



**HAL**  
open science

# Méthodes de séparation aveugle de sources et application à la télédétection spatiale

Moussa Sofiane Karoui

► **To cite this version:**

Moussa Sofiane Karoui. Méthodes de séparation aveugle de sources et application à la télédétection spatiale. Traitement du signal et de l'image [eess.SP]. Université Paul Sabatier - Toulouse III, 2012. Français. NNT: . tel-00790655

**HAL Id: tel-00790655**

**<https://theses.hal.science/tel-00790655>**

Submitted on 20 Feb 2013

**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 :**

Signal, Image, Acoustique & Optimisation

**En cotutelle avec :**

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

---

**Présentée et soutenue par :**

MOUSSA SOFIANE KAROUI

le : 17 décembre 2012

**Titre :**

Méthodes de séparation aveugle de sources et application à la  
télétection spatiale

---

**Ecole doctorale :**

Mathématiques, Informatique et Télécommunications

**Unité de recherche :**

Institut de Recherche en Astrophysique et Planétologie

**Composition du jury :**

BELBACHIR Mohamed Faouzi	Professeur	USTO MB	(Algérie)	Président
DEVILLE Yannick	Professeur	UPS TLSE III	(France)	Directeur de thèse
OUAMRI Abdelaziz	Professeur	USTO MB	(Algérie)	Directeur de thèse
HOSSEINI Shahram	Maître de conférences	UPS TLSE III	(France)	Encadrant
OULD MAMMAR Madani	Maître de conférences	Université de Mostaganem	(Algérie)	Rapporteur
ABED-MERAIM Karim	Professeur	Université d'Orléans	(France)	Rapporteur
BENTOUTOU Youcef	Directeur de recherche	CTS	(Algérie)	Invité

*IL Y A LA MEME DIFFERENCE ENTRE LES SAVANTS ET  
LES IGNORANTS QU'ENTRE LES VIVANTS ET LES MORTS.*

*"ARISTOTE"*

*Je dédie ce travail en premier lieu à la mémoire de mon père, qui a su me donner les bonnes bases pour affronter la vie, et à qui je dois tout simplement tout.*

*Mes dédicaces vont aussi pour ma chère mère, la plus courageuse des femmes, à mes frères « Amine » et « Walid », ainsi que ma petite sœur « Nihel ».*

*Aussi, je dédie ce travail à ma très chère femme « Sabrina », à qui j'exprime toute ma reconnaissance et ma profonde gratitude, pour sa générosité, son sacrifice au quotidien et son soutien et encouragements tout au long de ces années de thèse.*

*Enfin, je ne peux oublier mes petits anges « Iyed » et « Wael », ceux qui sont devenus ma raison d'exister.*

*Mes premiers remerciements vont à mes directeurs de thèse et encadrant, Yannick Deville, Abdelaziz Ouamri et Shahram Hosseini. Leurs qualités scientifiques et humaines ainsi que leur expérience dans le domaine de la recherche ont représenté de réels atouts pour mener mes travaux de cette manière durant ces années de thèse.*

*Mes remerciements vont aussi à messieurs Mohamed Faouzi Belbachir, Karim Abed-Meraïm, Madani Ould Mammar et Youcef Bentoutou, pour leur participation dans mon jury de soutenance.*

*Un grand merci à tous ceux (que je n'ai pas oublié de citer mais qui feraient doubler la taille de ce manuscrit si je devais le faire) qui ont contribué de près ou de loin dans cette thèse, et qui m'ont permis de mener mes travaux dans un environnement agréable et dans des circonstances idéales.*

*Clin d'œil à tous mes amis et collègues du Centre des Techniques Spatiales, du Centre de Développement des Satellites et de l'Agence Spatiale Algérienne.*

*Enfin, je remercie toute personne qui a le courage de lire ma thèse du début à la fin !*

Cette thèse concerne la séparation aveugle de sources, qui consiste à estimer un ensemble de signaux sources inconnus à partir d'un ensemble de signaux observés qui sont des mélanges à paramètres inconnus de ces signaux sources.

C'est dans ce cadre que le travail de recherche de cette thèse concerne le développement et l'utilisation de méthodes linéaires innovantes de séparation de sources pour des applications en imagerie de télédétection spatiale.

Des méthodes de séparation de sources sont utilisées pour prétraiter une image multispectrale en vue d'une classification supervisée de ses pixels.

Deux nouvelles méthodes hybrides non-supervisées, baptisées 2D-Corr-NLS et 2D-Corr-NMF, sont proposées pour l'extraction de cartes d'abondances à partir d'une image multispectrale contenant des pixels purs. Ces deux méthodes combinent l'analyse en composantes parcimonieuses, le clustering et les méthodes basées sur les contraintes de non-négativité.

Une nouvelle méthode non-supervisée, baptisée 2D-VM, est proposée pour l'extraction de spectres à partir d'une image hyperspectrale contenant des pixels purs. Cette méthode est basée sur l'analyse en composantes parcimonieuses.

Enfin, une nouvelle méthode est proposée pour l'extraction de spectres à partir d'une image hyperspectrale ne contenant pas de pixels purs, combinée avec une image multispectrale, de très haute résolution spatiale, contenant des pixels purs. Cette méthode est fondée sur la factorisation en matrices non-négatives couplée avec les moindres carrés non-négatifs.

Comparées à des méthodes de la littérature, d'excellents résultats sont obtenus par les approches méthodologiques proposées.

**Mots-clés :** séparation aveugle de sources, imagerie multi/hyperspectrale de télédétection spatiale, démixage spectral/spatial, analyse en composantes indépendantes, analyse en composantes parcimonieuses, factorisation en matrices non-négatives, moindres carrés non-négatifs, classification.

This thesis concerns the blind source separation problem, which consists in estimating a set of unknown source signals from a set of observed signals which are mixtures of these source signals, with unknown mixing coefficients.

In this thesis, we develop and use innovative linear source separation methods for applications in remote sensing imagery.

Source separation methods are used and applied in order to preprocess a multispectral image for a supervised classification of this image.

Two new unsupervised methods, called 2D-Corr-NLS and 2D-Corr-NMF, are proposed in order to extract abundance maps from a multispectral image with pure pixels. These methods are based on sparse component analysis, clustering and non-negativity constraints.

A new unsupervised method, called 2D-VM, is proposed in order to extract endmember spectra from a hyperspectral image with pure pixels. This method is based on sparse component analysis.

Also, a new method is proposed for extracting endmember spectra from a hyperspectral image without pure pixels, combined with a very high spatial resolution multispectral image with pure pixels. This method is based on non-negative matrix factorization coupled with non-negative least squares.

Compared to literature methods, excellent results are obtained by the proposed methodological approaches.

**Keywords:** blind source separation, remote sensing multi/hyperspectral imagery, spectral/spatial unmixing, independent component analysis, sparse component analysis, non-negative matrix factorization, non-negative least squares, classification.

هذه الأطروحة تتعلق بالفصل المكفوف للمصادر, والذي ينطوي على تقدير مجموعة غير معروفة من إشارات المصادر انطلاقاً من مجموعة من الإشارات الملحوظة و التي هي مزيج من إشارات المصادر.

في هذا الإطار, العمل البحثي لهذه الأطروحة يتعلق بتطوير واستخدام طرق مبتكرة للفصل الخطي للمصادر من أجل تطبيقات باستخدام صور الاستشعار عن بعد.

طرق لفصل المصادر استخدمت من أجل تجهيز صورة متعددة الاطيف لتصنيفها الموجه.

طريقتان جديدتان غير موجهتان تحملان اسم 2D-Corr-NLS و 2D-Corr-NMF اقترحتا من أجل استخراج خرائط التركيز انطلاقاً من صورة متعددة الاطيف تحتوي علي بكسلات محضة. الطريقتان تجمع بين التحليل الي عناصر متناثرة, التجميع و الطرق القائمة علي القيود الغير سلبية.

طريقة جديدة غير موجهة تحمل اسم 2D- VM اقترحت من أجل استخراج اطياف انطلاقاً من صورة جد متعددة الاطيف تحتوي علي بكسلات محضة. الطريقة تستند علي التحليل الي عناصر متناثرة.

ايضا, طريقة جديدة اقترحت من أجل استخراج اطياف من صورة جد متعددة الاطيف لا تحتوي علي بكسلات محضة, مشتركة مع صورة متعددة الاطيف تحتوي علي بكسلات محضة. و تستند هذه الطريقة الجديدة علي التحليل الي مصفوفات غير سلبية و علي المربعات الصغري الغير سلبية.

مقارنة مع الطرق الموجودة, تم الحصول علي نتائج ممتازة باستعمال الطرق المنهجية المقترحة.

**كلمات المفتاح :** الفصل المكفوف للمصادر, صور الاستشعار عن بعد المتعددة/الجد متعددة الاطيف, الفصل الطيفي/الفضائي, التحليل الي عوامل مستقلة, التحليل الي عوامل متناثرة, التحليل الي مصفوفات غير سلبية, المربعات الصغري الغير سلبية, التصنيف.

<b>Dédicaces</b>	<b>i</b>
<b>Remerciements</b>	<b>ii</b>
<b>Résumé</b>	<b>iii</b>
<b>Abstract</b>	<b>iv</b>
<b>ملخص</b>	<b>v</b>
<b>Table des matières</b>	<b>vi</b>
<b>Table des figures</b>	<b>x</b>
<b>Liste des tableaux</b>	<b>xiv</b>
<b>Abréviations</b>	<b>xv</b>
<b>Introduction générale</b>	<b>1</b>
<b>Chapitre 1 : Généralités et vue d'ensemble</b>	<b>7</b>
1.1. Télédétection spatiale et son processus d'analyse des données	9
1.2. Problématique abordée dans la thèse	15
1.3. Généralités sur la séparation aveugle de sources	19
1.4. Modélisation des images de télédétection spatiale selon la nomenclature de la séparation aveugle de sources	25
1.4.1. Approche intuitive : sources spectrales	25
1.4.2. Approche alternative : sources spatiales	27
1.5. Contributions méthodologiques de la thèse	28
1.5.1. Prétraitement par des méthodes classiques de séparation de sources d'une image multispectrale en vue de sa classification	29
1.5.2. Extraction de cartes d'abondances à partir d'une image multispectrale avec pixels purs	29
1.5.3. Extraction de spectres à partir d'une image hyperspectrale avec pixels purs	30
1.5.4. Extraction de spectres à partir d'une image hyperspectrale sans pixels purs, combinée avec une image multispectrale avec pixels purs.	30
1.6. Conclusion	31
Références bibliographiques citées dans le Chapitre 1	32

---

<b>Chapitre 2 : Panorama des méthodes utilisées dans les domaines concernés par la thèse</b>	<b>36</b>
2.1. Méthodes de séparation aveugle de sources	38
2.1.1. Méthodes fondées sur l'analyse en composantes indépendantes	38
2.1.2. Méthodes fondées sur la factorisation en matrices non-négatives	47
2.1.3. Méthodes fondées sur l'analyse en composantes parcimonieuses	53
2.2. Méthodes de démixage d'images de télédétection spatiale	56
2.2.1. Méthodes avec l'hypothèse d'existence de pixels purs	58
2.2.2. Méthodes avec l'hypothèse d'inexistence de pixels purs	59
2.3. Quelles méthodes à mettre en place ? selon quelles modélisations ? sous quelles hypothèses ? et pour quels objectifs ?	59
2.4. Critères de performance des méthodes à mettre en place	62
2.5. Conclusion	64
Références bibliographiques citées dans le Chapitre 2	65
<b>Chapitre 3 : Prétraitement par séparation de sources et classification d'une image multispectrale</b>	<b>78</b>
3.1. Introduction	80
3.2. Approche méthodologique proposée	82
3.2.1. Prétraitement par les méthodes classiques d'ACI ou FMN	83
3.2.2. Classification	83
3.3. Résultats expérimentaux	84
3.3.1. Données utilisées	84
3.3.2. Résultats et discussion	85
3.4. Conclusion	92
Références bibliographiques citées dans le Chapitre 3	93

---

<b>Chapitre 4 : Extraction de cartes d'abondances à partir d'une image multispectrale avec pixels purs</b>	<b>97</b>
4.1. Introduction	99
4.2. Approches méthodologiques proposées	102
4.2.1. Hypothèses et définitions	102
4.2.2. Méthodes d'extraction	104
4.3. Résultats expérimentaux	112
4.3.1. Données utilisées	112
4.3.2. Résultats et discussion	117
4.4. Conclusion	128
Références bibliographiques citées dans le Chapitre 4	129
<b>Chapitre 5 : Extraction de spectres à partir d'une image hyperspectrale avec pixels purs</b>	<b>133</b>
5.1. Introduction	135
5.2. Approche méthodologique proposée	137
5.2.1. Hypothèses et définitions	137
5.2.2. Méthode d'extraction	138
5.3. Résultats expérimentaux	141
5.3.1. Données utilisées	141
5.3.2. Résultats et discussion	143
5.4. Conclusion	152
Références bibliographiques citées dans le Chapitre 5	153
<b>Chapitre 6 : Extraction de spectres à partir d'une image hyperspectrale sans pixels purs, combinée avec une image multispectrale avec pixels purs</b>	<b>155</b>
6.1. Introduction	157
6.2. Approche méthodologique proposée	158
6.2.1. Intérêt de l'approche proposée	158
6.2.2. Méthode d'extraction	158

6.3. Résultats expérimentaux	162
6.3.1. Données utilisées	162
6.3.2. Résultats et discussion	164
6.4. Conclusion	168
Références bibliographiques citées dans le Chapitre 6	169
<b>Conclusion générale et perspectives</b>	<b>171</b>
<b>Valorisations scientifiques de l'auteur</b>	<b>175</b>

**Chapitre 1**

Fig. 1.1	Représentation d'une image de télédétection spatiale. (a) Bande spectrale. (b) Spectre	10
Fig. 1.2	Images de télédétection spatiale optique avec différentes résolutions spatiales. (a) Image de basse résolution spatiale. (b) Image d'une résolution spatiale élevée	11
Fig. 1.3	Spectre multi et hyperspectral. (a) Spectre multispectral discontinu à larges bandes. (b) Spectre hyperspectral contigu à bandes étroites.	12
Fig. 1.4	Représentation d'un pavé hyperspectral	12
Fig. 1.5	Schéma de base d'un système d'extraction et de reconnaissance d'information en télédétection spatiale	13
Fig. 1.6	Schéma d'un processus typique d'analyse et de traitement d'images de télédétection spatiale	15
Fig. 1.7	Illustration d'un mixel (pixel mélangé) contenant plusieurs matériaux purs	16
Fig. 1.8	Illustration du modèle de mélange spectral. (a) Mélange linéaire. (b) Mélange non linéaire	17
Fig. 1.9	Illustration d'un spectre linéairement mélangé	18
Fig. 1.10	Illustration du problème du cocktail ( <i>cocktail party problem</i> )	19
Fig. 1.11	Configuration générale de la séparation aveugle de sources	21
Fig. 1.12	Principe général des méthodes de SAS linéaire instantanée	23
Fig. 1.13	Modèle des données selon l'approche sources spectrales	26
Fig. 1.14	Modèle des données selon l'approche sources spatiales	28

**Chapitre 2**

Fig. 2.1	Différents cônes englobant les composantes d'un vecteur de données observées	52
Fig. 2.2	Représentation en deux bandes du nuage de points contenu dans un simplex	56

**Chapitre 3**

Fig. 3.1	Diagramme de l'approche méthodologique adoptée	82
Fig. 3.2	Vue en 3D de la zone d'étude	85
Fig. 3.3	Image multispectrale utilisée. (a) Canal proche-infrarouge. (b) Canal rouge. (c) Canal vert	85
Fig. 3.4	Classifications multispectrales par minimum de distance (a) des canaux bruts ou des canaux issus de (b) ACP, (c) LDA, (d) FastICA, (e) JADE, (f) SOBI, (g) FMN, (h) FMN-CP	87
Fig. 3.5	Classifications texturales par minimum de distance (a) des canaux bruts ou des canaux issus de (b) ACP, (c) LDA, (d) FastICA, (e) JADE, (f) SOBI, (g) FMN, (h) FMN-CP	88
Fig. 3.6	Classifications multispectrales par SVM (a) des canaux bruts ou des canaux issus de (b) ACP, (c) LDA, (d) FastICA, (e) JADE, (f) SOBI, (g) FMN, (h) FMN-CP	89
Fig. 3.7	Classifications texturales par SVM (a) des canaux bruts ou des canaux issus de (b) ACP, (c) LDA, (d) FastICA, (e) JADE, (f) SOBI, (g) FMN, (h) FMN-CP	90
Fig. 3.8	Légende des différentes classifications réalisées	91

**Chapitre 4**

Fig. 4.1	Schéma regroupant les différentes étapes des méthodes proposées	111
Fig. 4.2	Cartes d'abondances originales. (a) Premier ensemble. (b) Deuxième ensemble	114
Fig. 4.3	Images multispectrales synthétiques. (a) Première image. (b) Deuxième image	115
Fig. 4.4	Images multispectrales réelles. (a) Image Landsat ETM+ (six bandes spectrales) de la région d'Oran (Algérie). (b) Image Formosat 2 (quatre bandes spectrales) de la région de Toulouse (France)	116
Fig. 4.5	Histogramme du paramètre de détection. (a) Image synthétique 1. (b) Image synthétique 2	118

Fig. 4.6	Histogramme du paramètre de détection. (a) Image Landsat ETM+. (b) Image Formosat 2	119
Fig. 4.7	Paramètre de détection dans les zones mono et multi-sources. (a) Image synthétique 1. (b) Image synthétique 2	120
Fig. 4.8	Paramètre de détection dans les zones mono et multi-sources. (a) Image Landsat ETM+. (b) Image Formosat 2	121
Fig. 4.9	Cartes d'abondances estimées à partir de la première image synthétique par (a) la méthode 2D-Corr-NLS, (b) la méthode SMACC	122
Fig. 4.10	Cartes d'abondances estimées à partir de la deuxième image synthétique par (a) la méthode 2D-Corr-NLS, (b) la méthode SMACC	123
Fig. 4.11	Cartes d'abondances estimées à partir de l'image Landsat ETM+ par (a) la méthode 2D-Corr-NLS, (b) la méthode SMACC	124
Fig. 4.12	Cartes d'abondances estimées à partir de l'image Formosat 2 par (a) la méthode 2D-Corr-NLS, (b) la méthode SMACC	125
Fig. 4.13	Performance globale (%) d'extraction des cartes d'abondances. (a) Image synthétique 1. (b) Image synthétique 2	126
Fig. 4.14	Performance globale (%) d'extraction des cartes d'abondances. (a) Image Landsat ETM+. (b) Image Formosat 2	127
 <b>Chapitre 5</b>		
Fig. 5.1	Spectres originaux. (a) Premier ensemble. (b) Deuxième ensemble	142
Fig. 5.2	Spectres extraits à partir de la première image hyperspectrale synthétique. (a) endmember 1. (b) endmember 2. (c) endmember 3. (d) endmember 4. (e) endmember 5. (f) endmember 6. (g) endmember 7. (h) endmember 8	144
Fig. 5.3	Spectres extraits à partir de la deuxième image hyperspectrale synthétique. (a) endmember 1. (b) endmember 2. (c) endmember 3. (d) endmember 4. (e) endmember 5. (f) endmember 6. (g) endmember 7. (h) endmember 8	147

**Chapitre 6**

- Fig. 6.1 Spectres originaux. (a) Spectres hyperspectraux. (b) Spectres multispectraux 163
- Fig. 6.2 Cartes d'abondances utilisées pour la création de l'image hyperspectrale synthétique 164
- Fig. 6.3 Spectres extraits. (a) endmember 1. (b) endmember 2. (c) endmember 3. (d) endmember 4. (e) endmember 5. (f) endmember 6 165

**Chapitre 3**

Tab. 3.1	Précision totale (%) des classifications par minimum de distance	91
Tab. 3.2	Précision totale (%) des classifications par SVM	91

**Chapitre 4**

Tab. 4.1	Erreur quadratique moyenne normalisée (%) pour la première image synthétique. (a) Tous les pixels de l'image. (b) Pixels purs. (c) Pixels mélangés	126
Tab. 4.2	Erreur quadratique moyenne normalisée (%) pour la deuxième image synthétique. (a) Tous les pixels de l'image. (b) Pixels purs. (c) Pixels mélangés	126

**Chapitre 5**

Tab. 5.1	Erreur quadratique moyenne normalisée (%) pour les spectres extraits de la première image hyperspectrale synthétique	150
Tab. 5.2	Erreur quadratique moyenne normalisée (%) pour les spectres extraits de la deuxième image hyperspectrale synthétique	150
Tab. 5.3	Angle spectral (°) pour les spectres extraits de la première image hyperspectrale synthétique	150
Tab. 5.4	Angle spectral (°) pour les spectres extraits de la deuxième image hyperspectrale synthétique	151

**Chapitre 6**

Tab. 6.1	Erreur quadratique moyenne normalisée (%) pour les spectres extraits	167
Tab. 6.2	Angle spectral (°) pour les spectres extraits	167

Pour des raisons de lisibilité, la signification d'une abréviation ou d'un acronyme n'est souvent rappelée qu'à sa première apparition dans le texte d'un chapitre.

2D-Corr-NLS	2 Dimension-Correlation based-Non-negative Least Squares.
2D-Corr-NMF	2 Dimension-Correlation based-Non-negative Matrix Factorization.
2D-VM	2 Dimension-Variance of Mixtures.
ACI	Analyse en Composantes Indépendantes. <i>ICA</i> <i>Independent Component Analysis.</i>
ACP	Analyse en Composantes Principales. <i>PCA</i> <i>Principal Component Analysis.</i>
ACPa	Analyse en Composantes Parcimonieuses. <i>SCA</i> <i>Sparse Component Analysis.</i>
AFTN	Analyse Factorielle avec Transformation Non-négative. <i>FANT</i> <i>Factor Analysis with Non-negative Transformation.</i>
ALD	Analyse Linéaire Discriminante. <i>LDA</i> <i>Linear Discriminant Analysis.</i>
AMUSE	Algorithm for Multiple Unknown Signal Extraction.
AS	Angle Spectral. <i>SAM</i> <i>Spectral Angle Mapper.</i>
DUET	Degenerated Unmixing Estimation Technique.
EnMAP	Environmental Mapping and Analysis Program (capteur hyperspectral).
EQMN	Erreur Quadratique Moyenne Normalisée. <i>NMSE</i> <i>Normalized Mean Square Error.</i>
FastICA	Fast Independent Component Analysis.
FCLS	Fully Constrained Least Square.
FMN	Factorisation en Matrices Non-négatives. <i>NMF</i> <i>Non-negative Matrix Factorization.</i>
FMN-CP	Factorisation en Matrices Non-négatives et Codage Parcimonieux. <i>NMF-SC</i> <i>Non-negative Matrix Factorization and Sparse Coding.</i>
FMP	Factorisation en Matrices Positives. <i>PMF</i> <i>Positive Matrix Factorization.</i>

FOBI	Fourth Order Blind Identification.
Formosat 2	Satellite d'observation de la Terre.
FTN	Factorisation en Tenseurs Non-négatifs. <i>NTF</i> <i>Non-negative Tensor Factorization.</i>
HFC	Harsanyi-Farrand-Chang eigenthresholding based methods.
HYPXIM	HYPerspectral X IMagery (capteur hyperspectral).
IAM	Identification Aveugle de Mélanges. <i>BMI</i> <i>Blind Mixture Identification.</i>
Infomax	Information maximization.
JADE	Joint Approximate Diagonalization of Eigen-matrices.
Landsat ETM+	Land satellite Enhanced Thematic Mapper Plus.
Landsat TM	Land satellite Thematic Mapper.
LI-TEPCORR	Linear Instantaneous-TEMPoral CORRelation.
LI-TEMPROM	Linear Instantaneous-TEMPoral Ratio of Mixtures.
LI-TIFCOHERE	Linear Instantaneous-TIME-Frequency COHEREnce.
LI-TIFCORR	Linear Instantaneous-TIME-Frequency CORRelation.
LI-TIFROM	Linear Instantaneous-TIME-Frequency Ratio of Mixtures.
MCN	Moindres Carrés Non-négatifs. <i>NLS</i> <i>Non-negative Least Squares.</i>
MVS	Machines à Vecteurs de Support. <i>SVM</i> <i>Support Vector Machines.</i>
MVC-NMF	Minimum Volume Constrained-Non-negative Matrix Factorization.
MVSA	Minimum Volume Simplex Analysis.
N-FINDR	Fast autonomous spectral endmember determination algorithm.
NWHFC	Noise-Whitened HFC.
OWD	Orthogonalité W-Disjointe. <i>WDO</i> <i>W-Disjoint Orthogonality.</i>
PPI	Pixel Purity Index.
PRISMA	PREcursore IperSpettrale Mission Application (capteur hyperspectral).
SAS	Séparation Aveugle de Sources. <i>BSS</i> <i>Blind Source Separation.</i>

SGM	Scaled Gradient Methods.
SISAL	Simplex Identification via Split Augmented Lagrangian.
SMACC	Sequential Maximum Angle Convex Cone.
SOBI	Second Order Blind Identification.
SONS	Second Order Non-stationary source Separation.
Spot HRV	Système pour l'observation de la Terre Haute Résolution Visible.
VCA	Vertex Component Analysis.

# *INTRODUCTION GENERALE*

Les techniques d'imagerie spatiale permettent d'enrichir l'information portée par les images traditionnelles en ajoutant une dimension spectrale. Ces techniques collectent simultanément dans plusieurs bandes spectrales la lumière émise ou diffusée par les différents éléments qui composent la scène observée. Du fait de la diversité des propriétés physico-chimiques de ces éléments, les images obtenues dans les différents canaux spectraux peuvent révéler des informations très variées.

De telles données sont désormais produites de manière courante en télédétection spatiale dans différentes applications. De ce fait, la télédétection est devenue une discipline à part entière pour l'observation et l'étude de la surface de la Terre. En effet, les satellites optiques d'observation de la Terre ont permis à la télédétection spatiale de devenir un outil incontournable pour la compréhension, le suivi et la gestion de nombreux processus naturels.

Cet essor de la télédétection spatiale a permis à la communauté scientifique l'accès à un très grand éventail de données, des données volumineuses et de grandes dimensions largement diffusées dans différentes applications militaires, environnementales, minières, etc. La disponibilité de ces données laisse espérer des avancées dans toutes ces applications. Ces avancées passent par l'élaboration de méthodologies d'analyse, de traitement et d'interprétation des images de télédétection spatiale. En général, ces méthodologies conduisent à la réalisation de cartes thématiques d'occupation des sols.

Les cartes thématiques sont établies, soit manuellement par l'intervention d'experts (opérateurs humains), soit automatiquement par l'utilisation des techniques de traitement des signaux et des images. Notons que dans ce dernier cas, une intervention humaine mineure est toujours nécessaire pour l'interprétation des résultats. Les techniques automatiques largement utilisées sont basées sur le processus classificatoire. Ce dernier associe, d'une manière générale, chaque pixel de l'image de télédétection spatiale à une classe d'occupation des sols.

Les images de télédétection spatiale sont acquises le plus souvent sur des scènes hétérogènes constituées de diverses thématiques. Ainsi, chaque pixel de ces images peut contenir plusieurs constituants. Dans ce cas, les techniques traditionnelles de classification, qui consistent à affecter une et une seule classe d'occupation des sols à chaque pixel, peuvent occasionner des erreurs aux conséquences importantes dans certaines applications, en particulier lorsqu'il s'agit d'évaluation des superficies de telle ou telle classe de sols.

Le comportement spectral d'un pixel contenant plusieurs constituants est issu de la composition des comportements spectraux de ces divers constituants rassemblés géographiquement dans ce même pixel. Cette composition est le plus souvent linéaire. Ainsi, le spectre observé au niveau du pixel considéré est une moyenne pondérée des différents spectres des constituants présents dans le même pixel.

Afin de réduire les erreurs occasionnées par les techniques traditionnelles de classification, et pour une meilleure reconnaissance des classes d'occupation des sols, d'autres méthodes prenant en compte l'aspect décrit ci-dessus doivent être mises en place. Ces méthodes ont pour objectif de décomposer linéairement les spectres mesurés au niveau des pixels d'une image en un ensemble de spectres. Aussi, et pour contribuer aux efforts consentis dans l'automatisation des méthodes de traitement des images de télédétection spatiale, la décomposition employée dans ces méthodes, doit être réalisée simplement à partir de la connaissance des spectres mesurés. Une approche permettant une telle décomposition est l'approche dite de Séparation Aveugle de Sources (SAS) (*Blind Source Separation (BSS)*).

La SAS est un problème générique qui consiste à restaurer un ensemble de signaux sources à partir d'observations qui sont des mélanges de ces signaux sources. Cette séparation est dite "Aveugle" puisqu'on admet le peu d'information a priori sur ces signaux sources.

Les premiers travaux en SAS datent du milieu des années 1980. Dès lors, la séparation de sources a commencé à susciter l'intérêt de la communauté scientifique,

qui y a vu une solution potentielle pour plusieurs problèmes dans des applications très variées, traitant des signaux de natures différentes comme les signaux acoustiques, les signaux biomédicaux, les signaux de communications numériques, les images d'astrophysique, et bien entendu, les images de télédétection spatiale considérées dans la présente thèse.

Il existe différentes méthodes permettant la séparation de sources dans le cadre des mélanges linéaires instantanés. Ces méthodes sont le plus souvent regroupées en trois catégories de méthodes. La première catégorie regroupe les méthodes fondées sur l'Analyse en Composantes Indépendantes (ACI) (*Independent Component Analysis (ICA)*). Dans la deuxième catégorie, on trouve les méthodes basées sur la Factorisation en Matrices Non-négatives (FMN) (*Non-negative Matrix Factorization (NMF)*). Enfin, les méthodes fondées sur l'Analyse en Composantes Parcimonieuses (ACPa) (*Sparse Component Analysis (SCA)*) sont regroupées dans la troisième et dernière catégorie. Lorsqu'il s'agit d'applications en imagerie de télédétection spatiale, une quatrième catégorie de méthodes de séparation de sources peut être considérée. Les méthodes de cette dernière catégorie sont basées sur un concept géométrique.

C'est dans ce cadre que le travail de recherche de cette thèse concerne le développement et l'utilisation de méthodes innovantes de séparation de sources pour des applications en imagerie de télédétection spatiale. En effet, les contributions méthodologiques de cette thèse découlent de l'approche de la SAS pour prendre en compte les mélanges contenus dans certains pixels des images de télédétection spatiale, et par conséquent, améliorer l'analyse et le traitement de ces dernières.

En plus de cette introduction générale, le présent manuscrit est organisé en six chapitres et une conclusion générale.

Le premier chapitre est consacré à des généralités et à une vue d'ensemble de la thèse. Nous commençons dans ce chapitre par des notions sur la télédétection spatiale et son processus d'analyse des données. Ensuite, une description détaillée de la problématique abordée dans la thèse est donnée. Après cette description, des généralités

sur la SAS sont abordées. Deux modélisations des images de télédétection spatiale selon la nomenclature de la SAS sont décrites avant de donner un aperçu sur les contributions méthodologiques de notre travail et de conclure le premier chapitre.

Dans le deuxième chapitre nous donnons un panorama des méthodes concernées par notre travail de recherche. Dans un premier temps, les méthodes habituelles de la SAS sont décrites. Ces méthodes sont celles fondées sur l'ACI, la FMN et l'ACPa. Dans un deuxième temps, les techniques les plus utilisées pour démêler des images de télédétection spatiale sont abordées. Par la suite, nous exposons les motifs de notre choix d'une seule modélisation des images pour nos contributions méthodologiques. Les critères de performance des méthodes mises en place sont décrits avant de conclure le deuxième chapitre.

Le troisième chapitre est consacré au prétraitement par des méthodes classiques de SAS d'une image multispectrale de télédétection spatiale en vue d'une classification supervisée de ses pixels. Les méthodes utilisées dans ce chapitre sont celles fondées sur l'ACI et la FMN. Nous commençons ce chapitre par la description détaillée de l'approche proposée pour atteindre les objectifs de cette dernière. Ensuite, les données utilisées ainsi que les résultats obtenus sont présentés. À la fin et avant de conclure ce deuxième chapitre, les résultats sont discutés.

Dans le quatrième chapitre, l'extraction de cartes d'abondances à partir d'une image multispectrale est l'objectif visé. Les hypothèses et définitions, ainsi que la description des méthodes mises en place dans ce chapitre sont abordées dans un premier temps. Ces méthodes sont basées sur la combinaison d'une méthode d'ACPa, du clustering, et des méthodes fondées sur les contraintes de non-négativité. Les données utilisées, les résultats obtenus sont présentés dans un deuxième temps. Nous terminons ce chapitre par une conclusion.

L'extraction de spectres à partir d'une image hyperspectrale est abordée dans le cinquième chapitre. Ainsi, nous commençons ce chapitre par la description de la

méthode proposée. Cette dernière est basée sur l'ACPa. Par la suite, des résultats expérimentaux sont présentés. À la fin, une conclusion est donnée.

Le sixième et dernier chapitre est consacré à l'extraction de spectres à partir d'une image hyperspectrale combinée avec une image multispectrale. Nous débutons ce chapitre par un exposé de l'intérêt de l'approche proposée, et la description de la méthode mise en place. Cette méthode est basée sur la FMN. Avant de conclure ce chapitre, nous donnons des résultats expérimentaux.

Le domaine de recherche concerné par cette thèse est récent, et de nombreuses réflexions sont en cours, notamment sur le type des mélanges, ainsi que sur les possibilités d'applications de la SAS en imagerie de télédétection spatiale. Le travail présenté dans ce document, ne présente qu'une partie de l'application de la SAS en imagerie spatiale, et constitue pour nous une voie prometteuse pour de futurs travaux. Nous terminons donc ce manuscrit, avec une conclusion générale qui va nous permettre de revoir en globalité les travaux accomplis, de mettre en évidence les résultats obtenus, et de donner quelques perspectives de recherche au présent travail.

# CHAPITRE 1

## GENERALITES ET VUE D'ENSEMBLE

---

*Résumé* - Ce chapitre se propose dans un premier temps de fournir au lecteur un bref descriptif des principaux concepts de la télédétection spatiale optique pour des applications d'observation de la Terre. Dans une seconde étape, la problématique abordée dans la présente thèse est détaillée. Avant d'introduire brièvement les contributions méthodologiques présentées dans ce travail, des généralités sur l'approche dite de séparation aveugle de sources, ainsi que la modélisation des images de télédétection spatiale selon la nomenclature de cette dernière sont présentées. En effet, les apports méthodologiques pour résoudre la problématique de la thèse découlent de cette dernière approche.

---

## DANS CE CHAPITRE

1.1. Télédétection spatiale et son processus d'analyse des données	9
1.2. Problématique abordée dans la thèse	15
1.3. Généralités sur la séparation aveugle de sources	19
1.4. Modélisation des images de télédétection spatiale selon la nomenclature de la séparation aveugle de sources	25
1.4.1. Approche intuitive : sources spectrales	25
1.4.2. Approche alternative : sources spatiales	27
1.5. Contributions méthodologiques de la thèse	28
1.5.1. Prétraitement par séparation de sources et classification d'une image multispectrale	29
1.5.2. Extraction de cartes d'abondances à partir d'une image multispectrale avec pixels purs	29
1.5.3. Extraction de spectres à partir d'une image hyperspectrale avec pixels purs	30
1.5.4. Extraction de spectres à partir d'une image hyperspectrale sans pixels purs, combinée avec une image multispectrale avec pixels purs	30
1.6. Conclusion	31
Références bibliographiques citées dans le Chapitre 1	32

## **1.1. Télédétection spatiale et son processus d'analyse des données**

La télédétection spatiale est la discipline scientifique qui regroupe l'ensemble des connaissances et des techniques utilisées pour la détermination des caractéristiques physiques et biologiques de la surface de la Terre par des mesures effectuées à distance, sans contact matériel avec celle-ci [2].

La télédétection spatiale optique moderne est née de la photographie aérienne et intègre les développements récents de la recherche spatiale, de la physique et de l'informatique pour constituer aujourd'hui un outil des plus puissants et des plus flexibles pour la compréhension, le suivi et la gestion de nombreux processus naturels.

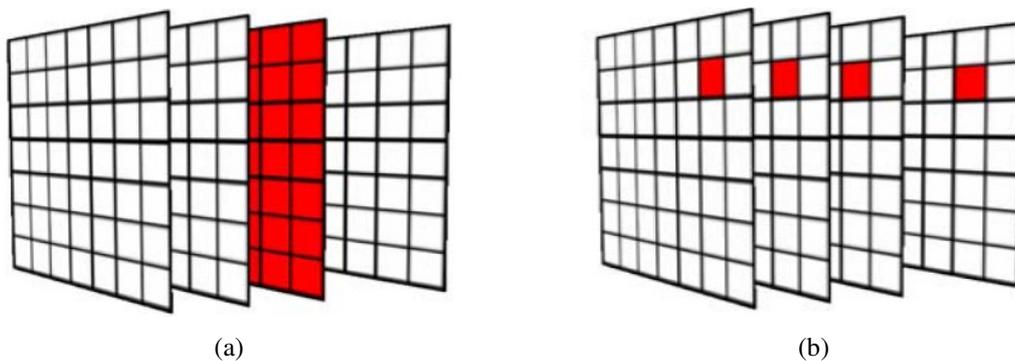
Les possibilités d'application de la télédétection spatiale sont en croissance constante et l'on découvre de plus en plus de domaines où elle est la source principale d'information pour les études de la transformation du globe à une échelle locale, régionale et même mondiale. Parmi ces applications, on peut citer celles terrestres comprenant la cartographie régulière et thématique, la géologie, la prospection minière, la géomorphologie, la pédologie, l'agriculture, l'aménagement des territoires, l'urbanisme, et la surveillance des catastrophes naturelles. D'autres applications non terrestres existent. Parmi celles-ci, on trouve celles liées aux études océanographiques (analyse de la couleur des océans, mesures des températures de surface de la mer,...) et celles relatives à l'étude de l'atmosphère (météorologie et climatologie).

L'information sur la surface de la Terre est traditionnellement une image (c'est-à-dire un signal fourni par un capteur qui sert à la reconstruction de la vérité-terrain), et est portée vers un système d'observation dans la grande majorité des applications à l'aide d'un rayonnement électromagnétique, comme la lumière, qui est la manifestation visible de ce rayonnement. Ce dernier est une onde électromagnétique possédant les propriétés principales d'émission, d'absorption, de réflexion, et de transmission [2]. Le phénomène de réflexion de la lumière par les surfaces constitue la base de la plupart des applications de la télédétection spatiale. En effet, les diverses surfaces réagissent différemment au rayonnement électromagnétique par la propriété de réflexion, ce qui

constitue la base des signatures spectrales. L'information sur la surface de la Terre devient donc traditionnellement une image de réflectance.

Les techniques d'imagerie spatiale permettent d'enrichir l'information portée par les images traditionnelles, dites "panchromatiques", en ajoutant une dimension spectrale : il s'agit de collecter simultanément dans différentes longueurs d'ondes la lumière réfléchi par les éléments qui composent la scène observée. Ainsi, les images de télédétection spatiale fournissent, pour chaque élément du plan spatial, appelé pixel, une mesure (réflectance) sur plusieurs longueurs d'ondes.

Les images de télédétection spatiale optique sont des données agencées en cubes avec deux directions spatiales définissant la position d'un pixel sur l'image, et une direction spectrale correspondant à la décomposition de la lumière à des longueurs d'ondes précises. L'ensemble des pixels sur une longueur d'onde forme une bande spectrale (Fig. 1.1(a)). L'ensemble des valeurs associées aux pixels ayant la même position sur l'image forme un spectre (Fig. 1.1(b)). L'analyse des spectres permet d'identifier, quantifier et cartographier la distribution spatiale des constituants de surface.



**Fig. 1.1.** Représentation d'une image de télédétection spatiale. (a) Bande spectrale. (b) Spectre.

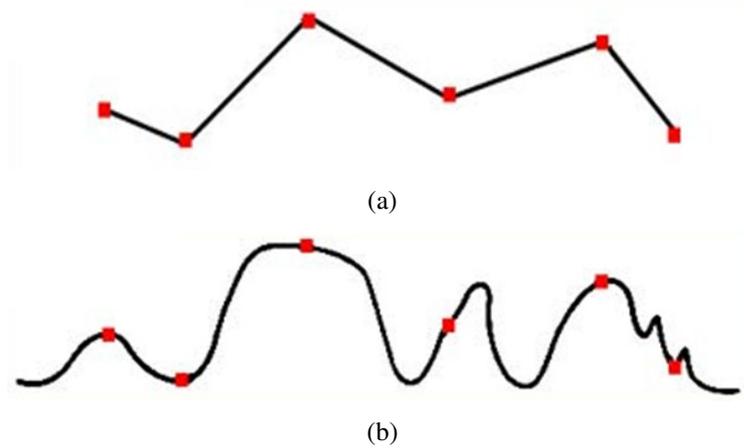
De telles données sont actuellement produites de manière courante en télédétection spatiale pour différentes applications. Ces données sont issues de systèmes spatiaux d'observation de plus en plus performants. Les capteurs embarqués à bord de ces systèmes d'observation, et par conséquent les images produites par ces capteurs, sont caractérisés par trois types de résolutions : la résolution spatiale, la résolution

spectrale, et la résolution radiométrique. La résolution spatiale est définie par le "champ de vision instantané" qui détermine l'aire de la surface "visible" par un élément du capteur (détecteur CCD par exemple). Donc pour pouvoir être spatialement résolu, un objet de la surface doit avoir une dimension supérieure ou égale à celle de cette aire. Les images sur lesquelles seuls les grands éléments sont visibles ont une résolution "grossière" ou "basse" (Fig. 1.2(a)). Les images à résolution "fine" ou "élevée" permettent l'identification d'éléments de plus petites dimensions (Fig. 1.2(b)).

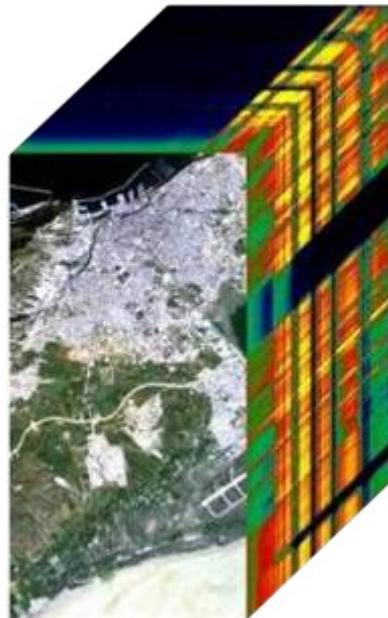


**Fig. 1.2.** Images de télédétection spatiale optique avec différentes résolutions spatiales. (a) Image de basse résolution spatiale. (b) Image d'une résolution spatiale élevée.

La résolution spectrale d'un capteur décrit la capacité de ce capteur à distinguer les différentes longueurs d'ondes des rayons qui lui parviennent. On parle d'imagerie multispectrale lorsque le nombre des longueurs d'ondes utilisées est généralement inférieur à dix. Lorsque ce nombre devient important (souvent supérieur à cent), on parle d'imagerie hyperspectrale. En imagerie multispectrale, on associe à chaque pixel plusieurs valeurs scalaires qui correspondent à la mesure du rayonnement électromagnétique incident sur le capteur dans quelques bandes spectrales larges et le plus souvent non contiguës (Fig. 1.3(a)). Au contraire, en imagerie hyperspectrale, on utilise un grand nombre de bandes spectrales étroites et contiguës (Fig. 1.3(b)). Dans ce dernier cas, l'image de télédétection spatiale est souvent appelée "pavé hyperspectral" ou "hypercube" (Fig. 1.4).



**Fig. 1.3.** Spectre multi et hyperspectral. (a) Spectre multispectral discontinu à larges bandes. (b) Spectre hyperspectral continu à bandes étroites.

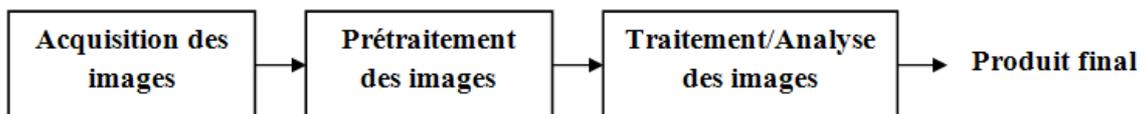


**Fig. 1.4.** Représentation d'un pavé hyperspectral.

La résolution radiométrique d'un capteur décrit sa capacité à reconnaître de petites différences dans l'intensité reçue de la surface observée. Le nombre maximum d'intensités différentes qu'il est possible de distinguer par un élément du capteur est en relation avec le nombre de bits utilisés pour les représenter et les enregistrer dans un système informatique. Une capacité de 8 bits par exemple, donne  $2^8=256$  intensités différentes.

