultats en terme de SAM et de $NMSE_\lambda$, avec des valeurs respectives de 2.65° et 4.97% . Cette conclusion est confirmée par l'aspect spatial en particulier pour l' $ERGAS$ et la $NMSE_S$. En effet, pour une image de résolution spatiale plus faible que le premier jeu de données synthétiques, la HMF-IPNMF permet d'atteindre une fidélité de qualité sur les deux aspects spatial et spectral.

La figure 3.7 illustre les résultats obtenus sur le deuxième jeu de données synthétiques, elle montre clairement d'un point de vue spatial que la HMF-IPNMF mène à la meilleure reconstruction en mettant en évidence plus de détails au niveau des structures des objets présents dans l'image.

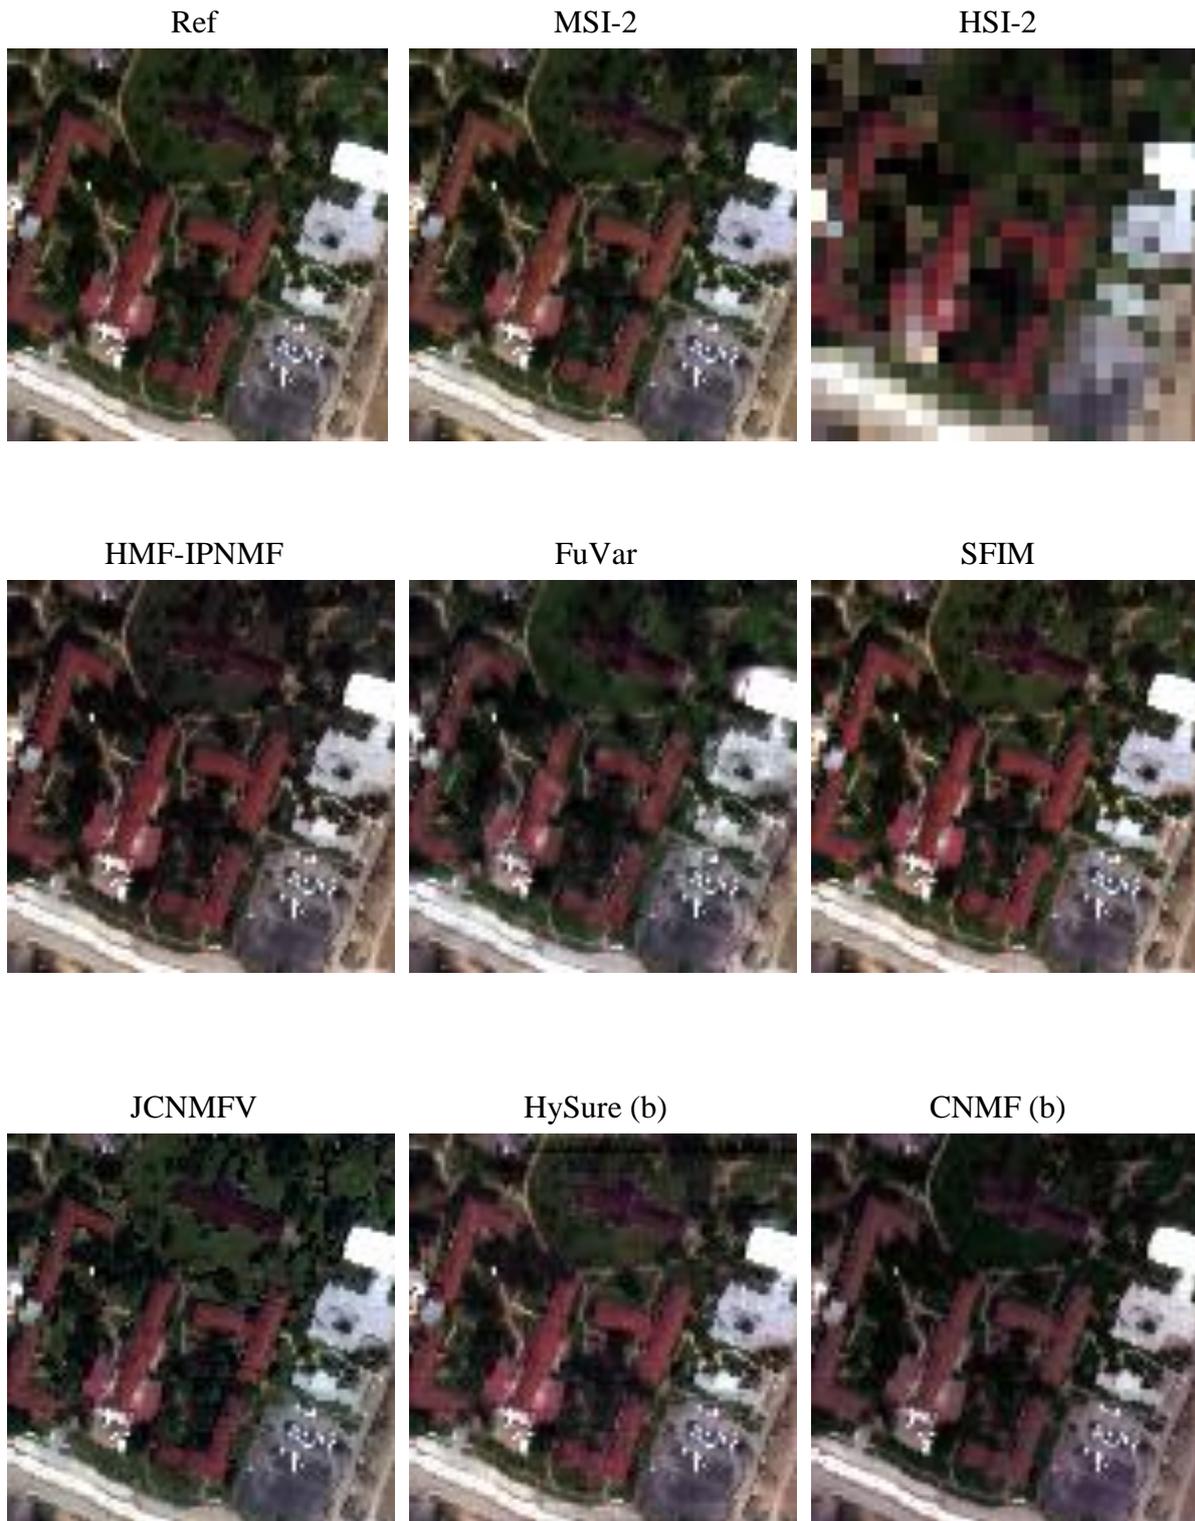


Figure 3.7 : Résultats en RVB de fusion des différents algorithmes pour le deuxième jeu de données synthétiques.

La figure 3.8 illustre les produits de fusion obtenus, nous notons clairement que la HMF-IPNMF restaure plus de détails par rapport aux autres méthodes comparées à l'image

hyperspectrale originale. De plus, la fidélité spectrale est la meilleure d'un point de vue visuel en particulier au niveau des bâtiments et de la végétation alentour.

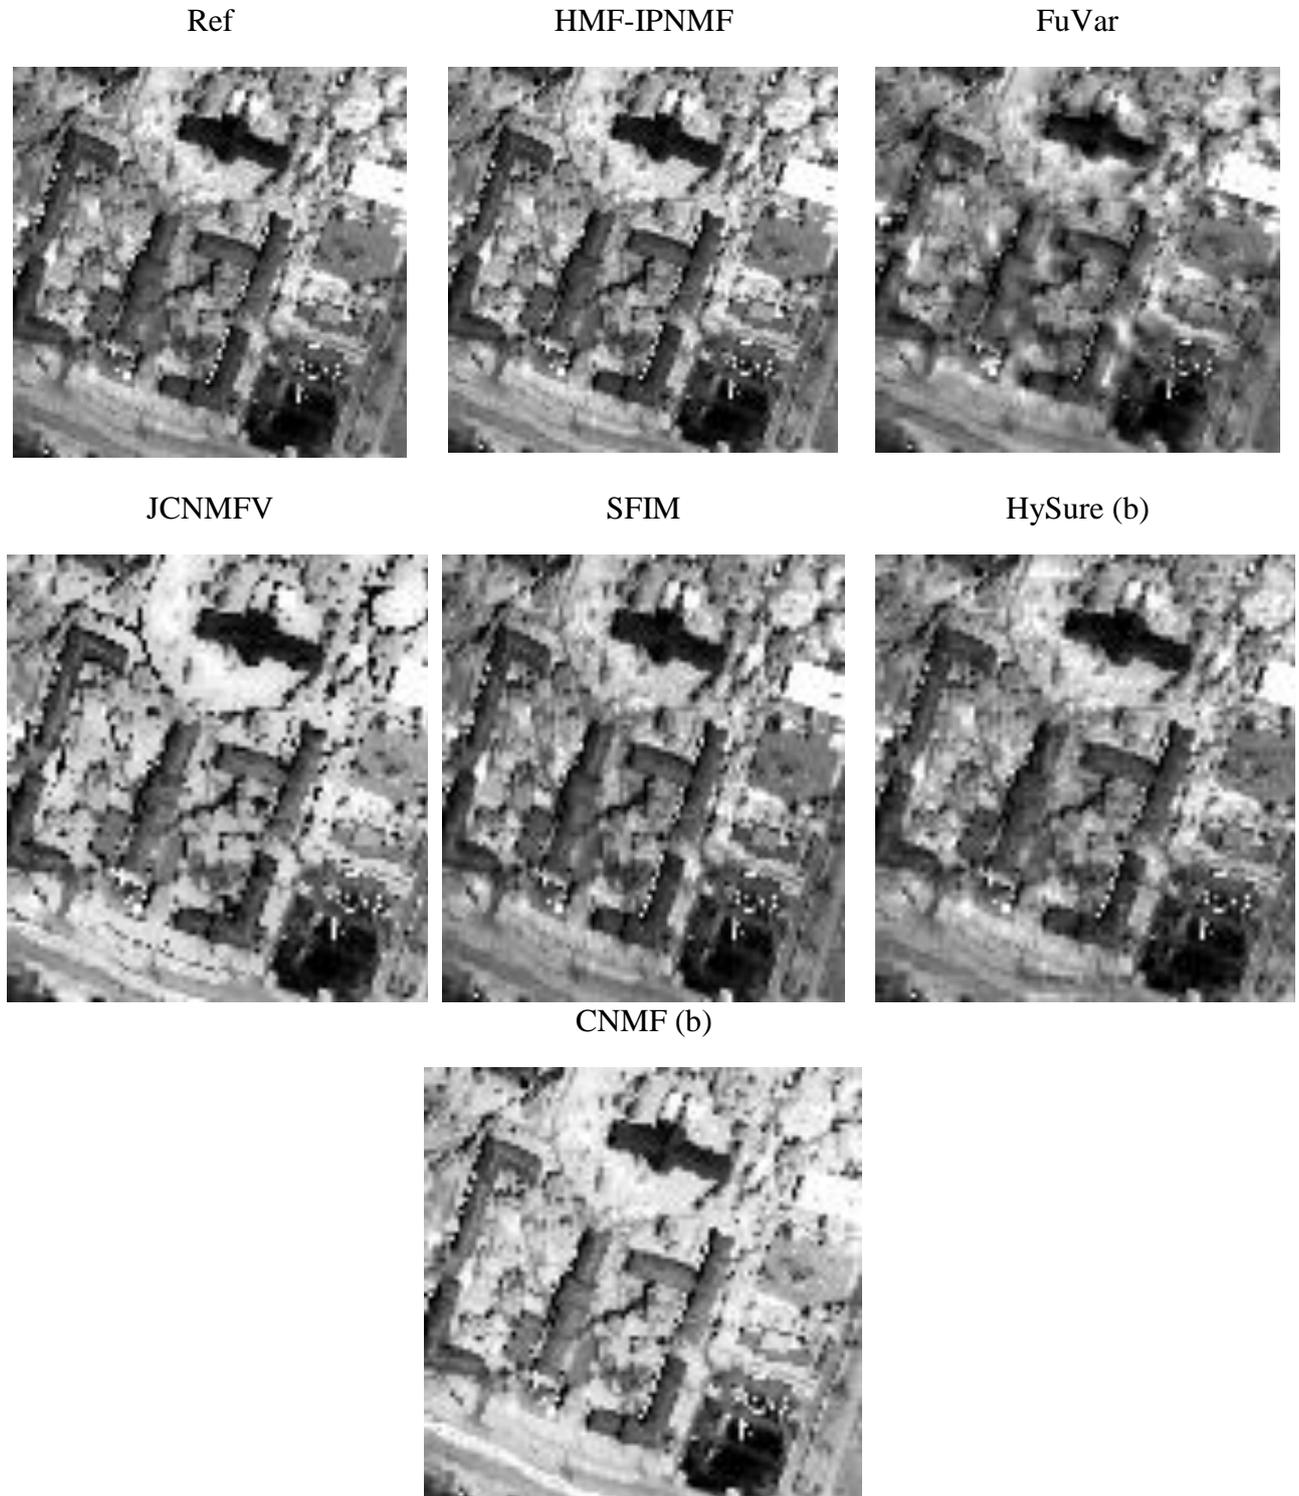


Figure 3.8 : Résultats de fusion des différents algorithmes pour la bande spectrale $0.817 \mu m$ pour le deuxième jeu de données synthétiques