La conception d'un capteur satellitaire passe inévitablement par un compromis entre les différentes résolutions présentées ci-dessus. Plus la résolution spatiale est fine, plus la résolution radiométrique est faible. Si on veut augmenter la résolution radiométrique sans réduire la résolution spatiale, il est nécessaire d'élargir la largeur des longueurs d'ondes, ce qui revient à diminuer la résolution spectrale. Inversement, une basse résolution spatiale permet une résolution radiométrique plus grande et une résolution spectrale plus fine.

Les caractéristiques des images de télédétection spatiale peuvent être exploitées de façon synergique pour l'extraction d'informations précieuses pour de nombreuses applications du monde réel. Dans ce contexte, un schéma général d'un système d'extraction et de reconnaissance d'information utilisant des images de télédétection spatiale, qui a la tâche d'interpréter la réalité physique des scènes observées, peut être décomposé en trois phases principales [15]. Ces phases sont représentées par la figure suivante (Fig. 1.5).



**Fig. 1.5.** Schéma de base d'un système d'extraction et de reconnaissance d'information en télédétection spatiale.

La phase d'acquisition est réalisée par un capteur embarqué sur une plate-forme (satellite d'observation de la Terre par exemple). Ce capteur a pour objectif la traduction de la réalité physique en un signal électrique, à savoir, une image numérique.

La phase de prétraitement vise à réduire les erreurs possibles issues de la phase d'acquisition. En effet, ces erreurs peuvent influencer négativement sur la phase de traitement et d'analyse. En général, ces erreurs sont de nature radiométrique ou géométrique. D'une part, les erreurs radiométriques sont principalement dues aux conditions atmosphériques. D'autre part, les erreurs géométriques peuvent provenir du mouvement de la plate-forme embarquant le capteur, la courbure de la Terre, ou même de la géométrie du système capteur lui-même.

Enfin, la phase de traitement et d'analyse vise à extraire les informations considérées (produit final) à partir des images prétraitées. Il existe deux principales approches pour réaliser un produit final. L'intervention directe d'un opérateur humain est au cœur de la première approche. Dans cette dernière, le processus de photo-interprétation des images est utilisé pour aboutir au produit final. La deuxième approche repose principalement sur l'utilisation des méthodes automatiques d'extraction et de reconnaissance d'informations contenues dans les images. Ces méthodes sont issues du domaine du traitement des signaux et des images. Notons qu'une intervention "mineure" d'un opérateur humain dans une ou plusieurs étapes de cette deuxième approche, est toujours nécessaire pour réaliser un produit final interprétable.

Le plus souvent, les méthodes automatiques d'analyse d'images de télédétection spatiale conduisent à la réalisation de cartes d'occupation des sols par le biais du processus de classification. Ce dernier, nécessite généralement une étape de prétraitement. Notons que cette étape de prétraitement n'est pas celle abordée plus haut, et qui concerne la correction des erreurs dues à la phase d'acquisition. Au contraire, le prétraitement visé ici est celui qui a pour objectif l'amélioration de la classification des données.

D'une manière générale, le prétraitement peut comporter une partie des étapes suivantes (Fig. 1.6) : 1) réduction de la dimensionnalité, 2) extraction de caractéristiques (textures, indices (brillance des sols, végétation,...), contours,...), et 3) sélection des caractéristiques pertinentes. La méthode la plus couramment utilisée dans la première étape est l'Analyse en Composantes Principales (ACP) (*Principal Component Analysis (PCA)*) [21]. Dans la deuxième étape, à partir des données, certaines caractéristiques sont extraites pour être injectées, en plus ou en remplacement des données initiales, dans le processus classificatoire. La dernière étape consiste à sélectionner (par le biais de mesures entre les différentes classes d'intérêt) les meilleures caractéristiques extraites auparavant.

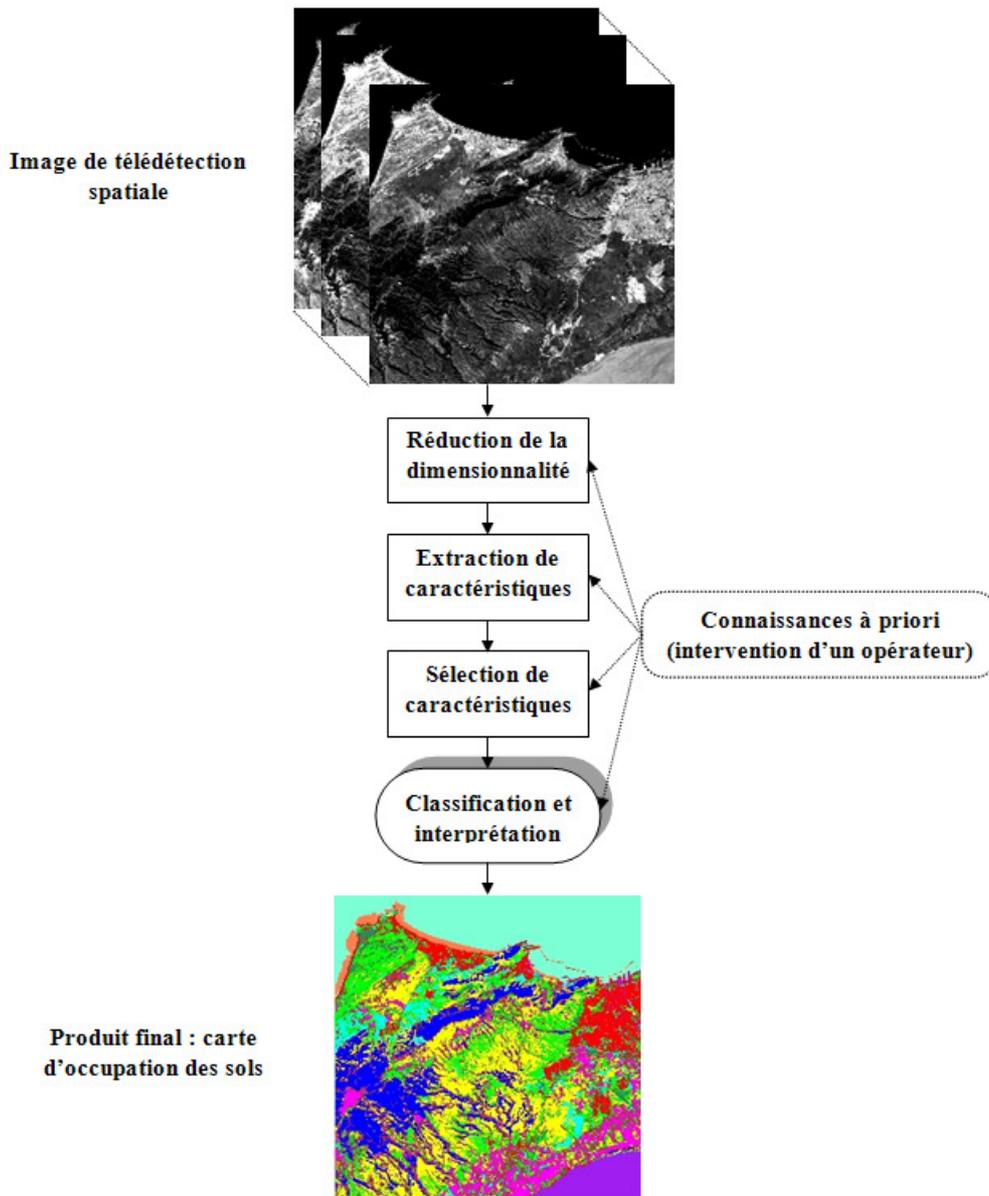


Fig. 1.6. Schéma d'un processus typique d'analyse et de traitement d'images de télédétection spatiale.

## 1.2. Problématique abordée dans la thèse

Quand on veut étudier un phénomène donné par l'utilisation de l'imagerie de télédétection spatiale, il est souhaitable d'avoir la meilleure adéquation possible entre les dimensions des pixels de l'image et les dimensions du phénomène à étudier. Or le plus souvent, une image de télédétection se situe entre les deux dimensions plutôt qu'en

correspondance avec l'une d'elles. Cette image, qui correspond à une grille constituée par le positionnement des pixels sur le terrain, est acquise généralement sur une scène hétérogène dans laquelle plusieurs constituants, qu'on appellera par la suite "matériaux purs", sont présents. Comme cette grille est entièrement arbitraire, puisqu'elle dépend de la trajectoire de la plate-forme, et lorsqu'on atteint les limites de la résolution spatiale du capteur, des pixels de la grille peuvent contenir chacun plusieurs matériaux purs (Fig. 1.7). Ces pixels mélangés sont appelés "mixels". Les pixels non mélangés, c'est-à-dire ceux qui ne contiennent chacun qu'un seul matériau pur, sont appelés "pixels purs".

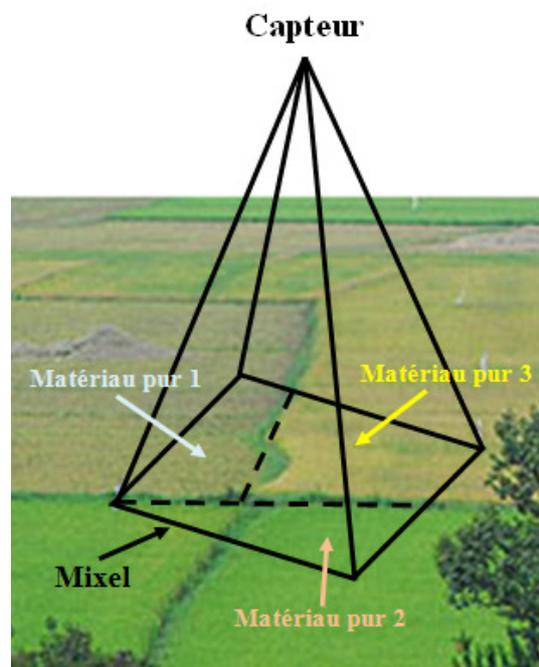
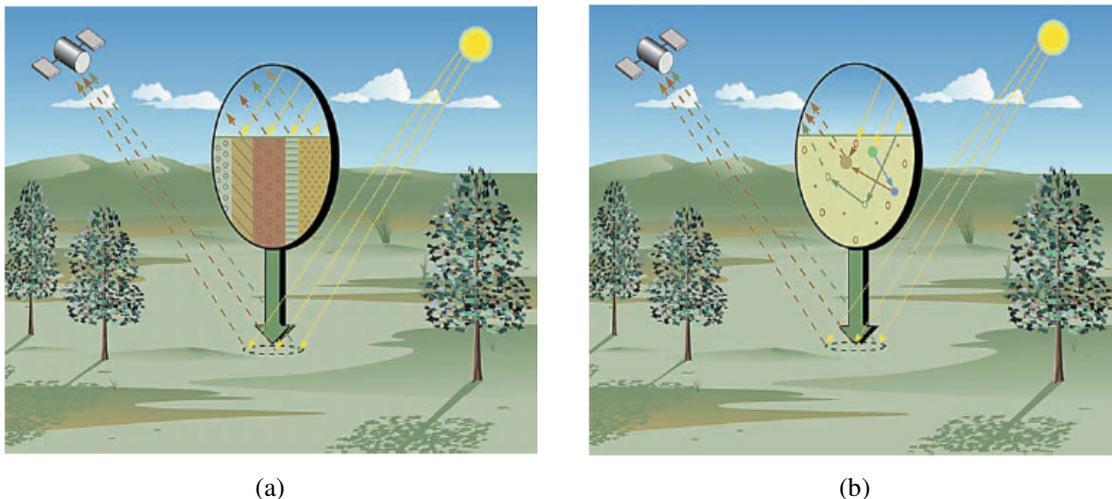


Fig. 1.7. Illustration d'un mixel (pixel mélangé) contenant plusieurs matériaux purs.

La présence de mixels dans une image de télédétection occasionne des erreurs dans le processus classificatoire. En effet, on est en présence de mixels présentant des valeurs ne correspondant à aucun des thèmes que l'on désire classer. Les conséquences des erreurs du processus classificatoire peuvent être importantes en cartographie, en particulier lorsqu'il s'agit d'évaluer des superficies de telle ou telle occupation du sol, ou encore de suivre les évolutions diachroniques de leur extension [15].

Le comportement spectral d'un mixel est issu de la composition des réponses spectrales des divers matériaux purs rassemblés géographiquement dans le même élément de résolution. Autrement dit, les spectres des matériaux purs, contenus dans le mixel, contribuent au spectre observé au niveau de ce dernier. Dans ce cas, on parle de "mélange spectral" (*spectral mixing*). Le modèle analytique le plus couramment utilisé pour représenter ce genre de mélange est de type linéaire [25]. En effet, le modèle linéaire reste parfaitement réaliste lorsqu'on s'intéresse aux grands ensembles d'occupation des sols présents dans une scène avec un relief relativement plat, et agencés en surfaces adjacentes constituant une sorte de "damier" (Fig. 1.8(a)). Dans le cas contraire, c'est-à-dire lorsque la scène observée est caractérisée par un relief accidenté, ou bien lorsqu'on est en présence de matériaux agencés de telle sorte que la réflexion de ces derniers est multiple (Fig. 1.8(b)), le modèle non linéaire est le plus adéquat pour représenter le mélange spectral [25]. Notons que même dans ce dernier cas, le modèle linéaire reste une bonne approximation du modèle non linéaire.



**Fig. 1.8.** Illustration du modèle de mélange spectral [25]. (a) Mélange linéaire. (b) Mélange non linéaire.

Ainsi, dans le modèle linéaire du mélange spectral, le spectre observé au niveau d'un mixel est un spectre linéairement mélangé, et il représente une moyenne pondérée (combinaison linéaire) des différents spectres des matériaux purs présents dans ce mixel (Fig. 1.9). La pondération affectée à chaque spectre d'un matériau pur représente l'"abondance" de ce dernier dans le mixel.

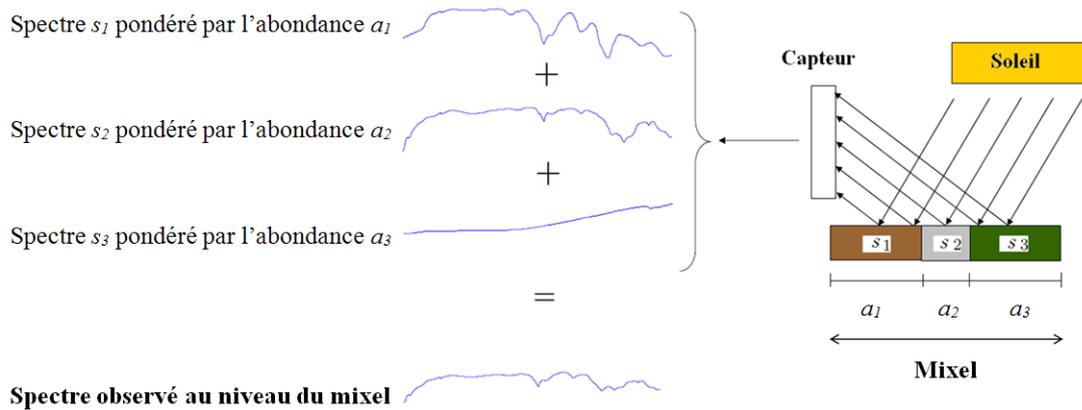


Fig. 1.9. Illustration d'un spectre linéairement mélangé.

Afin de réduire les erreurs du processus classificatoire occasionnées par la présence des mixels dans une image de télédétection spatiale, et pour une meilleure reconnaissance des ensembles d'occupation des sols présents dans la scène observée, d'autres méthodes prenant en compte cet aspect du mélange spectral doivent être mises en place. Ces méthodes ont pour objectif de décomposer les spectres mesurés ou observés au niveau des pixels d'une image en un ensemble de spectres purs (correspondant aux matériaux purs) et d'abondances respectives. Cette approche est appelée procédure de "démélange spectral" (*spectral unmixing*).

Il existe dans la littérature des méthodes permettant la réalisation du démélange spectral [15], mais l'inconvénient majeur de ces méthodes est qu'elles supposent que les spectres des matériaux purs présents dans la scène observée sont bien connus et référencés dans des catalogues de comportements spectraux (bibliothèques spectrales). D'une part, ces derniers ne sont souvent pas disponibles, et d'autre part, lorsque ces bibliothèques sont disponibles, les longueurs d'ondes utilisées en laboratoire pour les compiler ne correspondent pas toujours aux longueurs d'ondes utilisées sur le capteur. Aussi, et dans le cas où les longueurs d'ondes correspondent, il n'est généralement pas possible de connaître à l'avance dans une approche automatique, la nature des matériaux purs présents dans une image de télédétection spatiale. Tout cela rend les méthodes en question quasiment inutiles, ou bien très lourdes et lentes, ce qui réduit considérablement leur utilisation dans des applications réelles. Par conséquent, il faut recourir à d'autres méthodes capables de décomposer les spectres mesurés à partir seulement de la connaissance de ces derniers.

L'approche permettant une telle décomposition est l'approche dite de Séparation Aveugle de Sources (SAS) (*Blind Source Separation (BSS)*) [9, 13]. Les contributions méthodologiques de la présente thèse découlent de cette approche pour résoudre la problématique décrite ci-dessus.

### 1.3. Généralités sur la séparation aveugle de sources

Les techniques du traitement du signal trouvent des applications dans pratiquement tous les domaines de la technologie, particulièrement en audio. Une bonne partie des signaux audio sont des mélanges auxquels contribuent plusieurs sources. L'étude des mélanges audio a de nombreuses applications dont la plus populaire est le problème du cocktail (*cocktail party problem*) (Fig. 1.10). Ce nom provient de la situation rencontrée par exemple lors d'un joyeux déjeuner familial. Comment comprendre ce que dit notre voisin parmi les autres voix ? Un tel exploit est facilement réalisable par les couches supérieures du cortex. Ce type de comportement peut être aussi copié par un système artificiel. Ainsi, le terme "cocktail party" est devenu le surnom de la séparation aveugle de sources dans le domaine audio.



Fig. 1.10. Illustration du problème du cocktail (*cocktail party problem*).

La séparation aveugle de sources est une discipline plus au moins jeune, les premiers travaux sont attribués à Héault, Jutten et Ans au milieu des années 1980 [17]. Dans [22], Jutten et Taleb décrivent le problème biologique qui a initié les travaux sur la séparation de sources. Celui-ci consistait à étudier les réponses musculaires émises à l'issue de différentes sortes d'excitations.

Dans un contexte tout à fait général, la séparation de sources consiste à restaurer  $L$  signaux sources inconnus  $s_j$  à partir de  $K$  observations  $x_i$ . Ces observations sont des mélanges des signaux sources et proviennent généralement de capteurs, tels que des microphones, des antennes radiofréquences, des capteurs CCD... Le mélange entre les signaux sources est dû à la propagation simultanée de ces derniers jusqu'aux capteurs. La relation liant les sources et les observations est donnée par :

$$x = F(s), \quad (1.1)$$

où  $s = [s_1 \dots s_L]^T$  et  $x = [x_1 \dots x_K]^T$  sont deux vecteurs colonnes représentant respectivement l'ensemble des signaux sources et l'ensemble des signaux d'observations, et  $F(\cdot)$  dénote l'opérateur de mélange. L'originalité de la SAS réside dans le fait qu'on se place dans un contexte aveugle, c'est-à-dire que l'opérateur de mélange ainsi que les signaux sources sont inconnus.

L'objectif ambitieux de la SAS est de construire un système capable de fournir des sorties  $y_j$  égales aux signaux sources  $s_j$ . La reconstruction des signaux sources est réalisée grâce au modèle :

$$y = G(x), \quad (1.2)$$

où  $y = [y_1 \dots y_L]^T$  est un vecteur colonne représentant l'ensemble des signaux de sortie et  $G(\cdot)$  est l'opérateur inverse de  $F(\cdot)$ . Il apparaît ici deux problèmes qui peuvent être différents. En effet, on peut considérer le problème de l'estimation du modèle de mélange, que l'on appelle problème d'Identification Aveugle de Mélanges (IAM) (*Blind Mixture Identification (BMI)*). Ou bien, on peut considérer le problème appelé

restitution des sources [13] consistant à proposer une estimation des sources sans pour autant proposer une estimation de la structure de mélange. Bien entendu, ces deux problèmes coïncident lorsque le mélange est inversible. La configuration générale de la séparation aveugle de sources est donnée dans la figure (Fig. 1.11) suivante.

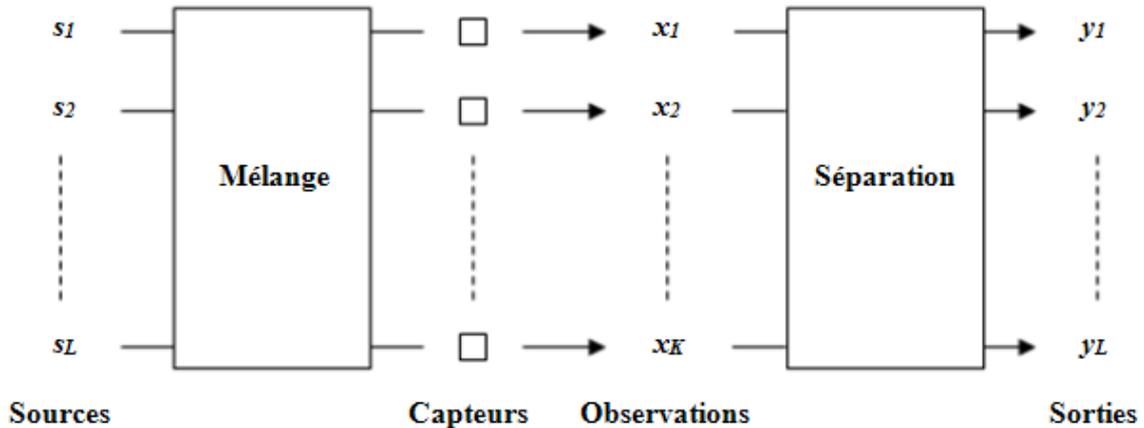


Fig. 1.11. Configuration générale de la séparation aveugle de sources.

La SAS est une "discipline générique" qui permet de nombreuses applications telles que la biologie et le génie biomédical [11, 24, 27, 35, 36], la chimie [30], et l'astrophysique d'une manière générale [1, 3, 29]. Un aperçu plus exhaustif des différentes applications de la SAS peut être trouvé dans [5, 9, 20, 23].

La SAS possède plusieurs degrés de difficulté. Plusieurs paramètres sont à prendre en considération, plus particulièrement, les deux points théoriques qui sont le type de mélange et le nombre  $K$  d'observations par rapport au nombre  $L$  de signaux sources.

Concernant le nombre  $K$  d'observations par rapport au nombre  $L$  de signaux sources, on conçoit que le cas "(sur)déterminé", c'est-à-dire  $K = L$  ( $K > L$ ), est plus simple à résoudre que le cas "sous-déterminé", c'est-à-dire  $K < L$ . Ce dernier cas ne peut être résolu qu'à l'aide d'importantes informations a priori. Selon l'objectif recherché, l'un ou l'autre cas sera considéré dans les chapitres liés à nos contributions méthodologiques relatives à des applications de la SAS en télédétection spatiale.

Pour le type de mélange, on trouve dans la littérature plusieurs types. Une première catégorie, largement étudiée, concerne les mélanges "linéaires", c'est-à-dire le cas où les observations sont des mélanges linéaires des signaux sources. Cette catégorie est découpée en trois sous-catégories :

"*Mélanges linéaires instantanés*" dans lesquels les valeurs des observations à un instant (lorsqu'il s'agit de signaux temporels monodimensionnels) ou à une position (lorsqu'il s'agit de signaux spatiaux bidimensionnels), ou à une longueur d'onde (lorsqu'il s'agit de spectres), s'écrivent comme des combinaisons linéaires des valeurs des signaux sources au même instant ou à la même position, ou à la même longueur d'onde. Dans ce cas, le modèle (1.1) s'écrit, pour des signaux temporels, sous la forme suivante :

$$x(t) = A s(t), \quad (1.3)$$

où  $A$  est une matrice constante inconnue dite "matrice de mélange". Cette dernière contient des coefficients constants dits "coefficients de mélange". On trouve pratiquement ce genre de mélange dans les applications où les temps de propagation, ou les décalages spatiaux, sont négligeables.

"*Mélanges linéaires à atténuations et retards*" dans lesquels les temps de propagation, ou les décalages spatiaux, sont pris en considération.

"*Mélanges linéaires convolutifs*" dans lesquels les capteurs fournissent des superpositions de versions filtrées des signaux sources reçus. Ce type de mélange est le plus général des trois présentés.

La seconde catégorie de mélange, concerne les mélanges non-linéaires, qui sont plus généraux. La complexité de cette dernière catégorie de mélanges limite son étude à des configurations particulières, comme par exemple le cas « post-non-linéaire » [34], ou bien le cas d'un mélange linéaire-quadratique [12, 18, 19, 26], ou encore le cas d'un mélange quadratique [4].

Les méthodes étudiées au cours de nos travaux ne concernent que les mélanges linéaires instantanés. Par conséquent, nous ne parlerons pas des autres types de mélanges dans la suite de ce manuscrit. Le principe général des méthodes de SAS linéaire instantanée (Fig. 1.12) consiste à transférer les observations dans un système qui inverse la matrice de mélange  $A$  afin de restaurer les signaux sources. La difficulté provient du fait que cette matrice est inconnue, ce qui revient à inverser une matrice inconnue. Cette difficulté nous amène à déterminer une estimation  $\hat{A}^{-1}$  de l'inverse de la matrice  $A^{-1}$ , pour en déduire par la suite une estimation des signaux sources en transférant les observations dans le système qui réalise la matrice  $\hat{A}^{-1}$ . On obtient alors :

$$y = \hat{A}^{-1} x, \quad (1.4)$$

et par conséquent :

$$y = \hat{A}^{-1} A s = \hat{s} \approx s, \quad (1.5)$$

ce qui nous permet de restituer les signaux sources. La matrice  $C = \hat{A}^{-1}$  est dite « matrice de séparation ».

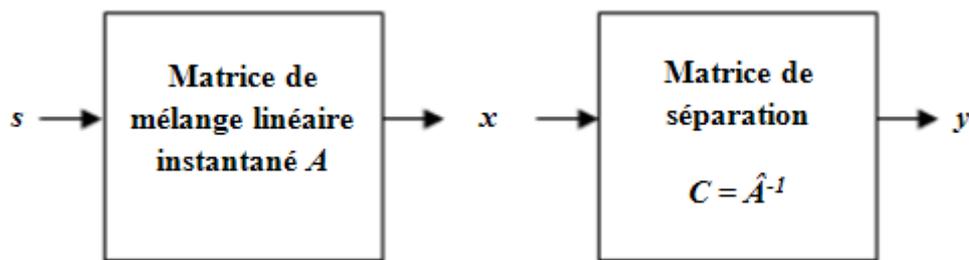


Fig. 1.12. Principe général des méthodes de SAS linéaire instantanée.

L'estimation d' $A^{-1}$  ou d'une grandeur associée (par exemple  $A$  pour en déduire ensuite une estimation d' $A^{-1}$ ) est faite à partir des seules observations en utilisant les seules hypothèses faites sur les sources.

Il existe différentes méthodes qui permettent la séparation de sources dans le cadre des mélanges linéaires instantanés. Ces méthodes sont généralement regroupées

en trois catégories de méthodes. La première catégorie concerne les méthodes d'Analyse en Composantes Indépendantes (ACI) (*Independent Component Analysis (ICA)*). Dans la seconde catégorie, on trouve les méthodes de Factorisation en Matrices Non-négatives (FMN) (*Non-negative Matrix Factorization (NMF)*). La troisième catégorie regroupe les méthodes d'Analyse en Composantes Parcimonieuses (ACPa) (*Sparse Component Analysis (SCA)*). Lorsqu'il s'agit d'applications en imagerie de télédétection spatiale, une quatrième catégorie de méthodes de séparation de sources peut être considérée. Les méthodes de cette dernière catégorie sont basées sur un concept géométrique.

L'ACI constitue l'une des classes de méthodes les plus utilisées en SAS. En effet, historiquement, pendant des années, séparation de sources et ACI ont été la même chose. Les travaux de Comon [8] ont permis de formaliser grâce au théorème de Darmois [10], l'équivalence entre ACI et SAS dans le cadre d'un mélange linéaire instantané, inversible et non bruité avec la présence d'au plus une source gaussienne. À partir de ces travaux, de nombreuses méthodes d'ACI ont été développées. Ces méthodes ont mené à de nombreux algorithmes dans le cadre des mélanges linéaires instantanés. Pour un exposé plus précis, nous renvoyons le lecteur aux ouvrages dédiés à l'ACI et la SAS [9, 13, 20].

Les méthodes de FMN sont regroupées dans la deuxième catégorie de méthodes permettant la séparation de sources. Ces méthodes retiennent une attention particulière de la part de la communauté scientifique [6, 7]. En effet, ces méthodes font l'hypothèse que les signaux sources et les coefficients de mélange sont non-négatifs, et par conséquent, elles sont particulièrement adaptées pour la séparation de signaux tels que les images de télédétection spatiale.

Les méthodes d'ACPa représentent une autre voie possible pour la SAS. Cette classe de méthodes est actuellement très populaire [9, 16, 31] et très attractive lorsque les signaux sources recherchés présentent, dans un domaine de représentation (temporel, spatial, temps-fréquence ou temps-échelle par exemple) un caractère parcimonieux, c'est-à-dire sont très faibles dans certaines zones de la représentation. Ce caractère

parcimonieux des signaux sources permet la restauration de ces derniers. L'ACPa permet en particulier la restauration des signaux sources gaussiens et/ou corrélés, ainsi que la séparation partielle des mélanges sous-déterminés.

Signalons ici, que dans le cadre de mélanges linéaires instantanés, les méthodes d'ACI et de FMN, ainsi que certaines méthodes d'ACPa, fournissent les signaux sources, au mieux à un facteur d'échelle (en incluant également le signe sauf pour la FMN) et à une permutation près. Cela constitue les indéterminations liées à la SAS linéaire instantanée [9, 13].

#### **1.4. Modélisation des images de télédétection spatiale selon la nomenclature de la séparation aveugle de sources**

Dans cette thèse, nous envisageons un moyen pour tirer profit des techniques de séparation aveugle de sources dans le domaine de la télédétection spatiale. Partant du fait que le modèle linéaire instantané est celui qui est le plus couramment utilisé pour représenter le mélange spectral, et conformément à la terminologie de la SAS, il s'agit dans un premier temps de répondre à la question suivante : qu'appelle-t-on "observations" et qu'appelle-t-on "sources" ? Très vite, il est possible d'identifier deux modélisations différentes des images de télédétection spatiale. En effet, nous pouvons répondre de deux manières différentes aux interrogations précédentes selon deux approches présentées ci-dessous.

##### **1.4.1. Approche intuitive : sources spectrales**

Comme expliqué dans la Section 1.2, nous considérons chaque spectre (vecteur ligne) associé à un pixel d'une image comme un mélange linéaire instantané des spectres (vecteurs lignes) associés aux  $L$  matériaux purs présents dans la même image (les  $K$  pixels de l'image sont représentés ici sous une forme unidimensionnelle). Les valeurs de chaque vecteur ligne correspondent aux  $N$  bandes spectrales de l'image. En rassemblant l'ensemble des pixels de l'image, nous obtenons un modèle cohérent avec (1.3) si on remplace  $t$  par  $n$  pour  $n = 1 \dots N$ . Ce dernier s'écrit sous la forme :

$$\begin{pmatrix} x_1(1) & \dots & x_1(N) \\ \vdots & \ddots & \vdots \\ x_K(1) & \dots & x_K(N) \end{pmatrix} = \begin{pmatrix} a_{11} & \dots & a_{1L} \\ \vdots & \ddots & \vdots \\ a_{K1} & \dots & a_{KL} \end{pmatrix} \begin{pmatrix} s_1(1) & \dots & s_1(N) \\ \vdots & \ddots & \vdots \\ s_L(1) & \dots & s_L(N) \end{pmatrix}, \quad (1.6)$$

où  $x_i(n)$  représente la  $i$ ème composante spectrale (réflectance) du pixel  $i$ ,  $s_j(n)$  est la  $j$ ème composante spectrale du matériau pur  $j$  et  $a_{ij}$  représente l'abondance du matériau pur  $j$  dans le pixel  $i$ . Ainsi, nous appelons "sources (spectrales)" les spectres des matériaux purs, et chaque observation correspond à un pixel de l'image. Une représentation bidimensionnelle de cette approche est donnée dans la figure (Fig. 1.13). En plus, les contraintes naturelles suivantes doivent être considérées :

$$s_j(n) \geq 0, a_{ij} \geq 0 \text{ et } \sum_j a_{ij} = 1, \forall \begin{matrix} i = 1 \dots K \\ j = 1 \dots L \\ n = 1 \dots N \end{matrix} \quad (1.7)$$

Ces contraintes naturelles signifient que les composantes spectrales ainsi que les abondances sont positives ou nulles, et que la somme des abondances sur chaque pixel vaut 1.

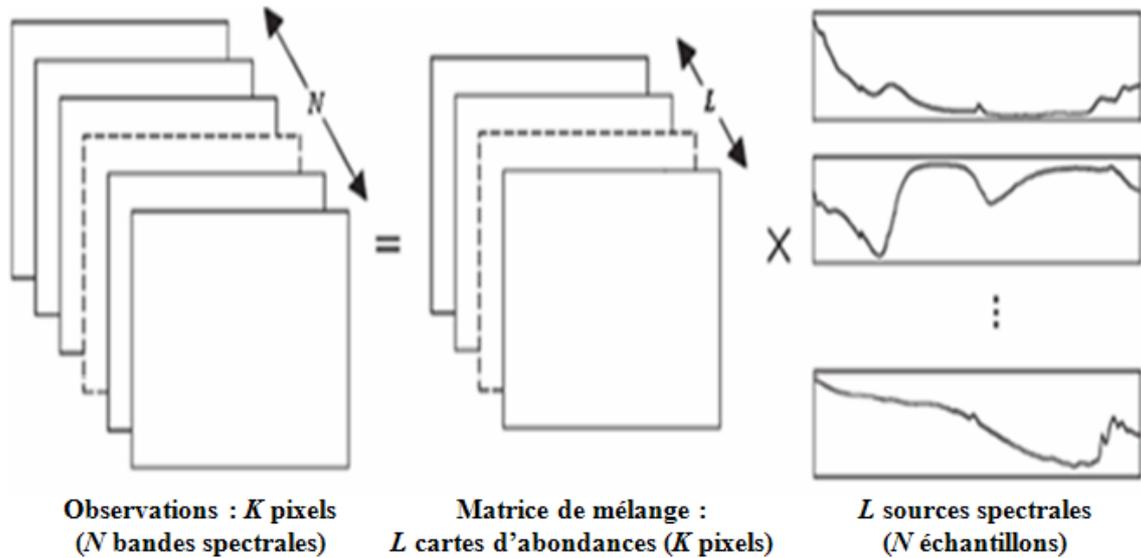


Fig. 1.13. Modèle des données selon l'approche sources spectrales.

### 1.4.2. Approche alternative : sources spatiales

Une alternative intéressante consiste à transposer (1.6). Nous obtenons ainsi :

$$\begin{pmatrix} x_I(1) & \dots & x_K(1) \\ \vdots & \ddots & \vdots \\ x_I(N) & \dots & x_K(N) \end{pmatrix} = \begin{pmatrix} s_I(1) & \dots & s_L(1) \\ \vdots & \ddots & \vdots \\ s_I(N) & \dots & s_L(N) \end{pmatrix} \begin{pmatrix} a_{I1} & \dots & a_{K1} \\ \vdots & \ddots & \vdots \\ a_{IL} & \dots & a_{KL} \end{pmatrix}. \quad (1.8)$$

Pour simplifier cette dernière présentation et respecter la terminologie de la séparation de sources, nous réécrivons (1.8) avec les notations suivantes :

$$\begin{pmatrix} \bar{x}_I(1) & \dots & \bar{x}_I(K) \\ \vdots & \ddots & \vdots \\ \bar{x}_N(1) & \dots & \bar{x}_N(K) \end{pmatrix} = \begin{pmatrix} \bar{a}_{I1} & \dots & \bar{a}_{IL} \\ \vdots & \ddots & \vdots \\ \bar{a}_{N1} & \dots & \bar{a}_{NL} \end{pmatrix} \begin{pmatrix} \bar{s}_I(1) & \dots & \bar{s}_I(K) \\ \vdots & \ddots & \vdots \\ \bar{s}_L(1) & \dots & \bar{s}_L(K) \end{pmatrix}. \quad (1.9)$$

Maintenant,  $\bar{x}_n(i)$  représente la *nième* composante spectrale du pixel *i*,  $\bar{a}_{nj}$  est la *nième* composante spectrale du matériau pur *j* et  $\bar{s}_j(i)$  représente l'abondance du matériau pur *j* dans le pixel *i*. Par conséquent, chaque "source (spatiale)" représente ici les abondances d'un matériau pur dans tous les pixels, et chaque observation correspond à une bande spectrale de l'image. Une représentation bidimensionnelle de cette approche est donnée dans la figure (Fig. 1.14). Par souci de lisibilité, les "barres" utilisées dans (1.9) pour les notations des sources, des coefficients de mélange et des observations, peuvent être enlevées (c'est-à-dire  $s_j(i)$  à la place de  $\bar{s}_j(i)$ , et ainsi de suite), mais il doit être clair que ces notations se réfèrent au modèle (1.9), et non pas au modèle (1.6). Par ailleurs, les contraintes naturelles définies dans (1.7) deviennent ici :

$$\bar{a}_{nj} \geq 0, \bar{s}_j(i) \geq 0 \text{ et } \sum_j \bar{s}_j(i) = 1, \forall \begin{matrix} i = 1 \dots K \\ j = 1 \dots L \\ n = 1 \dots N \end{matrix}. \quad (1.10)$$

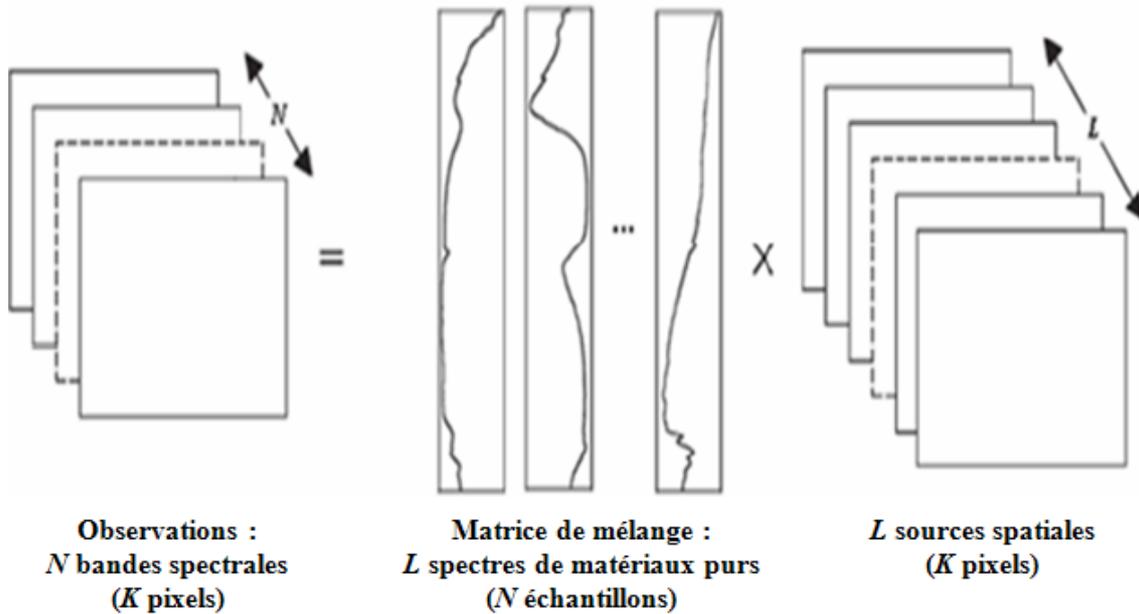


Fig. 1.14. Modèle des données selon l'approche sources spatiales.

## 1.5. Contributions méthodologiques de la thèse

Récemment, de nombreuses méthodes basées sur la philosophie de la séparation de sources ont été proposées pour démélanger de manière aveugle les pixels d'une image de télédétection spatiale, particulièrement une image hyperspectrale (un aperçu plus exhaustif de ces méthodes peut être trouvé dans [32, 33]). Cet engouement de la part de la communauté scientifique est un résultat direct de l'intérêt porté par les utilisateurs finaux à l'automatisation des techniques traditionnelles de traitement des données de télédétection spatiale, dans lesquelles l'intervention d'opérateurs humains est nécessaire. En dépit de tous les efforts déployés, il existe toujours un écart important entre les capacités potentielles de la télédétection spatiale et son exploitation dans le monde réel. Dans ce contexte, l'objectif principal de cette thèse est de fournir une contribution pour réduire un tel écart. La philosophie des travaux de recherche menés dans le cadre de cette thèse est de développer de nouvelles techniques permettant le traitement des données de télédétection spatiale pour des applications réelles, telles que l'extraction, l'identification, la quantification et la cartographie, avec un degré élevé de précision de la distribution spatiale des différentes occupations des sols. En particulier,

nos recherches ont porté sur quatre aspects, décrits brièvement dans ce qui suit, et qui seront présentés en détail chacun dans un chapitre (3-6) à part.

### **1.5.1. Prétraitement par séparation de sources et classification d'une image multispectrale**

Dans ce travail, nous utilisons des méthodes classiques de séparation de sources afin de réaliser un prétraitement d'une image multispectrale en vue d'une classification supervisée de ses pixels. Les méthodes en question sont fondées sur l'analyse en composantes indépendantes et la factorisation en matrices non-négatives. Ainsi, des algorithmes classiques (les plus populaires) de ces deux approches sont utilisés pour générer, à partir des bandes originales de l'image multispectrale, de nouvelles bandes (appelées aussi "néo-canaux"). Ces nouvelles bandes sont utilisées par la suite comme des entrées pour le classifieur supervisé choisi. Ce dernier est utilisé en intégrant l'information texturale issue de ces néo-canaux.

### **1.5.2. Extraction de cartes d'abondances à partir d'une image multispectrale avec pixels purs**

Le démélange d'une image multispectrale avec pixels purs est l'objectif ambitieux de cette partie de la thèse. En effet, on trouve dans la littérature très peu de travaux concernant le démélange d'une image multispectrale, et cela est principalement dû au peu d'informations spectrales (nombre réduit de bandes spectrales) contenues dans une telle image. Au contraire, la grande majorité des travaux de la littérature concerne le démélange d'une image hyperspectrale avec ou sans pixels purs. Ainsi, le présent travail représente un challenge scientifique intéressant, celui d'extraire des cartes d'abondances à partir d'une image multispectrale avec la présence de pixels purs. Deux nouvelles méthodes hybrides et non-supervisées sont proposées dans ce travail afin d'atteindre notre objectif selon l'approche "sources spatiales" du modèle de séparation décrivant l'image multispectrale. Ces deux méthodes sont basées sur l'analyse en composantes parcimonieuses, les méthodes de classification non-supervisée (clustering), ainsi que les contraintes de non-négativité utilisées dans la factorisation en matrices non-négatives et les Moindres Carrés Non-négatifs (MCN) (*Non-negative Least Squares (NLS)*).

### **1.5.3. Extraction de spectres à partir d'une image hyperspectrale avec pixels purs**

Comme expliqué dans la Section 1.1, la conception d'un capteur satellitaire passe inévitablement par un compromis entre les différentes résolutions, à savoir la résolution spatiale, la résolution spectrale et la résolution radiométrique. Ainsi, une image hyperspectrale, qui contient un nombre assez élevé de canaux spectraux, possède généralement une résolution spatiale moins fine que celle d'une image multispectrale. Cela induit une présence d'un grand nombre de mixels dans l'image en question. Les futurs capteurs hyperspectraux (tels que PRISMA, EnMAP, et HYPXIM [28]) seront caractérisés par une meilleure résolution spatiale, et par conséquent, le scénario d'existence de pixels purs sera très réaliste. C'est pourquoi, dans cette recherche, nous proposons une nouvelle méthode d'extraction de spectres hyperspectraux à partir d'une image avec pixels purs. Cette méthode, dans laquelle l'image est modélisée selon l'approche "sources spatiales" (c'est-à-dire les colonnes de la matrice de mélange correspondent aux spectres des matériaux purs), se réfère au problème d'identification aveugle de mélanges, et est basée sur l'analyse en composantes parcimonieuses.

### **1.5.4. Extraction de spectres à partir d'une image hyperspectrale sans pixels purs, combinée avec une image multispectrale avec pixels purs**

Dans cette partie de la thèse, nous proposons une méthode basée sur la factorisation en matrices non-négatives couplée avec les moindres carrés non-négatifs pour extraire les spectres des matériaux purs contenus dans une image hyperspectrale fortement mélangée (c'est-à-dire sans aucun pixel pur), en la combinant avec une image multispectrale, contenant des pixels purs, de la même scène. Ainsi, nous tirons profit, dans une telle approche, de l'information spectrale fournie par l'image hyperspectrale, et de l'information spatiale contenue dans l'image multispectrale.

## **1.6. Conclusion**

Dans ce premier chapitre, les principaux concepts de la télédétection spatiale et son processus d'analyse des données ont été présentés. La problématique abordée dans cette thèse a été détaillée. Des généralités sur l'approche dite de séparation aveugle de sources ont été abordées. Comme cette dernière approche est celle choisie pour résoudre la problématique de cette thèse, la modélisation des images de télédétection spatiale selon la nomenclature de cette approche a été présentée. En particulier, deux modélisations ont été données. La première est une modélisation dans laquelle les sources sont des spectres (signaux unidimensionnels). Dans la deuxième modélisation, les sources sont des cartes d'abondances (signaux images bidimensionnels). À la fin de ce chapitre, quatre aspects représentant nos contributions méthodologiques ont été brièvement décrits.

**Références bibliographiques citées dans le Chapitre 1**

- [1] O. Berné, C. Joblin, Y. Deville, J. D. Smith, M. Rapacioli, J. P. Bernard, J. Thomas, W. Reach, and A. Abergel, "Analysis of the emission of very small dust particles from Spitzer spectro-imagery data using Blind Signal Separation methods," *Astronomy and Astrophysics*, 469, pp. 575-586, 2007.
- [2] F. Bonn, G. Rochon, *Précis de Télédétection, Volume 1, Principes et Méthodes*, Presses de l'Université du Québec, 1993.
- [3] J. F. Cardoso, "Independent component analysis of the cosmic microwave background," *In Proceedings of the International Workshop on Independent Component Analysis and Blind Source Separation, ICA2003*, Nara, Japan, 2003.
- [4] C. Chaouchi, "Méthodes de séparation aveugle de sources non linéaires, étude du modèle quadratique," *Thèse de l'Université Paul Sabatier, Toulouse III*, 2011.
- [5] A. Cichocki, S. I. Amari, *Adaptive Blind Signal and Image Processing: Learning Algorithms and Applications*, Wiley, New York, 2003.
- [6] A. Cichocki, R. Zdunek, and S. I. Amari, "New Algorithms for Non-Negative Matrix Factorization and Applications to Blind Source Separation," *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 2006*, pp. V, Toulouse, France, 2006.
- [7] 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 & Sons, 2009.
- [8] P. Comon, "Independent Component Analysis, a new concept?" *Signal Processing*, 36(3), pp. 287-314, 1994. Special issue on Higher-Order Statistics.
- [9] P. Comon, C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*, Academic Press, 2010.
- [10] G. Darmais, "Analyse générale des liaisons stochastiques," *Revue de l'Institut International de Statistique*, 21(1-2), pp. 2-8, 1953.
- [11] Y. Deville, "Panorama des applications biomédicales des méthodes de séparation aveugle de sources," *In GRETSI*, pp. 8-11, Paris, France, 2003.

- [12] Y. Deville, S. Hosseini, "Blind identification and separation methods for linear-quadratic mixtures and/or linearly independent non-stationary signals," *In Proceedings of the 9<sup>th</sup> International Symposium on Signal Processing and its Applications, ISSPA 2007*, 2007.
- [13] Y. Deville, *Traitement du signal : signaux temporels et spatiotemporels – Analyse des signaux, théorie de l'information, traitement d'antenne, séparation aveugle de sources*, Ellipses Editions Marketing, Paris, 2011.
- [14] P. Garat, "Approche statistique pour la séparation aveugle de sources," *Thèse de l'Université Joseph Fourier, Grenoble I*, 1994.
- [15] M. C. Girard, C. M. Girard, *Traitement des Données de Télédétection*, Dunod, 2004.
- [16] R. Gribonval, S. Lesage, "A survey of sparse component analysis for source separation: principles, perspectives, and new challenges," *In Proceedings of the 14<sup>th</sup> European Symposium on Artificial Neural Networks, ESANN 2006*, pp. 323-330, Bruges, Belgium, 2006.
- [17] J. Héroult, C. Jutten, et B. Ans, "Détection de grandeurs primitives dans un message composite par une architecture de calcul neuromimétique en apprentissage non supervisé," *In GRETSI*, pp. 1017-1022, Nice, France, 1985.
- [18] S. Hosseini, Y. Deville, "Blind separation of linear-quadratic mixtures of real sources using a recurrent structure," *In Proceedings of the 7<sup>th</sup> Int. Work-Conference on Artificial and Natural Neural Networks, IWANN 2003*, 2, pp. 241-248, 2003.
- [19] S. Hosseini, Y. Deville, "Blind maximum likelihood separation of a linear-quadratic mixture," *In Proceedings of the International Workshop on Independent Component Analysis and Blind Source Separation, ICA2004*, pp. 694-701, Erratum: <http://arxiv.org/abs/1001.0863>, 2004.
- [20] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, Wiley Interscience, 2001.
- [21] I. T. Jolliffe, *Principal Component Analysis*, Springer Series, 2002.
- [22] C. Jutten, A. Taleb, "Source separation from dusk till dawn," *In Proceedings of the 2<sup>nd</sup> International Workshop on Independent Component Analysis and Blind Source Separation, ICA2000*, pp. 15-26, Helsinki, Finland, 2000.

- [23] C. Jutten, P. Comon, *Séparation de sources, tome 2*, Collection Traité IC2, Information-Commande-Communication, Hermès-Lavoisier, Paris, France, 2007.
- [24] A. Kachenoura, L. Albera, L. Senhadji, "Séparation aveugle de sources en ingénierie biomédicale," *ITBM-RBM*, 28, pp. 20-34, 2007.
- [25] N. Keshava, J. F. Mustard, "Spectral Unmixing," *IEEE Signal Processing Magazine*, 19, pp. 44-57, 2002.
- [26] M. Krob, M. Benidir, "Blind identification of a linear-quadratic model using higher-order statistics," *IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 1993, vol. 4*, pp. 440-443, 1993.
- [27] L. De Lathauwer, D. Callaerts, B. De Moor, and al., "Fetal electrocardiogram extraction by source subspace separation". In *Proceedings of the International Workshop on HOS*, pp. 134-138, Girona, Spain, 1995.
- [28] S. Michel, P. Gamet, and M. J. Lefevre-Fonollosa, "HYPXIM – A hyperspectral satellite defined for science, security and defence users," In *Proceedings of the Third IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2011*, Lisbon, Portugal, 2011.
- [29] D. Nuzillard, A. Bijaoui, "Blind source separation and analysis of multispectral astronomical images," *Astron. Astrophys. Suppl., Ser. 147*, pp. 129-138, 2000.
- [30] D. Nuzillard, "Comment la chimie analytique peut contribuer à l'étude des images astronomiques," In *GRETSI*, pp. 23-26, Paris, France, 2003.
- [31] P. D. O'Grady, B. A. Pearlmutter, and S. Rickard, "Survey of sparse and non-sparse methods in source separation," *International Journal of Imaging Systems and Technology (IJIST)*, 15, pp. 18-33, 2005.
- [32] M. Parente, A. Plaza, "Survey of geometric and statistical unmixing algorithms for hyperspectral images," In *Proceedings of the Second IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2010*, Reykjavik, Iceland, 2010.
- [33] J. Plaza, E. M. T. Hendrix, I. Garcia, G. Martin, and A. Plaza, "On endmember Identification in Hyperspectral Images Without Pure Pixels: A Comparison of Algorithms," *Journal of Mathematical Imaging and Vision*, 2011, DOI 10.1007/s10851-011-0276-0.

- [34] A. Taleb, C. Jutten, "Source separation in post-nonlinear mixtures," *IEEE Transactions on Signal Processing*, 10(47), pp. 2807-2820, 1999.
- [35] R. Vigário, J. Särelä, V. Jousmäki, M. Hämäläinen, and E. Oja, "Independent component analysis approach to the analysis of EEG and MEG recordings," *IEEE Transactions on Biomedical Engineering*, 47(5), pp. 589-593, 2000.
- [36] V. Zarzoso, A.-K. Nandi, "Noninvasive fetal electrocardiogram extraction: blind source separation versus adaptive noise cancellation," *IEEE Transactions on Biomedical Engineering*, 48(1), pp. 12-18, 2001.

## CHAPITRE 2

### PANORAMA DES METHODES UTILISEES DANS LES DOMAINES CONCERNES PAR LA THESE

---

*Résumé* - Ce chapitre est consacré à un panorama des méthodes utilisées dans les domaines concernés par la présente thèse. Ainsi, nous exposons dans un premier temps les méthodes habituelles de la séparation aveugle de sources. Ces méthodes sont celles basées sur l'analyse en composantes indépendantes, la factorisation en matrices non-négatives, et l'analyse en composantes parcimonieuses. Dans un second temps, nous présentons les méthodes les plus utilisées en matière de démixage d'images de télédétection spatiale. Ces dernières méthodes sont exposées selon deux hypothèses. La première est celle fondée sur l'existence de pixels purs dans une image. À l'inverse de la première, la seconde est fondée sur l'inexistence de pixels purs dans une image. Ensuite, un exposé des motifs du choix des méthodes à mettre en place est donné selon une modélisation des images, les hypothèses et les objectifs à atteindre. Avant de conclure ce chapitre, les critères de performance des méthodes à mettre en place sont présentés.

---

## DANS CE CHAPITRE

2.1. Méthodes de séparation aveugle de sources	38
2.1.1. Méthodes fondées sur l'analyse en composantes indépendantes	38
2.1.2. Méthodes fondées sur la factorisation en matrices non-négatives	47
2.1.3. Méthodes fondées sur l'analyse en composantes parcimonieuses	53
2.2. Méthodes de démixage d'images de télédétection spatiale	56
2.2.1. Méthodes avec l'hypothèse d'existence de pixels purs	58
2.2.2. Méthodes avec l'hypothèse d'inexistence de pixels purs	59
2.3. Quelles méthodes à mettre en place ? selon quelles modélisations ? sous quelles hypothèses ? et pour quels objectifs ?	59
2.4. Critères de performance des méthodes à mettre en place	62
2.5. Conclusion	64
Références bibliographiques citées dans le Chapitre 2	65

## 2.1. Méthodes de séparation aveugle de sources

La Séparation Aveugle de Sources (SAS) (*Blind Source Separation (BSS)*) est une discipline scientifique qui permet, à partir d'un ensemble de  $N$  signaux observés  $x_i$ , d'extraire  $L$  signaux sources  $s_j$ . Les signaux observés sont des mélanges des signaux sources. Le mélange le plus étudié à ce jour est du type "linéaire instantané", dans lequel les valeurs des signaux observés à une variable (le plus souvent, cette variable est temporelle ou spatiale) s'écrivent comme des combinaisons linéaires des valeurs des signaux sources pour cette même valeur de la variable. Ainsi, dans le cas d'une variable temporelle, la relation observations-sources s'écrit sous la forme  $x(t) = A s(t)$ , où  $s$  et  $x$  sont deux vecteurs colonnes représentant respectivement les signaux sources et les signaux observés, et comprenant respectivement  $L$  et  $N$  composantes et  $t$  est la variable. Notons ici, que si les données sont disponibles pour  $t = 1 \dots K$ , on peut alors écrire cette dernière équation sous la forme matricielle  $X = A S$ . Bien entendu, cette forme matricielle est celle évoquée par le modèle (1.9) dans le Chapitre 1. La matrice  $X$  de dimension  $N \times K$  est la matrice des observations, alors que la matrice  $S$  de dimension  $L \times K$  est celle des sources. La matrice  $A$  est une matrice constante inconnue de dimension  $N \times L$  dite "matrice de mélange". Il existe différentes méthodes qui permettent la séparation. Ces méthodes sont généralement répertoriées dans trois grandes catégories, à savoir, les méthodes d'Analyse en Composantes Indépendantes (ACI) (*Independent Component Analysis (ICA)*), les méthodes de Factorisation en Matrices Non-négatives (FMN) (*Non-negative Matrix Factorization (NMF)*), et les méthodes d'Analyse en Composantes Parcimonieuses (ACPa) (*Sparse Component Analysis (SCA)*). Nous présentons ci-dessous une vue d'ensemble des principaux critères de ces trois familles de méthodes de SAS. Un panorama plus général peut être trouvé dans [27, 28, 34, 35, 43, 72-74, 77, 81, 87]. S'agissant d'applications en imagerie de télédétection spatiale, une quatrième catégorie de méthodes peut être considérée. Ces méthodes sont le plus souvent basées sur un concept géométrique [17, 98, 108].

### 2.1.1. Méthodes fondées sur l'analyse en composantes indépendantes

L'ACI constitue l'une des classes de méthodes les plus utilisées en SAS. Elle peut être vue comme un prolongement de l'Analyse en Composantes Principales (ACP)

(*Principal Component Analysis (PCA)*) [75], mais dans lequel la non-corrélation (critère sur les sorties d'une ACP) est remplacée par une hypothèse statistique plus forte, celle de l'indépendance. Par conséquent, dans cette configuration, l'objectif de l'ACI est de déterminer des sorties du système de séparation de telle sorte que celles-ci soient statistiquement indépendantes. Mais, pour que le problème de la séparation soit résolu, les sorties doivent correspondre à une estimation des sources (aux indéterminations près de permutation et de facteur d'échelle). Or ces deux objectifs peuvent, dans certaines conditions, ne pas être résolus en même temps. En effet, G. Darmois [36] a montré qu'à partir de variables aléatoires dépendantes, il est toujours possible de construire une transformation de telle sorte que les variables aléatoires obtenues soient indépendantes. La seule hypothèse d'indépendance statistique des sources n'est donc pas suffisante à l'unicité de la solution du problème de la SAS. Dans le cas des mélanges linéaires instantanés avec au moins autant de signaux observés que les signaux sources, P. Comon [33] a démontré à l'aide du théorème de Darmois [37] que l'ACI est équivalente à la résolution du problème de la SAS à condition que les signaux sources soient non gaussiens sauf un au plus. Dans ce contexte, de nombreuses approches ont été envisagées. Dans leur version de base, ces approches font l'hypothèse que les signaux sources sont statistiquement indépendants, et qu'au plus un de ces signaux sources est gaussien.

L'ACI d'un vecteur aléatoire  $x$  consiste à estimer le modèle de données  $x = A s$ , par une transformation linéaire  $y = C x$ , de telle manière que les composantes de  $y$  soient aussi indépendantes que possible. L'indépendance statistique mutuelle entre  $L$  variables aléatoires  $s_j$ , avec  $j \in \{1 \dots L\}$ , signifie que la connaissance des valeurs prises par certaines variables n'informe en aucune manière sur les valeurs prises par les autres variables. Considérons le vecteur  $s$  comme étant un vecteur de variables aléatoires, et supposons que sa densité de probabilité  $f(s)$  existe. Le vecteur  $s$  a des composantes mutuellement indépendantes si et seulement si la densité de probabilité conjointe  $f(s)$  est factorisable par les densités de probabilité marginales  $f_j(s_j)$  :

$$f(s) = \prod_{j=1}^L f_j(s_j), \quad (2.1)$$

Les signaux sources  $s_j$  ne sont pas directement observables et leur densités de probabilité  $f_j(s_j)$  sont rarement connues, il est donc difficile d'utiliser la définition de l'indépendance statistique (2.1) pour estimer les signaux sources indépendants. Ainsi l'ACI estime les composantes de  $y$  par maximisation d'une mesure (critère) d'indépendance statistique. Nous présentons ci-dessous les principaux critères d'ACI ainsi que quelques méthodes utilisant ces derniers.

"*ACI par maximisation de la non-gaussianité*", cette dernière est l'un des critères les plus utilisés en ACI. Il est fondamental puisqu'il est impossible de séparer des signaux sources indépendants et identiquement distribués (i.i.d.) si la non-gaussianité de ceux-ci n'est pas respectée. Une mesure de cette non-gaussianité s'impose donc. La plus couramment utilisée est la valeur absolue du "kurtosis normalisé" qui est le "cumulant normalisé" d'ordre quatre [43]. Il est noté  $\gamma(\cdot)$  et défini par l'expression suivante (pour une variable aléatoire centrée) :

$$\gamma(y) = \frac{kurt(y)}{[cum_2(y, y)]^2} = \frac{cum_4(y, y, y, y)}{[cum_2(y, y)]^2} = \frac{E\{y^4\} - 3E\{y^2\}^2}{E\{y^2\}^2}, \quad (2.2)$$

où  $kurt(\cdot)$  est le kurtosis non-normalisé égal au cumulant non-normalisé d'ordre quatre  $cum_4(\cdot, \cdot, \cdot, \cdot)$ ,  $cum_2(\cdot, \cdot)$  est le cumulant d'ordre deux, et  $E\{\cdot\}$  représente l'opérateur d'espérance mathématique. Le kurtosis normalisé mesure l'écart de la densité de probabilité d'une variable aléatoire par rapport à une densité gaussienne : il vaut zéro pour une densité gaussienne. Des valeurs strictement négatives du kurtosis normalisé sont obtenues avec des distributions "sous-gaussiennes" (plus aplaties que la gaussienne), tandis que les distributions "sur-gaussiennes" (plus piquées que la gaussienne) donnent des valeurs strictement positives. On peut donc considérer que, plus la valeur absolue du kurtosis normalisé d'une variable aléatoire augmente, plus la densité de cette dernière s'écarte de la densité gaussienne. La maximisation de la valeur absolue du kurtosis normalisé constitue une méthode très simple pour espérer l'extraction des signaux sources. Cependant, cette méthode peut s'avérer peu robuste. En effet, l'estimation du kurtosis normalisé à partir de données représente des inconvénients. Le kurtosis normalisé est très sensible aux valeurs extrêmes à cause du

cumulant d'ordre quatre. Ainsi, son estimation peut être fortement faussée dans le cas d'un petit nombre de valeurs observées, et d'autres fonctions mesurant la non-gaussianité peuvent être préférables.

Une deuxième mesure de la non-gaussianité considérée dans la littérature trouve ses bases dans la théorie de l'information. Il est établi que pour un ensemble de variables aléatoires centrées de même variance, celle qui a une distribution gaussienne maximise l'"entropie différentielle" donnée par [43] :

$$H(y) = - \int f_y(u) \log(f_y(u)) du, \quad (2.3)$$

où  $f_y(\cdot)$  est la densité de probabilité de la variable aléatoire  $y$ . Cette remarque permet d'introduire une mesure normalisée de la non-gaussianité, appelée "néguentropie" et définie par [43] :

$$J(y) = H(y_g) - H(y), \quad (2.4)$$

où  $y_g$  est une variable aléatoire gaussienne, centrée, de même variance que  $y$ . On obtient ainsi une mesure qui est toujours positive ou nulle, et qui vaut zéro si et seulement si  $y$  a une distribution gaussienne. La néguentropie est une mesure robuste de la non-gaussianité, en revanche elle est difficile à calculer puisqu'elle nécessite l'estimation des densités de probabilité des signaux de sortie. En pratique, la néguentropie peut être approximée en utilisant les cumulants d'ordre supérieur. Une méthode classique d'approximation pour une variable aléatoire centrée à variance unitaire est :

$$J(y) \approx \frac{1}{12} E\{y^3\}^2 + \frac{1}{48} kurt(y)^2, \quad (2.5)$$

Cet estimateur basé sur le kurtosis demeure peu robuste. A. Hyvärinen [35, 74] a proposé une approximation robuste de la néguentropie :

$$J(y) \approx k_1 E\{G_1(y)\}^2 + k_2 [E\{G_2(y)\} - E\{G_2(y_g)\}]^2, \quad (2.6)$$

où  $k_1$  et  $k_2$  sont deux constantes positives,  $G_1$  et  $G_2$  deux fonctions non-quadratiques, avec  $G_1$  impaire et  $G_2$  paire. Une autre approche consiste à n'utiliser qu'une seule fonction non-quadratique  $G$ . Dans ce cas, l'approximation devient :

$$J(y) \propto [E\{G(y)\} - E\{G(y_g)\}]^2. \quad (2.7)$$

Toutes les méthodes basées sur la maximisation de la non-gaussianité nécessitent une normalisation des sorties. On peut par exemple imposer aux signaux sources extraits d'avoir une variance unitaire. Dans ce cas, le procédé consiste à décorréler et normaliser les observations centrées, afin que le signal de sortie  $y$  puisse être de variance unitaire en normalisant le vecteur d'extraction appliqué aux observations centrées, décorrélées et de variances unitaires.

L'une des méthodes les plus connues basées sur la maximisation de la non-gaussianité est "FastICA" [35, 74] qui est une méthode de type point-fixe. Cette méthode utilise au choix le kurtosis [70] ou la néguentropie [71].

"**ACI par minimisation de l'information mutuelle**". L'information mutuelle est une mesure permettant de caractériser directement l'indépendance statistique entre des variables aléatoires. Cette quantité notée  $I(.)$  est définie par [35, 74] :

$$I(y) = -H(y) + \sum_{j=1}^L H(y_j), \text{ avec } y = [y_1 \dots y_L]^T. \quad (2.8)$$

Cette quantité est toujours positive, et s'annule si et seulement si les variables aléatoires  $y_1, \dots, y_L$  sont statistiquement indépendantes, ce qui nous donne une mesure naturelle et générale de l'indépendance statistique. Cette mesure permet, dans un problème de la SAS, de mesurer quantitativement l'indépendance statistique des signaux sources estimés sans aucune hypothèse sur leur distribution. Les méthodes d'ACI basées sur cette mesure, minimisent l'information mutuelle entre les sorties du système d'ACI.

Le critère de minimisation de l'information mutuelle est étroitement lié à la maximisation de la non-gaussianité. En effet, pour des données centrées, décorréelées, et de variances unitaires, l'information mutuelle définie par (2.8) peut être réécrite en fonction de la néguentropie définie par (2.4), d'où la relation [33] :

$$I(y) = cste - \sum_{j=1}^L J(y_j). \quad (2.9)$$

Ainsi, le concept de maximisation de la non-gaussianité trouve naturellement sa justification dans ce lien direct avec la minimisation de l'information mutuelle. Néanmoins, il est algorithmiquement différent. En effet, dans le cadre de la maximisation de la non-gaussianité, il est possible d'utiliser des algorithmes à déflation, c'est-à-dire des algorithmes qui permettent l'extraction des signaux sources un à un, ce qui s'avère impossible pour la minimisation de l'information mutuelle.

Le critère de minimisation de l'information mutuelle a été notamment étudié par D. T. Pham [103, 104, 106, 107], K. E. Hild et al. [49, 60-62], Z. Q. Luo et J. Lu [85], M. Babaie-Zadeh et al. [8, 111] ou encore M. El Rhabi et al. [110].

"*ACI par maximisation de la vraisemblance*", qui a pour objectif de retrouver les paramètres des mélanges qui maximisent la vraisemblance de réalisation des observations. Le principal inconvénient de la maximisation de la vraisemblance réside dans la non-connaissance des densités de probabilité des signaux sources. On peut alors supposer soit qu'elles sont connues a priori, soit qu'elles appartiennent à une famille de distributions donnée. En utilisant des fonctions score, la maximisation de la vraisemblance correspond à la minimisation de la néguentropie ou la maximisation de l'entropie, comme cela a été montré par J. F. Cardoso dans [23]. La maximisation de l'entropie, appelée "Infomax", a été proposée par A. J. Bell et T. J. Sejnowski [9].

Des approches basées sur la maximisation de la vraisemblance ont été introduites par M. Gaeta et J. L. Lacoume [51, 52], puis entre autres par D. T. Pham et al. [101, 102], par L. Parra et al. [99, 100], ou par A. Belouchrani et J. F. Cardoso [11].

R. Guidara [57] et al. ont proposé plusieurs extensions des méthodes [101, 102] de D. T. Pham qui prennent en compte l'autocorrélation des signaux sources. Leurs approches permettent le traitement des signaux stationnaires [66, 67] ou non-stationnaires [55, 56].

La mise en œuvre pratique critère de la maximisation de la vraisemblance est liée à celle de la minimisation de l'information mutuelle, et par conséquent au critère de la maximisation de la non-gaussianité. Le lien entre ces différents critères a été étudié dans [82].

"*ACI basée sur les statistiques d'ordre deux*". Les critères d'ACI présentés ci-dessus négligent, dans leur version de base, toute structure (temporelle, spatiale, ou fréquentielle) des signaux sources, et nécessitent la non-gaussianité comme condition pour réaliser la séparation. Cette dernière condition peut être contournée en tenant compte de la structure des signaux sources, et en n'utilisant que des statistiques d'ordre deux. Notons ici, que seules (sans prise en compte de la structure des signaux sources) les statistiques d'ordre deux ne sont pas suffisantes pour permettre l'extraction des signaux sources.

Ainsi, la gaussianité des signaux sources n'est plus une limitation si l'on considère l'une des deux hypothèses suivantes : l'autocorrélation des signaux sources ou la non-stationnarité de ces derniers.

Dans le cas de la première hypothèse, c'est-à-dire les sources sont autocorrélées, il est possible de séparer des signaux sources en imposant la nullité de l'intercorrélacion des signaux de sortie décalés:

$$\exists \tau \neq 0 / E\{y_j y_{j'}(\tau)\} = 0, \forall j \neq j' \in \{1 \dots L\}, \quad (2.10)$$

où  $\tau$  représente un décalage temporel, spatial, ou fréquentiel. En effet, les matrices de covariance des signaux sources centrés définies par :

$$R_s(\tau) = E\{s s(\tau)^T\}, \quad (2.11)$$

sont réelles et diagonales. Les matrices de covariance des observations s'écrivent alors sous la forme :

$$R_x(\tau) = E\{x x(\tau)^T\} = A R_s(\tau) A^T, \quad (2.12)$$

et sont simultanément diagonalisables pour divers décalages  $\tau$ . Parmi les méthodes statistiques d'ordre deux les plus célèbres, et qui supposent l'autocorrélation des signaux sources, on peut citer AMUSE [118, 119] ou SOBI [10, 12]. AMUSE considère un décalage unique non nul pour réaliser la séparation à partir des observations blanchies. Cette méthode, remarquable par sa simplicité, représente un inconvénient majeur qui réside dans le choix du décalage. Pour remédier à ce problème, la méthode SOBI utilise plusieurs décalages choisis.

Concernant maintenant l'hypothèse de la non-stationnarité des signaux sources, cette dernière à l'ordre deux se traduit par une variation (temporelle, spatiale, ou fréquentielle) des statistiques des signaux, ce qui fournit de l'information supplémentaire. Dans ce cas, la décorrélation des sorties entre elles (à plusieurs instants, positions, ou fréquences) suffit pour effectuer la séparation. Parmi les premières approches traitant des signaux sources non-stationnaires, nous trouvons les travaux développés par K. Matsuoka et al. [88]. De son côté, A. Souloumiac a proposé une méthode adaptée aux signaux non-stationnaires [116]. Le même concept a été aussi abordé par D. T. Pham et J. F. Cardoso [105]. Nous retrouvons également l'algorithme SONS de S. Choi et al. [26], qui peut être vu comme une extension de l'algorithme SOBI aux signaux sources non-stationnaires. Nous citons aussi les travaux développés par A. Belouchrani, K. Abed-Meraim et al. [14]. On peut également citer la méthode mise en œuvre par K. Abed-Meraim et al. [1] exploitant la cyclo-stationnarité des sources. La non-stationnarité a été aussi utilisée dans d'autres travaux d'ACI, dont on cite ceux utilisant la décorrélation spectrale de S. Hosseini et al. [64, 65, 68, 112], les méthodes de décorrélation différentielle de Y. Deville et al. [38, 40] et S. Choi et al. [24, 25], l'approche temps-fréquence développée par A. Belouchrani et M. Amin [13], ou certaines méthodes combinant la non-stationnarité et l'autocorrélation des signaux sources [19, 121, 123].

Un état de l'art plus détaillé sur les méthodes d'ACI basées sur l'utilisation des statistiques d'ordre deux peut être trouvé dans [20].

"*ACI basée sur une approche tensorielle*". Comme souligné ci-dessus, l'utilisation des statistiques d'ordre deux, en négligeant la structure des signaux sources, ne peut être suffisante pour permettre la séparation. Le recours dans ce cas à des statistiques d'ordre supérieur, telles que les cumulants d'ordre supérieur à deux, est l'une des solutions classiques qui a été utilisée dans différentes approches de l'ACI. Théoriquement, l'indépendance statistique entre des signaux correspond à la nullité des cumulants croisés entre toutes les versions décalées de ces signaux et à tous les ordres. En pratique, les méthodes basées sur l'annulation de ces cumulants croisés opèrent à un certain ordre fixé. En général, cet ordre est fixé à quatre. Dans ce dernier cas, on parle des cumulants croisés d'ordre quatre, utilisés comme un critère d'indépendance statistique. Les cumulants d'ordre quatre, notés  $cum_4(y_{j_1}, y_{j_2}, y_{j_3}, y_{j_4})$  avec  $1 \leq j_1, j_2, j_3, j_4 \leq L$ , forment algébriquement un "tenseur" de cumulants d'ordre quatre, qui est un opérateur multilinéaire, de l'ensemble  $\mathcal{P}_{L,L}$  des matrices  $L \times L$ , vers  $\mathcal{P}_{L,L}$ , et qui, pour toute matrice  $P$ , fournit une matrice  $M$  qui a pour élément d'indice  $(j_1, j_2)$  :

$$M_{j_1 j_2}(P) = \sum_{j_3 j_4} p_{j_3 j_4} cum_4(y_{j_1}, y_{j_2}, y_{j_3}, y_{j_4}), \quad (2.13)$$

où  $p_{j_3 j_4}$  est l'élément d'indice  $(j_3, j_4)$  de la matrice  $P$ .

Notons que parmi les propriétés fondamentales du tenseur de cumulants d'ordre quatre, il est diagonal pour tout vecteur  $y$  dont les composantes sont des variables aléatoires mutuellement indépendantes. Il est donc tout à fait naturel d'essayer d'annuler les termes non-diagonaux par une diagonalisation.

Comme tout opérateur linéaire, un tenseur défini par les cumulants d'ordre quatre, peut être diagonalisé et, sous contrainte de blanchiment des signaux observés, il a été démontré dans [120], que toutes les "tranches" (matrices) de ce même tenseur peuvent être conjointement diagonalisées à l'aide d'une même matrice unitaire. C'est sur un tel principe qu'est fondée la méthode JADE [22], qui fait suite à la méthode FOBI [21]. Le critère de mesure de la diagonalité utilisé dans la méthode JADE est celui de la minimisation de la somme des carrés des termes non-diagonaux, qui est équivalent à la maximisation de la somme des carrés des termes diagonaux. Le concept de diagonalisation conjointe, utilisé dans JADE aux cumulants d'ordre quatre, a été généralisé par E. Moreau [91] aux cumulants de tout ordre supérieur à trois.

Nous terminons cette section relative à l'ACI, en donnant le lien existant entre celle-ci et le codage parcimonieux. Ce dernier est une méthode d'extraction d'informations pertinentes dans un vecteur de données. Il consiste à représenter linéairement un vecteur de données par un ensemble de vecteurs de base, de sorte que seulement quelques-uns de ces derniers soient activés en même temps [74]. La distribution d'un vecteur de données est dite "parcimonieuse" lorsque chaque composante de ce vecteur possède une densité de probabilité avec une raie en zéro. Le codage parcimonieux est donc étroitement lié à l'obtention d'une distribution sur-gaussienne [74]. Un vecteur de données sur-gaussien est aussi non-gaussien, cette non-gaussianité est maximisée, comme vue précédemment, par certaines méthodes d'ACI. Il est donc naturel de considérer l'ACI comme une méthode de codage parcimonieux, utile pour l'extraction de caractéristiques pertinentes.

### **2.1.2. Méthodes fondées sur la factorisation en matrices non-négatives**

Dans la section précédente, nous avons décrit quelques approches fondées sur l'ACI pour résoudre le problème de la SAS. Ces approches estiment des solutions sous la contrainte d'indépendance statistique. Dans certaines applications relevant du domaine des sciences de l'environnement, et utilisant des données qui possèdent la propriété de non-négativité, les solutions estimées par les méthodes basées sur l'ACI manquent d'interprétabilité physique.

En 1987, un sévère mais réaliste constat de R. Henry [59] montre les limites des algorithmes d'analyse factorielle pour l'étude des données atmosphériques. Il pointe du doigt le manque d'interprétabilité physique des solutions issues de ces méthodes. En effet, en sciences de l'environnement, les experts cherchent à représenter une matrice de données  $X$  par un produit matriciel de deux matrices  $A$  et  $S$ . Dans ce modèle, la matrice  $X$  est la matrice des signaux observés, et les matrices  $S$  et  $A$  sont respectivement la matrice des signaux sources et la matrice des intensités (mélanges) de ces mêmes signaux. Les méthodes d'analyse fondées sur l'ACI fournissent des solutions pour ce modèle, ces dernières ne possédant plus le caractère non-négatif, sont difficilement interprétées. Ce problème a conduit de nombreux chercheurs à développer et utiliser d'autres méthodes qui prennent en compte le caractère non-négatif des données utilisées. Les méthodes fondées sur la FMN sont des techniques qui prennent en compte la contrainte de non-négativité des données. Ces méthodes fortement influencées par les travaux de J. Shen et G. W. Israël [113] relatifs à l'Analyse Factorielle avec Transformation Non-négative (AFTN) (*Factor Analysis with Non-negative Transformation (FANT)*), et ceux fondés sur la Factorisation en Matrices Positives (FMP) (*Positive Matrix Factorization (PMF)*) de P. Paatero et al. [95-97], s'accordent parfaitement avec les données considérées dans cette thèse, à savoir les données de télédétection spatiale. Un inconvénient majeur de ces dernières méthodes est la lourdeur de leur programmation qui limite les dimensions des matrices à manipuler. Aussi, la convergence des algorithmes de ces méthodes est réputée pour être lente pour des problèmes de larges dimensions.

Le succès des méthodes de FMN a commencé avec les travaux de D. D. Lee et H. S. Seung [79]. Ces deux chercheurs, des *Bell Laboratories*, se sont inspirés des travaux sur les contraintes de positivité appliquées à une décomposition bilinéaire d'une matrice de données, mais aussi des travaux sur la perception visuelle et l'encodage des données visuelles par le cerveau. Leur constat de départ est que des études psychologiques et physiologiques ont prouvé que le cerveau décompose un objet en ses différentes parties pour faciliter sa représentation mentale. La question se pose alors de savoir comment cette représentation d'un tout en parties est réalisée. La représentation d'un objet en parties signifie que l'objet se sépare en plusieurs parties. Un objet

d'intensités strictement positives sera donc décomposé en parties d'intensités strictement positives. Pour reconstruire cet objet, les parties sont recollées ensemble. Le recollage des morceaux signifie qu'il faut réunir toutes les parties pour retrouver le tout. Ainsi, les parties sont sommées pour retrouver l'objet initial. De plus, lorsqu'un même objet est observé sous diverses conditions lumineuses, ses parties sont toujours les mêmes, mais avec des coefficients de pondération différents qui modélisent la luminosité ambiante. Ces coefficients sont forcément positifs. La représentation d'un objet par ses parties induit que seules des sommes, pondérées par des coefficients positifs, entre parties sont autorisées pour reconstruire l'objet initial, et que si l'objet est positif, alors ses parties le sont également.

Sous forme mathématique, la FMN peut être vue comme une méthode générale de décomposition matricielle. Elle permet d'approximer toute matrice  $X \in \mathbb{R}^{N \times K}$  dont les éléments sont tous non-négatifs (positifs ou nuls), grâce à une décomposition de la forme [80] :

$$X \approx A S, \quad (2.14)$$

où  $A$  et  $S$  sont deux matrices qui appartiennent respectivement à  $\mathbb{R}^{N \times L}$  et  $\mathbb{R}^{L \times K}$ . Dans le cadre de la SAS, la matrice  $X$  est la matrice composée des vecteurs lignes représentant les signaux observés. De même,  $S$  est la matrice dont les lignes représentent les signaux sources. La matrice  $A$  est la matrice de mélanges. L'originalité de la FMN réside dans la contrainte de non-négativité qu'elle impose à  $A$  et  $S$ . Soulignons ici, que le modèle (2.14) représente rigoureusement le modèle classique  $x(t) = A s(t)$  (avec  $t = 1 \dots K$ ) utilisé en séparation de sources (les signaux observés et les signaux sources sont représentés, dans cette section, sous forme de matrices, et non pas sous forme de vecteurs comme vu précédemment, pour respecter les notations de la FMN utilisées dans la littérature).

Déterminer les matrices  $A$  et  $S$  revient à minimiser une fonction objective de la matrice initiale  $X$  et du produit des deux matrices  $A$  et  $S$ . D. D. Lee et H. S. Seung [80] ont proposé deux méthodes basées sur la minimisation de deux fonctions objectives

différentes, sous la contrainte de non-négativité, avec des règles de mise à jour multiplicatives.

La première méthode est basée sur la minimisation de la distance euclidienne (norme de Frobenius) de la différence entre  $X$  et le produit  $A S$  :

$$D_F(X, A S) = \frac{1}{2} \|X - AS\|_F^2, \quad (2.15)$$

les règles de mise à jour multiplicatives associées sont [80] :

$$A \leftarrow A \bullet \frac{XS^T}{ASS^T} \quad \text{et} \quad S \leftarrow S \bullet \frac{A^T X}{A^T AS}, \quad (2.16)$$

où  $A \bullet B$  et  $\frac{A}{B}$  représentent respectivement la multiplication et la division matricielle élément par élément.

La deuxième méthode est basée sur la minimisation de la divergence de Kullback-Leibler entre  $X$  et le produit  $A S$  :

$$D_{KL}(X, A S) = \sum_{ni} X_{ni} \log\left(\frac{X_{ni}}{(AS)_{ni}}\right) + (AS)_{ni} - X_{ni}, \quad (2.17)$$

les règles associées sont [80] :

$$A \leftarrow A \bullet \frac{\frac{X}{AS} S^T}{ES^T} \quad \text{et} \quad S \leftarrow S \bullet \frac{A^T \frac{X}{AS}}{A^T E}, \quad (2.18)$$

où  $E$  est une matrice dont les éléments valent 1.

D. D. Lee et H. S. Seung [80] ont démontré que les deux fonctions objectives n'augmentent pas avec les règles de mise à jour (2.16) et (2.18), et que les deux algorithmes convergent toujours vers une solution de l'approximation (2.14).

Contrairement aux algorithmes initiaux de D. D. Lee et H. S. Seung, qui ont des règles de mise à jour multiplicatives, il existe une autre classe d'algorithmes de la FMN basés sur la descente en gradient projeté sur l'orthant positif (l'orthant positif est l'extension de la notion du quart de plan positif dans un espace de dimension supérieure) [84, 124]. Ces algorithmes, qui ont des règles de mise à jour additives, résolvent le problème des Moindres Carrés Non-négatifs (MCN) (*Non-negative Least Squares (NLS)*) en minimisant la fonction objective (2.15).

D'après R. Zdunek et A. Cichocki [124], si le problème des MCN est strictement convexe, alors il existe, pour chaque matrice fixe  $A$ , une matrice non-négative unique  $S$  qui satisfait la contrainte de non-négativité sur le gradient de (2.15) par rapport à  $S$ , noté  $G_S(S)$  :

$$S \geq 0, G_S(S) = \nabla_S D_F(X, A S) = A^T (A S - X) \geq 0. \quad (2.19)$$

De même, il existe, pour chaque matrice fixe  $S$ , une matrice non-négative unique  $A$  qui satisfait la contrainte de non-négativité sur le gradient de (2.15) par rapport à  $A$ , noté  $G_A(A)$  :

$$A \geq 0, G_A(A) = \nabla_A D_F(X, A S) = (A S - X) S^T \geq 0. \quad (2.20)$$

Les règles de mise à jour additives, satisfaisant la contrainte de non-négativité, des deux matrices  $A$  et  $S$  pour assurer la minimisation de la fonction objective (2.15) sont :

$$A \leftarrow P_\Phi [A - \eta_A G_A(A)] \quad \text{et} \quad S \leftarrow P_\Phi [S - \eta_S G_S(S)], \quad (2.21)$$

où  $P_{\Phi}[\xi]$  est la projection de  $\xi$  sur l'orthant positif,  $\eta_A$  et  $\eta_S$  représentent des pas d'apprentissage définis dans [124]. La projection  $P_{\Phi}[\xi]$  peut être effectuée selon plusieurs manières. Une des techniques les plus simples est de remplacer toutes valeurs négatives dans  $\xi$  par des valeurs nulles, ou dans des cas pratiques, par un petit nombre positif  $\varepsilon$  pour éviter des instabilités numériques. Ainsi, cette projection devient  $P_{\Phi}[\xi] = \max\{\xi, \varepsilon\}$ . Cependant, ce n'est pas la seule manière d'effectuer cette projection, il est plus efficace, en général, de choisir les pas d'apprentissage  $\eta_A$  et  $\eta_S$  d'une manière à préserver la non-négativité des solutions et d'accélérer la convergence des algorithmes.

D. Donoho et V. Stodden [45] ont donné une interprétation géométrique à la FMN. Géométriquement, et d'après ces auteurs, la FMN consiste à trouver un cône appartenant à l'orthant positif qui englobe les composantes des vecteurs des données observées. De ce point de vue, le cône n'est pas toujours unique sans contrainte supplémentaire, comme l'illustre la figure suivante (Fig. 2.1).

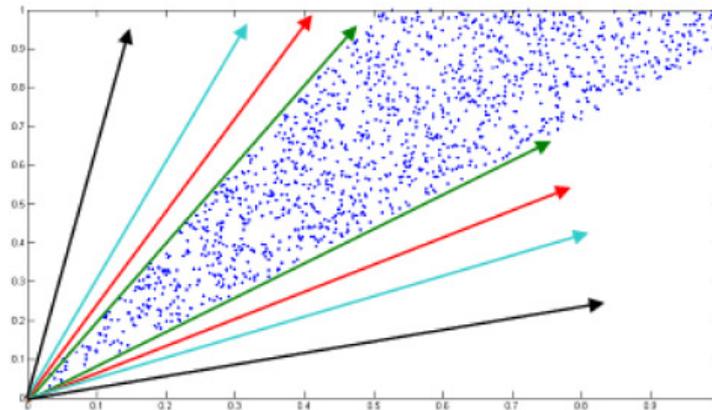


Fig. 2.1. Différents cônes englobant les composantes d'un vecteur de données observées.

À partir de cette interprétation géométrique, il apparaît que la FMN n'est pas unique (ce qui pose un problème pour la SAS), et ses algorithmes dépendent fortement de leur initialisation. En effet, tout couple de matrices non-négatives  $(A, S)$  vérifiant l'approximation (2.14) constitue une solution pour la FMN. Ainsi, pour un autre couple de matrices non-négatives  $(B, C)$  vérifiant l'approximation (2.14), on a :  $X \approx A S = B C$ .

Une condition nécessaire d'unicité donnée par D. Donoho et V. Stodden [45] est : les données observées ne doivent pas obéir à une contrainte de stricte positivité. En particulier, l'unicité est obtenue dans le cas où les données observées sont distribuées de telle façon que chaque axe définissant l'orthant positif contient au moins une composante des vecteurs des données observées. Dans ce cas, le seul cône positif englobant les vecteurs des données observées est l'orthant positif tout entier, ce qui donne l'unicité de la factorisation.

Une solution donnée par J. Eggert et K. Körner [48], permettant d'offrir une situation plus favorable pour limiter le nombre de solutions de la FMN, est la combinaison de la version initiale de la FMN de D. D. Lee et H. S. Seung et du codage parcimonieux. Cette combinaison, consiste à minimiser les fonctions objectives (2.15) et (2.17), mais en ajoutant des conditions qui renforcent le codage parcimonieux sur l'une ou les deux matrices  $A$  et  $S$ . Une manière de renforcer le codage parcimonieux est de l'inclure dans les fonctions objectives (2.15) et (2.17). Les nouvelles fonctions objectives incluant le codage parcimonieux, ainsi que les règles de mise à jour associées à ces fonctions sont données dans [29, 48]. D'après le dernier paragraphe de la Section 2.1.1, la combinaison de la FMN et du codage parcimonieux est étroitement liée à l'ACI non-négative [69].

D'autres algorithmes de la FMN peuvent être trouvés dans [15], ou dans [30], un ouvrage dédié à la FMN et à la Factorisation en Tenseurs Non-négatifs (FTN) (*Non-negative Tensor Factorization (NTF)*).

### 2.1.3. Méthodes fondées sur l'analyse en composantes parcimonieuses

L'analyse en composantes parcimonieuses est une autre voie en vogue de la SAS [53]. Apparue depuis peu, elle ne cesse de susciter l'intérêt de la communauté scientifique. Basée sur des hypothèses de parcimonie des signaux sources dans un domaine de représentation des signaux (temporel, spatial, fréquentiel, temps-fréquence, temps-échelle), elle apporte particulièrement des solutions pour la SAS avec des mélanges sous-déterminés, dans lesquels le nombre de signaux observés est inférieur au nombre des signaux sources à extraire. Elle permet aussi de contourner l'hypothèse

d'indépendance statistique, et même l'hypothèse de la non-corrélation des signaux sources employée dans les méthodes de l'ACI.