3.3.3. Résultats sur les données réelles

Les résultats obtenus sur les données réelles ainsi que les différents temps de calcul sont reportés dans le tableau 3.6.

		HMF-IPNMF	JCNMFV	FuVar	SFIM	CNMF		HySure		JNMF	
						(a)	(b)	(a)	(b)	(a)	(b)
Temps (s)		537.99	374.92	165.31	0.24	0.96	2.17	1.94	14.98	0.93	3.74
Critère	Valeur Idéale										
D_λ	0	0.0386	0.0495	0.0489	0.0506	0.1265	0.1267	0.0432	0.0444	0.0703	0.0740
D_S	0	0.0088	0.0437	0.0237	0.0577	0.0523	0.0469	0.0097	0.0094	0.0343	0.0123
$mQNR$	1	0.9529	0.9089	0.9285	0.8946	0.8279	0.8323	0.9476	0.9466	0.8979	0.9146

Tableau 3.6 : Valeurs des critères de performance sur les données réelles.

Le tableau 3.6 montre que la HMF-IPNMF gérant la variabilité spectrale mène à des résultats satisfaisants comparés aux résultats des autres méthodes testées. Elle présente les meilleures fidélités pour les deux aspects avec des valeurs les plus faibles de distorsion spectrale et spatiale. En particulier pour la D_λ avec une valeur de 0.0386.

La figure 3.9 illustre les images fusionnées des différentes méthodes, on observe que la FuVar conduit à une bonne reconstruction spatiale mettant en valeur plus de détails par rapport à la SFIM et à la CNMF. La HySure et la HMF-IPNMF présentent également plus de détails et de structures, en particulier la HMF-IPNMF met en évidence plus de détails et de relief au niveau des bâtiments et des routes.

La figure 3.10 montre les produits de la fusion pour la bande $0.815 \mu m$ pour les données réelles. Nous observons une meilleure reconstruction spatiale pour la HMF-IPNMF. En effet, les routes ainsi que les bâtiments autour sont mieux discernables comparés aux autres méthodes testées.

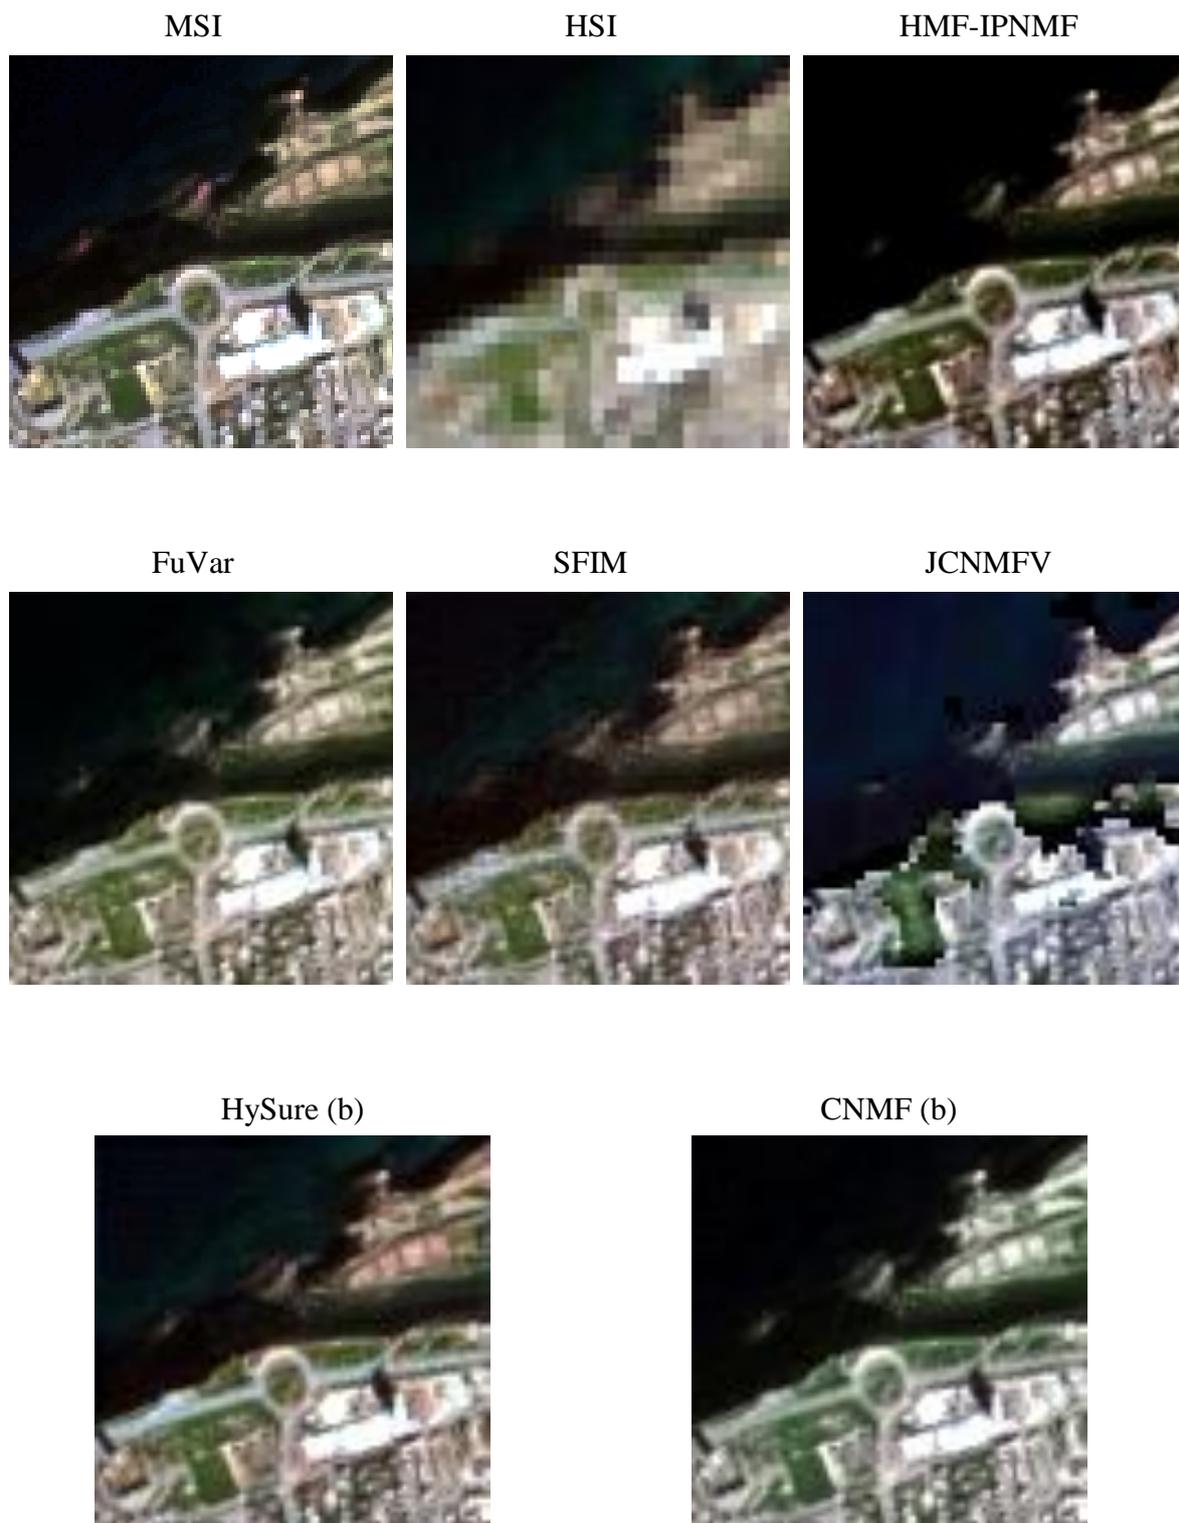


Figure 3.9 : Résultats en RVB de la fusion des différents algorithmes sur les données réelles.