Un signal est dit parcimonieux dans un domaine de représentation, s'il est plus souvent nul que la valeur de sa variance ne le laisserait penser [94, 109]. Cela signifie que le signal ne contient que quelques valeurs significatives dans le domaine d'analyse considéré. Notons ici qu'un signal peut présenter des propriétés de parcimonie dans un domaine d'analyse particulier sans qu'il en soit de même dans d'autres. Plusieurs transformations parcimonieuses ont été proposées, que le lecteur intéressé pourra trouver dans [32, 50, 63, 86].

Les méthodes de séparation fondées sur la parcimonie opèrent généralement en deux étapes. La première consiste à estimer les coefficients des mélanges. Cette estimation est réalisée dans un domaine d'analyse choisi selon les propriétés des signaux étudiés. Dans la seconde étape, l'estimation des signaux sources est réalisée, le plus souvent, par une simple inversion du modèle de séparation.

On distingue, généralement, trois catégories d'approches tirant avantage de la parcimonie des signaux sources. La première catégorie regroupe les approches avec de "fortes hypothèses de parcimonie". Dans la deuxième catégorie, on retrouve les approches "quasi-non-parcimonieuses", dans lesquelles, seules quelques zones bien choisies du domaine d'analyse sont utilisées pour estimer les coefficients des mélanges. La troisième catégorie, regroupe, quant à elle, les méthodes jouant sur un degré hybride de parcimonie entre les méthodes des deux catégories ci-dessus.

Les versions les plus restrictives des méthodes à fortes hypothèses de parcimonie supposent qu'au plus une source est présente dans chaque point du domaine d'analyse. On parle dans ce cas d'une Orthogonalité W-Disjointe (OWD) (*W-Disjoint Orthogonality (WDO)*) des signaux sources. Parmi les méthodes basées sur ce concept, nous trouvons la méthode DUET de J. Jourjine et al. [76].

Les méthodes quasi-non-parcimonieuses exigent des hypothèses de parcimonie beaucoup moins fortes que celles basées sur la OWD. En effet, ces méthodes nécessitent un petit nombre de zones du domaine d'analyse, dans lesquelles, une seule source est présente. Ces zones mono-sources sont retrouvées par l'utilisation d'un critère de détection. Parmi ces méthodes, figurent celles proposées par Y. Deville et al. Les premières méthodes ont été développées par F. Abrard et Y. Deville pour des mélanges linéaires instantanés [2-4]. Deux méthodes baptisées LI-TEMPROM et LI-TIFROM ont été proposées dans ce cadre en utilisant l'hypothèse de parcimonie des signaux sources dans le domaine temporel pour la première méthode, et dans le domaine temps-fréquence pour la seconde méthode. Ces deux méthodes utilisent la variance, calculée dans les atomes, des rapports des observations, dans les domaines d'analyse considérés, comme indicateur pour la détection des zones mono-sources. Chaque zone mono-source détectée permet d'estimer une colonne de la matrice de mélange. Une deuxième version de ces deux méthodes a été développée dans [39, 41, 44], où l'indicateur pour la détection des zones mono-sources est cette fois-ci basé sur l'utilisation des coefficients d'intercorrélations des signaux observés. Les deux méthodes associées à ce critère ont pour noms LI-TEPCORR dans le domaine temporel, et LI-TIFCORR pour le domaine temps-fréquence. Une troisième version opérant dans le domaine temps-fréquence a été proposée par B. Albouy et Y. Deville dans [5, 6]. Cette méthode baptisée LI-TIFCOHERE, utilise la cohérence des signaux observés comme critère de détection des zones mono-sources. D'autres extensions ont été proposées pour contourner certaines limitations des différentes méthodes citées ci-dessus. Ces extensions sont proposées dans [41, 42, 114, 115]. Des méthodes, inspirées de celles citées ci-dessus, qui sont adaptées pour des images, ont été proposées par I. Meganem et al. dans [89].

Les méthodes hybrides se basant à la fois sur celles quasi-non-parcimonieuses et celles utilisant le concept de l'OWD, ont été aussi étudiées. Nous citons, à titre d'exemple, la méthode d'Arberet et al. [7], qui est inspirée des méthodes DUET et LI-TIFROM.

## 2.2. Méthodes de démixage d'images de télédétection spatiale

Nous exposons dans cette section les principales méthodes de démixage d'images de télédétection spatiale. Nous commençons par rappeler qu'une image de télédétection spatiale est une grille constituée par le positionnement des pixels sur le terrain. Les images de télédétection spatiale sont, généralement, prises sur des scènes hétérogènes, dans lesquelles plusieurs matériaux, dits "matériaux purs", sont présents. Ainsi, un pixel d'une image de télédétection spatiale peut contenir plusieurs matériaux purs. Dans ce cas, on parle de pixels mélangés, qu'on appelle aussi "mixels", et le comportement spectral de ce dernier est un mélange des réponses spectrales des divers matériaux purs constituant ce mixel. Le modèle analytique le plus souvent utilisé pour représenter le mélange est de type linéaire [78]. Ainsi, dans ce modèle, le spectre observé au niveau d'un mixel est un spectre représentant une combinaison linéaire de spectres pondérés par les pourcentages, qu'on appelle aussi abondances, de présence de ces derniers dans ce mixel. Ce modèle est soumis à des contraintes naturelles de positivité des spectres et des abondances, et d'additivité des abondances (la somme des abondances dans chaque pixel vaut un).

Les méthodes de démixage linéaire développées jusqu'à présent ont pour but de retrouver, à partir seulement des spectres observés, les spectres des matériaux purs (endmembers) et leurs abondances. Cette procédure appelée procédure de démixage spectral, est un problème de séparation aveugle de sources. Toutefois, les méthodes les plus populaires sont basées sur un concept géométrique. En effet, à partir des contraintes naturelles du modèle, il apparaît que le nuage de points formant une image de télédétection spatiale est contenu dans un simplexe, comme l'illustre la figure suivante (Fig. 2.2). Les vertex du simplexe représentent les spectres des endmembers recherchés. Ainsi, le point clé de ces méthodes populaires réside dans la recherche des vertex du simplexe en question. Un panorama de ces méthodes est donné dans [17, 98, 108].

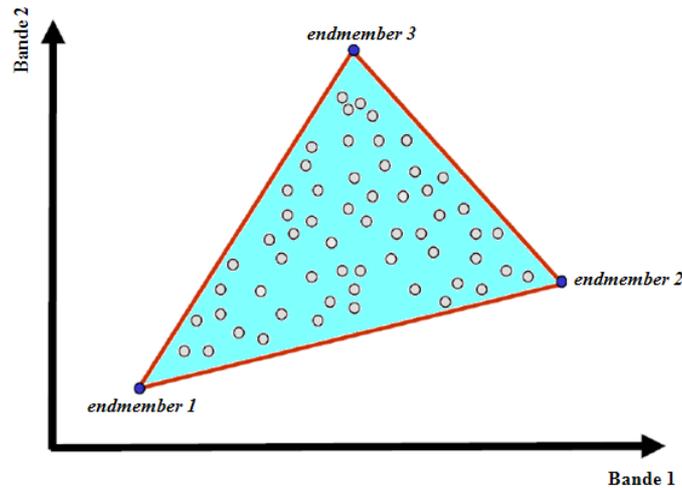


Fig. 2.2. Représentation en deux bandes du nuage de points contenu dans un simplexe [47].

Notons ici, que ces méthodes populaires, après généralement une phase de prétraitement pour la réduction de l'espace de travail, s'arrêtent généralement à l'extraction des endmembers (spectres des matériaux purs). Pour retrouver ensuite les abondances, il faut recourir à des méthodes d'inversion telles que les méthodes FCLS de D. C. Heinz et C. I. Chang [58], SGM de C. Theys et al. [117], et les méthodes Bayésiennes comme dans [46].

Il existe aussi des approches conjointes pour retrouver les endmembers et les abondances en une seule fois. Ces approches sont, le plus souvent, basées sur l'ACI, la FMN, ou sur des méthodes Bayésiennes [47].

Un autre point important lié aux méthodes de démixage d'images de télédétection spatiale, est le nombre de matériaux purs présents dans la scène imagée. Ce nombre peut être estimé par une ACP comme dans [78], ou en utilisant les méthodes HFC ou NWHFC décrites dans [31].

Nous nous arrêtons un petit moment dans cette section, pour signaler que la majorité des méthodes développées dans la littérature ne concernent que le démixage d'une **image hyperspectrale** de télédétection spatiale. En effet, l'information spectrale (nombre de bandes spectrales) contenue dans une image hyperspectrale permet un tel développement. **Au contraire, il existe très peu de travaux concernant le démixage**

**d'une image multispectrale**, et cela est principalement dû au peu de bandes spectrales contenues dans une telle image. Ainsi, le développement de méthodes permettant le démixage d'images multispectrales représente un challenge scientifique intéressant.

Il existe deux classifications des méthodes de démixage. La première classification est relative à la nature et au type des méthodes elles-mêmes : on trouve des méthodes géométriques, des méthodes statistiques, et d'autres à régressions parcimonieuses [17, 98]. La deuxième classification est liée à la nature des données à traiter : Il existe des méthodes faisant l'hypothèse d'existence, dans l'image, de pixels non-mélangés, qu'on appelle pixels purs (c'est-à-dire ne contenant qu'un seul matériau pur), et il existe des méthodes ne supposant pas cette dernière hypothèse (inexistence de pixels purs dans l'image) [108]. C'est cette deuxième classification de méthodes que nous présentons dans ce qui suit.

### **2.2.1. Méthodes avec l'hypothèse d'existence de pixels purs**

Les méthodes géométriques de démixage d'images supposant l'hypothèse d'existence de pixels purs pour chaque matériau, ont principalement pour but de retrouver les vertex du simplexe englobant le nuage de points d'une image. Ces vertex, avec l'hypothèse en question, appartiennent au nuage de points.

Parmi ces méthodes, les plus populaires sont : la méthode PPI de J. Boardman [18], celle baptisée N-FINDR de M. E. Winter [122], la méthode SMACC de J. Gruninger et al. décrite dans [54], et celle de J. M. P. Nascimento et J. M. Bioucas-Dias qui a pour nom VCA [93].

La méthode PPI cherche à retrouver le simplexe d'intérêt à partir de projections sur des espaces appropriés. La méthode N-FINDR calcule itérativement le simplexe de plus grand volume contenant le nuage de points. L'approche utilisée dans la méthode SMACC exploite les points extrêmes (les points les plus lumineux), parmi ceux appartenant au nuage de points, pour déterminer au fur et à mesure les vertex du cône convexe correspondant au simplexe d'intérêt. La méthode VCA exploite la projection dans des sous-espaces orthogonaux afin de retrouver directement les endmembers.

### 2.2.2. Méthodes avec l'hypothèse d'inexistence de pixels purs

À l'inverse des méthodes citées dans la sous-section précédente, les méthodes géométriques concernées par la présente sous-section font l'hypothèse d'inexistence de pixels purs dans l'image à démixer. Les méthodes de cette catégorie ont pour but de retrouver des vertex, qui n'appartiennent pas au nuage de points, du plus petit volume définissant le simplexe englobant la totalité des points de l'image.

Les méthodes les plus performantes de cette catégorie sont : la méthode MVC-NMF de L. Miao et H. Qi [90], les méthodes MVSA [83] et SISAL [16] de J. M. Bioucas-Dias.

La méthode MVC-NMF introduit dans la FMN un terme de régularisation du volume afin de retrouver le plus petit simplexe parmi ceux possibles qui circonscrivent le nuage de points. Les algorithmes des méthodes MVSA et SISAL résolvent un problème d'optimisation non-convexe avec des contraintes convexes. L'algorithme MVSA résout ce problème en implémentant une séquence de sous-contraintes quadratiques. SISAL résout le même problème d'optimisation par une séquence d'optimisations Lagrangiennes augmentées. Les deux algorithmes MVSA et SISAL sont initialisés par les résultats d'une VCA, et ces deux méthodes remplacent la contrainte de non-négativité des abondances par une contrainte plus douce définie par la fonction  $hinge(x) = 0$  si  $x \geq 0$  et  $-x$  si  $x < 0$ .

### 2.3. Quelles méthodes à mettre en place ? selon quelles modélisations ? sous quelles hypothèses ? et pour quels objectifs ?

La présente section a pour objectif d'exposer les motifs des contributions méthodologiques de la thèse. En effet, suite à la présentation des principales méthodes utilisées dans le domaine concerné par la présente thèse, il est tout à fait naturel de donner une réflexion, et un exposé des motifs conduisant à la mise en place de

méthodes pour atteindre l'objectif principal de cette thèse, à savoir le démixage d'images de télédétection spatiale selon le principe de la SAS linéaire.

Nous rappelons que les images de télédétection spatiale peuvent être modélisées selon deux approches différentes de la SAS linéaire. À partir de ces deux modélisations, nous essayons, dans ce qui suit, de voir quelle méthode de SAS est applicable ou pas dans l'une ou l'autre modélisation, selon, d'une part, les différents paramètres (hypothèses, critères, nombre de signaux observés par rapport au nombre des signaux sources) de ces méthodes de SAS, et d'autre part, le type de l'image manipulée.

La première approche est dite approche "sources spectrales", dans laquelle chaque pixel (spectre observé) d'une image de télédétection spatiale représente une observation, et les signaux sources à retrouver sont les spectres (signaux unidimensionnels) des matériaux purs présents dans la scène imagée. Dans cette approche, chaque colonne de la matrice de mélange représente les abondances d'un seul matériau dans la totalité de l'image. Selon cette approche, le modèle de séparation est sur-déterminé, puisque le nombre de pixels est généralement supérieur au nombre de spectres (ou matériaux purs) à retrouver.

Ces spectres (signaux sources) ne sont pas nécessairement statistiquement indépendants, puisque les spectres de matériaux différents peuvent avoir de grandes similitudes, notamment lorsqu'ils appartiennent à la même grande classe (végétation par exemple). À partir de ce constat, il apparaît que l'ACI n'est pas applicable selon cette approche.

Aussi, les spectres ne sont pas nécessairement parcimonieux, et donc l'ACPa n'est pas, elle non plus, applicable selon cette approche des sources spectrales.

Les signaux sources (spectres), ainsi que les abondances sont non-négatifs, mais la FMN est difficilement applicable à cause de son problème d'unicité.

De plus, d'un point de vue algorithmique, les méthodes habituelles de la SAS sont utilisées pour un petit nombre d'observations, alors que dans cette approche, le nombre d'observations (nombre de pixels) est très important. Inversement, le nombre d'échantillons dans chaque observation (correspondant au nombre de bandes spectrales de l'image utilisée) est très faible lorsqu'il s'agit d'une image multispectrale.

Ces différentes réserves mises en avant, il apparaît clairement que cette approche est à "abandonner" pour l'instant, puisqu'elle présente plusieurs degrés de difficulté.

La deuxième approche est dite approche "sources spatiales", dans laquelle chaque bande spectrale d'une image de télédétection spatiale représente une observation. Chaque colonne de la matrice de mélange est un spectre d'un matériau pur présent dans l'image. Les abondances des endmembers représentent les signaux sources recherchés. La carte d'abondances (signal bidimensionnel) de chaque matériau pur est une source à retrouver.

Selon cette approche, et lorsqu'il s'agit d'une image multispectrale, le modèle de séparation est, le plus souvent, sous-déterminé (puisque le nombre de bandes spectrales est généralement inférieur au nombre de cartes d'abondances à extraire). Au contraire, lorsqu'il s'agit d'une image hyperspectrale, avec de nombreuses bandes spectrales, le modèle de séparation est sur-déterminé.

Les cartes d'abondances, qu'on cherche à extraire, ne sont pas statistiquement indépendantes, à cause de la contrainte d'additivité des abondances [92]. Ainsi, l'ACI est difficilement applicable selon cette approche pour extraire les cartes d'abondances à partir d'une image multi/hyperspectrale. Cependant, on peut très bien envisager l'utilisation d'une ACI sur les bandes spectrales d'une image de télédétection spatiale, pour créer de nouvelles bandes (qu'on appelle "néo-canaux"), qu'on injecte par la suite dans un classifieur (non)supervisé, pour labéliser les pixels de la scène imagée. Cette manière de faire, dont on espère qu'elle améliore les résultats de la classification en utilisant les bandes spectrales originales, est valorisée dans le troisième chapitre, sur une image multispectrale avec un classifieur supervisé.

Ces mêmes cartes d'abondances respectent la contrainte de non-négativité, mais la FMN est difficilement applicable à cause, toujours, de son problème d'unicité. Là aussi, l'application d'une FMN selon la manière précédente, reste tout à fait envisageable. Le troisième chapitre contient aussi une valorisation de cette procédure avec la FMN.

Les cartes d'abondances, qui représentent les signaux sources, sont parcimonieuses, puisqu'un matériau pur ne peut être, en général, présent sur toute la scène observée. Ainsi, l'utilisation de l'ACP est appropriée pour identifier les coefficients de la matrice de mélange (qui contient dans ses colonnes les spectres des endmembers). Par contre, l'extraction des cartes d'abondances ne peut se faire ensuite par simple inversion de la matrice de mélange, puisque cette inversion ne respecte pas nécessairement la contrainte de non-négativité. Cependant, la combinaison de l'ACP avec la FMN ou les MCN permet sans doute d'extraire correctement les cartes d'abondances. Cette procédure est utilisée dans le quatrième et le cinquième chapitres pour extraire respectivement, avec l'hypothèse d'existence de pixels purs, des cartes d'abondances à partir d'une image multispectrale, et des spectres de matériaux purs à partir d'une image hyperspectrale.

La combinaison d'une image multispectrale, avec pixels purs, et d'une image hyperspectrale sans cette hypothèse, introduit des contraintes supplémentaires dans une éventuelle utilisation de la FMN pour l'extraction de spectres hyperspectraux. Ces contraintes permettent une bonne initialisation de la FMN, et par conséquent une convergence plus probable vers la solution souhaitée. Cette utilisation de la FMN sur une image multispectrale combinée avec une image hyperspectrale est décrite dans le sixième chapitre.

## **2.4. Critères de performance des méthodes à mettre en place**

Toute méthode de traitement du signal ou de l'image nécessite une évaluation de ses performances. La définition de critères d'évaluation s'impose tout naturellement.

Dans le troisième chapitre, et comme des classifications supervisées sont les résultats de l'approche mise en place, l'utilisation de la matrice dite "matrice de confusion" fait office de critère d'évaluation. Cette matrice, dont les lignes correspondent aux vraies classes (vérité terrain) et les colonnes correspondent aux classes issues de la classification, informe sur la précision totale de la classification.

Lorsqu'il s'agit d'extraction de cartes d'abondances (quatrième chapitre), ou des spectres (cinquième et sixième chapitres), à partir de données synthétiques, l'Erreur Quadratique Moyenne Normalisée (EQMN) (*Normalized Mean Square Error (NMSE)*), entre les cartes d'abondances/spectres originaux et les cartes d'abondances/spectres estimés, est utilisée comme critère de performance. Ce critère est défini comme suit :

$$EQMN_j = \frac{\|s_j - y_j\|_F^2}{\|s_j\|_F^2}, \forall j = 1 \dots L, \quad (2.22)$$

où  $y_j$  est la carte d'abondance/spectre estimé de  $s_j$ .

L'Angle Spectral (AS) (*Spectral Angle Mapper (SAM)*), entre spectre original et spectre estimé, est aussi utilisé comme critère d'évaluation lorsqu'il s'agit d'extraction de spectres à partir de données synthétiques. Cet angle est défini par :

$$AS_j = \arccos\left(\frac{\langle y_j, s_j \rangle}{\|y_j\| \|s_j\|}\right), \forall j = 1 \dots L. \quad (2.23)$$

Un autre critère de performance est également conçu pour l'évaluation des performances de l'extraction de cartes d'abondances à partir de données réelles. Ce critère consiste à sélectionner successivement sur les observations des zones mono-sources pour chaque source (classe) grâce à la vérité terrain. Ensuite, pour chacune des zones, nous examinons chaque carte d'abondances séparément, en calculant la moyenne de la carte d'abondance considérée sur la zone choisie. Ainsi, nous construisons une matrice, qu'on appelle "matrice de validation", dont l'entrée d'indice  $(j_1, j_2)$  est égale à

la moyenne des abondances de la zone mono-source  $j_1$  (qui contient la source  $j_1$ ) sur la carte d'abondances  $j_2$  (qui correspond à la source  $j_2$ ). Par conséquent, chaque élément diagonal  $(j_1, j_1)$  de cette matrice correspond à la performance d'extraction de la carte d'abondances  $j_1$ . Cet élément doit être proche de un lorsque la méthode d'extraction "fait correctement son travail". De même, les éléments non-diagonaux de cette matrice représentent les erreurs commises dans l'extraction des cartes d'abondances. Ils doivent être proches de zéro lorsque la méthode d'extraction, là aussi, "fait correctement son travail". La moyenne des éléments diagonaux représente la performance globale d'extraction des cartes d'abondances.

## **2.5. Conclusion**

Dans ce second chapitre, un panorama des principales méthodes utilisées dans les domaines concernés par la présente thèse a été exposé. Ces méthodes considèrent le domaine de la séparation aveugle de sources d'une part, et le domaine de démixage des images de télédétection spatiale d'autre part. Ainsi, les trois grandes catégories de méthodes de la SAS : celles fondées sur l'ACI, les méthodes de la FMN, ainsi que celles basées sur l'ACPa ont été présentées. Ensuite, les principales méthodes géométriques de démixage des images de télédétection spatiale ont été abordées. Aussi, une réflexion et un exposé des motifs du choix des méthodes à mettre en place dans cette thèse ont été donnés. À la fin de ce chapitre, les critères de performance des méthodes à mettre en place ont été détaillés.

## Références bibliographiques citées dans le Chapitre 2

- [1] K. Abed-Meraim, Yong Xiang, J. H. Manton, Yingbo Hua, "Blind Source-separation using Second-order Cyclostationary statistics," *IEEE Transactions on Signal Processing*, 49(4), pp. 694-701, 2001.
- [2] F. Abrard, Y. Deville, and P. White, "A new source separation approach based on time-frequency analysis for instantaneous mixtures," *In Proceedings of the 5<sup>th</sup> International Workshop on Electronics, Control, Modeling, Measurement and Signals, ECMS 2001*, pp. 259-267, Toulouse, France, 2001.
- [3] F. Abrard, "Méthodes de séparation aveugle de sources et applications : des statistiques d'ordre supérieur à l'analyse temps-fréquence" *Thèse de l'Université Paul Sabatier, Toulouse III*, 2003.
- [4] F. Abrard, Y. Deville, "A time-frequency blind signal separation method applicable to underdetermined mixtures of dependent sources," *Signal Processing*, 85(7), pp. 1389-1403, 2005.
- [5] B. Albouy, Y. Deville, "A time-frequency blind source separation method based on segmented coherence function," *In Proceedings of the 7<sup>th</sup> International Work-conference on Artificial and Natural Neural Networks, IWANN 2003*, 2, pp. 289-296, Mao, Menorca, Spain, 2003.
- [6] B. Albouy, "Méthodes de séparation aveugle de sources applicables à des Signaux de parole" *Thèse de l'Université Paul Sabatier, Toulouse III*, 2004.
- [7] S. Arberet, R. Gribonval, and F. Bimbot, "A robust method to count and locate audio sources in a stereophonic linear instantaneous mixtures," *In proceedings of the 6<sup>th</sup> International Conference on Independent Component Analysis and Blind Source Separation, ICA 2006*, pp. 536-543, Charleston, South Carolina, USA, 2006.
- [8] M. Babaie-Zadeh, C. Jutten, "A general approach for mutual information minimizing and its application to blind source separation," *Signal Processing*, 85(5), pp. 975-995, 2005.
- [9] A. J. Bell, T. J. Sejnowski, "An information-maximization approach to blind separation and blind deconvolution," *Neural Computation*, 7, pp. 1129-1159, 1995.

- [10] A. Belouchrani, K. Abed-Meraim, "Séparation aveugle au second ordre de sources corrélées," *In GRETSI*, pp. 309-312, Juan-Les-Pins, France, 1993.
- [11] A. Belouchrani, J. F. Cardoso, "Maximum likelihood source separation for discrete sources," *In Proceedings of the European Signal Processing Conference, EUSIPCO 1994, vol. 2*, pp. 768-771, Edinburgh, UK, 1994.
- [12] A. Belouchrani, K. Abed-Meraim, J. F. Cardoso, E. Moulines, "A Blind Source Separation Technique Using Second-Order Statistics," *IEEE Transactions on Signal Processing*, 45(2), pp. 434-444, 1997.
- [13] A. Belouchrani, M. G. Amin, "Blind Source Separation Based on Time-Frequency Signal Representations," *IEEE Transactions on Signal Processing*, 46(11), pp. 2888-2897, 1998.
- [14] A. Belouchrani, K. Abed-Meraim, M. G. Amin, A. M. Zoubir, "Blind Separation of Nonstationary Sources," *IEEE Signal Processing Letters*, 11(7), pp. 605-608, 2004.
- [15] M. W. Berry, M. Browne, A. N. Langville, V. P. Pauca, and R. J. Plemmons, "Algorithms and applications for approximate nonnegative matrix factorization," *Computational Statistics & Data Analysis*, 52(1), pp. 155-173, 2007.
- [16] J. M. Bioucas-Dias, "A Variable Splitting Augmented Lagrangian Approach to Linear Spectral Unmixing," *In Proceedings of the First IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2009*, Grenoble, France, 2009.
- [17] J. M. Bioucas-Dias, A. Plaza, "An overview on hyperspectral unmixing: geometrical, statistical, and sparse regression based approaches," *In Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2011*, pp. 1135-1138. 2011.
- [18] J. Boardman, "Automating spectral unmixing of AVIRIS data using convex geometry concepts," *In Summaries of the 4<sup>th</sup> Annual JPL Airborne Geoscience Workshop, 1*, pp. 11-14, Washington (D. C.), USA, 1993.

- [19] H. Bouchner, R. Aichner, and R. Kellermann, "A generalization of blind source separation algorithms for convolutive mixtures based on second-order statistics," *IEEE Transactions on Speech and Audio Processing*, 13(1), pp. 120-134, 2005.
- [20] H. Boumaraf, "Séparation Aveugle de Mélanges Convolutifs de Sources" *Thèse de l'Institut National Polytechnique de Grenoble*, 2005.
- [21] J. F. Cardoso, "Source separation using higher order moments," *In Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 1989*, pp. 2109-2112, Glasgow, UK, 1989.
- [22] J. F. Cardoso, A. Soudouki, "Blind beamforming for non gaussian signals," *IEE-proceedings-F*, 140(6), pp. 362-370, 1993.
- [23] J. F. Cardoso, "Infomax and maximum likelihood for blind source separation," *IEEE Signal Processing Letters*, 4, pp. 112-114, 1997.
- [24] S. Choi, A. Cichocki, "Algebraic differential decorrelation for nonstationary source separation," *IEEE Electronic Letters*, 37(23), pp. 1414-1415, 2001.
- [25] S. Choi, A. Cichocki, and Y. Deville, "Differential decorrelation for nonstationary source separation," *In Proceedings of the 3<sup>rd</sup> International Conference on Independent Component Analysis and Signal Separation, ICA 2001*, pp. 319-322, San Diego, California, USA, 2001.
- [26] S. Choi, A. Cichocki, and A. Belouchrani, "Second order non-stationary source separation," *Journal of VLSI Signal Processing*, 32(1-2), pp. 93-104, 2002.
- [27] S. Choi, A. Cichocki, H. M. Park, and S. Y. Lee, "Blind source separation and independent component analysis: a review," *Neural Information Processing – Letters and Reviews*, 6(1), 2005.
- [28] A. Cichocki, S. I. Amari, *Adaptive Blind and Image Processing: Learning Algorithms and Applications*, Wiley, New York, 2003.
- [29] A. Cichocki, R. Zdunek, and S. I. Amari, "New Algorithms for Non-Negative Matrix Factorization in Applications to Blind Source Separation," *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 2006*, pp. V, Toulouse, France, 2006.

- [30] A. Cichocki, R. Zdunek, A. H. Phan, and S. I. Amari, *Nonnegative Matrix and Tensor Factorization: Applications to Exploratory Multi-way Data Analysis and Blind Source Separation*, John Wiley & Sons, 2009.
- [31] C. I. Chang, Q. Du, "Estimation of number of spectrally distinct signal sources in hyperspectral imagery," *IEEE Transactions on Geoscience and Remote Sensing*, 42(3), pp. 608-619, 2004.
- [32] L. Cohen, *Time-frequency analysis*, Prentice hall PTR, Englewood, Cliffs, New Jersey, 1995.
- [33] P. Comon, "Independent Component Analysis, a new concept?" *Signal Processing*, 36(3), pp. 287-314, 1994. Special issue on Higher-Order Statistics.
- [34] P. Comon, C. Jutten, *Séparation de sources, tome 1*, Collection Traité IC2, Information-Commande-Communication, Hermès-Lavoisier, Paris, France, 2007.
- [35] P. Comon, C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*, Academic Press, 2010.
- [36] G. Darmais, "Analyse générale des liaisons de probabilités," *In Proceedings Int. Stat. Conferences 1947, III A*, p. 231, Washington (D.C.), USA, 1951.
- [37] G. Darmais, "Analyse générale des liaisons stochastiques," *Revue de l'Institut International de Statistique*, 21(1-2), pp. 2-8, 1953.
- [38] Y. Deville, S. Savoldelli, "A second-order differential approach for underdetermined convolutive source separation," *In Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 2001*, pp. 2741-2744, Salt Lake City, USA, 2001.
- [39] Y. Deville, "Temporal and time-frequency correlation-based blind source separation methods," *In Proceedings of the 4<sup>th</sup> International Symposium on Independent Component Analysis and Blind Signal Separation, ICA 2003*, pp. 1059-1064, Nara, Japan, 2003.
- [40] Y. Deville, M. Benali, and F. Abrard, "Differential source separation for underdetermined instantaneous or convolutive mixtures: concept and algorithms," *Signal Processing*, 84(10), pp. 1759-1776, 2004.

- [41] Y. Deville, M. Puigt, and B. Albouy, "Time-frequency blind signal separation: extended methods, performance evaluation for speech sources," *In Proceedings of the International Joint Conference on Neural Networks, IJCNN 2004, 1*, pp. 2741-2744, Salt Lake City, USA, 2004.
- [42] Y. Deville, D. Bisseur, M. Puigt, S. Hosseini, and H. Carfantan, "A time-scale correlation-based blind separation method applicable to correlated sources," *In Proceedings of the European Symposium on Artificial Neural Networks, ESANN 2006*, pp. 337-344, Bruges, Belgium, 2006.
- [43] Y. Deville, *Traitement du signal : signaux temporels et spatiotemporels – Analyse des signaux, théorie de l'information, traitement d'antenne, séparation aveugle de sources*, Ellipses Editions Marketing, Paris, 2011.
- [44] Y. Deville, M. Puigt, "Temporal and time-frequency correlation-based blind source separation methods. Part 1: linear instantaneous mixtures," *Signal Processing*, 87(3), pp. 374-407, 2007.
- [45] D. Donoho, V. Stodden, "When Does Non-Negative Matrix Factorization Give a Correct Decomposition into Parts?" *In Proceedings NIPS, 16*, pp. 1141-1149, 2003.
- [46] N. Dobigeon, J. Y. Tourneret, and C. I. Chang, "Semi-supervised linear spectral using a hierarchical Bayesian model for hyperspectral imagery," *IEEE Transactions on Signal Processing*, 56(7), pp. 2684-2696, 2008.
- [47] O. Eches, "Méthodes Bayésiennes pour le démelange d'images hyperspectrales" *Thèse de l'Institut Polytechnique de Toulouse*, 2010.
- [48] J. Eggert, E. Körner, "Sparse coding and NMF," *In Proceedings of the IEEE International Joint Conference on Neural Networks, 4*, pp. 2529-2533, 2004.
- [49] D. Erdogmus, K. E. Hild, Y. N. Rao, and J. C. Principe, "Minimax mutual information approach for independent component analysis," *Neural Computation*, 16(6), pp. 1235-1252, 2004.
- [50] J. Foote, "Visualizing music and audio using self-similarity," *In Proceedings of the seventh ACM International Conference on Multimedia*, pp. 77-80, Orlando, Florida, USA, 1999.

- [51] M. Gaeta, J. L. Lacoume, "Estimateurs du maximum de vraisemblance étendus à la séparation de sources non-Gaussiennes," *Traitement du Signal*, 7(5), pp. 419-434, 1990.
- [52] M. Gaeta, J. L. Lacoume, "Source separation without prior knowledge: The maximum likelihood solution," *In Proceedings of the European Signal Processing Conference, EUSIPCO 90*, pp. 621-624, 1990.
- [53] R. Gribonval, S. Lesage, "A survey of sparse component analysis for source separation : principles, perspectives, and new challenges," *In Proceedings of the 14<sup>th</sup> European Symposium on Artificial Neural Networks, ESANN 2006*, pp. 323-330, Bruges, Belgium, 2006.
- [54] J. Gruninger, A. J. Ratkowski, and M. L. Hoke, "The sequential maximum angle convex cone (SMACC) endmember model," *In Proceedings of the SPIE Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery X, 5425*, pp. 1-14, Orlando, Florida, USA, 2004.
- [55] R. Guidara, S. Hosseini, Y. Deville, "Blind Separation of Non-stationary Markovian Sources Using an Equivariant Newton-Raphson Algorithm," *IEEE Signal Processing Letters*, 16(5), pp. 426-429, 2009.
- [56] R. Guidara, S. Hosseini, Y. Deville, "Maximum likelihood blind image separation using non-symmetrical half-plane Markov random fields," *IEEE Transactions on Image Processing*, 18(11), pp. 2435-2450, 2009.
- [57] R. Guidara, "Méthodes markoviennes pour la separation aveugle de signaux et images" *Thèse de l'Université Paul Sabatier, Toulouse III*, 2009.
- [58] D. C. Heinz, C. I. Chang, "Fully Constrained Least Squares Linear Spectral Mixture Analysis Method for Material Quantification in Hyperspectral Imagery," *IEEE Transactions on Geoscience and Remote Sensing*, 39(3), pp. 529-545, 2001.
- [59] R. C. Henry, "Current factor analysis receptor models are ill-posed," *Atmospheric Environment*, 21, pp. 1815-1820, 1987.
- [60] K. E. Hild, D. Erdogmus, and J. C. Principe, "Blind source separation using Renyi's mutual information," *IEEE Signal Processing Letters*, 8(6), pp. 174-176, 2001.

- [61] K. E. Hild, D. Erdogmus, and J. C. Principe, "On-line minimum mutual information method for time-varying blind source separation," *In Proceedings of the 3<sup>rd</sup> International Symposium on Independent Component Analysis and Signal Separation, ICA 2001*, pp. 126-131, San Diego, California, USA, 2001.
- [62] K. E. Hild, D. Pinto, D. Erdogmus, and J. C. Principe, "Convolutive blind source separation by minimizing mutual information between segments of signals," *IEEE Transactions on Circuits and Systems: I Regular Papers*, 52(10), pp. 2188-2196, 2005.
- [63] F. Hlawatsch, G. F. Bourdeaux-Bartels, "Linear and quadratic time-frequency signal representations," *IEEE SP Magazine*, pp. 21-67, 1992.
- [64] S. Hosseini, Y. Deville, "Blind separation of nonstationary sources by spectral decorrelation," *In Proceedings of the Fifth International Conference on Independent Component Analysis and Blind Signal Separation, ICA 2004*, pp. 279-286, Granada, Spain, 2004.
- [65] S. Hosseini, Y. Deville, and H. Saylani, "From time-domain separation of stationary temporally correlated sources to frequency-domain separation of non-stationary sources," *In Proceedings of the Fourth International Conference on Physics in Signal and Image Processing, PSIP 2005*, pp. 55-59, Toulouse, France, 2005.
- [66] S. Hosseini, C. Jutten, D. T. Pham, "Markovian source separation," *IEEE Transactions on Signal Processing*, 51(12), pp. 3009-3019, 2003.
- [67] S. Hosseini, R. Guidara, Y. Deville, and C. Jutten, "Markovian blind image separation," *In Springer-Verlag (editor): Proceedings of the 6<sup>th</sup> International Conference on Independent Component Analysis and Blind Signal Separation, ICA 2006, LNCS 3889*, pp. 106-114, Charleston, South Carolina, USA, 2006.
- [68] S. Hosseini, Y. Deville, and H. Saylani, "Blind separation of linear instantaneous mixtures of non-stationary signals in the frequency domain," *Signal Processing*, 89(5), pp. 819-830, 2009.
- [69] P. O. Hoyer, "Non-negative Matrix Factorization with Sparseness Constraints," *Journal of Machine Learning Research*, 5, pp. 1457-1469, 2004.
- [70] A. Hyvärinen, E. Oja, "A Fast Fixed-Point Algorithm for Independent Component Analysis," *Neural Computation*, 9(7), pp. 1483-1492, 1997.

- [71] A. Hyvärinen, "Fast and Robust Fixed-Point Algorithms for Independent Component Analysis," *IEEE Transactions on Neural Networks*, 10(3), pp. 626-634, 1999.
- [72] A. Hyvärinen, "Survey on independent component analysis," *Neural Computing Surveys*, 2, pp. 94-128, 1999.
- [73] A. Hyvärinen, E. Oja, "Independent component analysis: Algorithms and applications," *Neural Networks*, 13(4-5), pp. 411-430, 2000.
- [74] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, Wiley Interscience, 2001.
- [75] I. T. Jolliffe, *Principal Component Analysis*, Springer Series, 2002.
- [76] A. Jourjine, S. Rickard, and O. Yilmaz, "Blind separation of disjoint orthogonal signals: Demixing n sources from 2 mixtures," *In Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 2000*, pp. 2985-2988, Istanbul, Turkey, 2000.
- [77] C. Jutten, P. Comon, *Séparation de sources, tome 2*, Collection Traité IC2, Information-Commande-Communication, Hermès-Lavoisier, Paris, France, 2007.
- [78] N. Keshava, J. F. Mustard, "Spectral Unmixing," *IEEE Signal Processing Magazine*, 19, pp. 44-57, 2002.
- [79] D. D. Lee, H. S. Seung, "Learning the parts of objects by non-negative matrix factorization," *Nature*, 401, pp. 788-791, 1999.
- [80] D. D. Lee, H. S. Seung, "Algorithms for Non-Negative Matrix Factorization," *Advances in Neural Information Processing Systems*, 13, pp. 556-562, MIT Press 2001.
- [81] T. W. Lee, *Independent Component Analysis: Theory and Applications*, Kluwer Academic Publishers, Boston, 1998.
- [82] T. W. Lee, M. Girolami, and T. J. Sejnowski, "A unifying information-theoretic framework for independent component analysis," *Journal of Computers and Mathematics with Applications*, 39(11), pp. 1-21, 2000.

- [83] J. Li, J. M. Bioucas-Dias, "Minimum Volume Simplex Analysis: A Fast Algorithm to Unmix Hyperspectral Data," *In Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2008*, Boston, USA, 2008.
- [84] C. J. Lin, "Projected Gradient Methods for Non-negative Matrix Factorization," *Neural Computation*, 19, pp. 2756-2779, 2007.
- [85] Z. Q. Luo, J. Lu, "On blind source separation using mutual information criterion," *Mathematical programming*, 97(3), pp. 587-603, 2003.
- [86] S. G. Mallat, Z. Zhang, "Matching pursuit in a time-frequency dictionary," *IEEE Transactions on Signal Processing*, 41(12), pp. 3397-3415, 1993.
- [87] A. Mansour, A. K. Barros, and N. Ohnishi, "Blind separation of sources: Methods, assumptions and applications," *EICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, E83-A(8), pp. 1498-1512, 2000.
- [88] K. Matsuoka, M. Ohya, and M. Kawamoto, "A neural net for blind separation of non-stationary signals," *Neural Networks*, 8(3), pp. 411-419, 1995.
- [89] I. Meganem, Y. Deville, M. Puigt, "Blind separation methods based on correlation for sparse possibly-correlated images," *In Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 2010*, pp. 1334-1337. 2010.
- [90] L. Miao, H. Qi, "Endmember Extraction from Highly Mixed Data Using Minimum Volume Constrained Nonnegative Matrix Factorization," *IEEE Transactions on Geoscience and Remote Sensing*, 45, pp. 765-777, 2007.
- [91] E. Moreau, "A generalization of joint-diagonalization criteria for source separation," *IEEE Transactions on Signal Processing*, 49(3), pp. 530-541, 2001.
- [92] J. M. P. Nascimento, J. M. Bioucas-Dias, "Does Independent Component Analysis Play a Role in Unmixing Hyperspectral Data?" *IEEE Transactions on Geoscience and Remote Sensing*, 43(1), pp. 175-187, 2005.
- [93] J. M. P. Nascimento, J. M. Bioucas-Dias, "Vertex Component Analysis: A Fast Algorithm to Unmix Hyperspectral Data," *IEEE Transactions on Geoscience and Remote Sensing*, 43(4), pp. 898-910, 2005.

- [94] P. D. O'Grady, B. A. Pearlmutter, and S. Rickard, "Survey of sparse and non-sparse methods in source separation," *International Journal of Imaging Systems and Technology (IJIST)*, 15, pp. 18-33, 2005.
- [95] P. Paatero, U. Tapper, P. Aalto, and M. Kulmala, "Matrix factorization methods for analyzing diffusion battery data," *Journal of Aerosol Sciences*, 22(S1), pp. 273-276, 1991.
- [96] P. Paatero, U. Tapper, "Positive matrix factorization: A non-negative factor model with optimal utilization of error estimates of data values," *Environmetrics*, 5, pp. 111-126, 1994.
- [97] P. Paatero, "Least squares formulation of robust non-negative factor analysis," *Chemometrics and Intelligent Laboratory Systems*, 37, pp. 23-35, 1997.
- [98] M. Parente, A. Plaza, "Survey of geometric and statistical unmixing algorithms for hyperspectral images," *In Proceedings of the Second IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2010*, Reykjavik, Iceland, 2010.
- [99] L. Parra, C. Spence, and B. De Vries, "Convolutive source separation and signal modeling with ML," *In Proceedings of the International Symposium on Intelligent Systems, ISIS 1997*, Reggio Calabria, Italy, 1997.
- [100] B. Pearlmutter, L. Parra, "A context-sensitive generalization of independent component analysis," *In proceedings of the 1996 International Conference on Neural Information Processing, ICONIP 1996*, Hong Kong, 1996.
- [101] D. T. Pham, P. Garat, C. Jutten, "Separation of mixture of independent sources through a maximum likelihood approach," *In Signal Processing VI, Proceedings of the 6<sup>th</sup> European Signal Processing Conference, EUSIPCO 1992*, pp. 771-774, Brussels, Belgium, 1992.
- [102] D. T. Pham, P. Garat, "Blind separation of mixtures of independent sources through a quasi maximum likelihood approach," *IEEE Transactions on Signal Processing*, 45(7), pp. 1712-1725, 1997.
- [103] D. T. Pham, "Mutual information approach to blind separation for stationary sources," *In Proceedings of the International Conference on Independent Component Analysis and Signal Separation, ICA 1999*, pp. 215-220, Aussois, France, 1999.

- [104] D. T. Pham, "Blind separation of instantaneous mixture of sources via the gaussian mutual information criterion," *Signal Processing*, 81(4), pp. 855-870, 2001.
- [105] D. T. Pham, J. F. Cardoso, "Blind separation of instantaneous mixtures of non-stationary sources," *IEEE Transactions on Signal Processing*, 49(9), pp. 1837-1847, 2001.
- [106] D. T. Pham, "Mutual information approach to blind separation for stationary sources," *IEEE Transactions on Information Theory*, 48(7), pp. 1935-1946, 2002.
- [107] D. T. Pham, "Mutual information approach to blind separation-deconvolution," *In Proceedings of the European Signal Processing Conference, EUSIPCO 2005*, Antalya, Turkey, 2005.
- [108] J. Plaza, E. M. T. Hendrix, I. Garcia, G. Martin, and A. Plaza, "On endmember Identification in Hyperspectral Images Without Pure Pixels: A Comparison of Algorithms," *Journal of Mathematical Imaging and Vision*, 2011, DOI 10.1007/s10851-011-0276-0.
- [109] M. Puigt, "Méthodes de separation aveugle de sources fondées sur des transformées temps-fréquence. Application à des signaux de parole," *Thèse de l'Université Paul Sabatier, Toulouse III*, 2007.
- [110] M. El Rhabi, G. Gelle, H. Fenniri, and G. Delaunay, "A penalized mutual information criterion for blind separation of convolutive mixtures," *Signal Processing*, 84(10), pp. 1979-1984, 2004.
- [111] S. Samadi, M. Babaie-Zadeh, C. Jutten, and K. Nayebi, "Blind source separation by adaptive estimation of score function difference," *In Springer-Verlag (editor): Proceedings of the 5<sup>th</sup> International Symposium on Independent Component Analysis and Blind Signal Separation, ICA 2004, LNCS 3195*, Granada, Spain, 2004.
- [112] H. Saylani, S. Hosseini, Y. Deville, and M. Habibi, "Système d'identification radio-fréquence multi-badge utilisant de nouvelles méthodes de séparation aveugle de sources à décorrélation spectrale," *Physical and Chemical News*, 35, pp. 31-42, 2007.

- [113] J. Shen, G. W. Israël, "A receptor model using non-negative transformation technique for ambient aerosol," *Atmospheric Environment*, 23(10), pp. 2289-2298, 1989.
- [114] D. Smith, J. Lukasiak, and I. Burnett, "A block-adaptative audio separation technique based upon time-frequency information," *In Proceedings of the 12<sup>th</sup> European Signal Processing Conference, EUSIPCO 2004*, pp. 393-396, Vienna, Austria, 2004.
- [115] D. Smith, J. Lukasiak, and I. Burnett, "Two channel, block adaptative audio separation using the cross correlation of time frequency information" *In Springer-Verlag: Proceedings of the 5<sup>th</sup> International Symposium on Independent Component Analysis and Blind Signal Separation, ICA 2004, LNCS 3195*, Granada, Spain, 2004.
- [116] A. Souloumiac, "Blind source detection and separation using second-order non-stationarity," *In Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 1995*, pp. 1912-1915, Detroit, Michigan, USA, 1995.
- [117] C. Theys, N. Dobigeon, J. Y. Tournet, and H. Lantéri, "Linear unmixing of hyperspectral images using a scaled gradient method," *In Proceedings of the IEEE-SP Workshop Stat. and Signal Processing, SSP 2009*, pp. 729-732, Cardiff, UK, 2009.
- [118] L. Tong, V. C. Soon, R. Liu, and Y. Huang, "AMUSE: a new blind identification algorithm," *In Proceedings of the IEEE International Symposium on Circuits and Systems, ISCAS 1990*, 3, pp. 1784-1787, New Orleans, Louisiana, USA, 1990.
- [119] L. Tong, R. W. Liu, V. C. Soon, and Y. F. Huang, "Indeterminacy and identifiability of blind identification," *IEEE Transactions on Circuits and Systems*, 38(5), pp. 499-509, 1991.
- [120] L. Tong, Y. Inouye, and R. W. Liu, "Waveform-Preserving Blind Estimation of Multiple Independent Sources," *IEEE Transactions on Signal Processing*, 41(7), pp. 2461-2470, 1993.

- [121] J. Van de Laar, "Instantaneous blind source separation based on the exploitation of temporal correlations and nonstationarity," *In Proceedings of the 14<sup>th</sup> Annual Workshop on Circuits, Systems and Signal Processing, ProRISC 2003*, pp. 391-398, Veldhoven, The Netherlands, 2003.
- [122] M. E. Winter, "Fast autonomous spectral endmember determination in hyperspectral data," *In Proceedings of the 13<sup>th</sup> International Conference on Applied Geologic Remote Sensing, 2*, pp. 337-344, Vancouver, Canada, 1999.
- [123] F. Yin, T. Mei, and J. Wang, "Blind source separation based on decorrelation and non-stationarity," *IEEE Transactions on Circuits and Systems*, 54(5), pp. 1150-1158, 2007.
- [124] R. Zdunek, A. Cichocki, "Fast nonnegative matrix factorization algorithms using projected gradient approaches for large-scale problems," *Computational Intelligence and Neuroscience*, ID 939567, 2008.

## CHAPITRE 3

### PRETRAITEMENT PAR SEPARATION DE SOURCES ET CLASSIFICATION D'UNE IMAGE MULTISPECTRALE

---

*Résumé* - Dans ce chapitre, nous utilisons des méthodes classiques de séparation aveugle de sources pour réaliser un prétraitement d'une image multispectrale de télédétection spatiale en vue d'améliorer la classification supervisée de ses pixels. Les algorithmes les plus populaires de l'analyse en composantes indépendantes, ainsi que de la factorisation en matrices non-négatives, sont utilisés pour réaliser ledit prétraitement, qui consiste à générer, à partir des bandes originales de l'image, des néo-canaux. Ces néo-canaux sont ensuite utilisés comme des entrées pour un classifieur supervisé intégrant l'information texturale. Ainsi, après une introduction, nous exposons l'approche adoptée pour atteindre notre objectif. Par la suite, des résultats expérimentaux sur une image multispectrale réelle de télédétection spatiale sont détaillés. Nous terminons le présent chapitre par une conclusion.

---

## *DANS CE CHAPITRE*

3.1. Introduction	80
3.2. Approche méthodologique proposée	82
3.2.1. Prétraitement par les méthodes classiques d'ACI ou FMN	83
3.2.2. Classification	83
3.3. Résultats expérimentaux	84
3.3.1. Données utilisées	84
3.3.2. Résultats et discussion	85
3.4. Conclusion	92
Références bibliographiques citées dans le Chapitre 3	93

### 3.1 Introduction

Dans ce chapitre, nous évaluons l'apport des méthodes classiques de l'approche dite de Séparation Aveugle de Sources (SAS) (*Blind Source Separation (BSS)*), pour le prétraitement d'une image multispectrale de télédétection spatiale en vue de la classification supervisée de ses pixels.

Les images acquises par les satellites d'observation de la Terre sont des documents utiles voire indispensables pour bon nombre de disciplines, du fait de la couverture globale de la surface terrestre et de la répétitivité de ces données. Ainsi, l'observation de la Terre depuis l'espace contribue, dans une large mesure, au suivi et à la discrimination de régions naturelles, à l'évolution et la compréhension de nombreux processus de l'environnement sur des zones parfois difficiles d'accès, ce qui permet un gain de temps non négligeable.

L'objectif principal de l'analyse des images de télédétection spatiale est l'interprétation de ces dernières. Cette interprétation est généralement réalisée par le processus de classification. Les méthodes traditionnelles de classification des images de télédétection spatiale se basent généralement sur la réponse spectrale des capteurs en considérant le pixel de façon individuelle. Cette réponse permet d'associer les propriétés spectrales de la surface terrestre avec certaines propriétés de couverture ou d'utilisation du sol. Chaque élément de la surface est donc caractérisé par une signature spectrale. Pour plus d'efficacité, la caractérisation d'un pixel sur l'image doit tenir compte, d'une part des propriétés spectrales propres au pixel, et d'autre part de celles des pixels voisins. Il faut donc que les méthodes de classification soient plus perfectionnées si on veut profiter pleinement des capacités spectrales et spatiales des images en essayant de dépasser la simple analyse spectrale pixel par pixel, en faisant intervenir le voisinage du pixel, c'est-à-dire la "texture". L'exploitation de l'information texturale consiste à intégrer cette dernière dans le processus classificatoire [32]. Le processus de classification peut nécessiter un prétraitement, notamment un prétraitement pour la réduction de la dimensionnalité.

Différentes techniques existent pour le prétraitement. La plus couramment utilisée est probablement l'Analyse en Composantes Principales (ACP) (*Principal Components Analysis (PCA)*). Celle-ci est motivée par la cohérence qui peut exister entre les différentes bandes spectrales d'une image multispectrale de télédétection spatiale. L'ACP linéaire cherche à représenter les observations initiales comme un mélange linéaire de quelques composantes décorréliées [22, 23, 33].

Dans le même esprit du prétraitement, on peut tout à fait envisager l'application, sur les observations initiales, des méthodes linéaires classiques de séparation de sources, à la place d'une ACP linéaire.

Nous rappelons brièvement ici que la séparation de sources linéaire a pour objectif d'estimer un ensemble de signaux sources à partir seulement d'un ensemble de signaux observés qui sont des mélanges linéaires de ces signaux sources [7, 8, 12-14, 20]. Aussi, la séparation de sources se résout, généralement, par l'utilisation d'une méthode appartenant à l'une des trois catégories de méthodes suivantes : 1) les méthodes basées sur l'Analyse en Composantes Indépendantes (ACI) (*Independent Component Analysis (ACI)*) [7, 12-14, 20]. 2) les méthodes fondées sur la Factorisation en Matrices Non-négatives (FMN) (*Non-negative Matrix Factorization (NMF)*) [3, 8-10, 35]. 3) les méthodes d'Analyse en Composantes Parcimonieuses (ACPa) (*Sparse Components Analysis (SCA)*) [17, 31].

Les techniques classiques d'ACI ont été déjà utilisées pour prétraiter des images de télédétection spatiale [4, 29]. Les résultats obtenus dans [4] montrent une insuffisance de la seule utilisation des techniques d'ACI pour l'extraction des différentes classes et la reconnaissance des différents thèmes d'intérêt dans la scène imagée. Dans les travaux de recherche du présent chapitre, nous utilisons les techniques les plus populaires d'ACI d'une part, et la FMN d'autre part pour générer de néo-canaux. Ces derniers sont utilisés comme des entrées pour un classifieur intégrant l'information texturale.

Nous signalons ici, qu'une grande partie du présent chapitre a été abordée dans nos travaux du Master 2 Recherche "Signal, Image Acoustique et Optimisation" de l'Université Paul Sabatier, Toulouse III [24], et du Magister "Techniques de Communication Modernes" de l'Université des Sciences et de la Technologie d'Oran - Mohamed Boudiaf [25], suite auxquels est née la présente thèse réalisée en cotutelle.

### 3.2 Approche méthodologique proposée

Nous visons l'élaboration d'une carte d'occupation des sols d'une zone d'étude à partir d'une image de télédétection spatiale. Pour cela nous procédons en deux étapes, comme l'illustre la figure Fig. 3.1. La première consiste en un prétraitement de l'image par des méthodes linéaires classiques de séparation de sources (ACI ou FMN). Dans la seconde étape nous réalisons un ensemble de classifications à partir d'un jeu d'échantillons représentant les thèmes d'intérêt. La base d'échantillons constituée de pixels significatifs pour chaque classe est choisie manuellement sur l'image, en se basant sur une campagne de reconnaissance déjà effectuée sur le terrain. Parmi les échantillons disponibles, un petit ensemble de pixels pour chaque classe est choisi, afin de servir dans la phase d'apprentissage. Après apprentissage et classification, l'ensemble des échantillons est utilisé pour la validation par le calcul des matrices de confusion (voir Section 2.4 du Chapitre 2).

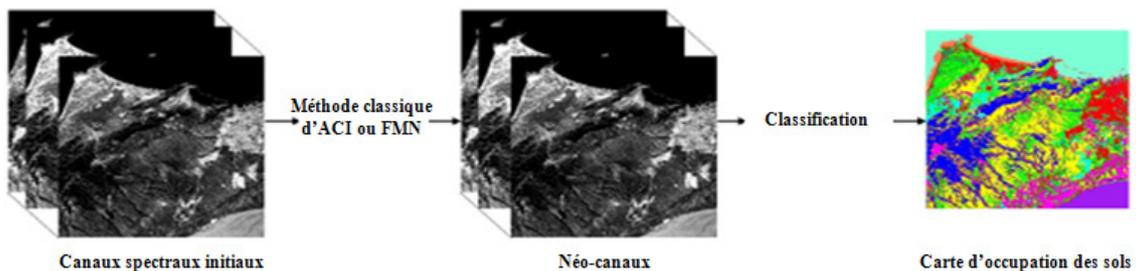


Fig. 3.1. Diagramme de l'approche méthodologique adoptée.

### **3.2.1 Prétraitement par les méthodes classiques d'ACI ou FMN**

Les algorithmes des méthodes classiques d'ACI ou FMN sont appliqués sur les canaux spectraux de l'image. Les algorithmes d'ACI utilisés ici, sont ceux parmi les plus populaires, à savoir : FastICA [13, 19, 20], JADE [5, 6, 30], et SOBI [1, 2]. Leur popularité est en partie due au fait qu'ils furent parmi les premiers algorithmes à permettre une réalisation pratique de l'ACI. Les algorithmes de la FMN [3, 10, 27] utilisés dans les travaux du présent chapitre, sont d'une part, l'algorithme initial de D. D. Lee et H. S. Seung [28] basé sur l'utilisation de règles de mise à jour multiplicatives, et d'autre part, le même algorithme combiné au codage parcimonieux (FMN-CP) [16]. Cette combinaison est étroitement liée à l'ACI non-négative [18], et permet d'offrir une situation plus favorable pour limiter le nombre de solutions de la FMN, qui n'est pas unique [15].

En sortie des algorithmes cités ci-dessus, nous obtenons le même nombre de néo-canaux qu'en entrée. Par la suite, ces néo-canaux sont utilisés comme des entrées pour un classifieur supervisé intégrant l'information texturale. Cette deuxième étape est détaillée ci-après.

### **3.2.2 Classification**

Les méthodes de classification des images de télédétection spatiale permettent une analyse de données en regroupant les pixels les plus semblables entre eux en différentes classes. Les méthodes les plus classiques n'introduisent que des informations d'ordre spectral. Ces méthodes posent le plus souvent des problèmes de confusion entre les différentes classes. Cela est dû à l'insuffisance de la réponse spectrale à caractériser un objet présent dans les images manipulées. Cette insuffisance nous amène à explorer le potentiel de la texture pour la classification des images de télédétection spatiale.

La texture se décrit en termes linguistiques tels que la rugosité, le contraste, la finesse, la régularité, etc. Une texture présente, à une échelle donnée, le même aspect visuel quelle que soit la zone observée. On rencontre deux types de définitions de la texture [11]. La première est déterministe et fait référence à une répétition spatiale d'un motif de base dans différentes directions. Dans [11], la texture est considérée comme

l'agencement d'un motif de base appelé "texton". La deuxième est probabiliste et cherche à caractériser l'aspect anarchique et homogène qui ne comprend ni motif localisable, ni fréquence de répétition principale. Dans [11] on retrouve une synthèse des deux définitions en considérant la texture comme une structure spatiale constituée de l'organisation de primitives ayant chacune un aspect aléatoire.

Ainsi, la texture s'évalue à l'aide de descripteurs. Parmi les méthodes utilisées pour l'extraction des descripteurs de texture, on peut citer : les méthodes statistiques, les méthodes basées sur un modèle de texture, les méthodes basées sur le filtrage et les méthodes géométriques. Dans les travaux de ce chapitre, la méthode statistique pour l'extraction des descripteurs suivants [26] : moyenne, variance et étendue, est utilisée. Ces descripteurs sont calculés pour chaque canal sur une fenêtre glissante de dimension 3x3 pixels.

L'affectation d'un pixel à une classe donnée est menée en utilisant l'un des deux classifieurs géométriques supervisés suivants. Le premier classifieur est celui basé sur la règle de la distance euclidienne minimum [34]. Le deuxième est basé sur les Machines à Vecteurs de Support (MVS) (*Support Vector Machines (SVM)*) [33, 34].

### **3.3 Résultats expérimentaux**

#### **3.3.1 Données utilisées**

La région d'Oran (Algérie), située à 400 km à l'ouest d'Alger, a été prise comme site d'étude pour la variété des thèmes en présence (zones urbaines, forêt, céréaliculture, eau, etc.) et son relief relativement accidenté (Fig. 3.2). Des confusions apparaissent sur les images multispectrales de cette zone. Ces confusions sont causées par l'effet d'ombre et par certains thèmes différents présentant des réponses spectrales similaires [32]. Cette situation présente un grand intérêt pour le test de l'apport des méthodes d'ACI ou FMN lors des essais de classification réalisés.



Fig. 3.2. Vue en 3D de la zone d'étude.

Dans les travaux de ce chapitre, nous utilisons une image de télédétection spatiale multispectrale de la zone d'étude provenant du capteur HRV embarqué sur le satellite d'observation de la Terre Spot. Cette image multispectrale, prise en février 2001, est caractérisée par une résolution spatiale de 20 mètres, et comporte trois canaux spectraux, à savoir : le proche-infrarouge, le rouge, et le vert (Fig. 3.3).

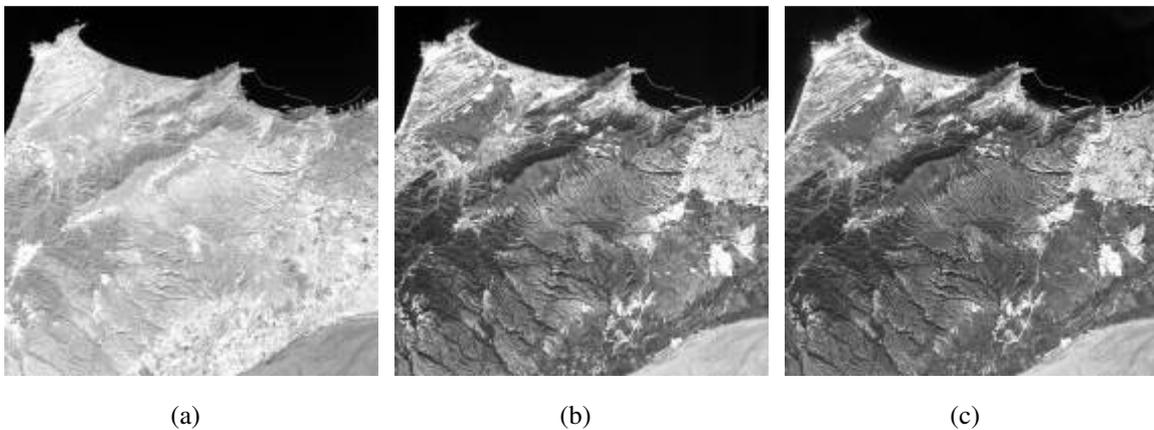


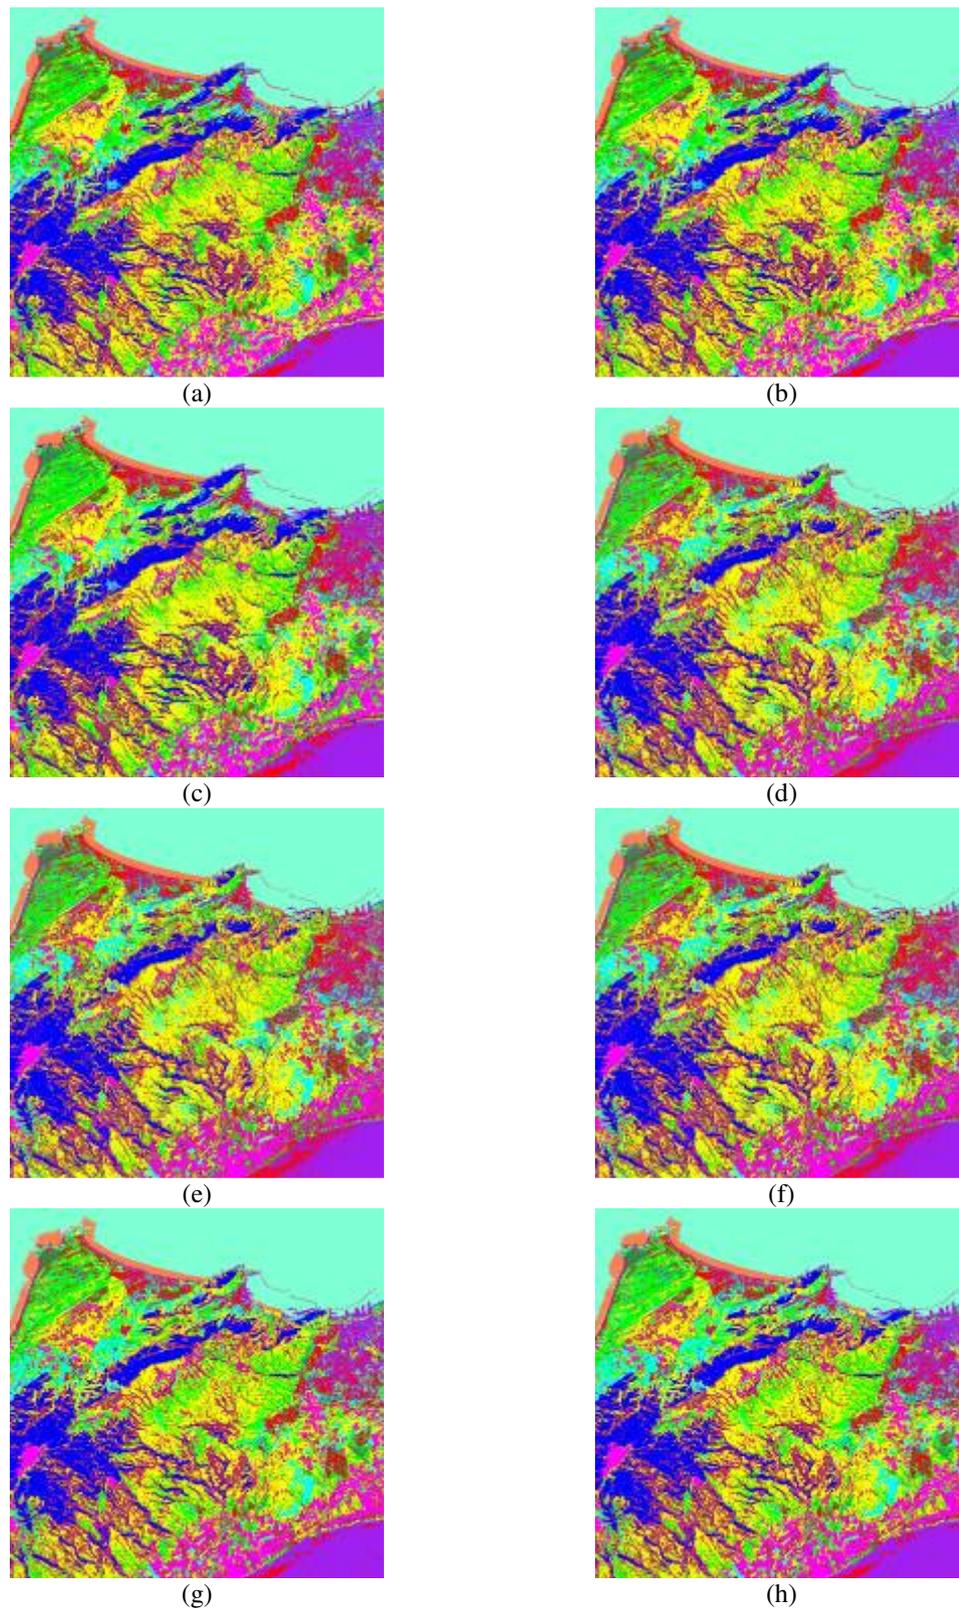
Fig. 3.3. Image multispectrale utilisée. (a) Canal proche-infrarouge. (b) Canal rouge. (c) Canal vert.

### 3.3.2 Résultats et discussion

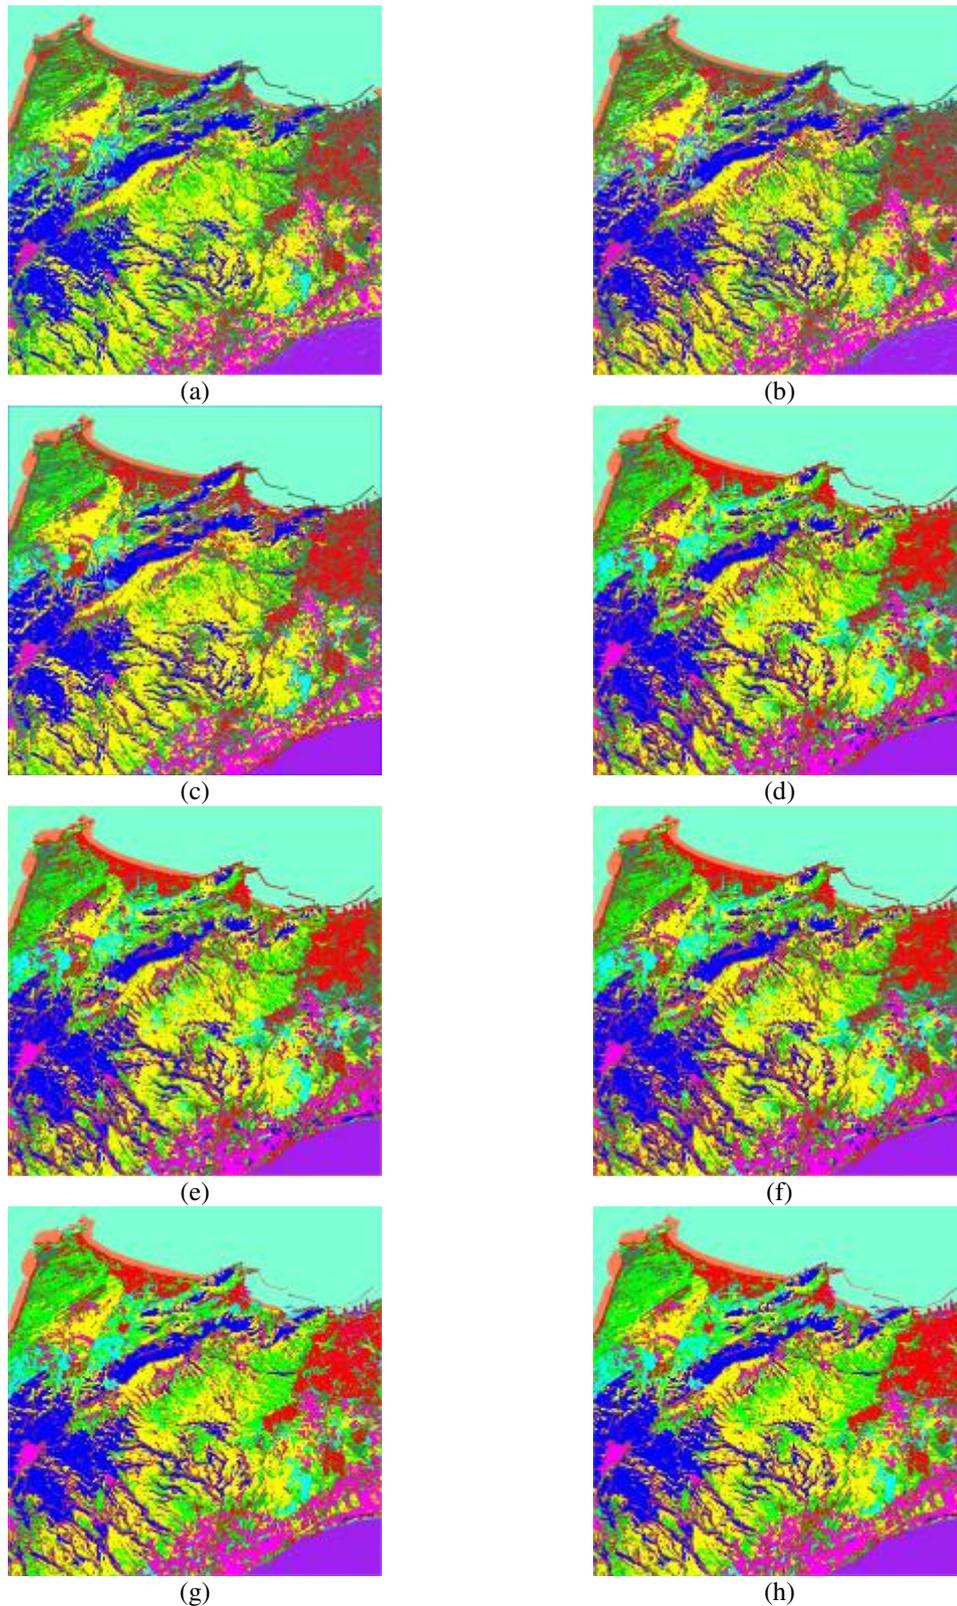
Les deux étapes de l'approche méthodologique adoptée sont appliquées sur l'image multispectrale utilisée. Une ACP ou une Analyse Linéaire Discriminante (ALD) (*Linear Discriminant Analysis (LDA)*) [33] sont aussi utilisées dans la première étape comme alternative aux méthodes d'ACI ou FMN considérées pour permettre une

comparaison. Notons ici, que la LDA est une transformation supervisée des canaux initiaux permettant l'obtention de néo-canaux selon le critère de Fisher [33]. Les différentes classifications supervisées, de la deuxième étape, sont réalisées en utilisant un jeu d'échantillons (vérité terrain) représentant les thèmes suivants : 1.urban, 2.sol nu, 3.forêt, 4.maquis, 5.jachère, 6.céréaliculture, 7.maraîchage, 8.sable, 9.saline, 10.ressac, 11.mer. La base d'échantillons est constituée de mille pixels significatifs par classe. Parmi ces échantillons, quatre cent pixels par classe sont choisis, afin de servir dans la phase d'apprentissage. Ces mêmes échantillons sont aussi utilisés dans la LDA. Les classifications par minimum de distance et par SVM sont réalisées en utilisant le logiciel commercial de traitement d'images ENVI [21].

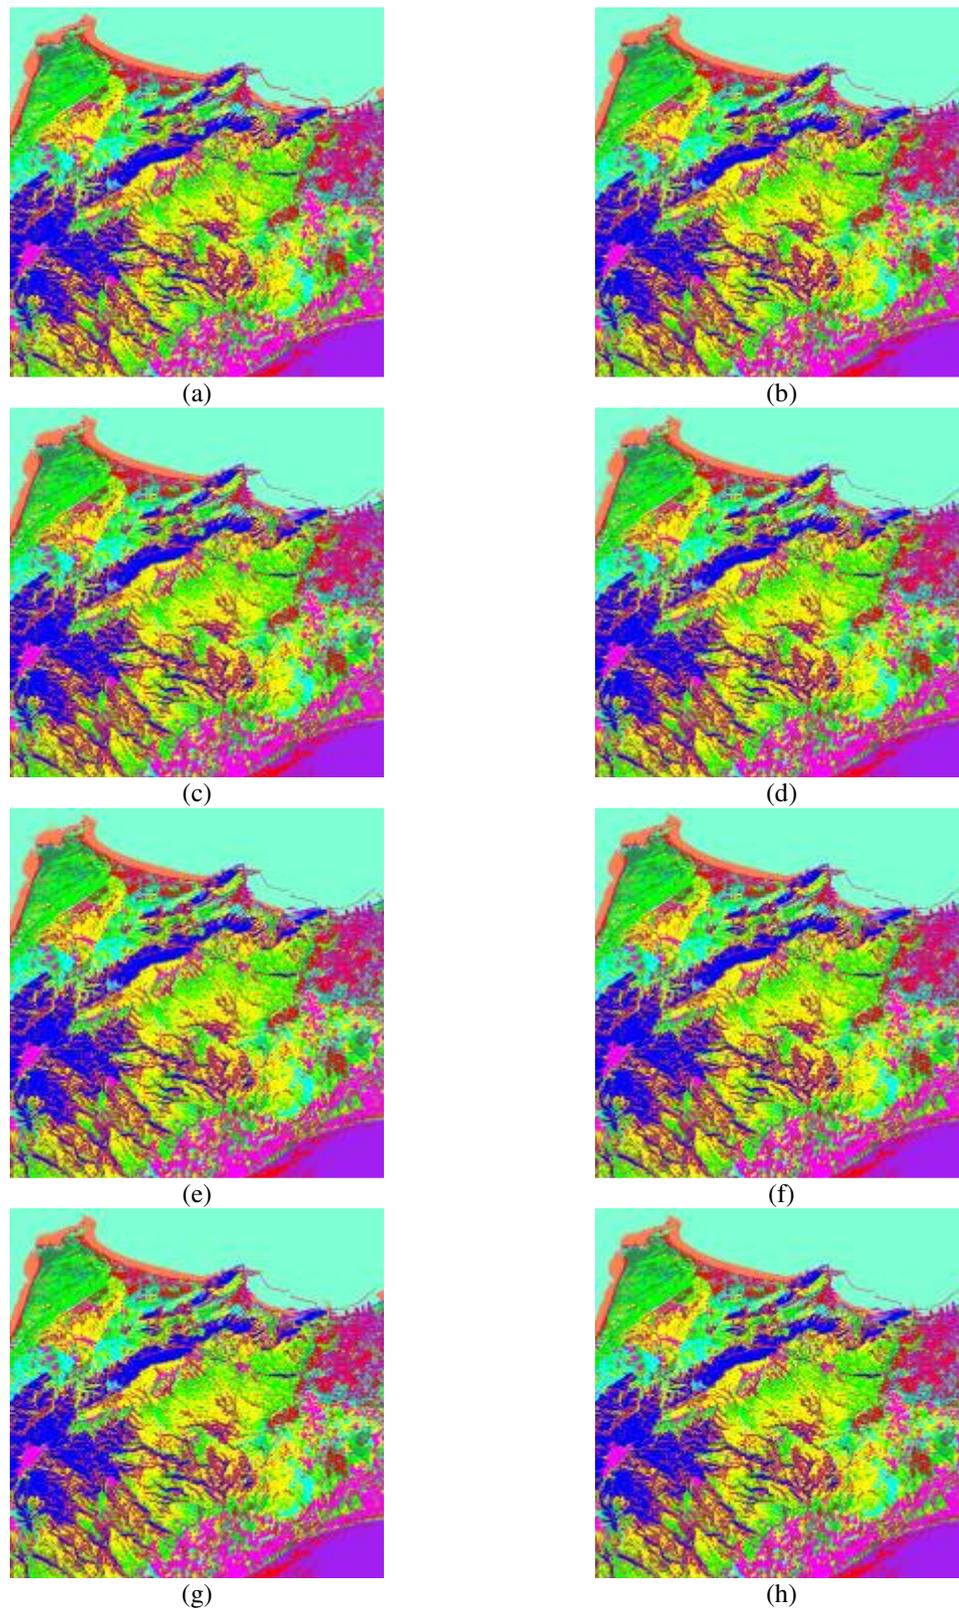
Les images classifiées à partir de l'information issue des canaux bruts ou des canaux issus des différentes transformations, ou rien qu'à partir de l'information texturale (moyenne, variance et étendue de chaque canal brut ou transformé), sont données dans les figures suivantes.



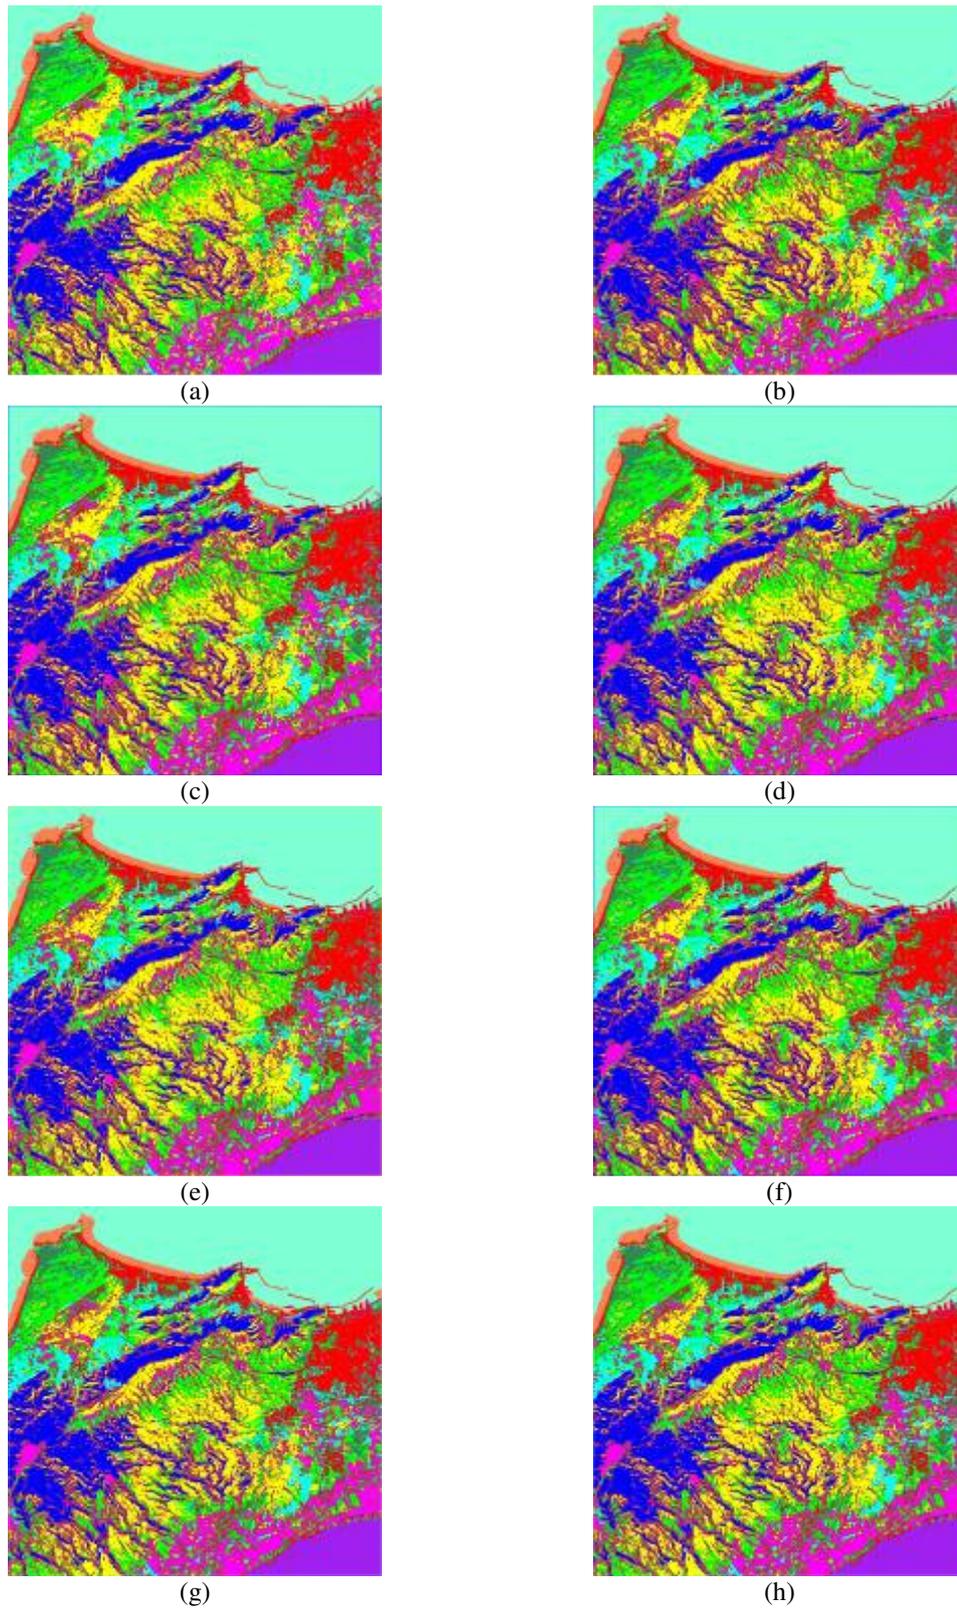
**Fig. 3.4.** Classifications multispectrales par minimum de distance (a) des canaux bruts ou des canaux issus de (b) ACP, (c) LDA, (d) FastICA, (e) JADE, (f) SOBI, (g) FMN, (h) FMN-CP.



**Fig. 3.5.** Classifications texturales par minimum de distance (a) des canaux bruts ou des canaux issus de (b) ACP, (c) LDA, (d) FastICA, (e) JADE, (f) SOBI, (g) FMN, (h) FMN-CP.



**Fig. 3.6.** Classifications multispectrales par SVM (a) des canaux bruts ou des canaux issus de (b) ACP, (c) LDA, (d) FastICA, (e) JADE, (f) SOBI, (g) FMN, (h) FMN-CP.



**Fig. 3.7.** Classifications texturales par SVM (a) des canaux bruts ou des canaux issus de (b) ACP, (c) LDA, (d) FastICA, (e) JADE, (f) SOBI, (g) FMN, (h) FMN-CP.

La légende des différentes classifications réalisées est donnée dans la figure suivante (Fig. 3.8).

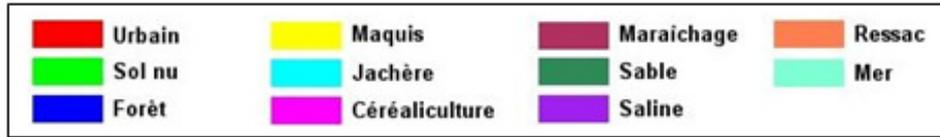


Fig. 3.8. Légende des différentes classifications réalisées.

La précision totale des différentes classifications par minimum de distance, et par SVM, est donnée respectivement dans Tab. 3.1, et Tab. 3.2.

Tab. 3.1. Précision totale (%) des classifications par minimum de distance.

	Canaux bruts	Canaux ACP	Canaux LDA	Canaux FastICA	Canaux JADE	Canaux SOBI	Canaux FMN	Canaux FMN-CP
Classification multispectrale	72,29 %	72,29 %	77,23 %	77,50 %	77,50 %	77,50 %	80,35 %	81,42 %
Classification texturale	71,93 %	69,64 %	81,20 %	89,76 %	89,89 %	90,07 %	94,27 %	95,09 %

Tab. 3.2. Précision totale (%) des classifications par SVM.

	Canaux bruts	Canaux ACP	Canaux LDA	Canaux FastICA	Canaux JADE	Canaux SOBI	Canaux FMN	Canaux FMN-CP
Classification multispectrale	80,64 %	81,44 %	81,76 %	82,29 %	82,43 %	82,83 %	83,15 %	83,68 %
Classification texturale	90,61 %	94,59 %	94,55 %	95,64 %	95,80 %	95,98 %	96,20 %	96,40 %

Les figures précédentes relatives aux différentes classifications obtenues, nous montrent que les classifications multispectrales des canaux bruts, et des canaux issus de l'ACP et de la LDA, sont sujettes à des confusions entre les classes jachère, sol nu et maquis, entre urbain et saline et entre maraîchage, céréaliculture, maquis et forêt. Ces confusions sont causées principalement par l'effet d'ombre ainsi que la similarité des réponses spectrales de ces classes sur les canaux initiaux.

Les mêmes figures montrent que les confusions précédentes sont significativement réduites dans les classifications multispectrales et texturales des canaux issus des méthodes d'ACI ou FMN. Cette réduction est confirmée par la précision totale donnée dans les tableaux précédents. L'amélioration des précisions totales est due à la fois aux opérations de prétraitement, par les méthodes d'ACI ou FMN, effectuées sur les canaux bruts, et à l'utilisation de l'information texturale dans le processus de classification.

Les tableaux précédents montrent aussi que la classification des canaux issus de la méthode combinant la FMN et le codage parcimonieux (FMN-CP) donne les meilleurs résultats, avec une amélioration de la précision totale qui avoisine les 10 % pour la classification multispectrale par minimum de distance, et plus de 20 % pour la classification texturale avec le même classifieur. Cette tendance est aussi retrouvée dans les classifications par SVM, mais le gain est minime, et cela peut s'expliquer par le fait que le classifieur SVM est plus sophistiqué que celui par minimum de distance.

### **3.4 Conclusion**

Dans ce troisième chapitre, les méthodes classiques d'ACI ou FMN (méthodes linéaires de séparation de sources) ont été utilisées comme des prétraitements d'une image multispectrale de télédétection spatiale. Les sorties obtenues par ces prétraitements ont été par la suite injectées dans des classifieurs supervisés intégrant l'information texturale.

Les résultats obtenus nous conduisent à la conclusion suivante : la combinaison des techniques classiques d'ACI ou FMN, utilisées comme des prétraitements sur les données brutes, avec un classifieur et des descripteurs de texture simples, est d'un apport significatif pour la reconnaissance et la classification automatique des images satellitaires, et conduit à des résultats similaires à ceux obtenus par l'utilisation d'une méthode de classification plus sophistiquée (SVM) et plus gourmande en temps de calcul, et en ressources informatiques.

### Références bibliographiques citées dans le Chapitre 3

- [1] A. Belouchrani, K. Abed-Meraim, "Séparation aveugle au second ordre de sources corrélées," *In GRETSI*, pp. 309-312, Juan-Les-Pins, France, 1993.
- [2] A. Belouchrani, K. Abed-Meraim, J. F. Cardoso, E. Moulines, "A Blind Source Separation Technique Using Second-Order Statistics," *IEEE Transactions on Signal Processing*, 45(2), pp. 434-444, 1997.
- [3] M. W. Berry, M. Browne, A. N. Langville, V. P. Pauca, and R. J. Plemmons, "Algorithms and applications for approximate nonnegative matrix factorization," *Computational Statistics & Data Analysis*, 52(1), pp. 155-173, 2007.
- [4] A. Bijaoui, D. Nuzillard, T. Deb Barma, "BSS, Classification and Pixel Demixing," *In Proceedings of the Fifth International Conference on Independent Component Analysis and Blind Signal Separation, ICA 2004, LNCS 3195*, pp. 97-104, Granada, Spain, 2004.
- [5] J. F. Cardoso, "Source separation using higher order moments," *In Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 1989*, pp. 2109-2112, Glasgow, UK, 1989.
- [6] J. F. Cardoso, A. Souloumiac, "Blind beamforming for non gaussian signals," *IEE-proceedings-F*, 140(6), pp. 362-370, 1993.
- [7] S. Choi, A. Cichocki, H. M. Park, and S. Y. Lee, "Blind source separation and independent component analysis: a review," *Neural Information Processing – Letters and Reviews*, 6(1), 2005.
- [8] A. Cichocki, S. I. Amari, *Adaptive Blind and Image Processing: Learning Algorithms and Applications*, Wiley, New York, 2003.
- [9] A. Cichocki, R. Zdunek, and S. I. Amari, "New Algorithms for Non-Negative Matrix Factorization in Applications to Blind Source Separation," *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 2006*, pp. V, Toulouse, France, 2006.
- [10] A. Cichocki, R. Zdunek, A. H. Phan, and S. I. Amari, *Nonnegative Matrix and Tensor Factorization: Applications to Exploratory Multi-way Data Analysis and Blind Source Separation*, John Wiley & Sons, 2009.