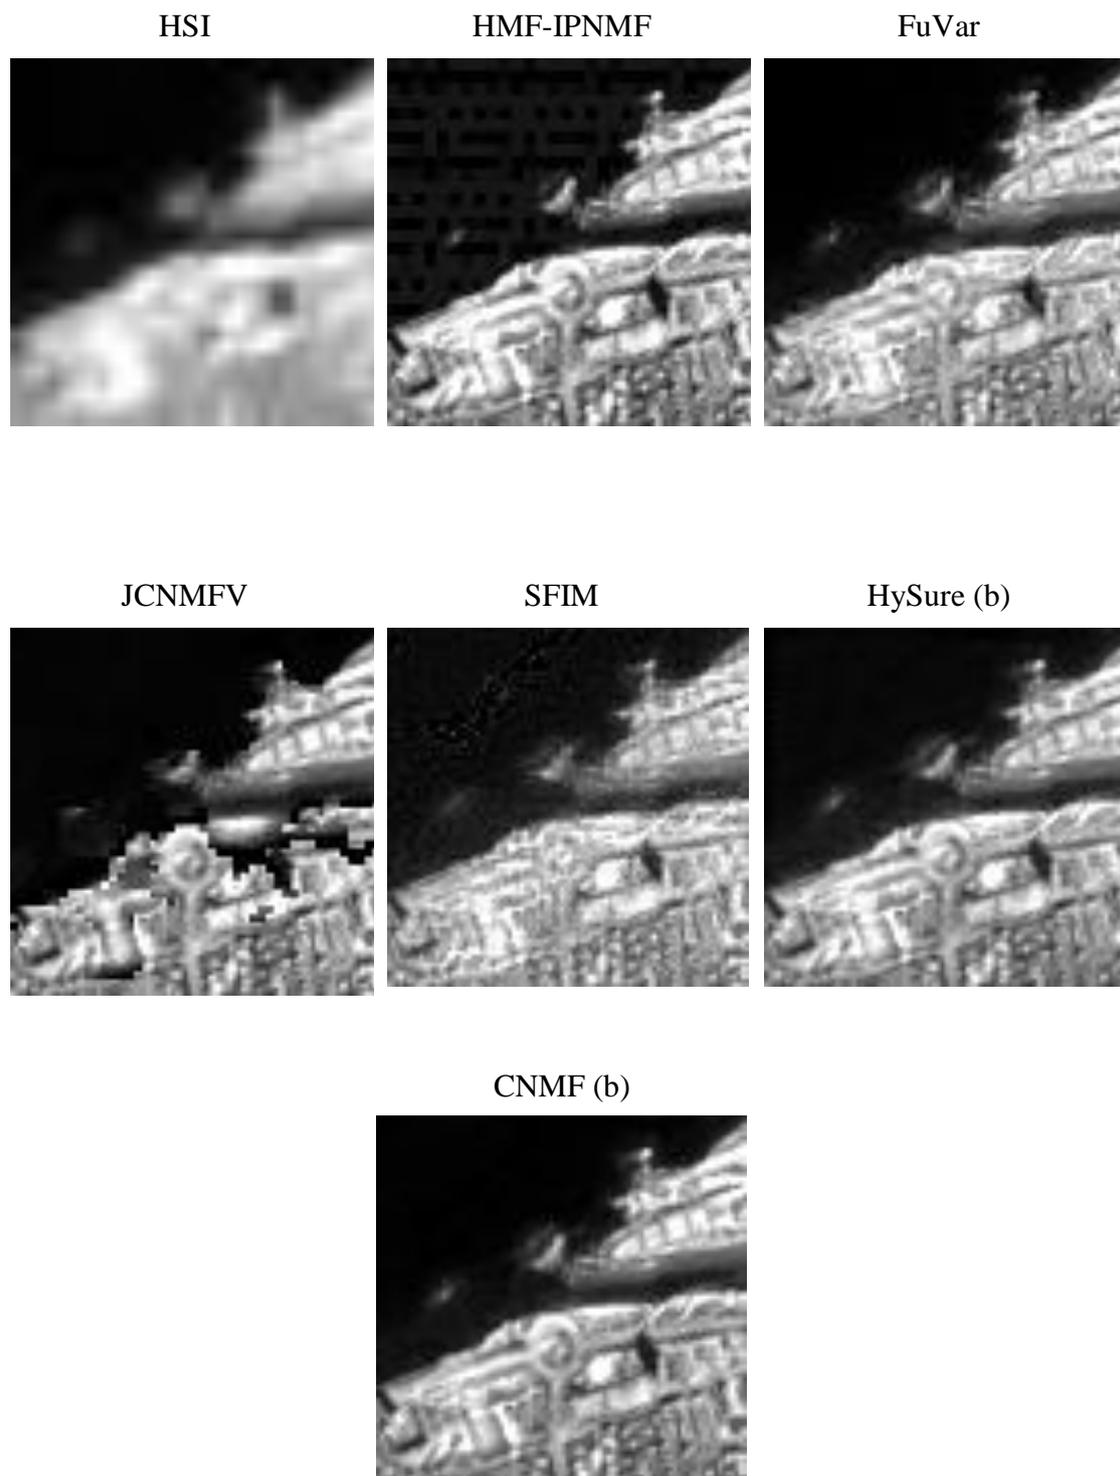


Figure 3.10 : Résultats de fusion des différents algorithmes pour la bande spectrale $0.815 \mu m$ pour données réelles.

3.4. Conclusion

Dans ce chapitre, deux nouvelles approches ont été testées pour la fusion des images multispectrales à haute résolution spatiale et des images hyperspectrales à haute résolution spectrale. Les deux méthodes développées, à savoir la HMF-IPNMF et la JCNMFV considérant la variabilité spectrale, ont été appliquées à des ensembles de données synthétiques et réelles. Leurs performances ont été évaluées en utilisant des critères sur les deux plans spatial et spectral.

Les résultats obtenus démontrent clairement que la HMF-IPNMF dans cette étude permet d'obtenir des images hyperspectrales fusionnées de meilleure qualité avec une fidélité spectrale et spatiale plus fine que les méthodes récentes de la littérature. Les excellentes qualités spatiales et spectrales des données fusionnées, peuvent certainement contribuer à la classification précise d'une région imagée de plus fine résolution.

Conclusion et perspectives

Dans cette deuxième partie de la thèse, les différentes méthodes de fusion des images de télédétection ont été présentées. La première partie de l'état de l'art est dédiée aux techniques de pansharpening. Par la suite, les principales méthodes de multisharpening ou hypersharpening ont été introduites, en particulier les méthodes basées sur le démélange spectral linéaire. La dernière partie de l'état est consacré à l'aspect d'évaluation de la qualité des produits de fusion en présentant les deux types. L'un se base sur la perception humaine qui reste robuste tout en étant sujette à la subjectivité de l'opérateur. L'autre manière d'évaluer un produit de fusion est l'analyse quantitative.

Le deuxième chapitre introduit les deux méthodes proposées : *Hyperspectral and Multispectral data Fusion based on IP-NMF (HMF-IPNMF)* et *Joint-Criterion NMF (JCNMF)* multiplicative étendue. Pour chaque méthode, les algorithmes utilisés sont détaillés. En particulier, les deux méthodes intègrent la variabilité spectrale dans le processus de multisharpening. Dans un premier temps, le modèle mathématique des données est fourni. Par la suite, les étapes et l'algorithme de la HMF-IPNMF sont exposés. Dans un second temps, la JCNMF multiplicative étendue est présentée. En particulier, la modification au niveau du modèle de données pour considérer le phénomène de variabilité spectrale est exposée. Cette adaptation qui concerne les matrices des spectres et des abondances est formulée. De plus, l'algorithme de la JCNMF multiplicative étendue est introduit.

Le dernier chapitre est dédié aux performances des méthodes de fusion d'images de télédétection proposées. Premièrement, la description des données synthétiques et réelles considérées pour les tests est présentée. Les tests et résultats des deux méthodes développées dans ce travail de recherche sont analysés. Les tests des deux méthodes développées, à savoir la HMF-IPNMF et la JCNMF multiplicative étendue considérant la variabilité spectrale, ont été comparées aux récentes méthodes de la littérature. Leurs performances ont été évaluées en utilisant des critères sur les deux plans spatial et spectral. Les résultats obtenus démontrent clairement que les méthodes proposées permettent d'obtenir des images hyperspectrales fusionnées de meilleure qualité en combinant des fidélités spectrale et spatiale plus fines. Les produits de fusion issus de ces méthodes proposées contribueront à la classification précise d'une région imagée de plus fine résolution.

Parmi les perspectives de ces travaux, nous pouvons citer la possibilité d'adapter les matrices des spectres et des abondances utilisées pour intégrer la variabilité à d'autres méthodes de fusion considérant le démélange comme la *Coupled NMF (CNMF)* ou la *Joint NMF (JNMF)*. L'autre perspective possible est l'utilisation d'autres techniques de régression linéaire comme la *Scaled Constrained Least Squares Unmixing (SCLSU)* pour estimer les abondances multispectrales.

Conclusion Générale

L'objectif de cette thèse a été de développer des méthodes de démixage spectral et de fusion d'images afin d'extraire des informations et d'améliorer la résolution des images hyperspectrales dans le cadre de la télédétection. Les méthodes proposées dans les deux thèmes abordés sont issues de la Séparation Aveugle de Sources (SAS). Comme mentionné dans la première partie de la thèse, les méthodes de SAS appliquées dans le cadre d'images hyperspectrales de télédétection considèrent le modèle de mélange linéaire instantané pour sa simplicité. Or, ce dernier est limité essentiellement par deux phénomènes dont l'impact est non-négligeable qui sont la non-linéarité et la variabilité spectrale. La variabilité spectrale est le cœur des travaux de cette thèse. Le but consiste à intégrer la variabilité spectrale dans le démixage spectral et la fusion d'images de télédétection.

La première partie de la thèse a montré la pertinence de prendre en considération le phénomène de la variabilité spectrale et les différentes philosophies pour l'aborder pour le démixage spectral. En particulier l'état de l'art introduit dans le premier chapitre a permis de catégoriser les méthodes traitant la variabilité spectrale. Dans une première expérimentation sur la variabilité spectrale, nous avons appliqué une méthode prenant en considération cette dernière à savoir l'*Inertia-Constrained Pixel-By-Pixel Nonnegative Matrix Factorisation* (IP-NMF) sur des données hyperspectrales de fonds marins. L'analyse du modèle de mélange introduit dans le cadre du projet HypFom (qui vise à développer des modèles et des méthodes avancées d'inversion, d'estimation et de séparation de sources pour la cartographie des fonds marins) et issu des simulations réalisées avec l'outil OSOAA (Ordres Successifs Océan Atmosphère Avancé), a prouvé la possibilité d'appliquer l'IP-NMF pour ce type de données. Suite à cette analyse, des données hyperspectrales ont été générées synthétiquement pour valider l'aspect théorique. Ainsi, des images hyperspectrales comportant une bathymétrie différente au niveau de chaque pixel autour d'une profondeur de référence ont été simulées. Les résultats obtenus ont clairement montré que plus l'intervalle de variation autour de la profondeur de référence augmente plus le gain en terme de performance de l'IP-NMF est meilleur comparé à un cas de variation faible. Une des perspectives naturelles de ce travail est d'appliquer l'IP-NMF à des données synthétiques présentant des bathymétries différentes de celles utilisées pour les expérimentations pour étudier les performances de l'IP-NMF. L'autre aspect intéressant envisagé concerne les performances, en particulier l'erreur de reconstruction, de l'IP-NMF sur des données réelles. La troisième piste est d'appliquer l'IP-NMF ou bien de développer une nouvelle approche dans le cas où les scènes étudiées présentent des fonds non plats qui peuvent engendrer de la non-linéarité.

Le premier chapitre de la première partie a mis en relief que les méthodes paramétriques incorporant la variabilité spectrale dans le modèle de mélange linéaire instantané sont une manière directe et simple de traiter la variabilité spectrale et présentent des performances robustes. Nous avons donc développé de nouvelles méthodes de démixage suivant cette approche. Pour cela un nouveau modèle de mélange a été proposé. Il considère la variabilité spectrale sous une forme additive en intégrant deux nouvelles variables par pixel au modèle de mélange linéaire instantané. Par la suite, trois méthodes ont été développées. Pour chaque méthode, deux algorithmes d'optimisation issus de la classe de méthodes basées sur la NMF ont été introduits dans le chapitre trois de la partie une de ce manuscrit. Par ailleurs, le chapitre trois a permis de comprendre les différents développements et les améliorations apportées au premier modèle de données pour aboutir au troisième modèle qui prend en considération la

Conclusion générale

structure des matrices impliquées et les amplitudes des spectres pour les reconstruire de manière plus efficiente.

Le quatrième chapitre a permis de valider la partie théorique sur des données synthétiques et réelles. En effet, les tests réalisés ont été divisés en deux parties. La première montre clairement que la troisième méthode développée mène à des résultats très satisfaisants en matière de reconstruction spatiale et spectrale, et en particulier pour des données en présence de bruit conséquent comparée aux deux autres approches proposées. De plus, une étude sur l'initialisation des différents algorithmes prenant en compte la variabilité spectrale permet de fixer une initialisation particulière pour gagner en performance sur l'estimation des spectres pour les trois méthodes proposées. La deuxième partie des tests a analysé les techniques développées pour les comparer aux différentes méthodes récentes de la littérature. Les approches utilisées pour la comparaison s'inscrivent dans la classe des techniques paramétriques et gèrent de manière différente la variabilité spectrale. Les études sur des données synthétiques et réelles démontrent clairement que la troisième méthode proposée, dans sa version multiplicative, conduit aux meilleures performances. Par ailleurs, la méthode d'initialisation apporte un gain aux approches de la littérature dans le cas des données réelles.