- [11] J. P. Cocquerez, S. Philipp, *Analyse d'images : filtrage et segmentation*, Edition Masson, 1995.
- [12] P. Comon, "Independent Component Analysis, a new concept?" *Signal Processing*, 36(3), pp. 287-314, 1994. Special issue on Higher-Order Statistics.
- [13] P. Comon, C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*, Academic Press, 2010.
- [14] Y. Deville, *Traitement du signal : signaux temporels et spatiotemporels – Analyse des signaux, théorie de l'information, traitement d'antenne, séparation aveugle de sources*, Ellipses Editions Marketing, Paris, 2011.
- [15] D. Donoho, V. Stodden, "When Does Non-Negative Matrix Factorization Give a Correct Decomposition into Parts?" *In Proceedings NIPS*, 16, pp. 1141-1149, 2003.
- [16] J. Eggert, E. Körner, "Sparse coding and NMF," *In Proceedings of the IEEE International Joint Conference on Neural Networks*, 4, pp. 2529-2533, 2004.
- [17] R. Gribonval, S. Lesage, "A survey of sparse component analysis for source separation : principles, perspectives, and new challenges," *In Proceedings of the 14<sup>th</sup> European Symposium on Artificial Neural Networks, ESANN 2006*, pp. 323-330, Bruges, Belgium, 2006.
- [18] P. O. Hoyer, "Non-negative Matrix Factorization with Sparseness Constraints," *Journal of Machine Learning Research*, 5, pp. 1457-1469, 2004.
- [19] A. Hyvärinen, E. Oja, "A Fast Fixed-Point Algorithm for Independent Component Analysis," *Neural Computation*, 9(7), pp. 1483-1492, 1997.
- [20] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, Wiley Interscience, 2001.
- [21] ITT Corporation: ENVI – Solutions for Data Vis. And Image Analysis.  
<http://www.itvis.com/envi/>.
- [22] A. K. Jain, R. P. W. Duin, and J. Mao, "Statistical Pattern Recognition: A Review," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1), pp. 4-37, 2000.
- [23] I. T. Jolliffe, *Principal Component Analysis*, Springer Series, 2002.

- [24] M. S. Karoui, "Application des méthodes de séparation aveugle à la télédétection spatiale" *Mémoire de Master 2 Recherche de l'Université Paul Sabatier, Toulouse III*, 2007.
- [25] M. S. Karoui, "Séparation aveugle de sources en imagerie. Application à la télédétection spatiale" *Mémoire de Magister de l'Université des Sciences et de la Technologie d'Oran - Mohamed Boudiaf*, 2008.
- [26] M. Kawamura, K. Tsujino, Y. Tsujiko, "Characteristic Analysis of High Resolution Satellite Imagery for Forest Species Discrimination," *In Proceedings of the IEEE International Geoscience and Remote Sensing Symposium, IGARSS 2004*, pp. 2358-2361, 2004.
- [27] D. D. Lee, H. S. Seung, "Learning the parts of objects by non-negative matrix factorization," *Nature*, 401, pp. 788-791, 1999.
- [28] D. D. Lee, H. S. Seung, "Algorithms for Non-Negative Matrix Factorization," *Advances in Neural Information Processing Systems*, 13, pp. 556-562, MIT Press 2001.
- [29] H. El Maia, A. Hammouch, D. Aboutajdine, "Apport de la séparation de sources en cartographie forestière," *In 5<sup>ème</sup> journées d'optique, OPTIQUE 2006*, Rabat, Morocco, 2006.
- [30] E. Moreau, "A generalization of joint-diagonalization criteria for source separation," *IEEE Transactions on Signal Processing*, 49(3), pp. 530-541, 2001.
- [31] P. D. O'Grady, B. A. Pearlmutter, and S. Rickard, "Survey of sparse and non-sparse methods in source separation," *International Journal of Imaging Systems and Technology (IJIST)*, 15, pp. 18-33, 2005.
- [32] A. Safia, M. F. Belbachir, T. Iftene, "La transformation en ondelettes pour l'extraction de la texture-couleur. Application à la classification combinée des images (HRV) de Spot," *International Journal of Remote Sensing*, 27(18), pp. 3977-3990, 2006.
- [33] J. Y. Tourneret, "Classification et reconnaissance des formes" *Cours du M2R SIAO de Toulouse*, 2006.
- [34] B. Tso, P. M. Mather, *Classification methods for remotely sensed data*, CRC Press, 2009.

- [35] R. Zdunek, A. Cichocki, "Fast nonnegative matrix factorization algorithms using projected gradient approaches for large-scale problems," *Computational Intelligence and Neuroscience*, ID 939567, 2008.

## CHAPITRE 4

### EXTRACTION DE CARTES D'ABONDANCES A PARTIR D'UNE IMAGE MULTISPECTRALE AVEC PIXELS PURS

---

*Résumé* - Dans ce quatrième chapitre, nous proposons deux nouvelles méthodes spatiales non-supervisées, appelées **2D-Corr-NLS** et **2D-Corr-NMF**, pour l'extraction de cartes d'abondances à partir d'une image multispectrale de télédétection spatiale, avec la présence de pixels purs dans cette dernière. Ces méthodes sont liées au problème de la séparation aveugle de sources, et sont basées sur une combinaison de l'analyse en composantes parcimonieuses, le clustering et les contraintes de non-négativité. Ainsi, après une introduction, nous exposons l'approche méthodologique adoptée pour atteindre notre objectif. Les méthodes d'extraction mises en place, ainsi que les hypothèses et définitions relatives à ces dernières sont détaillées. Par la suite, des résultats expérimentaux sur des données synthétiques et réelles sont présentés. Nous terminons le présent chapitre par une conclusion.

---

## DANS CE CHAPITRE

4.1. Introduction	99
4.2. Approches méthodologiques proposées	102
4.2.1. Hypothèses et définitions	102
4.2.2. Méthodes d'extraction	104
4.3. Résultats expérimentaux	112
4.3.1. Données utilisées	112
4.3.2. Résultats et discussion	117
4.4. Conclusion	128
Références bibliographiques citées dans le Chapitre 4	129

## 4.1 Introduction

Comme développé dans le chapitre précédent, l'interprétation des images de télédétection spatiale conduit, généralement, à la réalisation d'une carte d'occupation des sols par le biais d'une classification. Les techniques traditionnelles de classification assignent une et une seule classe d'occupation des sols à chaque pixel d'une image multispectrale de télédétection spatiale. Or, le spectre associé à chaque pixel de cette image peut être un mélange des contributions de différents spectres de matériaux purs, qu'on appelle "endmembers", présents dans la scène imagée [21]. Autrement dit, chaque bande spectrale de l'image peut être considérée comme un mélange d'images qui correspondent respectivement à chaque endmember. Dans une telle situation, les techniques de classification traditionnelles ne sont pas acceptables pour de nombreuses applications majeures, telles que la surveillance environnementale, l'agriculture de précision, la géologie minière, etc. Les méthodes de Séparation Aveugle de Sources (SAS) (*Blind Source Separation (BSS)*) sont attractives dans ce cadre, car elles permettent d'estimer des signaux sources inconnus, à partir seulement de la connaissance de signaux observés, qui sont des mélanges des signaux source [7]. En appliquant ces méthodes de SAS à une image multispectrale de télédétection spatiale, on peut espérer extraire chaque image, appelée "carte d'abondances", correspondant à chaque endmember, ce qui permet donc, une meilleure analyse quantitative des différents thèmes constituant la scène imagée.

Des efforts importants sont déployés par la communauté scientifique dans ce cadre, mais la plupart des méthodes développées concernent les images hyperspectrales (voir par exemple, les méthodes citées dans [3, 33]) et non pas les images multispectrales. En effet, la richesse spectrale des images hyperspectrales permet un tel développement. Lorsqu'il s'agit d'images multispectrales, la conception et la mise en place de méthodes de séparation de sources, permettant l'extraction des cartes d'abondances, représentent un défi scientifique intéressant. Notons ici, qu'il existe très peu de méthodes automatiques [12, 23, 38] aboutissant au même objectif. Par conséquent, nous proposons dans le cadre des travaux du présent chapitre, deux

nouvelles méthodes non-supervisées, liées au problème de la SAS, applicables aux images multispectrales de télédétection spatiale.

En imagerie multispectrale de télédétection spatiale, le mélange est, généralement, supposé linéaire instantané [3, 12, 13, 17, 21, 29, 31, 33-36, 38]. Ainsi, on admet que chaque bande spectrale de l'image multispectrale est un mélange linéaire des cartes d'abondances associées aux endmembers. Selon cette modélisation (Section 1.4.2 du Chapitre 1), et selon la nomenclature de la SAS, les signaux sources (sources spatiales), qu'on veut extraire, sont les cartes d'abondances des matériaux purs (voir Eq. (1.9) du Chapitre 1).

Une grande partie des méthodes de SAS, développées à partir des premiers travaux de J. Héroult et al. [15, 16, 20], sont des méthodes qui concernent les mélanges linéaires instantanés, et sont basées sur l'Analyse en Composantes Indépendantes (ACI) (*Independent Component Analysis (ICA)*) (les méthodes les plus populaires peuvent être retrouvées dans [7]). Récemment, d'autres méthodes, pour résoudre le problème de la SAS, ont été développées. Parmi celles-ci, on trouve les méthodes d'Analyse en Composantes Parcimonieuses (ACPa) (*Sparse Component Analysis (SCA)*) [1, 7, 8, 19], qui exploitent la parcimonie des signaux sources dans différents domaines de représentation des signaux. Lorsque les signaux sources et les coefficients des mélanges obéissent à des contraintes de non-négativité (Eq. (1.10) du Chapitre 1), et vérifiées par les images de télédétection spatiale, les méthodes de SAS fondées sur la Factorisation en Matrices Non-négatives (FMN) (*Non-negative Matrix Factorization (NMF)*) [5, 6, 26, 27] peuvent être utilisées.

Les cartes d'abondances, qu'on cherche à extraire, ne sont pas statistiquement indépendantes, à cause de la contrainte d'additivité des abondances (Eq. (1.10) du Chapitre 1) [30]. Ainsi, l'ACI n'est pas adéquate dans le cadre des travaux de ce chapitre. Ces mêmes cartes d'abondances sont parcimonieuses, puisqu'un matériau pur ne peut être, généralement, présent sur toute la scène imagée. De ce fait, l'ACPa peut être envisagée pour identifier les coefficients de mélange (qui forment la matrice de mélange : première matrice du second terme de l'Eq. (1.9) du Chapitre 1, et dont les

colonnes représentent les spectres des endmembers). Par contre, l'extraction des cartes d'abondances ne peut se faire par simple inversion du modèle de séparation, puisque cette inversion ne respecte pas nécessairement la contrainte de non-négativité. Cette contrainte de non-négativité est utilisée dans les méthodes de FMN, et aussi dans les Moindres Carrés Non-négatifs (MCN) (*Non-negative Least Squares (NLS)*). Mais la FMN ne peut être utilisée seule, à cause de son problème de non unicité de la solution [9], et de la dépendance de son point de convergence par rapport à l'initialisation. De même, les MCN ne peuvent être utilisés seuls pour réaliser une séparation "aveugle", en estimant à la fois les coefficients des mélanges et les cartes d'abondances comme dans la FMN. Les MCN peuvent être considérées comme des méthodes "non-aveugles", du fait qu'elles peuvent déterminer des coefficients non-négatifs impliqués dans la décomposition d'un vecteur observé sur un ensemble de vecteurs "connus". Dans cette situation, les MCN possèdent l'avantage de fournir une solution unique.

Pour contourner les limitations soulignées dans le paragraphe précédent, nous proposons dans ce chapitre deux méthodes hybrides non-supervisées, baptisées **2D-Corr-NLS** et **2D-Corr-NMF**, pour l'extraction de cartes d'abondances à partir d'une image multispectrale de télédétection spatiale. Ces méthodes combinent la première étape (détection de zones mono-sources, définies ci-après) d'une méthode spatiale d'ACPa basée sur la corrélation des observations avec des hypothèses de faible parcimonie sur les cartes d'abondances (signaux sources), et le clustering pour l'estimation de la matrice non-négative de mélange. Cette dernière matrice est utilisée par la suite comme entrée pour la méthode de FMN ou les MCN, afin de démêler chaque pixel de l'image, et par conséquent d'extraire les cartes d'abondances. Un avantage important de nos approches, est leur applicabilité à un modèle de séparation globalement sous-déterminé, mais localement (sur)déterminé, comme détaillé plus loin dans le présent chapitre. Cela n'est pas le cas pour la méthode décrite dans [23].

## 4.2 Approches méthodologiques proposées

### 4.2.1 Hypothèses et définitions

La première étape des méthodes proposées dans le présent chapitre est basée sur l'ACPa. Certaines méthodes d'ACPa exigent des signaux sources qu'ils soient disjoints (sans chevauchement) dans le domaine de représentation des signaux considéré [7, 19], ce qui est assez restrictif. Au contraire, seules quelques zones, appelées "zones mono-sources" contenant seulement des pixels purs, ne doivent pas contenir des signaux sources (abondances des matériaux purs) qui soient actifs en même temps dans le domaine spatial lors de l'utilisation de la première étape des méthodes que nous proposons ci-dessous. Cette étape est basée sur les méthodes de l'ACPa décrites dans [8, 28].

Les méthodes introduites ci-après sont basées sur certaines hypothèses et définitions. Ces dernières concernent les abondances des matériaux purs dans le domaine spatial. Ce domaine est divisé en petites zones, notées  $\Omega$ , et qu'on appelle "zones d'analyse". Ces zones de dimension deux sont constituées de pixels adjacents : pour des raisons de lisibilité, les valeurs des pixels dans la bande spectrale  $p$  sont notées  $x_p(i)$  dans ce qui suit, c'est-à-dire, en utilisant un seul indice (au lieu de deux) pour le pixel  $i$ , mais nous prenons en compte la structure en deux dimensions des images dans nos méthodes. Le domaine spatial est exploré par l'utilisation de zones d'analyse adjacentes ou qui se chevauchent. Dans chaque zone  $\Omega$ , nous calculons les coefficients d'intercorrélation  $\rho_{x_p x_q}(\Omega)$  entre les signaux observés non-centrés  $x_p(i)$  et  $x_q(i)$ . Toutes les valeurs  $x_p(i)$  du signal  $x_p$  (respectivement  $x_q$ ) sur la zone  $\Omega$  sont réarrangées sous forme d'un vecteur à une dimension noté  $x_p(\Omega)$  (respectivement  $x_q(\Omega)$ ). Les coefficients d'intercorrélation sur la zone  $\Omega$ , sont définis par :

$$\rho_{x_p x_q}(\Omega) = \frac{\langle x_p(\Omega), x_q(\Omega) \rangle}{\|x_p(\Omega)\| \|x_q(\Omega)\|}, \quad \forall p, q = 1 \dots N \text{ et } p > q, \quad (4.1)$$

où  $\langle \cdot, \cdot \rangle$  et  $\|\cdot\|$  représentent respectivement le produit scalaire et la norme vectorielle.

**Définition 1** un matériau pur est dit "isolé" dans une zone d'analyse si seul ce matériau pur est présent dans cette zone d'analyse (c'est-à-dire, si seul ce matériau pur donne un vecteur non-nul  $s_j(\Omega)$ , d'éléments  $s_j(i)$ , dans cette zone). Compte tenu de l'Eq. (1.10) du Chapitre 1, l'abondance de ce matériau pur est égale à un dans cette zone.

**Définition 2** un matériau pur est dit "accessible" dans le domaine spatial s'il existe au moins une zone d'analyse dans laquelle il est isolé.

**Hypothèse 1** chaque matériau pur est accessible dans le domaine spatial.

En imagerie multispectrale de télédétection spatiale, l'hypothèse de parcimonie ci-dessus dans le domaine spatial, est équivalente à **la présence d'au moins une zone mono-source contenant seulement des pixels purs pour chaque matériau pur**. Cette hypothèse reste tout à fait réaliste pour des images multispectrales à haute résolution spatiale, contenant des zones étendues pour les différentes classes d'occupation des sols d'intérêt.

**Hypothèse 2** dans chaque zone d'analyse, les vecteurs non-nuls  $s_j(\Omega)$  sont "linéairement indépendants" (s'il existe au moins deux de ces vecteurs dans une zone d'analyse).

Cette dernière hypothèse introduit une contrainte sur les abondances des matériaux purs, mais cette contrainte est beaucoup moins restrictive que celles définies dans de nombreuses méthodes de SAS (comme l'indépendance statistique). Cette hypothèse est, particulièrement, réaliste dans les travaux concernés par ce chapitre, grâce à la contrainte énoncée dans l'Eq. (1.10) du Chapitre 1. En effet, si on considère la situation où seulement deux vecteurs  $s_j(\Omega)$  et  $s_{j'}(\Omega)$  sont non-nuls dans la zone  $\Omega$  contenant  $M$  pixels, alors, d'après l'Eq. (1.10) du Chapitre 1, nous avons  $s_j(\Omega) + s_{j'}(\Omega) = 1_M$ , où  $1_M$  est un vecteur contenant  $M$  composantes qui valent toutes 1. Si  $s_j(\Omega)$  et  $s_{j'}(\Omega)$  sont linéairement dépendants, alors ces deux vecteurs vérifient aussi la condition  $c_1 s_j(\Omega) + c_2 s_{j'}(\Omega) = 0_M$ , avec  $c_1$  et  $c_2$  deux constantes non-nulles en même temps. En résolvant les deux précédentes équations, il peut facilement être démontré

que cette situation correspond au cas où  $s_j$  et  $s_{j'}$  sont constantes sur toute la zone considérée  $\Omega$ . Cette situation est très spécifique, et son exclusion dans l'Hypothèse 2 n'est pas restrictive : l'impossibilité de séparer deux sources qui restent constantes n'est pas une surprise.

En imagerie multispectrale de télédétection spatiale, le modèle de séparation est, généralement, sous-déterminé (nombre de bandes spectrales  $N$  inférieur au nombre de cartes d'abondances  $L$ ). Cette configuration ne constitue pas une restriction, lorsqu'on considère les deux hypothèses suivantes :

**Hypothèse 3** le modèle de séparation est localement (sur)déterminé, c'est-à-dire,  $N \geq L(\Omega)$  dans n'importe quelle zone d'analyse  $\Omega$ , où  $L(\Omega)$  est le nombre de matériaux purs présents dans la zone  $\Omega$ .

**Hypothèse 4** dans chaque zone d'analyse  $\Omega$ , la sous-matrice composée des colonnes de la matrice de mélange, et correspondant aux matériaux purs présents, est de rang plein.

#### 4.2.2 Méthodes d'extraction

Les méthodes proposées opèrent en différentes étapes décrites ci-dessous.

**1- Etape de détection** qui consiste à détecter automatiquement les zones mono-sources. Cette détection est réalisée par l'utilisation de la propriété suivante :

**Propriété 1** une condition nécessaire et suffisante, pour qu'un matériau pur soit isolé dans une zone d'analyse  $\Omega$ , est :

$$|\rho_{x_p, x_q}(\Omega)| = 1, \forall p, q = 1 \dots N \text{ et } p > q, \quad (4.2)$$

**Preuve de la Propriété 1** Pour chaque zone d'analyse  $\Omega$ , l'Eq. (1.9) du Chapitre 1 implique :

$$x_p(\Omega) = \sum_{j=1}^L a_{pj} s_j(\Omega), \quad \forall p = 1 \dots N. \quad (4.3)$$

Aussi, l'application de l'inégalité de Cauchy-Schwarz à (4.1) donne :

$$|\rho_{x_p x_q}(\Omega)| \leq 1, \quad \forall p, q = 1 \dots N \text{ et } p > q, \quad (4.4)$$

avec égalité si et seulement si  $x_p(\Omega)$  et  $x_q(\Omega)$  sont linéairement dépendants.

Si seul un matériau pur, avec l'indice  $j$ , est présent dans une zone d'analyse  $\Omega$ , et en supposant que tous les coefficients de mélange  $a_{pj}$  sont non-nuls, à partir de l'équation (4.3), tous les signaux observés  $x_p(\Omega)$ , avec  $p = 1 \dots N$ , sont colinéaires. Par conséquent, l'égalité est obtenue, quels que soient  $p$  et  $q$ , dans (4.4). Ainsi, la condition de détection donnée dans (4.2) est vérifiée.

Maintenant, supposons qu'au moins deux vecteurs  $s_j(\Omega)$  sont non-nuls. Il peut facilement être démontré que, si  $x_p(\Omega)$  et  $x_q(\Omega)$  étaient linéairement dépendants, quels que soient  $p$  et  $q$ , avec  $p, q = 1 \dots N$  et  $p > q$ , alors, en utilisant l'Hypothèse 2, toutes les colonnes de la matrice de mélange, avec des indices correspondant aux indices des vecteurs non-nuls seraient colinéaires. Cela n'est pas vrai à cause de l'Hypothèse 4. Par conséquent, dans ce cas, au moins une paire  $(x_p(\Omega), x_q(\Omega))$  est composée de vecteurs linéairement indépendants, et par conséquent, la condition de détection exprimée dans (4.2) n'est pas vérifiée. Cela termine la preuve de la Propriété 1.

Notons ici, que nous considérons les versions non-centrées des signaux observés, car, dans nos travaux, avec la contrainte de somme unitaire des abondances, la transposition de la Propriété 1 aux versions centrées des signaux observés (comme utilisé dans [8, 28]), ne permet pas la détection des zones mono-sources. En effet, si deux vecteurs, des signaux sources,  $s_j(\Omega)$  et  $s_{j'}(\Omega)$  sont non-nuls, alors, en utilisant la contrainte de somme unitaire des abondances, nous obtenons :

$$s_j(\Omega) + s_{j'}(\Omega) = 1_M. \quad (4.5)$$

Pour les versions centrées  $S_j(\Omega)$  et  $S_{j'}(\Omega)$  des signaux sources, l'Eq. (4.5) devient :

$$S_j(\Omega) + S_{j'}(\Omega) = 0_M. \quad (4.6)$$

Quels que soient  $p$  et  $q$ , avec  $p, q = 1 \dots N$ , et  $p > q$ , l'Eq. (1.9) du Chapitre 1, pour les versions centrées  $X_p(\Omega)$  et  $X_q(\Omega)$  des signaux observés, conduit à :

$$\begin{cases} X_p(\Omega) = a_{pj}S_j(\Omega) + a_{pj'}S_{j'}(\Omega) \\ X_q(\Omega) = a_{qj}S_j(\Omega) + a_{qj'}S_{j'}(\Omega) \end{cases} \quad (4.7)$$

En utilisant l'Eq. (4.6), l'Eq. (4.7) devient :

$$\begin{cases} X_p(\Omega) = (a_{pj} - a_{pj'})S_j(\Omega) \\ X_q(\Omega) = (a_{qj} - a_{qj'})S_j(\Omega) \end{cases} \quad (4.8)$$

Dans ce cas,  $X_p(\Omega)$  et  $X_q(\Omega)$  sont colinéaires. Par conséquent, la version centrée de la condition de détection (c'est-à-dire, la version centrée de l'Eq. (4.2)) est vérifiée, malgré la présence de deux matériaux purs (avec la possibilité qu'ils soient linéairement indépendants) dans la zone d'analyse considérée.

La Propriété 1 est utilisée comme suit dans nos méthodes. Pour chaque zone d'analyse, nous calculons le paramètre suivant :

$$\min_{p,q} (|\rho_{x_p x_q}(\Omega)|), \quad \forall p, q = 1 \dots N \text{ et } p > q. \quad (4.9)$$

La moyenne ou le maximum peuvent aussi être utilisés, mais le minimum est plus restrictif. Si le paramètre (4.9) est supérieur à un seuil (proche de 1), nous considérons que la zone d'analyse examinée est une zone mono-source.

**2- Etape d'estimation** qui consiste à calculer des estimations des colonnes candidates de la matrice de mélange  $A$  (Eq. (1.3) du Chapitre 1). Chaque zone mono-source, nous conduit à une estimation  $\hat{a}_j$  d'une colonne (correspondant à un spectre d'un endmember) de la matrice de mélange, en utilisant la formule suivante :

$$\hat{a}_j = \begin{pmatrix} \text{median}(x_1(\Omega)) \\ \cdot \\ \cdot \\ \cdot \\ \text{median}(x_N(\Omega)) \end{pmatrix}. \quad (4.10)$$

Notre motivation pour l'utilisation de cette approche est la suivante : dans nos travaux, les abondances, qu'on cherche à extraire, sont non-négatives et contraintes à une somme unité sur chaque pixel. Dans une zone mono-source parfaite, une abondance est égale à un, tandis que les autres valent zéro. Ainsi, dans chaque pixel de la zone mono-source considérée, chaque observation est égale au coefficient de mélange associé à l'abondance qui vaut un. En pratique, pour chaque observation (chaque bande spectrale), la médiane de toutes les valeurs des pixels présents dans la zone mono-source considérée, donne une estimation précise du coefficient de mélange associé à l'abondance qui vaut un. Cette approche est donc spécifique aux contraintes de non-négativité et de somme unitaire, et différente des approches utilisées dans [8, 28]. Notons, que les colonnes estimées sont toujours non-négatives, puisqu'on utilise la médiane sur des données non-négatives.

Chacune des zones mono-sources où le "même" matériau pur est présent permet l'estimation du "même" spectre d'un matériau pur (une colonne candidate de l'estimation  $\hat{A}$  de la matrice de mélange). Par conséquent, le clustering, qui constitue l'étape suivante, est une approche attractive pour l'obtention d'un spectre "unique" pour chaque matériau pur. Dans cette étape d'estimation, nous associons le paramètre de détection (4.9) à chaque colonne estimée. En effet, ce paramètre peut être utilisé comme un degré de confiance dans l'étape de clustering, tel que détaillé ci-après.

**3- Etape de clustering** qui consiste à sélectionner  $L$  colonnes pour la matrice de mélange estimée  $\hat{A}$  parmi toutes les colonnes estimées dans l'étape précédente.

Le clustering est une méthode non-supervisée qui permet le regroupement de données hétérogènes, selon une distance ou une mesure de similarité, en groupes homogènes, qu'on appelle "clusters". Les mesures les plus populaires sont la distance Euclidienne, la distance de Manhattan, la distance de Mahalanobis et la distance de Hamming. L'approche la plus populaire du clustering est celle du partitionnement [11].

Les algorithmes les plus utilisés en clustering par partitionnement sont le  $k$ -means et ses différentes variantes (fuzzy  $c$ -means,  $k$ -medians). Ces algorithmes choisissent  $k$  centres initiaux, où  $k$  est déterminé par un utilisateur et correspond au nombre de clusters désirés (dans les travaux de ce chapitre, ce nombre correspond au nombre de colonnes d' $\hat{A}$ , et aussi le nombre de matériaux purs). Chaque point (vecteur colonne estimé de la matrice de mélange) des données est alors assigné au cluster dont le centre (vecteur colonne) est le plus proche du point considéré. Le centre de chaque cluster est ensuite mis à jour par la moyenne (pour les algorithmes  $k$ -means et fuzzy  $c$ -means), ou la médiane (pour l'algorithme  $k$ -medians), des points appartenant au même cluster. L'assignation et la mise à jour sont répétées jusqu'à ce que les assignations, des différents points des données, ne changent plus, ou d'une manière équivalente, jusqu'à ce que les centres ne changent plus.

Dans nos travaux, nous utilisons l'algorithme du fuzzy  $c$ -means. Cet algorithme choisit le centre de chaque cluster selon le degré de confiance le plus élevé. Ici, nous définissons le degré de confiance de chaque colonne estimée comme la valeur de son paramètre de détection (4.9). Les colonnes sont ainsi obtenues avec une indétermination de permutation, ce qui ne constitue pas une restriction pour nos travaux. Soulignons aussi, que la matrice de mélange estimée, constituée des colonnes obtenues, est aussi non-négative.

L'algorithme fuzzy  $c$ -means requiert différents paramètres. Le paramètre le plus sensible est le nombre de clusters. Différents choix de ce nombre conduisent à des

résultats différents. Ainsi, l'estimation du nombre optimal  $k^*$  de clusters est une étape majeure du clustering. Plusieurs indices de validité du clustering sont proposés dans la littérature, pour l'estimation du nombre optimal de clusters [2, 4, 10, 24, 32, 37]. Leur calcul est basé sur la procédure générale suivante :

- i) Lancement de l'algorithme désiré du clustering pour différentes valeurs de  $k$ .
- ii) Calcul de l'indice de validité pour chaque résultat.
- iii) Choix du nombre optimal de clusters  $k^*$ .

Dans les travaux du présent chapitre, nous utilisons l'indice de validité défini dans [22].

**4- Etape d'extraction** qui consiste à extraire les  $L$  sources spatiales (cartes d'abondances) sous la contrainte de non-négativité. Deux méthodes alternatives sont utilisées dans nos travaux pour atteindre cet objectif. La première méthode est celle des MCN. Les MCN introduites par C. L. Lawson et R. J. Hanson [25] résolvent le problème matriciel suivant :

$$\text{Minimiser } \|\hat{A} \hat{s} - x\|, \text{ sous la contrainte } \hat{s} \geq 0. \quad (4.11)$$

Dans notre approche, les MCN sont appliqués sur chaque pixel de l'image multispectrale séparément. Ainsi, dans (4.11),  $\hat{A}$  représente la matrice de mélange identifiée dans l'étape précédente,  $x$  représente le vecteur associé à un pixel de l'image, et  $\hat{s}$  est le vecteur estimé des valeurs des abondances présentes dans le pixel considéré. Il faut souligner ici, que les MCN n'introduisent pas de contraintes sur les signes des éléments d' $\hat{A}$  et  $x$ , mais nécessitent que le nombre d'éléments non-nuls dans le vecteur estimé  $\hat{s}$  soit au moins égal au nombre d'éléments dans le vecteur  $x$  (et les MCN fournissent ainsi une solution unique). Cette dernière condition est vérifiée grâce à l'Hypothèse 3.

La deuxième méthode utilisée est celle de la FMN proposée par D. D. Lee et H. S. Seung [26, 27]. Contrairement aux MCN, les règles de mise à jour multiplicatives,

définies par D. D. Lee et H. S. Seung, de la FMN sont utilisées pour démêler une image multispectrale toute entière, et non pas pixel par pixel. La matrice  $\hat{A}$  est initialisée ici par la matrice non-négative identifiée dans l'étape précédente (étape de clustering). La matrice initiale de  $\hat{S}$  est déduite de la matrice des observations et de la matrice  $\hat{A}$  identifiée dans l'étape précédente, par l'utilisation des MCN. Nous soulignons ici, que la FMN permet la mise à jour de la matrice estimée dans l'étape de clustering, ce qui est très attractif si cette matrice n'est pas estimée précisément dans cette dernière étape.

Un autre point important lié à la contrainte de somme unitaire des abondances doit être pris en considération dans l'étape d'extraction. Cette contrainte naturelle, formulée dans l'Eq. (1.10) du Chapitre 1, peut être traitée par les méthodes des MCN et la FMN, en utilisant une technique simple et efficace [14] : nous augmentons les matrices des observations et de mélange par une ligne constante strictement positive. Le problème matriciel des MCN et les règles de mise à jour multiplicatives de la FMN prennent ces deux matrices étendues comme entrées. Nous soulignons aussi dans ce paragraphe, que l'indétermination d'échelle de la SAS est ici évitée grâce à cette contrainte de somme unitaire des abondances.

Les différentes étapes définies ci-dessus constituent nos méthodes proposées, baptisées *2D-Corr-NLS* et *2D-Corr-NMF*, pour l'extraction de cartes d'abondances à partir d'une image multispectrale de télédétection spatiale. Un schéma regroupant les différentes étapes des méthodes proposées est donné dans la figure (Fig. 4.1) suivante.

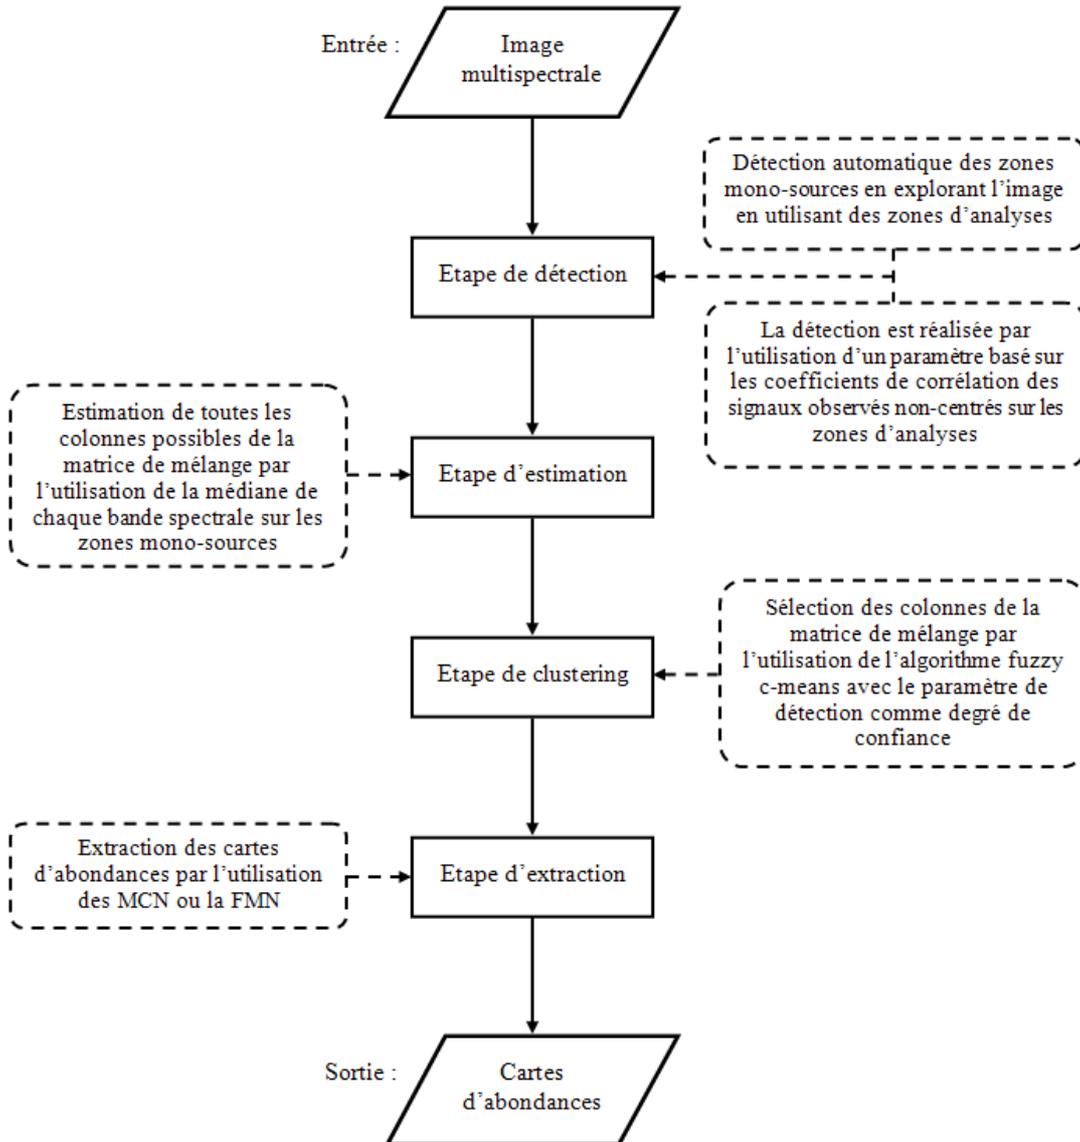


Fig. 4.1. Schéma regroupant les différentes étapes des méthodes proposées.

Lorsqu'il s'agit de l'extraction de cartes d'abondances à partir d'une image multispectrale synthétique, l'évaluation des performances des méthodes proposées est réalisée par l'utilisation du critère basé sur l'Erreur Quadratique Moyenne Normalisée (EQMN) (*Normalized Mean Square Error (NMSE)*), entre les cartes d'abondances originales et les cartes d'abondances estimées pour chaque matériau pur (voir Eq. (2.22) de la Section 2.4 du Chapitre 2).

Lorsqu'il s'agit de l'extraction de cartes d'abondances à partir d'une image multispectrale réelle ou aussi synthétique, le critère défini dans la Section 2.4 du Chapitre 2 (page 63) est utilisé pour l'évaluation des performances des méthodes proposées.

### **4.3 Résultats expérimentaux**

Des expériences, basées sur des données synthétiques mais réalistes, et sur des données réelles, sont effectuées pour l'évaluation des performances des méthodes proposées et d'une méthode de la littérature.

#### **4.3.1 Données utilisées**

Deux ensembles de cartes d'abondances (signaux sources) synthétiques mais réalistes, de dimension 400x400 pixels, sont créés à partir de classifications réelles (en moyennant les valeurs des pixels des classifications sur une fenêtre glissante de taille 5x5 pixels).

Le premier ensemble contient huit cartes d'abondances (Fig. 4.2(a)). Chacune de ces cartes d'abondances contient au moins 1,5 % de pixels purs. Pour chacune de ces cartes, un spectre de quatre échantillons est aléatoirement généré. Ainsi, une matrice de mélange avec huit colonnes et quatre lignes est créée. Ensuite, tenant en compte toutes les hypothèses mentionnées plus haut, quatre observations (quatre bandes spectrales) sont générées (Fig. 4.3(a)) en mélangeant linéairement les cartes d'abondances. Les quatre observations générées contiennent 56 % de pixels purs.

Dans le deuxième ensemble, on trouve dix cartes d'abondances (Fig. 4.2(b)). Chacune d'elles contient au moins 0,25 % de pixels purs. Là aussi, un spectre de quatre échantillons est aléatoirement généré, pour obtenir une matrice de mélange avec dix colonnes et quatre lignes. Cette matrice de mélange est utilisée pour générer quatre bandes spectrales (quatre observations) (Fig. 4.3(b)). Ces observations contiennent 42 % de pixels purs.

Notons ici, que dans les deux ensembles, le nombre d'observations est globalement inférieur au nombre de cartes d'abondances à extraire, et par conséquent, le modèle de séparation, dans les deux cas, est globalement sous-déterminé. Aussi, les mélanges réalisés sont prétraités (mise à zéro des abondances les plus faibles si nécessaire, et normalisation des abondances restantes, pour respecter la contrainte de somme unitaire) de telle sorte que le modèle de séparation soit (sur)déterminé dans chaque zone d'analyse.

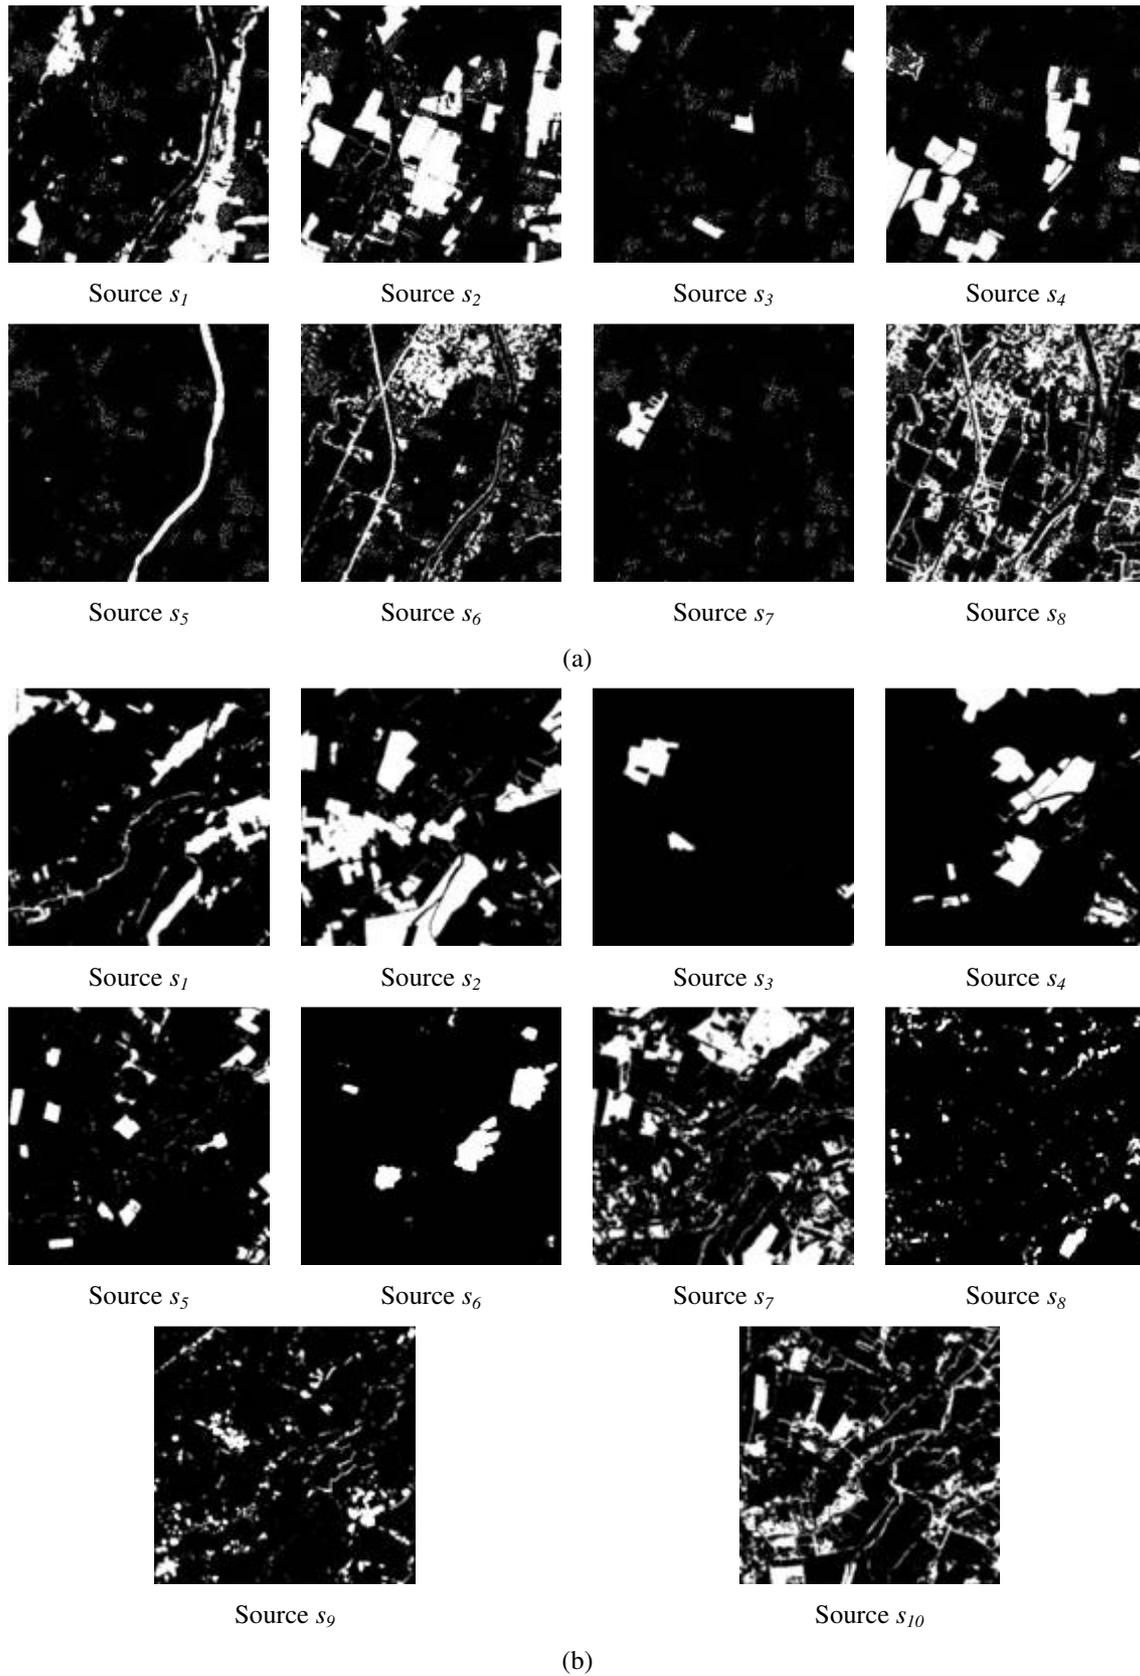
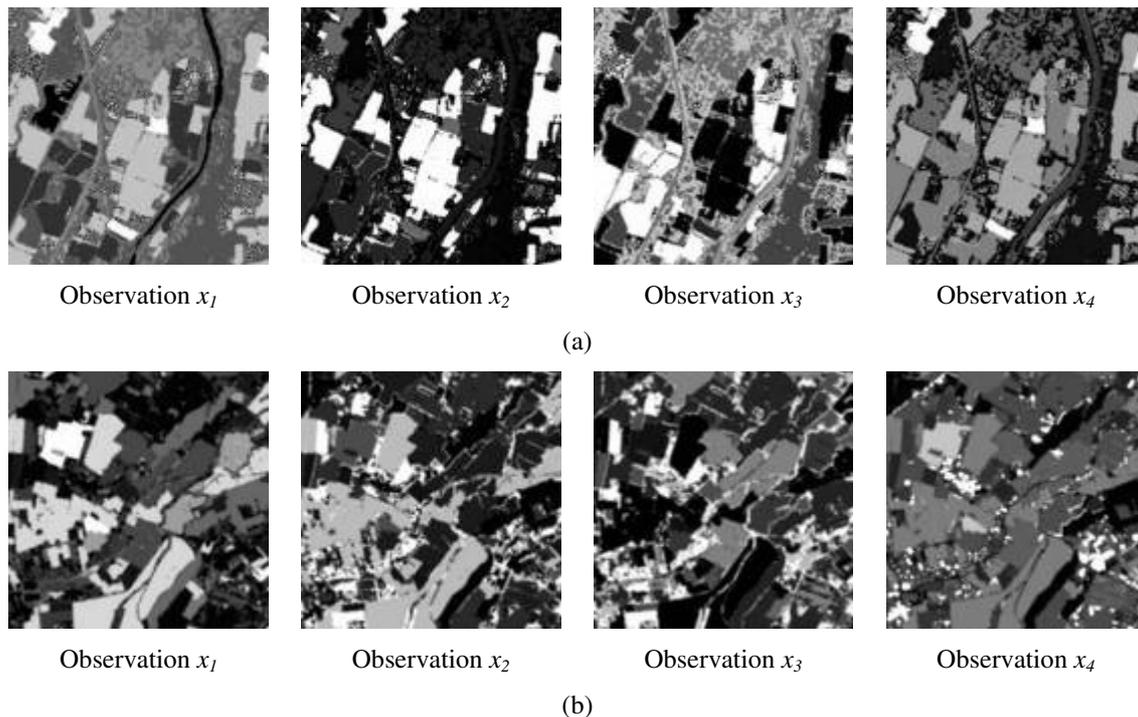


Fig. 4.2. Cartes d'abondances originales. (a) Premier ensemble. (b) Deuxième ensemble.



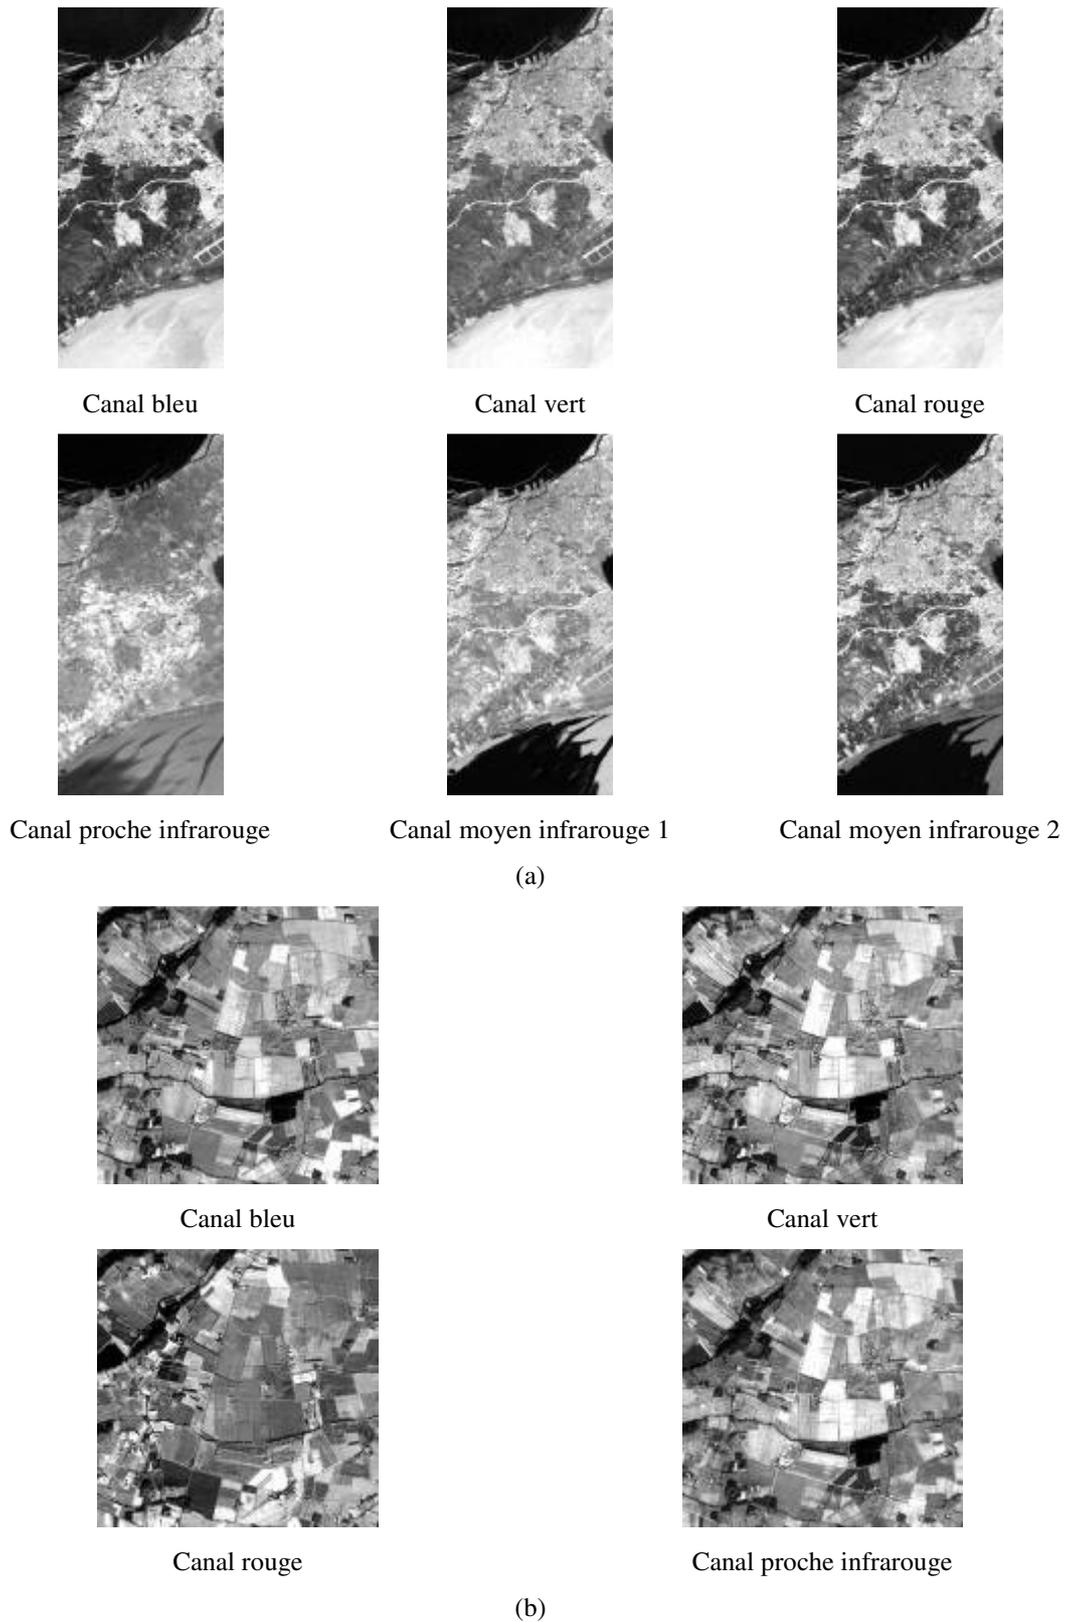
**Fig. 4.3.** Images multispectrales synthétiques. (a) Première image. (b) Deuxième image.

Deux images multispectrales réelles sont aussi utilisées dans le cadre des travaux du présent chapitre.

La première image multispectrale est issue du capteur ETM+ embarqué sur le satellite Landsat. Cette image avec six bandes spectrales (Fig. 4.4(a)), et une résolution spatiale de 30 mètres, couvre une partie de la région d'Oran (Algérie). Cette zone est caractérisée par une diversité des thèmes d'occupation des sols (urbain, forêt, cultures céréalières, etc.).

La seconde image multispectrale provient du capteur embarqué sur le satellite Formosat 2. Cette image avec une résolution spatiale de 8 mètres, et quatre bandes spectrales (Fig. 4.4(b)), couvre une partie de la région de Toulouse (France). Cette zone est aussi caractérisée par une diversité thématique.

Les zones d'étude, régions d'Oran et de Toulouse, avec leur diversité thématique, présentent une situation à grand intérêt pour le test et l'évaluation des performances des méthodes proposées.



**Fig. 4.4.** Images multispectrales réelles. (a) Image Landsat ETM+ (six bandes spectrales) de la région d'Oran (Algérie). (b) Image Formosat 2 (quatre bandes spectrales) de la région de Toulouse (France).

### 4.3.2 Résultats et discussion

Les méthodes proposées sont appliquées aux images synthétiques et réelles. Nous signalons ici, que notre méthode 2D-Corr-NMF donne sensiblement les mêmes résultats que la méthode 2D-Corr-NLS. Par conséquent, nous ne détaillons pas dans la suite les résultats de la méthode 2D-Corr-NMF. En plus, la méthode SMACC [12], avec la contrainte de somme unitaire, est aussi appliquée aux données utilisées pour permettre une comparaison. Cette dernière méthode implémentée dans le logiciel commercial de traitement d'images ENVI (ITT Corporation) [18], est l'une des rares méthodes applicables à un modèle sous-déterminé défini par les images multispectrales de télédétection spatiale, contrairement à la méthode décrite dans [23]. Soulignons ici, que la méthode SMACC requiert que le nombre des endmembers (qui correspond au nombre de clusters) soit connu. Ce nombre est automatiquement détecté par nos méthodes, et est fourni à la méthode SMACC. Cette dernière méthode utilise la géométrie convexe (cônes convexes) pour extraire les cartes d'abondances. Les points extrêmes (les points les plus lumineux) sont utilisés pour identifier le premier cône convexe correspondant à la première carte d'abondances. Une projection oblique sous contraintes est ensuite appliquée au cône existant pour déduire la carte d'abondances suivante. Le cône convexe est augmenté pour inclure le spectre du nouvel endmember. Le processus est répété jusqu'à l'obtention du nombre désiré de cartes d'abondances.

Notons que le nombre optimal de clusters détecté automatiquement par nos méthodes est huit pour la première image synthétique, et dix pour la seconde. Cela, correspond au nombre de cartes générées dans les deux ensembles de données synthétiques. Pour les images réelles, le nombre optimal de clusters (qui correspond au nombre de cartes d'abondances) détecté automatiquement par nos méthodes est dix huit pour l'image Landsat ETM+, et onze pour l'image Formosat 2. Pour chacune des deux images réelles, certaines cartes d'abondances correspondent en réalité à la même classe d'occupation des sols. Ainsi, nous regroupons manuellement ces cartes "similaires" après l'étape d'extraction. Au final, nous obtenons onze cartes d'abondances pour l'image Landsat ETM+, et sept cartes d'abondances pour l'image Formosat 2. Ces cartes d'abondances sont assignées à des classes d'occupation des sols.

Afin de vérifier (particulièrement sur les images réelles) l'existence des zones mono-sources, nous traçons (Figs. 4.5 et 4.6) les histogrammes du paramètre de détection formulé dans (4.9) sur la totalité de chacune des images utilisées, en explorant ces images par l'utilisation de zones adjacentes de taille 5x5 pixels. Ces histogrammes montrent que le paramètre de détection est proche de un dans certaines zones, qui correspondent aux zones mono-sources, tandis qu'il est significativement inférieur à un dans les autres zones, qui correspondent aux zones multi-sources.

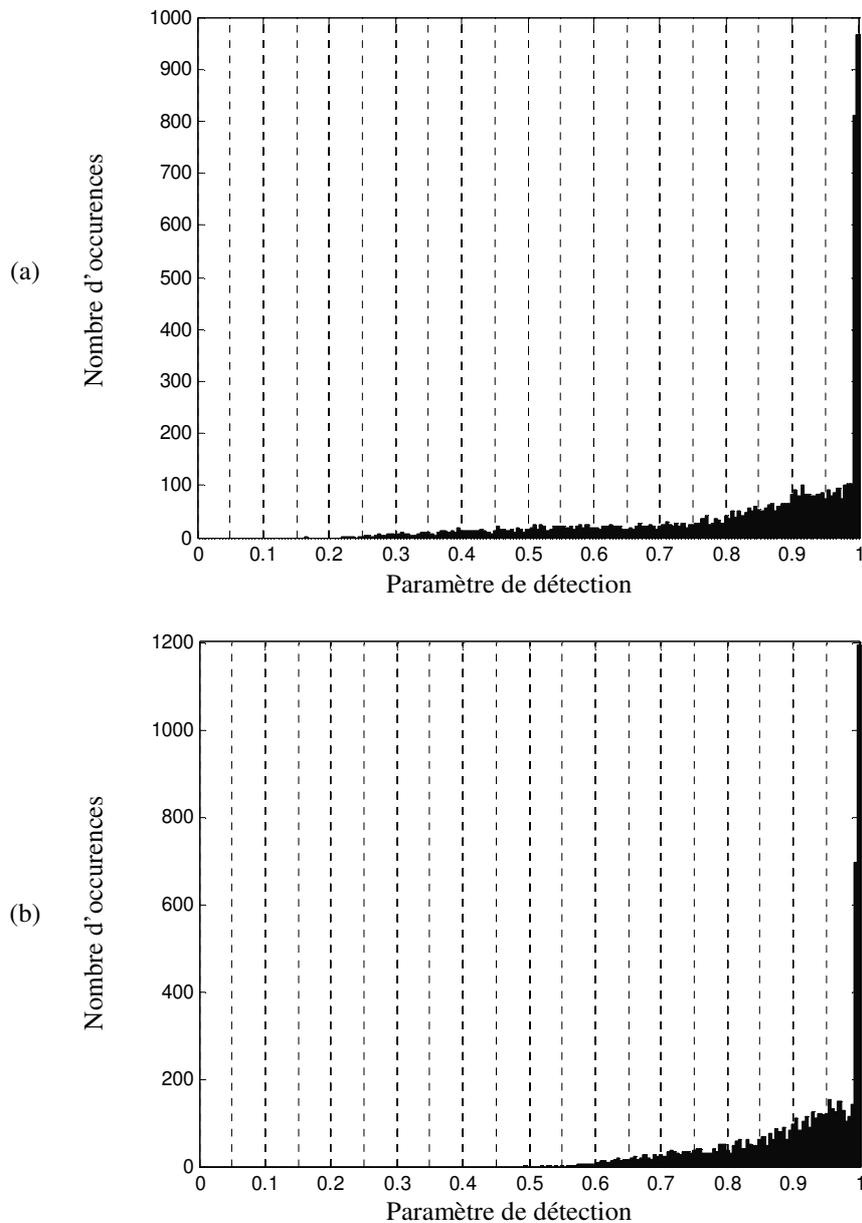
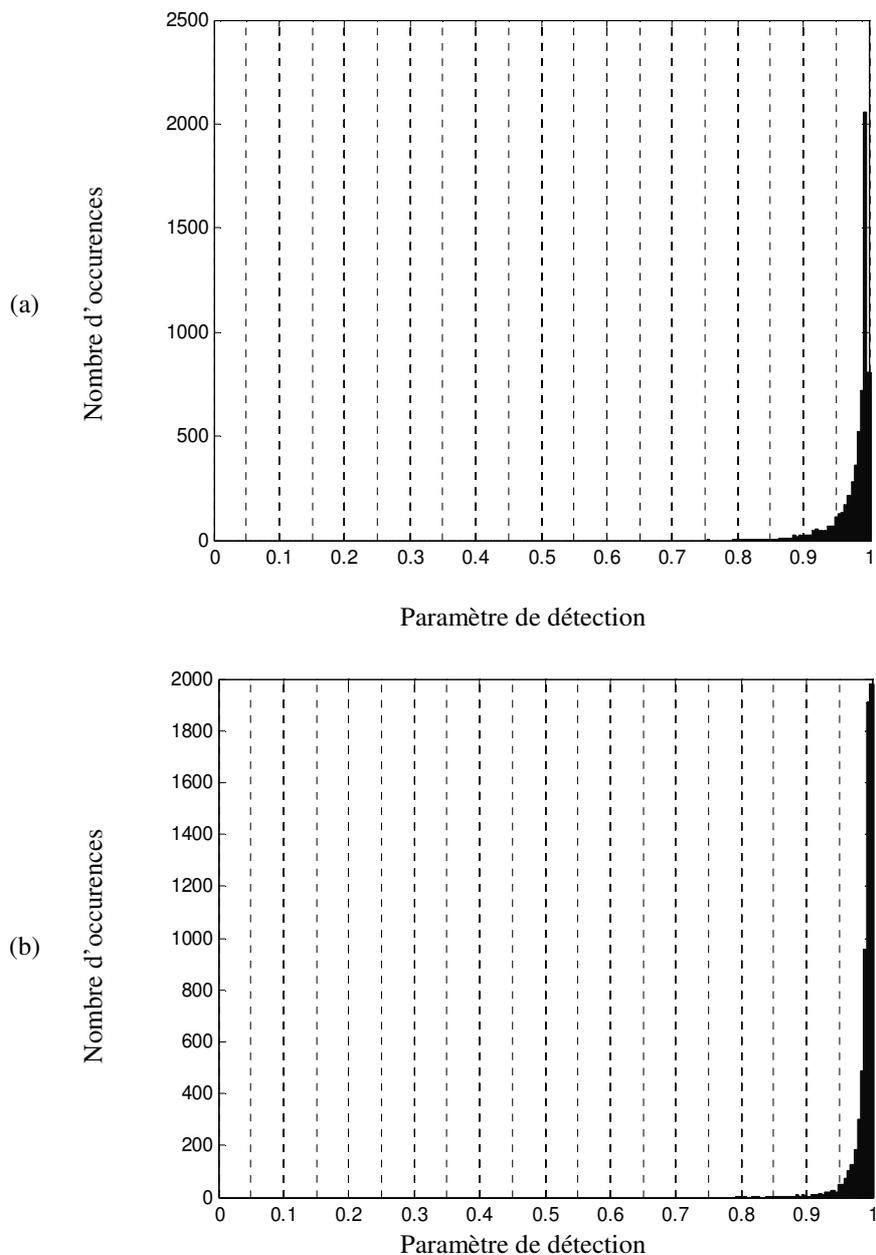


Fig. 4.5. Histogramme du paramètre de détection. (a) Image synthétique 1. (b) Image synthétique 2.



**Fig. 4.6.** Histogramme du paramètre de détection. (a) Image Landsat ETM+. (b) Image Formosat 2.

Aussi, et afin d'évaluer la robustesse du paramètre de détection à distinguer les zones mono-sources de celles multi-sources, nous sélectionnons, à partir des données utilisées, 1) une zone mono-source pour chaque matériau pur, et 2) pour chaque matériau pur, une zone multi-source, dans laquelle ce matériau pur est dominant. Nous calculons les valeurs du paramètre de détection défini dans (4.9) pour chacune des zones sélectionnées. Les résultats sont donnés dans Figs. 4.7 et 4.8. À partir de ces résultats,

nous remarquons que le paramètre de détection prend, dans les zones multi-sources, des valeurs significativement inférieures aux valeurs qu'il prend dans les zones mono-sources. Par conséquent, nous pouvons conclure que ce paramètre est très pertinent pour la détection des zones mono-sources. Aussi, ce test permet, d'une certaine manière, de fixer le seuil de détection (fixé dans nos tests à 0,992).

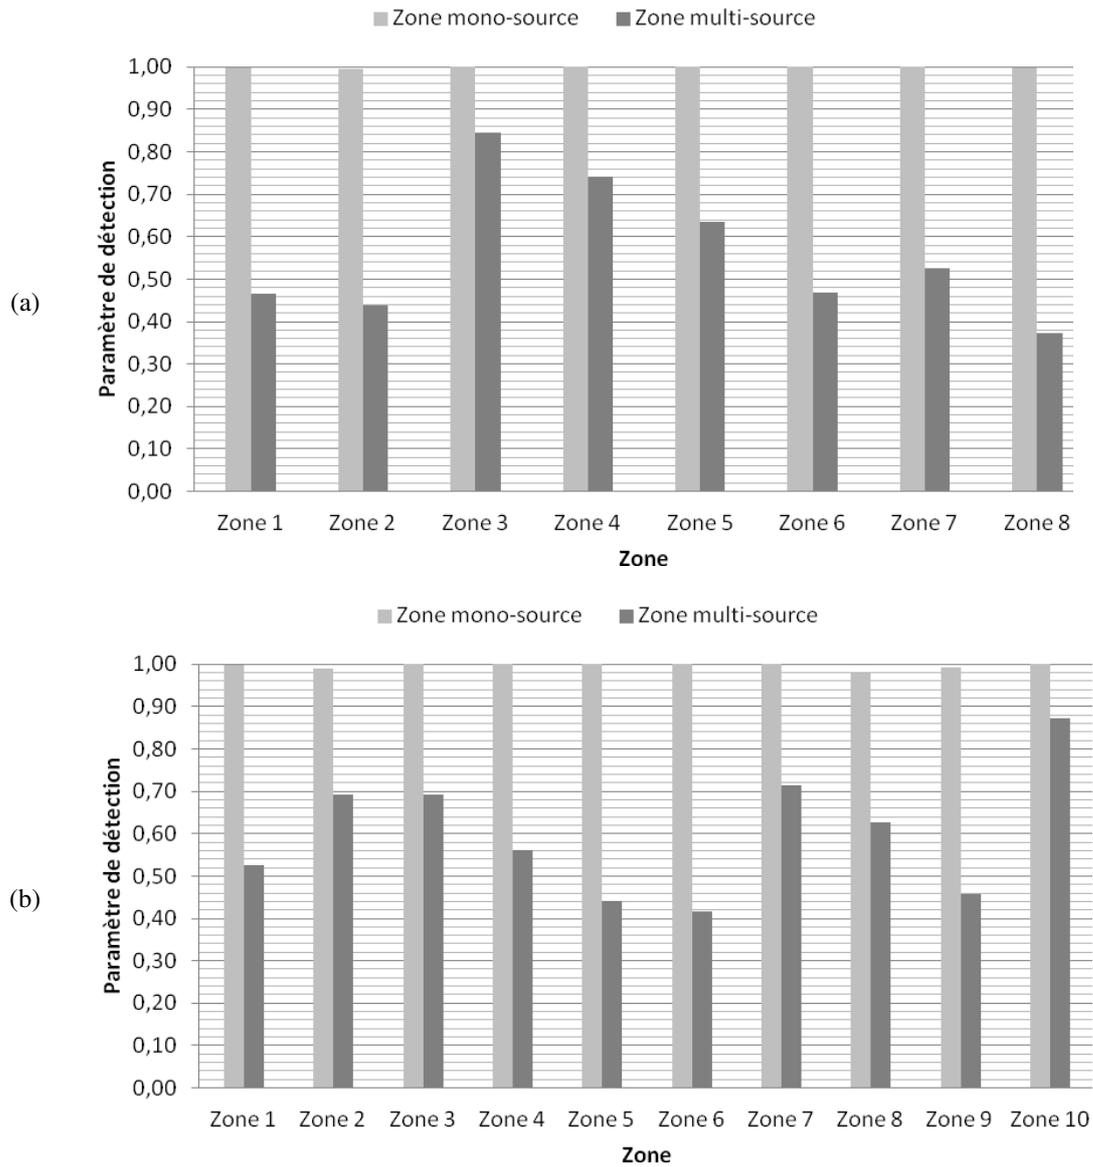
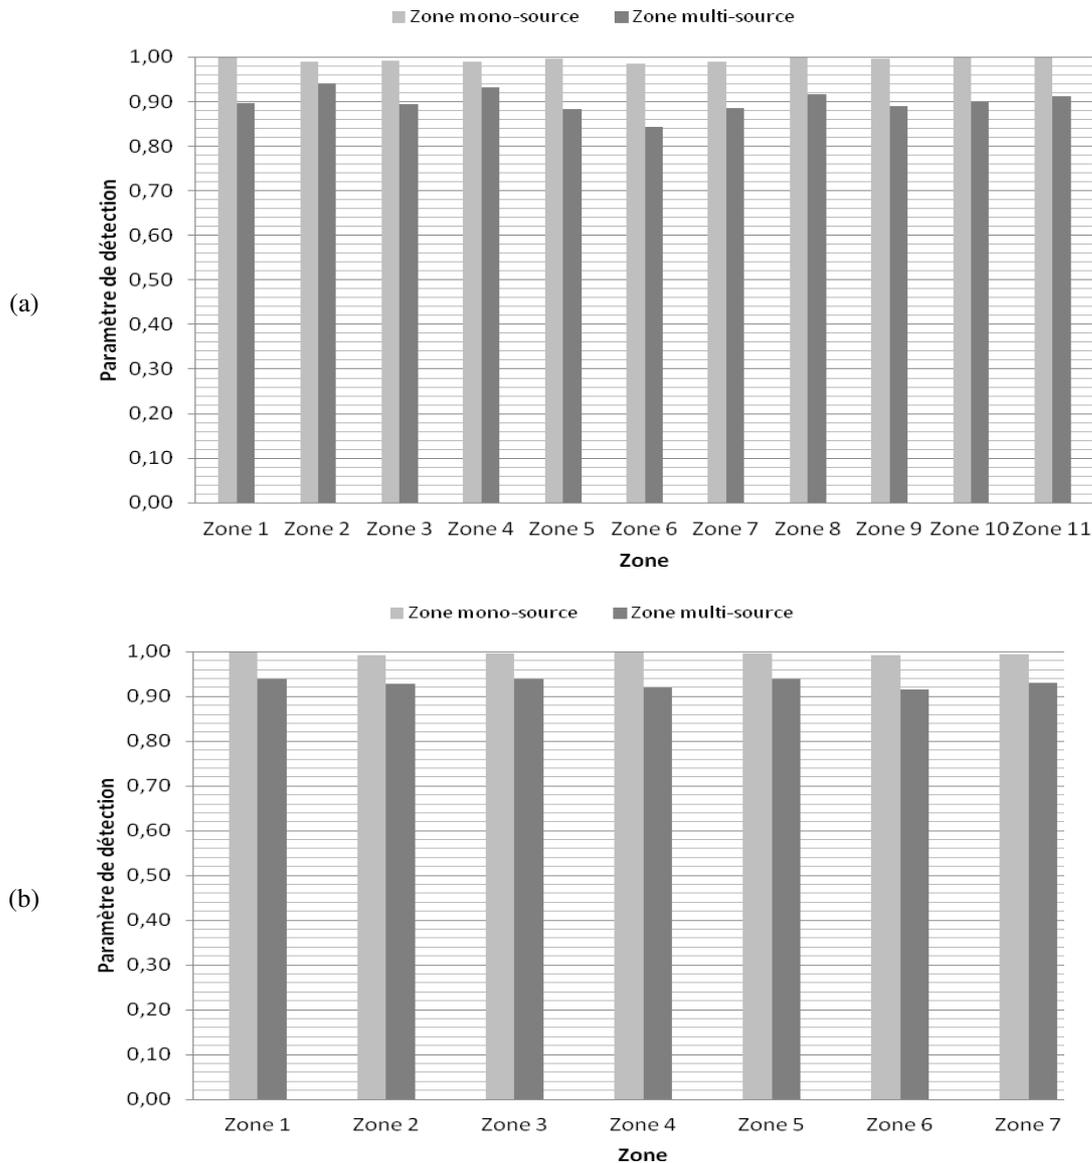
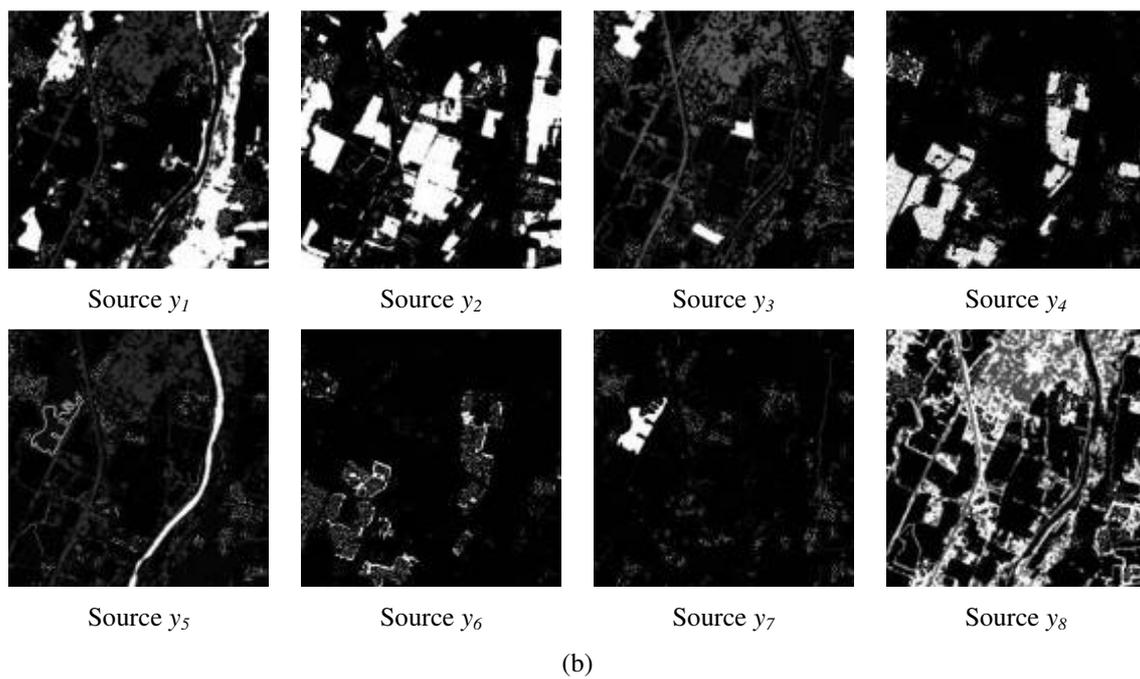
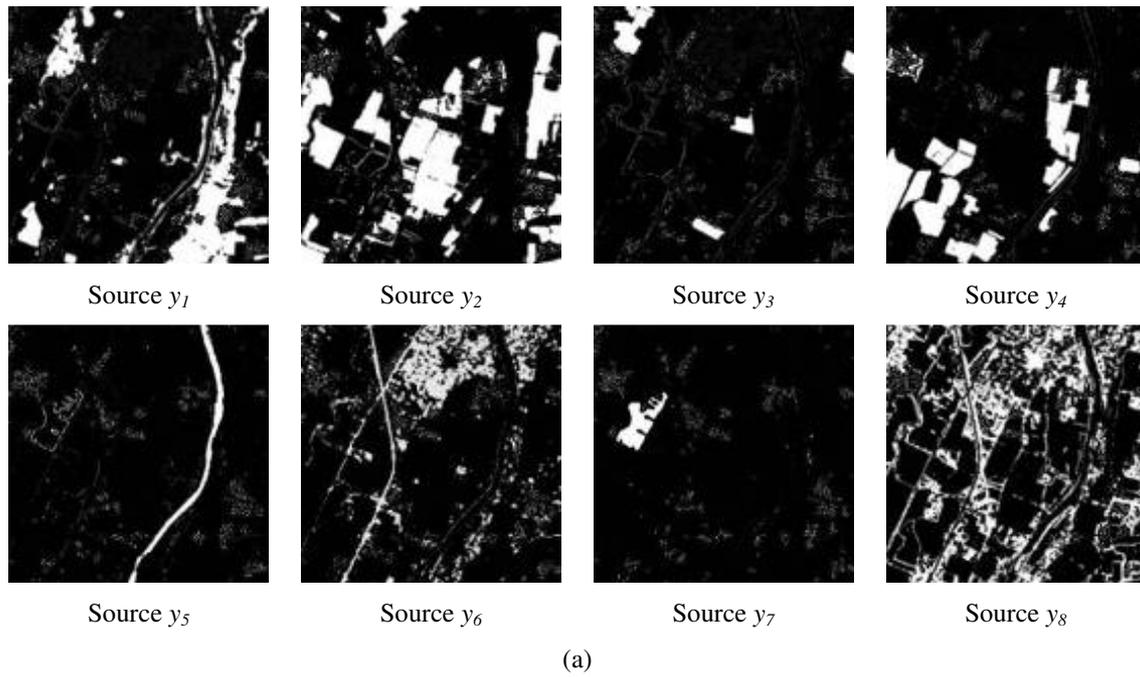


Fig. 4.7. Paramètre de détection dans les zones mono et multi-sources. (a) Image synthétique 1. (b) Image synthétique 2.



**Fig. 4.8.** Paramètre de détection dans les zones mono et multi-sources. (a) Image Landsat ETM+. (b) Image Formosat 2.

Les cartes d'abondances estimées par les méthodes 2D-Corr-NLS et SMACC sont données dans Figs. 4.9 - 4.12, pour les données synthétiques et réelles. L'erreur quadratique moyenne normalisée pour la première image synthétique est donnée dans Tab. 4.1. Dans Tab. 4.2., nous donnons l'erreur quadratique moyenne normalisée pour la seconde image synthétique. Les performances globales d'extraction des cartes d'abondances pour chacune des données utilisées sont données dans Figs. 4.12 et 4.13.



**Fig. 4.9.** Cartes d'abondances estimées à partir de la première image synthétique par (a) la méthode 2D-Corr-NLS, (b) la méthode SMACC.

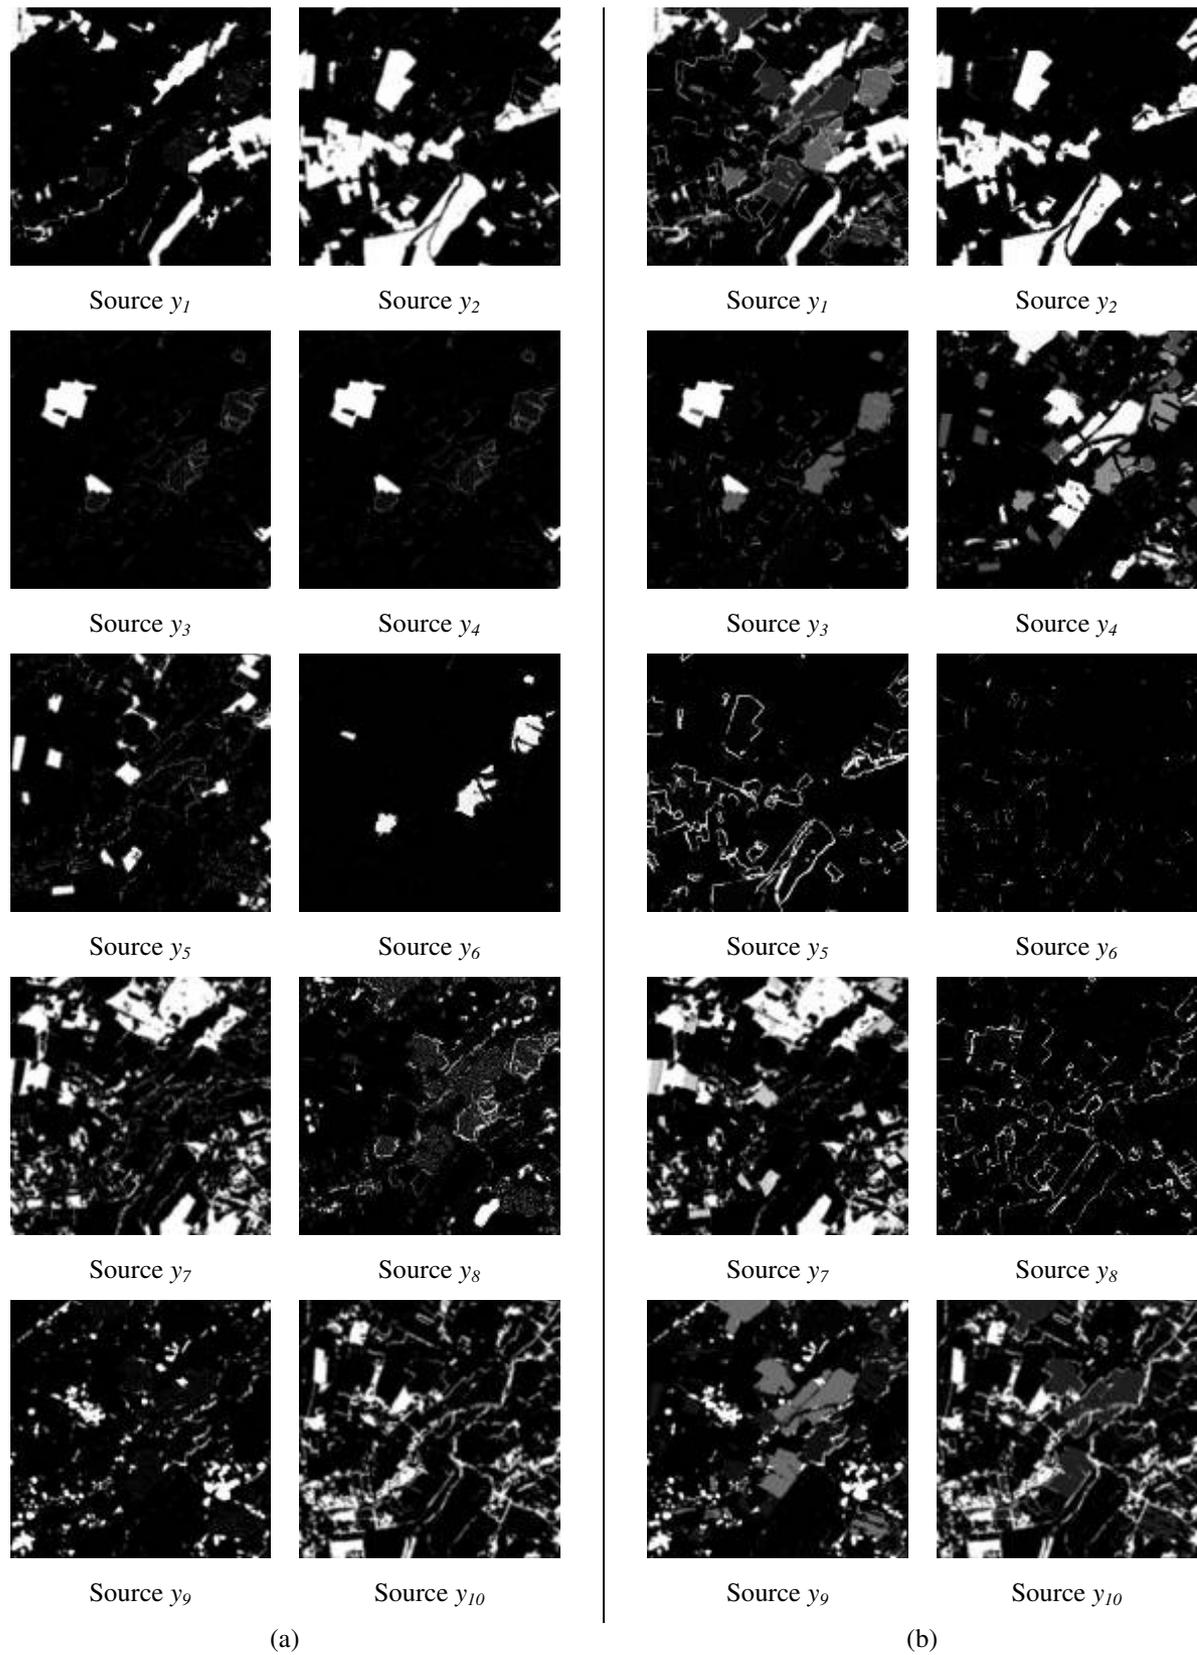
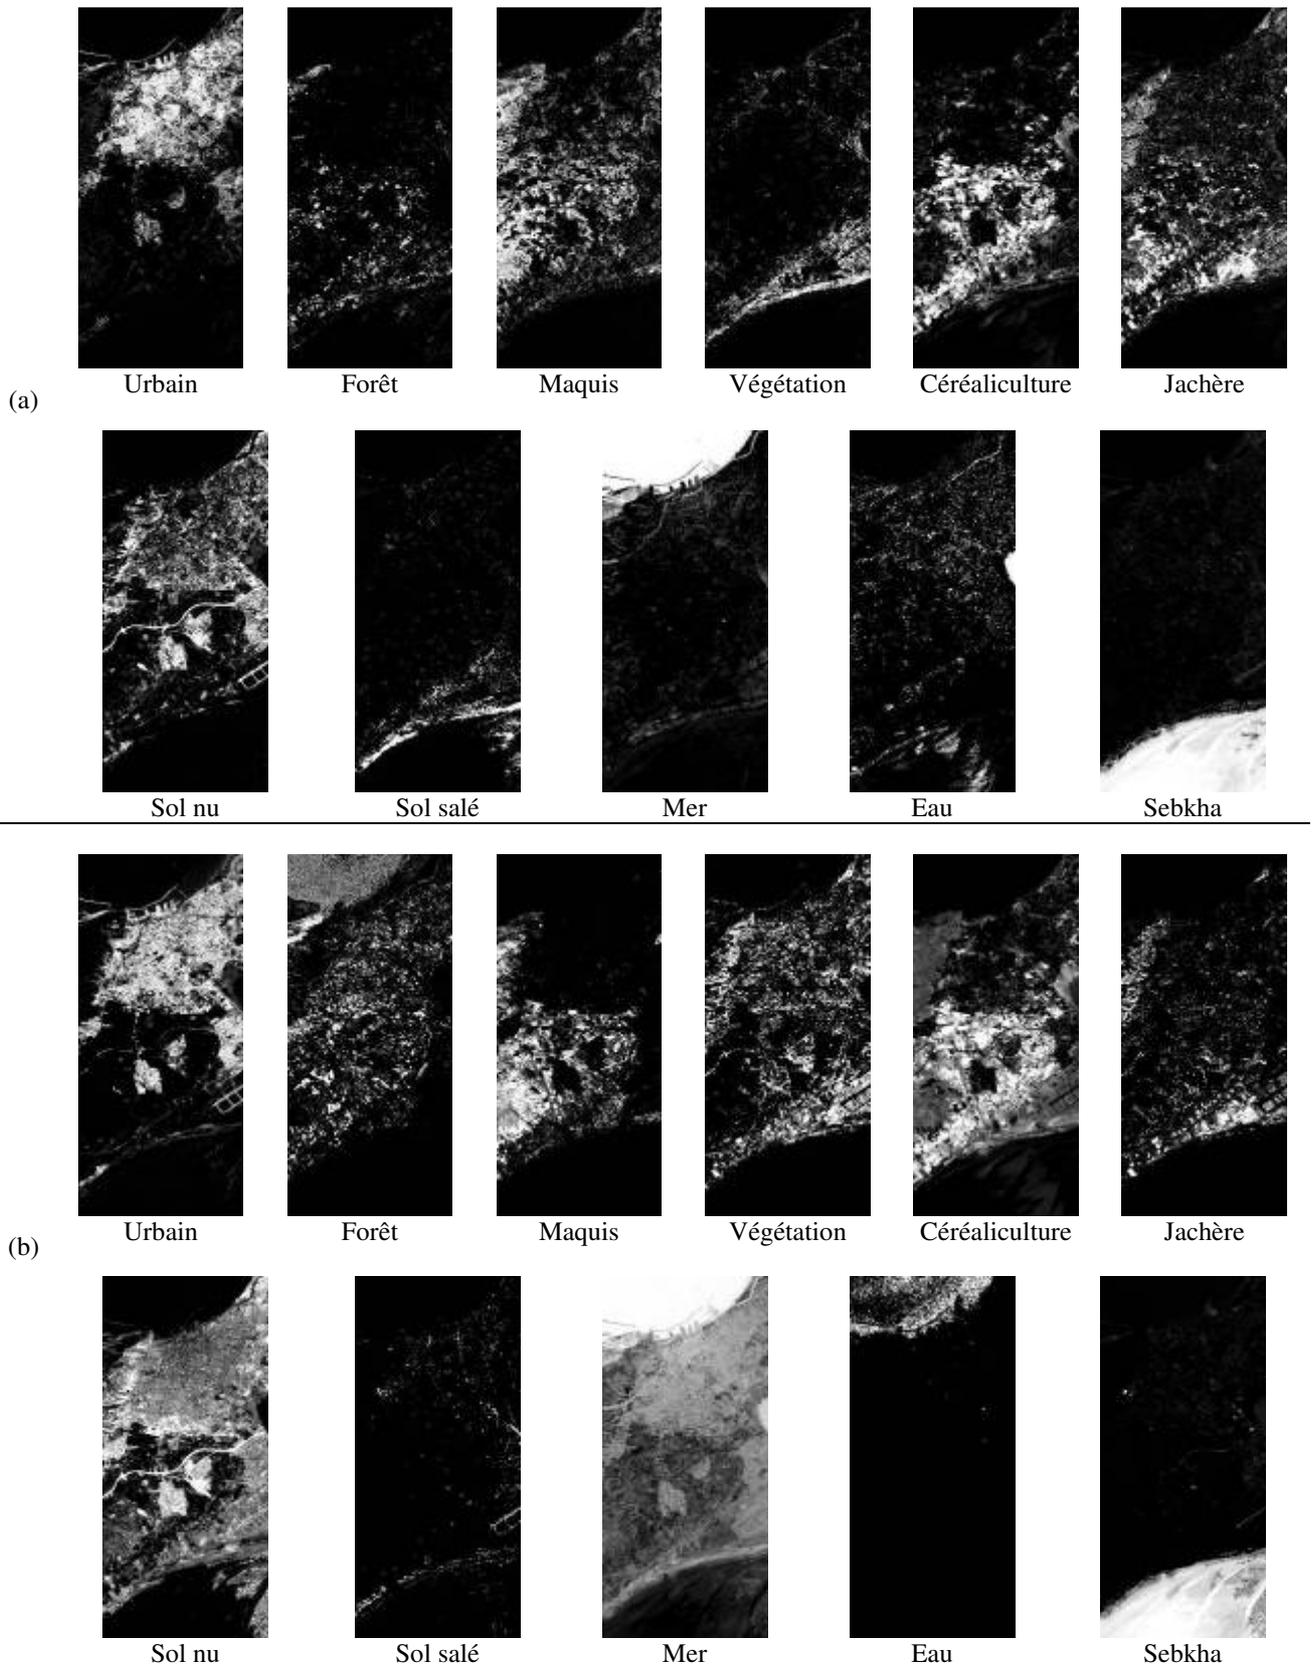


Fig. 4.10. Cartes d'abondances estimées à partir de la deuxième image synthétique par (a) la méthode 2D-Corr-NLS, (b) la méthode SMACC.