Une des extensions envisagées concerne la pénalisation des abondances dans le cas d'une scène incluant des zones homogènes pour augmenter la parcimonie des abondances.

La deuxième partie de la thèse a été consacrée à l'aspect fusion d'images de télédétection pour améliorer la résolution spatiale des images hyperspectrales. Le premier chapitre de cette partie est dédié à l'état de l'art sur la fusion d'images de télédétection en présentant les méthodes de pansharpening dans un premier temps, et par la suite, les techniques de multisharpening. De plus, les différentes méthodes d'évaluation des produits de fusion, suivant l'analyse d'un opérateur humain et les métriques, ont été introduites.

Le deuxième chapitre présente les deux méthodes développées : *Hyperspectral and Multispectral data Fusion based on IP-NMF* (HMF-IPNMF) et *Joint-Criterion NMF* (JCNMF) multiplicative étendue pour le cas de la variabilité spectrale (JCNMFV). L'algorithme de la HMF-IPNMF est présenté, il considère une stratégie séquentielle simple intégrant la variabilité spectrale pour estimer les spectres hyperspectraux et les abondances multispectrales pour les fusionner et obtenir le produit de fusion. L'extension de la JCNMF concerne la modification des matrices des spectres et des abondances pour gérer le phénomène de la variabilité spectrale.

Le chapitre trois de la deuxième partie a mis en évidence les performances des méthodes de fusion proposées en les comparant avec des méthodes récentes de fusion. Les expérimentations réalisées ont été divisées en deux parties. La première considère le protocole de Wald pour créer des données synthétiques avec des facteurs de dégradation spatiale de deux et quatre respectivement. Les résultats des métriques permettent de conclure que la HMF-IPNMF que mène aux meilleures performances. La deuxième partie valide sur la base de critère de performances les conclusions obtenues sur les données synthétiques et sur des données réelles. Sur la base de ces travaux de recherche, plusieurs perspectives peuvent être suivies comme : appliquer l'adaptation utilisée au niveau du modèle de données de la JCNMF aux autres méthodes basées sur la NMF comme *Coupled NMF* (CNMF) ou la *Joint NMF* (JNMF). L'autre perspective est d'appliquer la *Scaled Constrained Least Squares Unmixing* (SCLSU) pour estimer les abondances multispectrales. En effet, cette dernière permet d'une certaine manière d'intégrer la variabilité spectrale car c'est un cas particulier de l'*Extended Linear Mixing Model*.

Références bibliographiques

- [1] S. Paul and G. Ducher, *Terminologie de télédétection et photogrammétrie : manuel terminologique didactique de télédétection et photogrammétrie : français-anglais*. Conseil international de la langue française, 1997.
- [2] K. Tempfli, G.C. Huurneman, W.H. Bakker, L.L.F. Janssen, W.F. Feringa, A.S.M. Gieske, K.A. Grabmaier, C.A. Hecker, J.A. Horn, N. Kerle, F.D. van der Meer, G.N. Parodi, C. Pohl, C.V. Reeves, F.J.A. van Ruitenbeek, E.M. Schetselaar, M.J.C. Weir, E. Westinga and T. Woldai, *Principles of Remote Sensing: An Introductory Textbook*. ITC, 2009.
- [3] S. Khorram, C. F. van der Wiele, F. H. Koch, S. A. C. Nelson, and M. D. Potts, *Principles of applied remote sensing*. Springer, 2016.
- [4] S. Liang and J. Wang, “A systematic view of remote sensing,” in *Advanced Remote Sensing (Second Edition) Terrestrial Information Extraction and Applications*, Academic Press, 2020, pp. 1–57.
- [5] L. Giannoni, F. Lange, and I. Tachtsidis, “Hyperspectral imaging solutions for brain tissue metabolic and hemodynamic monitoring: Past, current and future developments,” *J. Opt. (United Kingdom)*, vol. 20, no. 4, p. 44009, 2018, doi: 10.1088/2040-8986/aab3a6.
- [6] P. Pradham, N. H. Younan, and R. L. King, “Concepts of image fusion in remote sensing applications,” in *Image Fusion: Algorithms and Applications*, A. Press, Ed. 2008, pp. 391–428.
- [7] E. Christophe, C. Mailhes, and P. Duhamel, “Hyperspectral image compression: Adapting SPIHT and EZW to anisotropic 3-D wavelet coding,” *IEEE Trans. Image Process.*, vol. 17, no. 12, pp. 2334–2346, 2008, doi: 10.1109/TIP.2008.2005824.
- [8] J. A. Richards and J. Xiuping, *Remote Sensing Digital Image Analysis*, 4 th edition. Berlin Heidelberg: Springer-Verlag, 2006.
- [9] R. A. Borsoi T. Imbiriba, J.C.M. Bermudez, C. Richard, J. Chanussot, L. Drumetz, J. Tourneret, A. Zare and C. Jutten, “Spectral variability in hyperspectral data unmixing: A comprehensive review,” *arXiv*, pp. 1–37, 2020.
- [10] 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 J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 5, no. 2, pp. 354–379, 2012, doi: 10.1109/JSTARS.2012.2194696.
- [11] P. Comon and C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*. Academic Press, 2010.
- [12] Y. Deville, “Blind Source Separation and Blind Mixture Identification Methods,” *Wiley Encyclopedia of Electrical and Electronics Engineering*. pp. 1–33, Feb. 2016, doi: <https://doi.org/10.1002/047134608X.W8300>.
- [13] B. Somers, G. P. Asner, L. Tits, and P. Coppin, “Endmember variability in Spectral Mixture Analysis: A review,” *Remote Sens. Environ.*, vol. 115, no. 7, pp. 1603–1616, 2011, doi: <https://doi.org/10.1016/j.rse.2011.03.003>.

- [14] A. Zare and K. C. Ho, “Endmember Variability in Hyperspectral Analysis: Addressing Spectral Variability During Spectral Unmixing,” *IEEE Signal Process. Mag.*, vol. 31, no. 1, pp. 95–104, 2014, doi: 10.1109/MSP.2013.2279177.
- [15] N. Dobigeon, J.-Y. Tournet, C. Richard, J. C. M. Bermudez, S. McLaughlin, and A. O. Hero, “Nonlinear Unmixing of Hyperspectral Images: Models and Algorithms,” *IEEE Signal Process. Mag.*, vol. 31, no. 1, pp. 82–94, 2014, doi: 10.1109/MSP.2013.2279274.
- [16] I. Meganem, P. Déliot, X. Briottet, Y. Deville, and S. Hosseini, “Linear-quadratic mixing model for reflectances in urban environments,” *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 1, pp. 544–558, 2014, doi: 10.1109/TGRS.2013.2242475.
- [17] I. Meganem, Y. Deville, S. Hosseini, P. Déliot, and X. Briottet, “Linear-quadratic blind source separation using NMF to unmix urban hyperspectral images,” *IEEE Trans. Signal Process.*, vol. 62, no. 7, pp. 1822–1833, 2014, doi: 10.1109/TSP.2014.2306181.
- [18] C. Revel, Y. Deville, V. Achard, X. Briottet, and C. Weber, “Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation: A Hyperspectral Unmixing Method Dealing with Intra-Class Variability,” *Remote Sensing*, vol. 10, no. 11. 2018, doi: 10.3390/rs10111706.
- [19] N. Keshava and J. F. Mustard, “Spectral unmixing,” *IEEE Signal Process. Mag.*, vol. 19, no. 1, pp. 44–57, 2002, doi: 10.1109/79.974727.
- [20] P. Comon, “Independent component analysis, a new concept,” *Signal Processing*, vol. 36, pp. 287–314, 1994, doi: 10.1016/0165-1684(94)90029-9.
- [21] J. M. P. Nascimento and J. M. B. Dias, “Does independent component analysis play a role in unmixing hyperspectral data?,” *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 1, pp. 175–187, 2005, doi: 10.1109/TGRS.2004.839806.
- [22] D. Benachir, Y. Deville, S. Hosseini, M. S. Karoui, and A. Hameurlain, “Hyperspectral image unmixing by non-negative matrix factorization initialized with modified independent component analysis,” in *2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 2013, pp. 1–4, doi: 10.1109/WHISPERS.2013.8080719.
- [23] 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,” in *2013 IEEE 11th International Workshop of Electronics, Control, Measurement, Signals and their application to Mechatronics*, 2013, pp. 1–6, doi: 10.1109/ecmsm.2013.6648948.
- [24] M. Plumbley, “Conditions for nonnegative independent component analysis,” *IEEE Signal Process. Lett.*, vol. 9, no. 6, pp. 177–180, 2002, doi: 10.1109/LSP.2002.800502.
- [25] M. D. Plumbley, “Algorithms for nonnegative independent component analysis,” *IEEE Trans. Neural Networks*, vol. 14, no. 3, pp. 534–543, 2003, doi: 10.1109/TNN.2003.810616.
- [26] N. Dobigeon, J. Tournet, and C. Chang, “Semi-Supervised Linear Spectral Unmixing Using a Hierarchical Bayesian Model for Hyperspectral Imagery,” *IEEE Trans. Signal Process.*, vol. 56, no. 7, pp. 2684–2695, 2008, doi: 10.1109/TSP.2008.917851.

- [27] N. Dobigeon, S. Moussaoui, M. Coulon, J. Y. Tourneret, and A. O. Hero, “Joint Bayesian endmember extraction and linear unmixing for hyperspectral imagery,” *IEEE Trans. Signal Process.*, vol. 57, no. 11, pp. 4355–4368, 2009, doi: 10.1109/TSP.2009.2025797.
- [28] F. Z. Benhalouche, “Méthodes de démixage et de fusion des images multispectrales et hyperspectrales de télédétection spatiale,” , Thèse de doctorat, Université Toulouse III – Paul Sabatier et Université des Sciences et de la Technologie d’Oran, 2018.
- [29] M. Parente and A. Plaza, “Survey of geometric and statistical unmixing algorithms for hyperspectral images,” in *2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, 2010, pp. 1–4, doi: 10.1109/WHISPERS.2010.5594929.
- [30] A. Plaza, P. Martínez, R. Pérez, and J. Plaza, “A quantitative and comparative analysis of endmember extraction algorithms from hyperspectral data,” *IEEE Trans. Geosci. Remote Sens.*, vol. 42, no. 3, pp. 650–663, 2004, doi: 10.1109/TGRS.2003.820314.
- [31] J. W. Boardman, F. A. Kruse, and R. O. Green, “Mapping target signatures via partial unmixing of AVIRIS data.,” *Fifth JPL Airborne Earth Sci. Work.*, vol. 95, no. JPL Publication, pp. 23–26, 1995.
- [32] A. A. Green, M. Berman, P. Switzer, and M. D. Craig, “A Transformation for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal,” *IEEE Trans. Geosci. Remote Sens.*, vol. 26, no. 1, pp. 65–74, 1988, doi: 10.1109/36.3001.
- [33] C. I. Chang and A. Plaza, “A fast iterative algorithm for implementation of pixel purity index,” *IEEE Geosci. Remote Sens. Lett.*, vol. 3, no. 1, pp. 63–67, 2006, doi: 10.1109/LGRS.2005.856701.
- [34] M. E. Winter, “N-FINDR: an algorithm for fast spectral endmember determination in hyperspectral data,” in *Proc. SPIE*, 1999, vol. 3753, no. July, pp. 266–275, doi: 10.1117/12.366289.
- [35] J. Plaza, E. M. T. Hendrix, I. García, G. Martín, and A. Plaza, “On Endmember Identification in Hyperspectral Images Without Pure Pixels: A Comparison of Algorithms,” *J. Math. Imaging Vis.*, vol. 42, no. 2, pp. 163–175, 2012, doi: 10.1007/s10851-011-0276-0.
- [36] J. H. Gruninger, A. J. Ratkowski, and M. L. Hoke, “The sequential maximum angle convex cone (SMACC) endmember model,” in *In Algorithms and technologies for multispectral, hyperspectral, and ultraspectral imagery X*, 2004, vol. 5425, pp. 1–14, doi: 10.1117/12.543794.
- [37] J. M. P. Nascimento and J. M. Bioucas-Dias, “Vertex component analysis: A fast algorithm to unmix hyperspectral data,” *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 4, pp. 898–910, 2005, doi: 10.1109/TGRS.2005.844293.
- [38] I. T. Jolliffe, *Principal Component Analysis*, Springer S. New York: Springer-Verlag, 2002.
- [39] L. Miao and H. Qi, “Endmember Extraction From Highly Mixed Data Using Minimum Volume Constrained Nonnegative Matrix Factorization,” *IEEE Trans. Geosci. Remote Sens.*, vol. 45, no. 3, pp. 765–777, 2007, doi: 10.1109/TGRS.2006.888466.

- [40] J. Li, A. Agathos, D. Zaharie, J. M. Bioucas-Dias, A. Plaza, and X. Li, "Minimum volume simplex analysis: A fast algorithm for linear hyperspectral unmixing," *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 9, pp. 5067–5082, 2015, doi: 10.1109/TGRS.2015.2417162.
- [41] J. Li and J. Bioucas-Dias, "Minimum Volume Simplex Analysis: A Fast Algorithm to Unmix Hyperspectral Data," in *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*, 2008, pp. 250–253, doi: 10.1109/IGARSS.2008.4779330.
- [42] J. M. Bioucas-Dias, "A variable splitting augmented Lagrangian approach to linear spectral unmixing," in *2009 First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, 2009, pp. 1–4, doi: 10.1109/WHISPERS.2009.5289072.
- [43] D. C. Heinz and C. I. Chang, "Fully Constrained Least Squares Linear Spectral Mixture Analysis Method for Material Quantification in Hyperspectral Imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 39, no. 3, pp. 529–545, 2001, doi: 10.1109/36.911111.
- [44] J. M. Bioucas-Dias and M. A. T. Figueiredo, "Alternating direction algorithms for constrained sparse regression: Application to hyperspectral unmixing," in *2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, WHISPERS 2010 - Workshop Program*, 2010, pp. 1–4, doi: 10.1109/WHISPERS.2010.5594963.
- [45] M. Iordache, J. M. Bioucas-Dias, and A. Plaza, "Sparse Unmixing of Hyperspectral Data," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 6, pp. 2014–2039, 2011, doi: 10.1109/TGRS.2010.2098413.
- [46] M. Iordache, J. M. Bioucas-Dias, and A. Plaza, "Total variation spatial regularization for sparse hyperspectral unmixing," *IEEE Trans. Geosci. Remote Sens.*, vol. 50, no. 11, pp. 4484–4502, 2012, doi: 10.1109/TGRS.2012.2191590.
- [47] M. Iordache, J. M. Bioucas-Dias, A. Plaza, and B. Somers, "MUSIC-CSR: Hyperspectral unmixing via multiple signal classification and collaborative sparse regression," *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 7, pp. 4364–4382, 2014, doi: 10.1109/TGRS.2013.2281589.
- [48] X. Fu, W. K. Ma, J. M. Bioucas-Dias, and T. H. Chan, "Semiblind Hyperspectral Unmixing in the Presence of Spectral Library Mismatches," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 9, pp. 5171–5184, 2016, doi: 10.1109/TGRS.2016.2557340.
- [49] Z. Zhang, S. Liao, H. Fang, H. Zhang, and S. Wang, "Sparse hyperspectral unmixing using spectral library adaptive adjustment," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 12, no. 12, pp. 4873–4887, 2019, doi: 10.1109/JSTARS.2019.2939829.
- [50] 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 Recognit.*, vol. 45, no. 12, pp. 4263–4278, 2012, doi: 10.1016/j.patcog.2012.05.008.

- [51] 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,” in *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2012, pp. 3074–3077, doi: 10.1109/IGARSS.2012.6350776.
- [52] 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,” in *2013 8th International Workshop on Systems, Signal Processing and Their Applications, WoSSPA 2013*, 2013, pp. 42–49, doi: 10.1109/WoSSPA.2013.6602334.
- [53] D. Benachir, Y. Deville, S. Hosseini, and M. S. Karoui, “Blind unmixing of hyperspectral remote sensing data: A new geometrical method based on a two-source sparsity constraint,” *Remote Sens.*, vol. 12, no. 19, pp. 1–25, 2020, doi: 10.3390/rs12193198.
- [54] P. Paatero, U. Tapper, P. Aalto, and M. Kulmala, “Matrix factorization methods for analyzing diffusion battery data,” *J. Aerosol Sci.*, vol. 22(S1), pp. 273–276, 1991, doi: 10.1016/S0021-8502(05)80089-8.
- [55] D. D. Lee and H. S. Seung, “Learning the parts of objects by non-negative matrix factorization,” *Nature*, vol. 401, pp. 788–791, 1999, doi: 10.1038/44565.
- [56] A. Cichocki, R. Zdunek, and S. I. Amari, “Nonnegative matrix and tensor factorization [lecture notes],” *IEEE Signal Process. Mag.*, vol. 25, no. 1, pp. 142–145, 2008, doi: 10.1109/MSP.2008.4408452.
- [57] I. S. Dhillon and S. Sra, “Generalized nonnegative matrix approximations with Bregman divergences,” *Neural Inf. Process. Syst.*, pp. 283–290, 2005.
- [58] D. Donoho and V. Stodden, “When does non-negative matrix factorization give a correct decomposition into parts?,” *Neural Inf. Process. Syst.*, vol. 16, pp. 1141–1149, 2003.
- [59] M. S. Karoui, “Méthodes de séparation aveugle de sources et applications,” Thèse de doctorat, Université Toulouse III – Paul Sabatier et Université des Sciences et de la Technologie d’Oran, 2012.
- [60] 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*, John Wiley. Chichester, UK, 2009.
- [61] S. Wild, J. Curry, and A. Dougherty, “Improving non-negative matrix factorizations through structured initialization,” *Pattern Recognit.*, vol. 37, no. 11, pp. 2217–2232, 2004, doi: 10.1016/j.patcog.2004.02.013.
- [62] H. Qiao, “New SVD based initialization strategy for non-negative matrix factorization,” *Pattern Recognit. Lett.*, vol. 63, pp. 71–77, 2015, doi: 10.1016/j.patrec.2015.05.019.
- [63] P. Hoyer, “Non-negative sparse coding,” in *Proceedings of the 12th IEEE Workshop on Neural Networks for Signal Processing*, 2002, pp. 557–565, doi: 10.1109/NNSP.2002.1030067.
- [64] S. Essid and C. Févotte, “Smooth nonnegative matrix factorization for unsupervised audiovisual document structuring,” *IEEE Trans. Multimed.*, vol. 15, no. 2, pp. 415–425, 2013, doi: 10.1109/TMM.2012.2228474.

- [65] A. Cichocki and R. Zdunek, "Multilayer nonnegative matrix factorization using projected gradient approaches," *Int. J. Neural Syst.*, vol. 17, no. 6, pp. 431–446, 2007.
- [66] C. J. Lin, "Projected gradient methods for nonnegative matrix factorization," *Neural Comput.*, vol. 19, no. 10, pp. 2756–2779, 2007, doi: 10.1162/neco.2007.19.10.2756.
- [67] D. D. Lee and H. S. Seung, "Algorithms for Non-Negative Matrix Factorization," *Neural Inf. Process. Syst.*, 2001, doi: 10.1142/S1793005715400013.
- [68] 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, no. 2, pp. 111–126, 1994, doi: 10.1002/env.3170050203.
- [69] Y. Qian, S. Jia, J. Zhou, and A. Robles-Kelly, "Hyperspectral Unmixing via L1/2 Sparsity-Constrained Nonnegative Matrix Factorization," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 11, pp. 4282–4297, 2011, doi: 10.1109/TGRS.2011.2144605.
- [70] W. He, H. Zhang, and L. Zhang, "Total variation regularized non-negative matrix factorization for smooth hyperspectral unmixing," *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 7, pp. 3909–3921, 2017, doi: 10.1109/TGRS.2017.2683719.
- [71] X. R. Feng, H. C. Li, J. Li, Q. Du, A. Plaza, and W. J. Emery, "Hyperspectral unmixing using sparsity-constrained deep nonnegative matrix factorization with total variation," *IEEE Trans. Geosci. Remote Sens.*, vol. 56, no. 10, pp. 6245–6257, 2018, doi: 10.1109/TGRS.2018.2834567.
- [72] A. Robin, K. Cawse-Nicholson, A. Mahmood, and M. Sears, "Estimation of the Intrinsic Dimension of Hyperspectral Images: Comparison of Current Methods," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 8, no. 6, pp. 2854–2861, 2015, doi: 10.1109/JSTARS.2015.2432460.
- [73] C. I. Chang and Q. Du, "Estimation of number of spectrally distinct signal sources in hyperspectral imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 42, no. 3, pp. 608–619, 2004, doi: 10.1109/TGRS.2003.819189.
- [74] J. M. Bioucas-Dias and J. M. P. Nascimento, "Hyperspectral subspace identification," *IEEE Trans. Geosci. Remote Sens.*, vol. 46, no. 8, pp. 2435–2445, 2008, doi: 10.1109/TGRS.2008.918089.
- [75] L. Gao, Q. Du, W. Yang, and B. Zhang, "A comparative study on noise estimation for hyperspectral imagery," *Work. Hyperspectral Image Signal Process. Evol. Remote Sens.*, vol. 6, no. 2, pp. 488–498, 2013, doi: 10.1109/WHISPERS.2012.6874262.
- [76] P. Huard and R. Marion, "Study of non-linear mixing in hyperspectral imagery -A first attempt in the laboratory," in *Workshop on Hyperspectral Image and Signal Processing, Evolution in Remote Sensing*, 2011, pp. 1–4, doi: 10.1109/WHISPERS.2011.6080953.
- [77] F. Z. Benhalouche, Y. Deville, M. S. Karoui, and A. Ouamri, "Hyperspectral Unmixing Based on Constrained Bilinear or Linear-Quadratic Matrix Factorization," *Remote Sens.*, vol. 13, no. 11, 2021, doi: <https://doi.org/10.3390/rs13112132>.
- [78] F. Z. Benhalouche, Y. Deville, M. S. Karoui, and A. Ouamri, "Bilinear matrix factorization using a gradient method for hyperspectral endmember spectra extraction," in *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016, pp. 6565–6568, doi: 10.1109/IGARSS.2016.7730715.

- [79] J. Broadwater and A. Banerjee, "Mapping intimate mixtures using an adaptive kernel-based technique," in *2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 2011, pp. 1–4, doi: 10.1109/WHISPERS.2011.6080881.
- [80] C. Revel, "Apport de la prise en compte de la variabilité intra-classe dans les méthodes de démixtion hyperspectral pour l'imagerie urbaine.," Thèse de doctorat, Université Toulouse III – Paul Sabatier, 2016.
- [81] J. Plaza, A. Plaza, R. Pérez, and P. Martínez, "Joint linear/nonlinear spectral unmixing of hyperspectral image data," in *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2007, pp. 4037–4040, doi: 10.1109/IGARSS.2007.4423735.
- [82] R. Heylen, D. Burazerović, and P. Scheunders, "Non-linear spectral unmixing by geodesic simplex volume maximization," *IEEE J. Sel. Top. Signal Process.*, vol. 5, no. 3, pp. 534–542, 2011, doi: 10.1109/JSTSP.2010.2088377.
- [83] Y. Altmann, N. Dobigeon, and J. Y. Tourneret, "Unsupervised post-nonlinear unmixing of hyperspectral images using a Hamiltonian Monte Carlo algorithm," *IEEE Trans. Image Process.*, vol. 23, no. 6, pp. 2663–2675, 2014, doi: 10.1109/TIP.2014.2314022.
- [84] A. Halimi, Y. Altmann, N. Dobigeon, and J. Y. Tourneret, "Nonlinear unmixing of hyperspectral images using a generalized bilinear model," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 11, pp. 4153–4162, 2011, doi: 10.1109/TGRS.2010.2098414.
- [85] P. Garder, D. Dranishnikov, A. Zare, and J. Chanusso, "A sparsity promoting bilinear unmixing model," in *2012 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 2012, pp. 1–4, doi: 10.1109/WHISPERS.2012.6874255.
- [86] N. Yokoya, J. Chanussot, and A. Iwasaki, "Generalized bilinear model based nonlinear unmixing using semi-nonnegative matrix factorization," *2012 IEEE Int. Geosci. Remote Sens. Symp.*, 2012, doi: 10.1109/IGARSS.2012.6351282.
- [87] M. S. Karoui, F. Z. Benhalouche, Y. Deville, and K. Djerriri, "A Linear NMF-Unmixing-Based Approach Addressing Spectral Variability for Shadow Compensation in Hyperspectral Remote Sensing Data," *2020 Mediterr. Middle-East Geosci. Remote Sens. Symp. M2GARSS 2020 - Proc.*, pp. 121–124, 2020, doi: 10.1109/M2GARSS47143.2020.9105294.
- [88] B. Hapke, *Theory of Reflectance and Emittance Spectroscopy (2nd ed.)*. Cambridge University Press, 2012.
- [89] B. Griffin, M. K. Griffin, and H. K. Burke, "Compensation of Hyperspectral Data for Atmospheric Effects," *Lincoln Lab. J.*, vol. 14, no. 1, pp. 29–54, 2003.
- [90] M. A. Cochrane, "Using vegetation reflectance variability for species level classification of hyperspectral data," *Int. J. Remote Sens.*, vol. 21, no. 10, pp. 2075–2087, 2000, doi: 10.1080/01431160050021303.

- [91] D. A. Roberts, M. Gardner, R. Church, S. Ustin, G. Scheer, and R. O. Green, "Mapping chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models," *Remote Sens. Environ.*, vol. 65, no. 3, pp. 267–279, 1998, doi: 10.1016/S0034-4257(98)00037-6.
- [92] P. E. Dennison, K. Q. Halligan, and D. A. Roberts, "A comparison of error metrics and constraints for multiple endmember spectral mixture analysis and spectral angle mapper," *Remote Sens. Environ.*, vol. 93, no. 3, pp. 359–367, 2004, doi: 10.1016/j.rse.2004.07.013.
- [93] C. Quintano, A. Fernández-Manso, and D. A. Roberts, "Multiple Endmember Spectral Mixture Analysis (MESMA) to map burn severity levels from Landsat images in Mediterranean countries," *Remote Sens. Environ.*, vol. 136, pp. 76–88, 2013, doi: 10.1016/j.rse.2013.04.017.
- [94] R. Heylen, A. Zare, P. Gader, and P. Scheunders, "Hyperspectral Unmixing with Endmember Variability via Alternating Angle Minimization," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 8, pp. 4983–4993, 2016, doi: 10.1109/TGRS.2016.2554160.
- [95] C. Ann Bateson, G. P. Asner, and C. A. Wessman, "Endmember bundles: a new approach to incorporating endmember variability into spectral mixture analysis," *IEEE Trans. Geosci. Remote Sens.*, vol. 38, no. 2, pp. 1083–1094, 2000, doi: 10.1109/36.841987.
- [96] A. Bateson and B. Curtiss, "A method for manual endmember selection and spectral unmixing," *Remote Sens. Environ.*, vol. 55, no. 3, pp. 229–243, 1996, doi: 10.1016/S0034-4257(95)00177-8.
- [97] B. Somers, M. Zortea, A. Plaza, and G. P. Asner, "Automated Extraction of Image-Based Endmember Bundles for Improved Spectral Unmixing," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 5, no. 2, pp. 396–408, 2012, doi: 10.1109/JSTARS.2011.2181340.
- [98] M. Xu, L. Zhang, and B. Du, "An Image-Based Endmember Bundle Extraction Algorithm Using Both Spatial and Spectral Information," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 8, no. 6, pp. 2607–2617, 2015, doi: 10.1109/JSTARS.2014.2373491.
- [99] K. Canham, A. Schlamm, A. Ziemann, B. Basener, and D. Messinger, "Spatially adaptive hyperspectral unmixing," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 11, pp. 4248–4262, 2011, doi: 10.1109/TGRS.2011.2169680.
- [100] C. Andreou, D. Rogge, and R. Müller, "A New Approach for Endmember Extraction and Clustering Addressing Inter- and Intra-Class Variability via Multiscaled-Band Partitioning," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 9, no. 9, pp. 4215–4231, 2016, doi: 10.1109/JSTARS.2016.2519610.
- [101] T. Uezato, R. J. Murphy, A. Melkumyan, and A. Chlingaryan, "A Novel Endmember Bundle Extraction and Clustering Approach for Capturing Spectral Variability Within Endmember Classes," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 11, pp. 6712–6731, 2016, doi: 10.1109/TGRS.2016.2589266.
- [102] F. J. García-Haro, S. Sommer, and T. Kemper, "A new tool for variable multiple endmember spectral mixture analysis (VMESMA)," *Int. J. Remote Sens.*, vol. 26, no. 10, pp. 2135–2162, 2005, doi: 10.1080/01431160512331337817.

- [103] C. Deng and C. Wu, “A spatially adaptive spectral mixture analysis for mapping subpixel urban impervious surface distribution,” *Remote Sens. Environ.*, vol. 133, pp. 62–70, 2013, doi: 10.1016/j.rse.2013.02.005.
- [104] M. A. Veganzones, G. Tochon, M. Dalla-Mura, A. J. Plaza, and J. Chanussot, “Hyperspectral image segmentation using a new spectral unmixing-based binary partition tree representation,” *IEEE Trans. Image Process.*, vol. 23, no. 8, pp. 3574–3589, 2014, doi: 10.1109/TIP.2014.2329767.
- [105] P. A. Thouvenin, N. Dobigeon, and J. Y. Tourneret, “Hyperspectral unmixing with spectral variability using a perturbed linear mixing model,” *IEEE Trans. Signal Process.*, vol. 64, no. 2, pp. 525–538, 2016, doi: 10.1109/TSP.2015.2486746.
- [106] L. Drumetz, S. Henrot, M. A. Veganzones, J. Chanussot, and C. Jutten, “Blind hyperspectral unmixing using an extended linear mixing model to address spectral variability,” *IEEE Trans. Image Process.*, vol. 25, no. 8, pp. 3890–3905, 2016, doi: 10.1109/TIP.2016.2579259.
- [107] L. Drumetz, J. Chanussot, C. Jutten, W. K. Ma, and A. Iwasaki, “Spectral variability aware blind hyperspectral image unmixing based on convex geometry,” *IEEE Trans. Image Process.*, vol. 29, pp. 4568–4582, 2020, doi: 10.1109/TIP.2020.2974062.
- [108] F. Z. Benhalouche, M. S. Karoui, and Y. Deville, “An NMF-based approach for hyperspectral unmixing using a new multiplicative-tuning linear mixing model to address spectral variability,” in *European Signal Processing Conference*, 2019, pp. 1–5, doi: 10.23919/EUSIPCO.2019.8902707.
- [109] T. Imbiriba, R. A. Borsoi, and J. C. M. Bermudez, “Generalized Linear Mixing Model Accounting for Endmember Variability,” in *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2018, pp. 1862–1866, doi: 10.1109/ICASSP.2018.8462214.
- [110] D. Hong, N. Yokoya, J. Chanussot, and X. X. Zhu, “An Augmented Linear Mixing Model to Address Spectral Variability for Hyperspectral Unmixing,” *IEEE Trans. Image Process.*, vol. 28, no. 4, pp. 1923–1938, 2019, doi: 10.1109/TIP.2018.2878958.
- [111] S. Jay and M. Guillaume, “Regularized estimation of bathymetry and water quality using hyperspectral remote sensing,” *Int. J. Remote Sens.*, vol. 37, no. 2, pp. 263–289, 2016, doi: 10.1080/01431161.2015.1125551.
- [112] Z. Lee, A. Weidemann, and R. Arnone, “Combined effect of reduced band number and increased bandwidth on shallow water remote sensing: The case of world view 2,” *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 5, pp. 2577–2586, 2013, doi: 10.1109/TGRS.2012.2218818.
- [113] M. Guillaume, A. Minghelli, Y. Deville, M. Chami, L. Juste, X. Lenot, B. Lafrance, S. Jay, X. Briottet and V. Serfaty, “Mapping benthic habitats by extending non-negative matrix factorization to address the water column and seabed adjacency effects,” *Remote Sens.*, vol. 12, no. 13, pp. 1–23, 2020, doi: 10.3390/rs12132072.
- [114] S. Jay and M. Guillaume, “A novel maximum likelihood based method for mapping depth and water quality from hyperspectral remote-sensing data,” *Remote Sens. Environ.*, vol. 147, pp. 121–132, 2014, doi: 10.1016/j.rse.2014.01.026.

- [115] S. Jay, M. Guillaume, A. Minghelli, Y. Deville, M. Chami, B. Lafrance, and V. Serfaty “Hyperspectral remote sensing of shallow waters: Considering environmental noise and bottom intra-class variability for modeling and inversion of water reflectance,” *Remote Sens. Environ.*, vol. 200, no. October, pp. 352–367, 2017, doi: 10.1016/j.rse.2017.08.020.
- [116] Y. Deville, S.E. Brezini, F.Z. Benhalouche, M.S. Karoui, M. Guillaume, X. Lenot, B. Lafrance, M. Chami, S. Jay, A. Minghelli, X. Briottet and V. Serfaty, “Hyperspectral Oceanic Remote Sensing with Adjacency Effects: From Spectral-Variability-Based Modeling to Performance of Associated Blind Unmixing Methods,” in *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2019, pp. 282–285, doi: 10.1109/IGARSS.2019.8898430.
- [117] M. Chami, B. Lafrance, B. Fougny, J. Chowdhary, T. Harmel, and F. Waquet, “A vector radiative transfer model of coupled atmosphere-ocean system for a rough sea surface application to the estimates of the directional variations of the water leaving reflectance to better process multi-angular satellite sensors data over the ocean.,” *Opt. Express*, vol. 23, pp. 27829–27852, 2015, doi: 10.1364/oe.23.027829.
- [118] V. E. Brando, J. M. Anstee, M. Wettle, A. G. Dekker, S. R. Phinn, and C. Roelfsema, “A physics based retrieval and quality assessment of bathymetry from suboptimal hyperspectral data,” *Remote Sens. Environ.*, vol. 113, no. 4, pp. 755–770, 2009, doi: 10.1016/j.rse.2008.12.003.
- [119] A. G. Dekker, S. R. Phinn, J. Anstee, P. Bissett, V. E. Brando, B. Casey P. Fearn, J. Hedley, W. Klonowski, Z. P. Lee, M. Lynch, M. Lyons, C. Mobley and C. Roelfsema, “Intercomparison of shallow water bathymetry, hydro-optics, and benthos mapping techniques in Australian and Caribbean coastal environments,” *Limnol. Oceanogr. Methods*, vol. 9, pp. 396–425, 2011, doi: 10.4319/lom.2011.9.396.
- [120] J. Hedley, C. Roelfsema, and S. R. Phinn, “Efficient radiative transfer model inversion for remote sensing applications,” *Remote Sens. Environ.*, vol. 113, no. 11, pp. 2527–2532, 2009, doi: 10.1016/j.rse.2009.07.008.
- [121] M. Guillaume, L. Juste, X. Lenot, Y. Deville, B. Lafrance, M. Chami, S. Jay, A. Minghelli, X. Briottet and V. Serfaty, “NMF Hyperspectral Unmixing Of The Sea Bottom: Influence Of The Adjacency Effects, Model and Method,” in *2018 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 2018, pp. 1–5, doi: 10.1109/WHISPERS.2018.8747064.
- [122] K. B. Petersen and M. S. Pedersen, *The matrix Cookbook*. Technical Univ. Denmark, 2008.
- [123] S. E. Brezini, M. S. Karoui, F. Z. Benhalouche, Y. Deville, and A. Ouamri, “A pixel-by-pixel NMF-based method for hyperspectral unmixing using a new linear mixing model to address additively-tuned spectral variability,” in *Image and Signal Processing for Remote Sensing XXV*, 2019, no. September, p. 111550I, doi: /10.1117/12.2533159.
- [124] S. E. Brezini, M. S. Karoui, F. Z. Benhalouche, Y. Deville, and A. Ouamri, “An NMF-Based Method for Hyperspectral Unmixing Using A Structured Additively-Tuned Linear Mixing Model to Address Spectral Variability,” in *2020 Mediterranean and Middle-East Geoscience and Remote Sensing Symposium, M2GARSS 2020 - Proceedings*, 2020, pp. 45–48, doi: 10.1109/M2GARSS47143.2020.9105265.

- [125] S. E. Brezini, Y. Deville, M. S. Karoui, F. Z. Benhalouche, and A. Ouamri, “A Penalization-Based NMF Approach for Hyperspectral Unmixing Addressing Spectral Variability with an Additively-Tuned Mixing Model,” in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 2021, pp. 3841–3844, doi: 10.1109/IGARSS47720.2021.9553366.
- [126] M. S. Karoui, F.Z. Benhalouche, Y. Deville, K. Djerriri, X. Briottet, T. Houet, A. Le Bris and C. Weber, “Partial linear NMF-based unmixing methods for detection and area estimation of photovoltaic panels in urban hyperspectral remote sensing data,” *Remote Sens.*, vol. 11, no. 18, 2019, doi: 10.3390/rs11182164.
- [127] K. R. M. Adeline *et al.*, “Description de la campagne aéroportée UMBRA : étude de l’impact anthropique sur les écosystèmes urbains et naturels avec des images THR multispectrales et hyperspectrales,” *Rev. Française Photogrammétrie Télédétection*, no. 202, pp. 79–92, 2013, doi: 10.52638/rfpt.2013.53.
- [128] C. Brabant, E. Alvarez-Vanhard, A. Larbi, G. Morin, K. Thanh Nguyen, A. Thomas and T. Houet, “Comparison of hyperspectral techniques for urban tree diversity classification,” *Remote Sens.*, vol. 11, no. 11, p. 1269, 2019, doi: 10.3390/rs11111269.
- [129] C. Miesch, L. Poutier, V. Achard, X. Briottet, X. Lenot, and Y. Boucher, “Direct and inverse radiative transfer solutions for visible and near-infrared hyperspectral imagery,” *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 7, pp. 1552–1562, 2005, doi: 10.1109/TGRS.2005.847793.
- [130] C. Debes *et al.*, “Hyperspectral and LiDAR data fusion: Outcome of the 2013 GRSS data fusion contest,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 7, no. 6, pp. 2405–2418, 2014, doi: 10.1109/JSTARS.2014.2305441.
- [131] G. Vivone, L. Alparone, J. Chanussot, M. Dalla Mura, A. Garzelli, G.A. Licciardi, R. Restaino and L. Wald, “A Critical Comparison Among Pansharpening Algorithms,” *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 5, pp. 2565–2586, 2015, doi: 10.1109/TGRS.2014.2361734.
- [132] C. Pohl and J. van Genderen, *Remote Sensing Image Fusion A Practical Guide*, CRC Press. 2016.
- [133] K. K. Teoh, H. Ibrahim, and S. K. Bejo, “Investigation on several basic interpolation methods for the use in remote sensing application,” in *Proceedings of the 2008 IEEE Conference on Innovative Technologies in Intelligent Systems and Industrial Applications, CITISIA*, 2008, no. July, pp. 60–65, doi: 10.1109/CITISIA.2008.4607336.
- [134] B. Aiazzi, L. Alparone, S. Baronti, and A. Garzelli, “Context-driven fusion of high spatial and spectral resolution images based on oversampled multiresolution analysis,” *IEEE Trans. Geosci. Remote Sens.*, vol. 40, no. 10, pp. 2300–2312, 2002, doi: 10.1109/TGRS.2002.803623.
- [135] 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,” *Photogramm. Eng. Remote Sens.*, vol. 56, no. 4, pp. 459–467, 1990.
- [136] 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 Geosci. Remote Sens. Lett.*, vol. 1, no. 4, pp. 309–312, 2004, doi: 10.1109/LGRS.2004.834804.

- [137] T. M. Tu, S. C. Su, H. C. Shyu, and P. S. Huang, "A new look at IHS-like image fusion methods," *Inf. Fusion*, vol. 2, no. 3, pp. 177–186, 2001, doi: 10.1016/S1566-2535(01)00036-7.
- [138] M. Chikr El-Mezouar, N. Taleb, K. Kpalma, and J. Ronsin, "An IHS-based fusion for color distortion reduction and vegetation enhancement in IKONOS imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 5, pp. 1590–1602, 2011, doi: 10.1109/TGRS.2010.2087029.
- [139] P. S. Chavez, S. C. Sides, and J. A. Anderson, "Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic," *Photogramm. Eng. Remote Sens.*, vol. 57, no. 3, pp. 295–303, 1991, doi: 10.1306/44b4c288-170a-11d7-8645000102c1865d.
- [140] H. R. Shahdoosti and H. Ghassemian, "Spatial PCA as a new method for image fusion," in *AISP 2012 - 16th CSI International Symposium on Artificial Intelligence and Signal Processing*, 2012, no. Aisp, pp. 90–94, doi: 10.1109/AISP.2012.6313724.
- [141] C. A. Laben and B. V. Brower, "Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening," US patent : 6011875, 2000.
- [142] T. Ranchin and L. Wald, "Fusion of high spatial and spectral resolution images: The ARSIS concept and its implementation," *Photogramm. Eng. Remote Sensing*, vol. 66, no. 1, pp. 49–61, 2000.
- [143] J. G. Liu, "Smoothing Filter-based Intensity Modulation: A spectral preserve image fusion technique for improving spatial details," *Int. J. Remote Sens.*, vol. 21, no. 18, pp. 3461–3472, 2000, doi: 10.1080/014311600750037499.
- [144] L. J. Guo and J. M. M. Moore, "Pixel block intensity modulation: Adding spatial detail to tm band 6 thermal imagery," *Int. J. Remote Sens.*, vol. 19, no. 13, pp. 2477–2491, 1998, doi: 10.1080/014311698214578.
- [145] M. M. Khan, J. Chanussot, L. Condat, and A. Montanvert, "Indusion: Fusion of multispectral and panchromatic images using the induction scaling technique," *IEEE Geosci. Remote Sens. Lett.*, vol. 5, no. 1, pp. 98–102, 2008, doi: 10.1109/LGRS.2007.909934.
- [146] 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," *Int. J. Remote Sens.*, vol. 26, no. 3, pp. 595–614, 2005, doi: 10.1080/01431160512331314056.
- [147] K. Amolins, Y. Zhang, and P. Dare, "Wavelet based image fusion techniques - An introduction, review and comparison," *ISPRS J. Photogramm. Remote Sens.*, vol. 62, pp. 249–263, 2007, doi: 10.1016/j.isprsjprs.2007.05.009.
- [148] M. Choi, R. Y. Kim, M. R. Nam, and H. O. Kim, "Fusion of multispectral and panchromatic satellite images using the curvelet transform," *IEEE Geosci. Remote Sens. Lett.*, vol. 2, no. 2, pp. 136–140, 2005, doi: 10.1109/LGRS.2005.845313.
- [149] L. Alparone, S. Baronti, A. Garzelli, and F. Nencini, "The curvelet transform for fusion of very-high resolution multi- spectral and panchromatic images," in *25th Annual Symposium of the European Association of Remote Sensing Laboratories (EARSeL)*, 2005, pp. 95–102.

- [150] Jeannic Guillaume, “Représentation structurelle d’images par transformées locales en ondelettes orientées et codage,” thèse de doctorat, Université de Nantes, 2008.
- [151] M. N. Do and M. Vetterli, “The contourlet transform: An efficient directional multiresolution image representation,” *IEEE Trans. Image Process.*, vol. 14, no. 12, pp. 2091–2106, 2005, doi: 10.1109/TIP.2005.859376.
- [152] P. J. Burt and E. H. Adelson, “The Laplacian Pyramid as a Compact Image Code,” in *Readings in Computer Vision*, San Francisco (CA): Morgan Kaufmann, 1987, pp. 671–679.
- [153] B. Aiazzi, L. Alparone, S. Baronti, A. Garzelli, and M. Selva, “MTF-tailored multiscale fusion of high-resolution MS and pan imagery,” *Photogramm. Eng. Remote Sensing*, vol. 72, no. 5, pp. 591–596, 2006, doi: 10.14358/PERS.72.5.591.
- [154] L. Loncan, “Fusion of hyperspectral and panchromatic images with very high spatial resolution,” Thèse de doctorat, Université de Grenoble, 2016.
- [155] A. R. Gillespie, A. B. Kahle, and R. E. Walker, “Color enhancement of highly correlated images. I. Decorrelation and HSI contrast stretches,” *Remote Sens. Environ.*, vol. 20, no. 3, pp. 209–235, 1986, doi: [https://doi.org/10.1016/0034-4257\(86\)90044-1](https://doi.org/10.1016/0034-4257(86)90044-1).
- [156] C. Ballester, V. Caselles, L. Igual, J. Verdera, and B. Rougé, “A variational model for P+XS image fusion,” *Int. J. Comput. Vis.*, vol. 69, no. 1, pp. 43–58, 2006, doi: 10.1007/s11263-006-6852-x.
- [157] I. Amro, J. Mateos, M. Vega, R. Molina, and A. K. Katsaggelos, “A survey of classical methods and new trends in pansharpening of multispectral images,” *EURASIP J. Adv. Signal Process.*, vol. 2011, pp. 1–22, 2011, doi: 10.1186/1687-6180-2011-79.
- [158] H. Ghassemian, “A review of remote sensing image fusion methods,” *Inf. Fusion*, vol. 32, pp. 75–89, 2016, doi: 10.1016/j.inffus.2016.03.003.
- [159] 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 Trans. Geosci. Remote Sens.*, vol. 46, no. 5, pp. 1301–1312, 2008, doi: 10.1109/TGRS.2007.912448.
- [160] M. S. Karoui, “Linear spectral unmixing-based method including extended nonnegative matrix factorization for pan-sharpening multispectral remote sensing images,” in *Image and Signal Processing for Remote Sensing XIX*, 2013, vol. 8892, doi: 10.1117/12.2028100.
- [161] M. S. Karoui, K. Djerriri, and I. Boukerch, “Pansharpening multispectral remote sensing data by multiplicative joint nonnegative matrix factorization,” *Int. J. Remote Sens.*, vol. 37, no. 4, pp. 805–818, 2016, doi: 10.1080/01431161.2015.1137650.
- [162] M. Selva, B. Aiazzi, F. Butera, L. Chiarantini, and S. Baronti, “Hyper-sharpening: A first approach on SIM-GA data,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 8, no. 6, pp. 3008–3024, 2015, doi: 10.1109/JSTARS.2015.2440092.
- [163] M. Selva, B. Aiazzi, F. Butera, L. Chiarantini, and S. Baronti, “Hyper-sharpening of hyperspectral data: A first approach,” in *2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 2014, pp. 1–4, doi: 10.1109/WHISPERS.2014.8077543.

- [164] R. B. Gomez, A. Jazaeri, and M. Kafatos, “Wavelet-based hyperspectral and multispectral image fusion,” in *Proc.SPIE,Geo-Spatial Image and Data Exploitation II*, Jun. 2001, vol. 4383, doi: 10.1117/12.428249.
- [165] Y. Zhang and M. He, “Multi-spectral and hyperspectral image fusion using 3-D wavelet transform,” *J. Electron.*, vol. 24, no. 2, pp. 218–224, 2007, doi: 10.1007/s11767-005-0232-5.
- [166] F. Palsson, J. R. Sveinsson, M. O. Ulfarsson, and J. A. Benediktsson, “Model-based fusion of multi-and hyperspectral images using PCA and wavelets,” *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 5, pp. 2652–2663, 2015, doi: 10.1109/TGRS.2014.2363477.
- [167] R. C. Hardie, M. T. Eismann, and G. L. Wilson, “MAP estimation for hyperspectral image resolution enhancement using an auxiliary sensor,” *IEEE Trans. Image Process.*, vol. 13, no. 9, pp. 1174–1184, 2004, doi: 10.1109/TIP.2004.829779.
- [168] Q. Wei, N. Dobigeon, and J. Y. Tourneret, “Fast Fusion of Multi-Band Images Based on Solving a Sylvester Equation,” *IEEE Trans. Image Process.*, vol. 24, no. 11, pp. 4109–4120, 2015, doi: 10.1109/LSP.2016.2608858.
- [169] M. Simoes, J. Bioucas-Dias, L. B. Almeida, and J. Chanussot, “A convex formulation for hyperspectral image superresolution via subspace-based regularization,” *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 6, pp. 3373–3388, 2015, doi: 10.1109/TGRS.2014.2375320.
- [170] N. Yokoya, T. Yairi, and A. Iwasaki, “Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion,” *IEEE Trans. Geosci. Remote Sens.*, vol. 50, no. 2, pp. 528–537, 2012, doi: 10.1109/TGRS.2011.2161320.
- [171] M. S. Karoui, Y. Deville, and S. Kreri, “Joint nonnegative matrix factorization for hyperspectral and multispectral remote sensing data fusion,” in *2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 2013, pp. 1–4, doi: 10.1109/WHISPERS.2013.8080718.
- [172] M. S. Karoui, Y. Deville, F. Z. Benhalouche, and I. Boukerch, “Hypersharpener by Joint-Criterion Nonnegative Matrix Factorization,” *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 3, pp. 1660–1670, 2017, doi: 10.1109/TGRS.2016.2628889.
- [173] F. Z. Benhalouche, M. S. Karoui, Y. Deville, and A. Ouamri, “Hyperspectral and multispectral data fusion based on linear-quadratic nonnegative matrix factorization,” *J. Appl. Remote Sens.*, vol. 11, no. 2, pp. 1–18, May 2017, doi: 10.1117/1.JRS.11.025008.
- [174] N. Akhtar, F. Shafait, and A. Mian, “Sparse spatio-spectral representation for hyperspectral image super-resolution,” in *in Proc. European Conf. Computer Vision*, 2014, pp. 63–78, doi: 10.1007/978-3-319-10584-0_5.
- [175] J. Mairal, F. Bach and G. Sapiro, “Online Dictionary Learning for Sparse Coding,” in *Proceedings of the 26th annual international conference on machine learning*, 2009, pp. 689–696.
- [176] Q. Wei, J. Bioucas-Dias, N. Dobigeon, and J. Y. Tourneret, “Hyperspectral and Multispectral Image Fusion Based on a Sparse Representation,” *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 7, pp. 3658–3668, 2015, doi: 10.1109/TGRS.2014.2381272.

- [177] N. Yokoya, C. Grohnfeldt, and J. Chanussot, “Hyperspectral and Multispectral Data Fusion: A comparative review of the recent literature,” *IEEE Geosci. Remote Sens. Mag.*, vol. 5, no. 2, pp. 29–56, 2017, doi: 10.1109/MGRS.2016.2637824.
- [178] L. Wald, T. Ranchin, and M. Mangolini, “Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images,” *Photogramm. Eng. Remote Sensing*, vol. 63, no. 6, pp. 691–699, 1997.
- [179] J. Zhou, D. L. Civco, and J. A. Silander, “A wavelet transform method to merge Landsat TM and SPOT panchromatic data,” *Int. J. Remote Sens.*, vol. 19, no. 4, pp. 743–757, 1998, doi: 10.1080/014311698215973.
- [180] C. Thomas, “Fusion d’Images de Résolutions Spatiales Différentes,” Thèse de doctorat, Ecole des Mines Paris, 2006.
- [181] Y. Xia and Z. Chen, “Quality Assessment for Remote Sensing Images: Approaches and Applications,” in *Proceedings - 2015 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2015*, 2015, pp. 1029–1034, doi: 10.1109/SMC.2015.186.
- [182] W. Shi, C. Q. Zhu, Y. Tian, and J. Nichol, “Wavelet-based image fusion and quality assessment,” *Int. J. Appl. Earth Obs. Geoinf.*, vol. 6, no. 3–4, pp. 241–251, 2005, doi: 10.1016/j.jag.2004.10.010.
- [183] L. Alparone, B. Aiazzi, S. Baronti, A. Garzelli, F. Nencini, and M. Selva, “Multispectral and panchromatic data fusion assessment without reference,” *Photogramm. Eng. Remote Sensing*, vol. 74, no. 2, pp. 193–200, 2008, doi: 10.14358/PERS.74.2.193.
- [184] A. Garzelli, F. Nencini, and L. Capobianco, “Optimal MMSE pan sharpening of very high resolution multispectral images,” *IEEE Trans. Geosci. Remote Sens.*, vol. 46, no. 1, pp. 228–236, 2008, doi: 10.1109/TGRS.2007.907604.
- [185] Z. Wang and A. C. Bovik, “A universal image quality index,” *IEEE Signal Process. Lett.*, vol. 9, no. 3, pp. 81–84, 2002, doi: 10.1109/97.995823.
- [186] X. Otazu, M. González-Audicana, O. Fors, and J. Núñez, “Introduction of Sensor Spectral Response into Image Fusion Methods. Application to Wavelet-Based Methods,” *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 10, pp. 2376–2385, 2005, doi: 10.1109/TGRS.2005.856106.
- [187] S. E. Brezini, M. S. Karoui, F. Z. Benhalouche, Y. Deville, and A. Ouamri, “Hypersharpener by an NMF-Unmixing-Based Method Addressing Spectral Variability,” *IEEE Geosci. Remote Sens. Lett.*, 2021, doi: 10.1109/LGRS.2021.3072405.
- [188] M. S. Karoui, F. Z. Benhalouche, S. E. Brezini, Y. Deville, and Y. K. Benkouider, “Hypersharpener by a Multiplicative Joint-Criterion NMF Method Addressing Spectral Variability,” in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 2021, pp. 4472–4475, doi: 10.1109/IGARSS47720.2021.9553972.
- [189] Y. T. Solano Correa, F. Bovolo, and L. Bruzzone, “Change detection in very high resolution multisensor optical images,” *Image Signal Process. Remote Sens. XX*, vol. 9244, no. September, p. 924410, 2014, doi: 10.1117/12.2068171.
- [190] U.S. Geological Survey, “Landsat 8 band designations.” <https://www.usgs.gov/media/images/landsat-8-band-designations>.

- [191] “EO-1 (Earth Observing-1).” <https://earth.esa.int/web/eoportal/satellite-missions/e/eo-1>.
- [192] R. A. Borsoi, T. Imbiriba, and J. C. M. Bermudez, “Super-Resolution for Hyperspectral and Multispectral Image Fusion Accounting for Seasonal Spectral Variability,” *IEEE Trans. Image Process.*, vol. 29, pp. 116–127, 2020, doi: 10.1109/TIP.2019.2928895.

Publications scientifiques de l'auteur

Article de revue internationale

S. E. Brezini, M. S. Karoui, F. Z. Benhalouche, Y. Deville, and A. Ouamri, “Hypersharpener by an NMF-Unmixing-Based Method Addressing Spectral Variability,” *IEEE Geosci. Remote Sens. Lett.*, vol. 19, pp. 1–5, 2022, Art no. 5505405, doi: 10.1109/LGRS.2021.3072405.

Actes de conférences internationales avec comité de lecture

S. E. Brezini, M. S. Karoui, F. Z. Benhalouche, Y. Deville, and A. Ouamri, “A pixel-by-pixel NMF-based method for hyperspectral unmixing using a new linear mixing model to address additively-tuned spectral variability,” in *Image and Signal Processing for Remote Sensing XXV*, 2019, 111550I, doi: /10.1117/12.2533159.

S. E. Brezini, M. S. Karoui, F. Z. Benhalouche, Y. Deville, and A. Ouamri, “An NMF-Based Method for Hyperspectral Unmixing Using A Structured Additively-Tuned Linear Mixing Model to Address Spectral Variability,” in *2020 Mediterranean and Middle-East Geoscience and Remote Sensing Symposium, M2GARSS 2020 - Proceedings*, 2020, pp. 45–48, doi: 10.1109/M2GARSS47143.2020.9105265.

S. E. Brezini, Y. Deville, M. S. Karoui, F. Z. Benhalouche, and A. Ouamri, “A Penalization-Based NMF Approach for Hyperspectral Unmixing Addressing Spectral Variability with an Additively-Tuned Mixing Model,” in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 2021, pp. 3841–3844, doi: 10.1109/IGARSS47720.2021.9553366.

Y. Deville, **S.E. Brezini**, F.Z. Benhalouche, M.S. Karoui, M. Guillaume, X. Lenot, B. Lafrance, M. Chami, S. Jay, A. Minghelli, X. Briottet and V. Serfaty, “Hyperspectral Oceanic Remote Sensing with Adjacency Effects: From Spectral-Variability-Based Modeling to Performance of Associated Blind Unmixing Methods,” in *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2019, pp. 282–285, doi: 10.1109/IGARSS.2019.8898430.

Y. Deville, **S.E. Brezini**, F.Z. Benhalouche, M.S. Karoui, M. Guillaume, X. Lenot, B. Lafrance, M. Chami, S. Jay, A. Minghelli, X. Briottet and V. Serfaty, “Blind Unmixing Based on Spectral-Variability Modeling for Hyperspectral Oceanic Remote Sensing Data with Adjacency Effects,” in *7 ème Colloque Scientifique du Groupe Hyperspectral de la Société Française de Photogrammétrie et de Télédétection (SFPT-GH)*, 2019.

M. S. Karoui, F. Z. Benhalouche, **S.E. Brezini**, Y. Deville and Y.K. Benkouider, “Hypersharpener by a Multiplicative Joint-Criterion NMF Method Addressing Spectral Variability,” in *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2021, pp. 4472–4475.

F. Z. Benhalouche, M. S. Karoui, **S.E. Brezini**, Y. Deville and Y.K. Benkouider, “Hypersharpener Based on Extended Coupled Nonnegative Matrix Factorization Addressing Spectral Variability,” in *2022 Mediterranean and Middle-East Geoscience and Remote Sensing Symposium, M2GARSS 2022*, 2022.