**Fig. 4.11.** Cartes d'abondances estimées à partir de l'image Landsat ETM+ par (a) la méthode 2D-Corr-NLS, (b) la méthode SMACC.

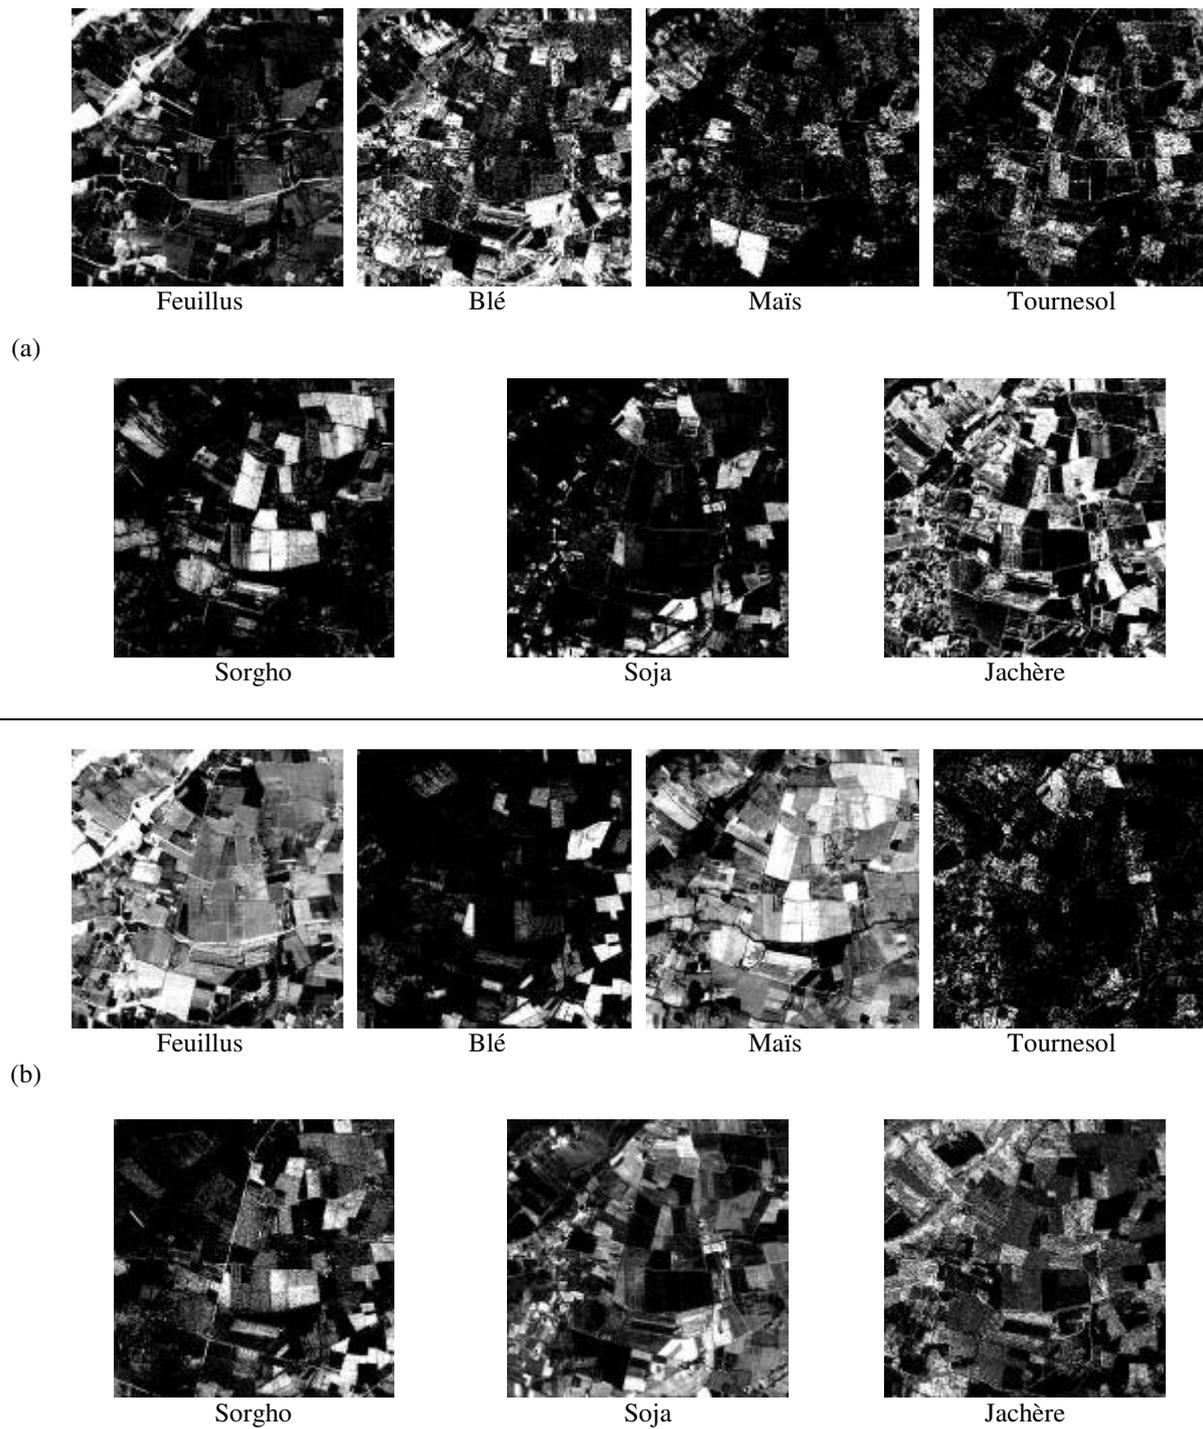


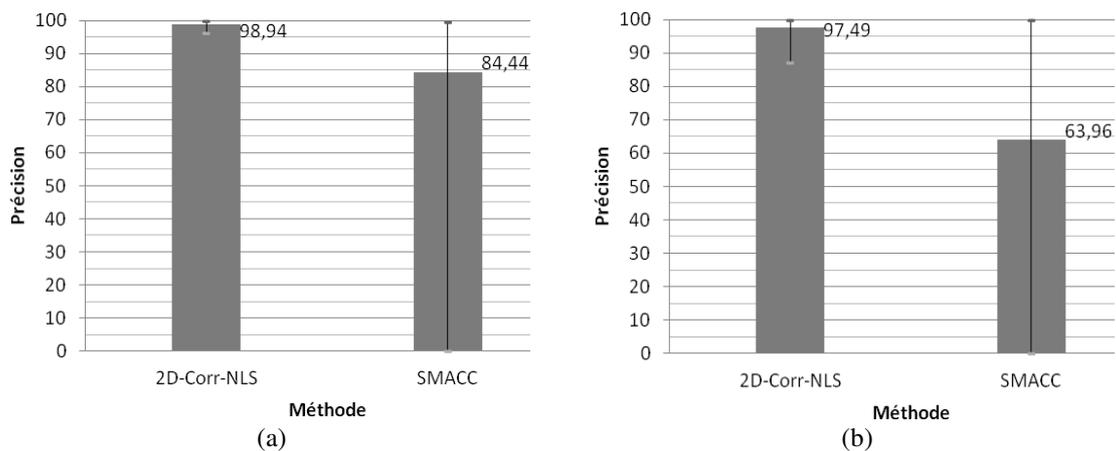
Fig. 4.12. Cartes d'abondances estimées à partir de l'image Formosat 2 par (a) la méthode 2D-Corr-NLS, (b) la méthode SMACC.

**Tab. 4.1.** Erreur quadratique moyenne normalisée (%) pour la première image synthétique. (a) Tous les pixels de l'image. (b) Pixels purs. (c) Pixels mélangés.

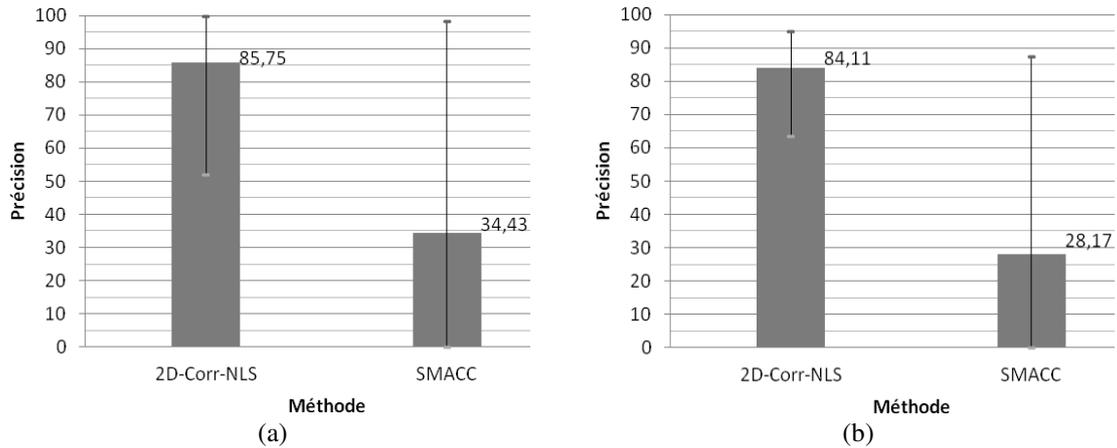
Méthode	Source $s_1$	Source $s_2$	Source $s_3$	Source $s_4$	Source $s_5$	Source $s_6$	Source $s_7$	Source $s_8$	Moyenne
<b>(a)</b>									
2D-Corr-NLS	0,99	0,00	0,40	0,57	7,44	1,90	1,25	0,15	1,59
SMACC	3,71	0,55	45,25	12,01	22,98	112,95	4,67	4,55	25,83
<b>(b)</b>									
2D-Corr-NLS	0,03	0,00	0,04	0,01	0,05	0,26	0,03	0,04	0,06
SMACC	1,74	0,04	17,57	5,08	5,98	112,89	0,40	3,90	18,45
<b>(c)</b>									
2D-Corr-NLS	3,54	0,01	2,39	3,18	25,87	2,90	8,89	0,24	5,88
SMACC	8,93	3,19	198,81	44,56	65,33	112,98	31,45	5,06	58,79

**Tab. 4.2.** Erreur quadratique moyenne normalisée (%) pour la deuxième image synthétique. (a) Tous les pixels de l'image. (b) Pixels purs. (c) Pixels mélangés.

Méthode	Source $s_1$	Source $s_2$	Source $s_3$	Source $s_4$	Source $s_5$	Source $s_6$	Source $s_7$	Source $s_8$	Source $s_9$	Source $s_{10}$	Moyenne
<b>(a)</b>											
2D-Corr-NLS	5,51	0,35	5,77	8,72	11,59	19,95	1,33	54,78	2,21	0,32	11,05
SMACC	21,26	6,66	21,25	41,01	132,47	102,20	18,48	133,47	27,74	2,18	50,67
<b>(b)</b>											
2D-Corr-NLS	0,17	0,00	0,41	2,75	0,09	3,01	0,02	23,98	2,63	0,08	3,31
SMACC	8,35	0,06	13,25	34,66	100,05	100,00	16,33	100,00	117,66	4,04	49,44
<b>(c)</b>											
2D-Corr-NLS	13,94	1,18	21,73	22,11	23,72	54,19	2,71	74,78	2,13	0,40	21,69
SMACC	41,65	22,32	45,12	55,28	166,65	106,66	20,75	155,20	11,56	1,57	62,68



**Fig. 4.13.** Performance globale (%) d'extraction des cartes d'abondances. (a) Image synthétique 1. (b) Image synthétique 2.



**Fig. 4.14.** Performance globale (%) d'extraction des cartes d'abondances. (a) Image Landsat ETM+. (b) Image Formosat 2.

Globalement, Tab. 4.1, Figs. 4.9 et 4.10 montrent que notre méthode 2D-Corr-NLS donne de meilleurs résultats que la méthode SMACC pour les images synthétiques, plus particulièrement, pour l'extraction de la sixième carte d'abondances à partir de la première image synthétique, et les cinquième, sixième et huitièmes cartes d'abondances à partir de la deuxième image synthétique. L'amélioration moyenne de l'erreur quadratique moyenne normalisée est d'environ 24 % pour notre méthode 2D-Corr-NLS comparée à la méthode SMACC pour la première image synthétique, et d'environ 39 % pour la deuxième image synthétique. La Fig. 4.13 montre qu'en termes de performance globale d'extraction des cartes d'abondances, les meilleurs résultats sont aussi obtenus par notre méthode 2D-Corr-NLS pour les deux images synthétiques.

Pour les images multispectrales réelles, Figs. 4.11, 4.12 et 4.14 montrent que notre méthode 2D-Corr-NLS est plus performante que la méthode SMACC : l'amélioration de la performance globale d'extraction des cartes d'abondances est supérieure à 51 % pour l'image Landsat ETM+, et d'environ 56 % pour l'image Formosat 2. Figs. 4.11(b) et 4.12(b) (qui correspondent aux cartes d'abondances extraites par la méthode SMACC) montrent que les cartes d'abondances de certaines classes ne sont pas clairement extraites. Au contraire, Figs. 4.11(a) et 4.12(a) (qui correspondent aux cartes d'abondances extraites par notre méthode 2D-Corr-NLS) montrent une nette amélioration de l'extraction des différentes cartes d'abondances des différentes classes d'occupation des sols.

## 4.4 Conclusion

Dans ce chapitre, deux méthodes hybrides non-supervisées, baptisées 2D-Corr-NLS et 2D-Corr-NMF, ont été proposées pour démêler chaque pixel d'une image multispectrale de télédétection spatiale contenant des pixels purs. Ces méthodes sont basées sur un critère de corrélation de l'approche dite d'analyse en composantes parcimonieuses, combinée au clustering et aux méthodes basées sur les contraintes de non-négativité. Plus particulièrement, les méthodes proposées sont applicables au modèle de séparation sous-déterminé défini par l'imagerie multispectrale de télédétection spatiale.

Comparées à la méthode SMACC, et selon les résultats obtenus dans nos travaux (24 % et 39 % d'amélioration de l'erreur quadratique moyenne normalisée pour les images synthétiques, et plus de 51 % et 55 % d'amélioration des performances globales d'extraction des cartes d'abondances pour les images réelles), les méthodes proposées sont très attractives pour démêler les images multispectrales de télédétection spatiale.

Finalement, nous terminons le présent chapitre en soulignant que les méthodes proposées ici pour démêler les pixels d'une image *multispectrale* avec pixels purs sont aussi applicables, avec moins de restrictions (l'Hypothèse 3 devient très facilement vérifiée), à une image *hyperspectrale* avec pixels purs. Cet aspect sera abordé dans le chapitre suivant pour l'extraction de spectres à partir d'une image hyperspectrale avec pixels purs.

## Références bibliographiques citées dans le Chapitre 4

- [1] F. Abrard, Y. Deville, "A time-frequency blind signal separation method applicable to underdetermined mixtures of dependent sources," *Signal Processing*, 85(7), pp. 1389-1403, 2005.
- [2] J. C. Bezdek, *Pattern recognition with fuzzy objective function algorithms*, Springer, 1981.
- [3] J. M. Bioucas-Dias, A. Plaza, "An overview on hyperspectral unmixing: geometrical, statistical, and sparse regression based approaches," *In Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2011*, pp. 1135-1138. 2011.
- [4] A. O. Boudraa, "Dynamic estimation of number of clusters in data sets," *Electronics Letters*, 35(19), pp. 1606-1607, 1999.
- [5] A. Cichocki, R. Zdunek, and S. I. Amari, "New Algorithms for Non-Negative Matrix Factorization in Applications to Blind Source Separation," *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 2006*, pp. V, Toulouse, France, 2006.
- [6] A. Cichocki, R. Zdunek, A. H. Phan, and S. I. Amari, *Nonnegative Matrix and Tensor Factorization: Applications to Exploratory Multi-way Data Analysis and Blind Source Separation*, John Wiley & Sons, 2009.
- [7] P. Comon, C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*, Academic Press, 2010.
- [8] Y. Deville, M. Puigt, "Temporal and time-frequency correlation-based blind source separation methods. Part I: determined and underdetermined linear instantaneous mixtures," *Signal Processing*, 87(3), pp. 374-407, 2007.
- [9] D. Donoho, V. Stodden, "When Does Non-Negative Matrix Factorization Give a Correct Decomposition into Parts?" *In Proceedings NIPS, 16*, pp. 1141-1149, 2003.
- [10] Y. Fukayama, M. Sugeno, "A new method of choosing the number of clusters for fuzzy c-means method," *In Proceedings of the 5<sup>th</sup> Fuzzy Systems Symposium*, pp. 247-250, 1989.

- [11] G. Gan, C. Ma, J. Wu, *Data Clustering: Theory, Algorithms, and Applications*, SIAM, 2007.
- [12] J. Gruninger, A. J. Ratkowski, and M. L. Hoke, "The sequential maximum angle convex cone (SMACC) endmember model," *In Proceedings of the SPIE Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery X*, 5425, pp. 1-14, Orlando, Florida, USA, 2004.
- [13] J. H. Han, D. S. Huang, Z. L. Sun, Y. M. Cheung, "A Novel Mixed Pixels Unmixing Method for Multispectral Images," *In Proceedings of the IEEE International Joint Conference on Neural Networks*, 4, pp. 2541-2545, 2004.
- [14] D. C. Heinz, C. I. Chang, "Fully Constrained Least Squares Linear Spectral Mixture Analysis Method for Material Quantification in Hyperspectral Imagery," *IEEE Transactions on Geoscience and Remote Sensing*, 39(3), pp. 529-545, 2001.
- [15] J. Herault, C. Jutten, and B. Ans, "Détection de grandeurs primitives dans un message composite pour une architecture de calcul neuromimétique en apprentissage non supervisé," *In GRETSI*, pp. 1017-1022, 1985.
- [16] J. Herault, C. Jutten, "Space or time adaptive signal processing by neural network models," *In International Conference on Neural Networks for Computing*, 1986.
- [17] A. Ifarraguerri, C. Chang, "Multispectral and Hyperspectral Image Analysis with Convex Cones," *IEEE Transactions on Geoscience and Remote Sensing*, 37(2), pp. 756-770, 1999.
- [18] ITT Corporation: ENVI – Solutions for Data Vis. And Image Analysis. <http://www.ittvis.com/envi/>.
- [19] A. Jourjine, S. Rickard, and Ö. Yilmaz, "Blind separation of disjoint orthogonal signals: Demixing N sources from 2 mixtures," *In Proceedings of the IEEE International Conference on Acoustic, Speech, and Signal Processing, ICASSP 2000*, pp. 2985-2988, 2000.
- [20] C. Jutten, J. Herault, "Blind separation of sources. Part i: an adaptive algorithm based on neuromimetic architecture," *Signal Processing*, 24(1), pp. 1-10, 1991.
- [21] N. Keshava, J. F. Mustard, "Spectral Unmixing," *IEEE Signal Processing Magazine*, 19, pp. 44-57, 2002.

- [22] D. J. Kim, Y. W. Park, D. J. Park, "A Novel Validity Index for Determination of the Optimal Number of Clusters," *IEICE Transactions on Information and Systems*, E84-D(2), pp. 281-285, 2001.
- [23] I. Kopriva, A. Cichocki, "Blind multispectral image decomposition by 3D nonnegative tensor factorization," *Optics Letters*, 34(14), pp. 2210-2212, 2009.
- [24] S. H. Kwon, "Cluster validity index for fuzzy clustering," *Electronics Letters*, 34(22), pp. 2176-2177, 1999.
- [25] C. L. Lawson, R. J. Hanson, *Solving Least Squares Problems*, SIAM, 1974.
- [26] D. D. Lee, H. S. Seung, "Learning the parts of objects by non-negative matrix factorization," *Nature*, 401, pp. 788-791, 1999.
- [27] D. D. Lee, H. S. Seung, "Algorithms for Non-Negative Matrix Factorization," *Advances in Neural Information Processing Systems*, 13, pp. 556-562, MIT Press 2001.
- [28] I. Meganem, Y. Deville, M. Puigt, "Blind separation methods based on correlation for sparse possibly-correlated images," *In Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 2010*, pp. 1334-1337, 2010.
- [29] Y. Moudden, J. Bobin, "Hyperspectral BSS Using GMCA With Spatio-Spectral Sparsity Constraints," *IEEE Transactions on Image Processing*, 20(3), pp. 872-879, 2011.
- [30] J. M. P. Nascimento, J. M. Bioucas-Dias, "Does Independent Component Analysis Play a Role in Unmixing Hyperspectral Data?" *IEEE Transactions on Geoscience and Remote Sensing*, 43(1), pp. 175-187, 2005.
- [31] A. Pacheco, H. McNairn, "Evaluating multispectral remote sensing and spectral unmixing analysis for crop residue mapping," *Remote Sensing of Environment*, 114, pp. 2219-2228, 2010.
- [32] N. R. Pal, J. C. Bezdek, "On cluster validity for the fuzzy c-means model," *IEEE Transactions on Fuzzy Systems*, 3(3), pp. 370-379, 1995.
- [33] M. Parente, A. Plaza, "Survey of geometric and statistical unmixing algorithms for hyperspectral images," *In Proceedings of the Second IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2010*, Reykjavik, Iceland, 2010.

- [34] A. Quirin, J. Korczak, "Representation of Genetic Individuals for Unmixing Multispectral Data," *In Proceedings of the IEEE Congress on Evolutionary Computation*, pp. 1325-1331, 2005.
- [35] H. Ren, Y. L. Chang, "Multispectral subpixel detection using least square unmixing," *In Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2006*, pp. 2754-2756, 2006.
- [36] J. Settle, "On Constrained Energy Minimization and the Partial Unmixing of Multispectral Image," *IEEE Transactions on Geoscience and Remote Sensing*, 40(3), pp. 718-721, 2002.
- [37] N. L. Xie, G. A. Beni, "A validity measure for fuzzy clustering," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(8), pp. 841-847, 1991.
- [38] C. M. Zhu, J. C. Luo, Z. F. Shen, J. L. Li, X. D. Hu, "A spatial adaptive algorithm for endmember extraction on multispectral remote sensing image," *[Article in Chinese] Guang Pu Xue Yu Guang Pu Fen Xi*, 31(10), pp. 2814-8, 2011.

## CHAPITRE 5

### EXTRACTION DE SPECTRES A PARTIR D'UNE IMAGE

#### HYPERSPECTRALE AVEC PIXELS PURS

---

*Résumé* - Dans ce chapitre, nous proposons une nouvelle méthode non-supervisée, appelée **2D-VM**, pour l'extraction de spectres à partir d'une image hyperspectrale de télédétection spatiale, avec la présence de pixels purs dans cette dernière. Cette méthode est liée au problème d'identification aveugle des mélanges, et est basée sur l'analyse en composantes parcimonieuses. Ainsi, après une introduction, nous exposons l'approche méthodologique adoptée pour atteindre notre objectif. La méthode d'extraction mise en place, ainsi que les hypothèses et définitions relatives à cette dernière sont détaillées. Avant de conclure ce cinquième chapitre, nous présentons des résultats expérimentaux sur des données synthétiques.

---

## DANS CE CHAPITRE

5.1. Introduction	135
5.2. Approche méthodologique proposée	137
5.2.1. Hypothèses et définitions	137
5.2.2. Méthode d'extraction	138
5.3. Résultats expérimentaux	141
5.3.1. Données utilisées	141
5.3.2. Résultats et discussion	145
5.4. Conclusion	152
Références bibliographiques citées dans le Chapitre 5	153

## 5.1 Introduction

Nous rappelons en guise d'introduction qu'à l'origine, les images de la Terre prises par des capteurs spatiaux ou même aéroportés furent monochromes (c'est-à-dire, des images avec une seule large bande spectrale). Il est ensuite survenu l'idée d'observer la même scène dans quelques bandes spectrales, ce qui a donné naissance à l'imagerie multispectrale (c'est-à-dire, qu'on est en possession d'images avec différentes larges bandes spectrales, et pas nécessairement contiguës). C'est dans les années 1980 que le concept d'imagerie hyperspectrale a été mis en œuvre dans le *Jet Propulsion Laboratory (JPL)* de la NASA [6]. Contrairement à une image multispectrale, dans une image hyperspectrale, une scène est observée dans plusieurs centaines de bandes spectrales étroites et contiguës. Aussi, comme expliqué dans le Chapitre 1, les pixels d'une image hyperspectrale ne sont pas nécessairement composés à cent pour cent d'éléments spectralement purs (les endmembers). C'est dans ce cadre qu'intervient l'approche de démixage spectral (*spectral unmixing*). Nous rappelons aussi que cette dernière approche est, généralement, fondée sur l'hypothèse suivante [10] : le spectre d'un pixel d'une image hyperspectrale est le résultat du mélange des spectres de tous les endmembers présents dans le pixel considéré. Le modèle analytique le plus couramment utilisé pour représenter ce genre de mélange est de type linéaire [3, 7, 8, 10, 14, 16]. Ainsi, nous rappelons que la réflectance non-négative  $x_n(i)$  mesurée dans la bande spectrale  $\lambda_n$ , et issue du pixel  $i$  d'une image hyperspectrale, est donnée par (voir aussi Eq. (1.9) du Chapitre 1) :

$$x_n(i) = \sum_{j=1}^L a_{nj} \cdot s_j(i), \quad \forall n = 1 \dots N \text{ et } \forall i = 1 \dots K, \quad (5.1)$$

où  $a_{nj}$  représente la réflectance non-négative du endmember  $j$  dans la bande spectrale  $\lambda_n$ ,  $s_j(i)$  est l'abondance non-négative du endmember  $j$  dans le pixel  $i$ , et  $L$  représente le nombre d'endmembers.  $N$  et  $K$  sont respectivement le nombre de bandes spectrales, et le nombre de pixels de l'image hyperspectrale. Les abondances non-négatives sont sujettes à la contrainte de somme unitaire sur chaque pixel (voir aussi Eq. (1.10) du Chapitre 1) :

$$\sum_{j=1}^L s_j(i) = 1, \forall i = 1 \dots K. \quad (5.2)$$

Les méthodes de démixage spectral linéaire, développées jusqu'à présent, ont pour objectif de retrouver, à partir seulement des spectres observés, les spectres des endmembers et leurs abondances. Ces méthodes, basées sur un concept géométrique pour la plupart d'entre elles, peuvent être considérées comme des méthodes de Séparation Aveugle de Sources (SAS) (*Blind Source Separation (BSS)*) [5]. Toutefois, ces méthodes ne réalisent pas, généralement, une séparation complète (c'est-à-dire, extraction des signaux sources (selon la nomenclature de la SAS)), mais s'arrêtent à l'identification des colonnes de la matrice de mélange. Ainsi, ces méthodes sont, plutôt, liées au problème d'Identification Aveugle de Mélanges (IAM) (*Blind Mixture Identification (BMI)*) [5], qu'au problème de la SAS.

Nous rappelons ici qu'un panorama des méthodes de démixage spectral peut être trouvé dans [3, 16, 17]. Aussi, on trouve deux classifications de ces méthodes. La première classification est relative au concept (géométrique, statistique, à régressions parcimonieuses) de ces méthodes [3, 16], et la deuxième est liée à la nature des données à traiter : avec ou sans pixels purs [17]. Nous nous intéressons dans ce qui suit aux images hyperspectrales avec pixels purs.

Nous signalons ici que les imageurs hyperspectraux "existants" fournissent, généralement, des images avec plusieurs pixels mélangés. Dans de telles situations, la présence de pixels purs, pour chacun des endmembers, n'est pas du tout garantie. Par contre, la résolution spatiale des "futurs" capteurs hyperspectraux (tels que les capteurs PRISMA, EnMAP et HYPXIM [13]) permettra sans doute la présence, dans les images, de pixels purs pour chacun des endmembers. Dans ce cas, l'extraction des spectres des endmembers à partir d'une image hyperspectrale, est réalisée en effectuant une recherche, dans l'image hyperspectrale, pour l'identification des pixels purs.

C'est dans ce contexte, que nous proposons dans le présent chapitre une nouvelle méthode non-supervisée, baptisée **2D-VM**, pour l'extraction des spectres des

endmembers, à partir d'une image hyperspectrale comportant quelques pixels purs pour chacun des endmembers présents dans la scène imagée. Notre nouvelle méthode, relativement similaire aux méthodes proposées dans le Chapitre 4, est liée au problème d'identification aveugle de mélanges, et est basée sur l'Analyse en Composantes Parcimonieuses (ACPa) (*Sparse Component Analysis (SCA)*). Elle consiste, en premier lieu, à détecter quelques zones de pixels purs pour ensuite extraire les spectres des endmembers.

## 5.2 Approche méthodologique proposée

### 5.2.1 Hypothèses et définitions

La méthode proposée utilise une version modifiée de l'étape de détection de l'approche, fondée sur l'ACPa, décrite dans [1] et dans le Chapitre 4, et est basée sur certaines hypothèses et définitions (les mêmes définitions que celles énoncées dans le Chapitre 4). Nous rappelons ici que ces hypothèses et définitions concernent les abondances des endmembers, considérées dans le domaine spatial de l'image. Soulignons ici, que notre motivation pour considérer les abondances des endmembers, et l'utilisation de l'ACPa est : les abondances sont forcément parcimonieuses, puisqu'un endmember ne peut être, généralement, présent partout dans une scène.

Nous signalons ici que la méthode que nous proposons ci-dessous est moins restrictive que celles décrites dans [9]. En effet, dans notre méthode, l'image hyperspectrale doit contenir seulement quelques zones contenant seulement des pixels purs dans le domaine spatial de l'image.

Nous rappelons aussi, que le domaine spatial est divisé en petites zones, notées  $\Omega$ , et qu'on appelle "zones d'analyse". Ces zones de dimension deux sont constituées de pixels adjacents. Le domaine spatial est exploré par l'utilisation de zones d'analyse adjacentes ou qui se chevauchent. Dans chaque zone d'analyse  $\Omega$ , nous calculons les valeurs des variances  $\text{var}_{i \in \Omega}[x_n(i)]$  des signaux observés (les réflectances non-négatives mesurées) dans toutes les bandes spectrales  $n$ .

Nous rappelons dans ce qui suit les définitions relatives aux endmembers.

**Définition 1** un endmember est dit "isolé" dans une zone d'analyse si seul cet endmember est présent dans cette zone (c'est-à-dire, si seul cet endmember donne un vecteur non-nul avec les éléments  $s_j(i)$  dans cette zone d'analyse). Cette zone d'analyse est appelée "zone mono-source". Bien entendu, compte tenu de (5.2), l'abondance de cet endmember est égale à un dans cette zone.

**Définition 2** un endmember est dit "accessible" dans le domaine spatial s'il existe au moins une zone d'analyse dans laquelle il est isolé.

**Hypothèse 1** chaque endmember est accessible dans le domaine spatial.

En imagerie hyperspectrale de télédétection spatiale, l'hypothèse de parcimonie ci-dessus dans le domaine spatial, est équivalente à **la présence d'au moins une zone mono-source pour chacun des endmembers présents dans la scène imagée**. Cette hypothèse est tout à fait réaliste pour les futurs capteurs hyperspectraux avec une fine résolution spatiale.

**Hypothèse 2** lorsque plusieurs endmembers sont présents dans une zone d'analyse, leurs abondances doivent prendre des valeurs significativement différentes dans les pixels constituant cette zone d'analyse, de telle sorte qu'au moins une variance de  $x_n(\Omega)$ , avec  $n = 1 \dots N$ , soit non-négligeable.

### 5.2.2 Méthode d'extraction

La méthode proposée opère en trois différentes étapes décrites ci-dessous.

**1- Etape de détection** qui consiste à détecter automatiquement les zones mono-sources. Cette détection est réalisée par l'utilisation de la propriété suivante :

**Propriété 1** une condition nécessaire et suffisante, pour qu'un endmember soit isolé dans une zone d'analyse  $\Omega$ , est :

$$\text{var}_{i \in \Omega}[x_n(i)] = 0, \forall n = 1 \dots N. \quad (5.3)$$

Notons que, compte tenu de la contrainte de somme unitaire des abondances formulée dans (5.2), nous considérons ici la variance des signaux observés, comme une alternative à la variance des rapports des signaux observés utilisés dans d'autres applications [1]. Nous signalons ici que la détection des zones mono-sources peut être effectuée aussi par l'utilisation de la Propriété 1 du Chapitre 4.

La Propriété 1 est utilisée comme suit dans notre méthode. Pour chaque zone d'analyse, nous calculons le paramètre suivant :

$$\max_n \left( \text{var}_{i \in \Omega}[x_n(i)] \right), \forall n = 1 \dots N. \quad (5.4)$$

Si le paramètre (5.4) est inférieur à un seuil (positif et proche de 0), nous considérons que la zone d'analyse examinée est une zone mono-source. Bien entendu, la moyenne ou le minimum peuvent aussi être utilisés, mais le maximum est le plus restrictif.

**2- Etape d'estimation** qui consiste à calculer des estimations des spectres des endmembers. Chaque zone mono-source  $\Omega$ , nous conduit à une estimation d'un spectre d'un endmember  $\hat{a}_j$ , en utilisant la formule suivante :

$$\hat{a}_j = \begin{pmatrix} \text{median}(x_1(\Omega)) \\ \cdot \\ \cdot \\ \cdot \\ \text{median}(x_N(\Omega)) \end{pmatrix}. \quad (5.5)$$

Dans cette étape d'estimation, nous associons le paramètre de détection (5.4) à chaque spectre estimé. En effet, ce paramètre peut être utilisé comme un degré de confiance dans l'étape suivante détaillée ci-après.

**3- Etape d'extraction** qui consiste à extraire les spectres des endmembers. Chaque zone mono-source (contenant des pixels purs avec un seul endmember) donne un spectre estimé "possible" pour l'endmember présent dans cette zone pure. Pour cette raison, après l'extraction du spectre  $\hat{a}_1$  du premier endmember, chaque spectre estimé  $\hat{a}_r$  est comparé avec tous les spectres précédemment extraits  $\hat{a}_j$ , en utilisant l'Angle Spectral (AS) (*Spectral Angle Mapper (SAM)*). Nous rappelons que l'angle spectral entre deux spectres estimés est donné par :

$$AS(\hat{a}_j, \hat{a}_r) = \arccos \left( \frac{\langle \hat{a}_j, \hat{a}_r \rangle}{\|\hat{a}_j\| \|\hat{a}_r\|} \right), \quad \forall j \neq r. \quad (5.6)$$

Si tous les angles calculés sont supérieurs à un seuil, nous considérons que le spectre estimé  $\hat{a}_r$  est un "nouveau spectre extrait". Sinon, c'est-à-dire, si  $\hat{a}_r$  est similaire à un des spectres précédemment extraits  $\hat{a}_j$ , nous choisissons (entre ces deux spectres similaires) le spectre ayant la plus faible valeur du paramètre (5.4) comme étant le spectre extrait (c'est-à-dire, nous remplaçons  $\hat{a}_j$  par  $\hat{a}_r$  si  $\hat{a}_r$  donne une valeur du paramètre (5.4) plus faible que celle que donne  $\hat{a}_j$ ).

Les différentes étapes définies précédemment constituent notre nouvelle méthode, baptisée **2D-VM**, pour l'extraction des spectres à partir d'une image hyperspectrale de télédétection spatiale contenant des pixels purs.

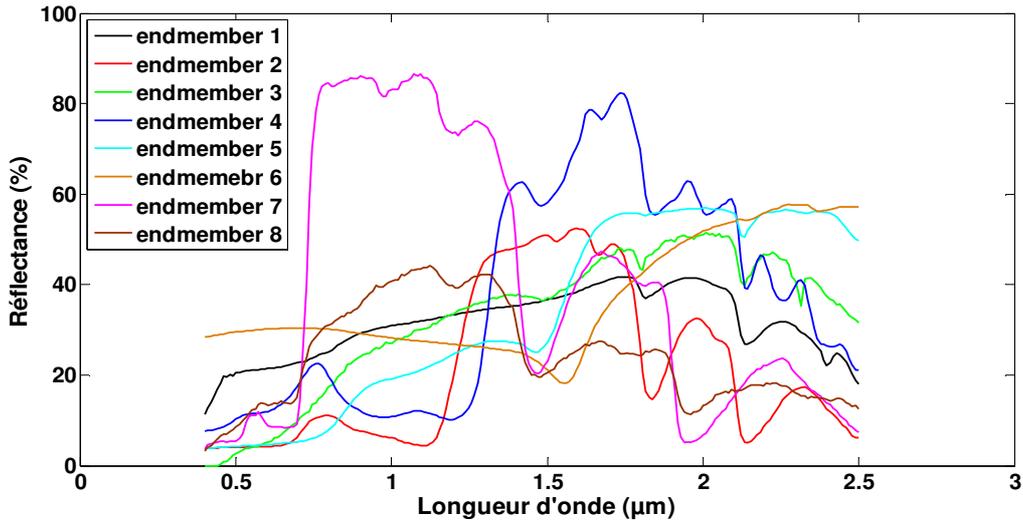
L'évaluation des performances de la méthode proposée est réalisée par l'utilisation de l'angle spectral entre les spectres originaux et les spectres extraits. Aussi, le critère basé sur l'Erreur Quadratique Moyenne Normalisée (EQMN) (*Normalized Mean Square Error (NMSE)*), entre les spectres originaux et les spectres extraits, peut être utilisé pour l'évaluation des performances de la méthode proposée (voir Section 2.4 du Chapitre 2).

## 5.3 Résultats expérimentaux

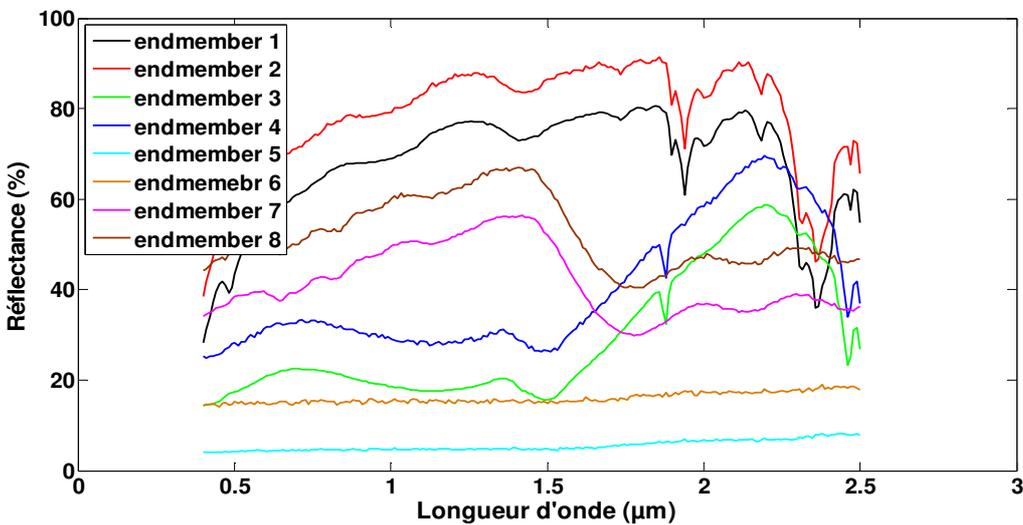
Des expériences, basées sur des données synthétiques mais réalistes, sont effectuées pour l'évaluation des performances de la méthode proposée et de cinq méthodes de la littérature.

### 5.3.1 Données utilisées

Deux ensembles de huit spectres (huit endmembers) sont sélectionnés à partir de la bibliothèque spectrale compilée par *United States Geological Survey (USGS)*, et mesurés de 0,4 à 2,5  $\mu\text{m}$  [4]. Le premier ensemble contient huit spectres aléatoirement sélectionnés (Fig. 5.1(a)). Le second ensemble contient, lui aussi, huit spectres, regroupés en quatre paires, chacune d'elles contenant deux spectres fortement corrélés (Fig. 5.1(b)). La motivation principale pour le choix de spectres corrélés réside dans le fait que, dans notre méthode, chaque spectre estimé est comparé aux spectres précédemment extraits, par l'utilisation de l'angle spectral (5.6), qui est en réalité l'arc cosinus du coefficient de corrélation non-centré. Ce choix permet donc, d'évaluer la robustesse de notre méthode d'extraction.



(a)



(b)

Fig. 5.1. Spectres originaux. (a) Premier ensemble. (b) Deuxième ensemble.

Les deux ensembles de spectres sont par la suite indépendamment utilisés pour générer, selon le modèle linéaire de mélange (5.1), deux images hyperspectrales synthétiques mais réalistes. Ces deux images, de dimension 400x400 pixels, sont créées en utilisant huit cartes d'abondances (voir Fig. 4.2(a) du Chapitre 4) générées à partir d'une classification réelle de l'occupation des sols d'une scène (en moyennant les valeurs des pixels de la classification sur une fenêtre glissante de taille 5x5 pixels). Nous rappelons que chacune de ces cartes d'abondances contient au moins 1,5 % de pixels purs.

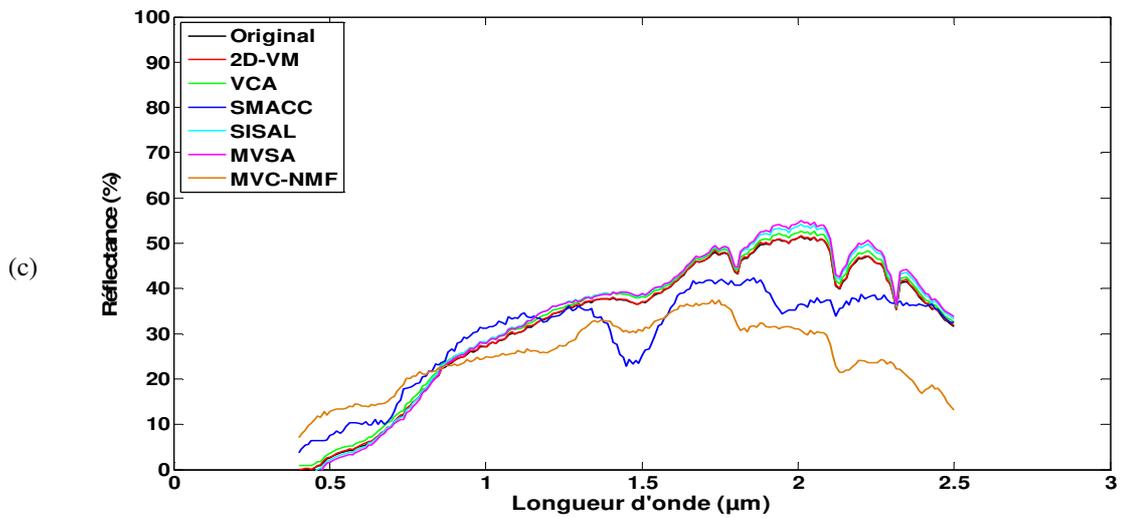
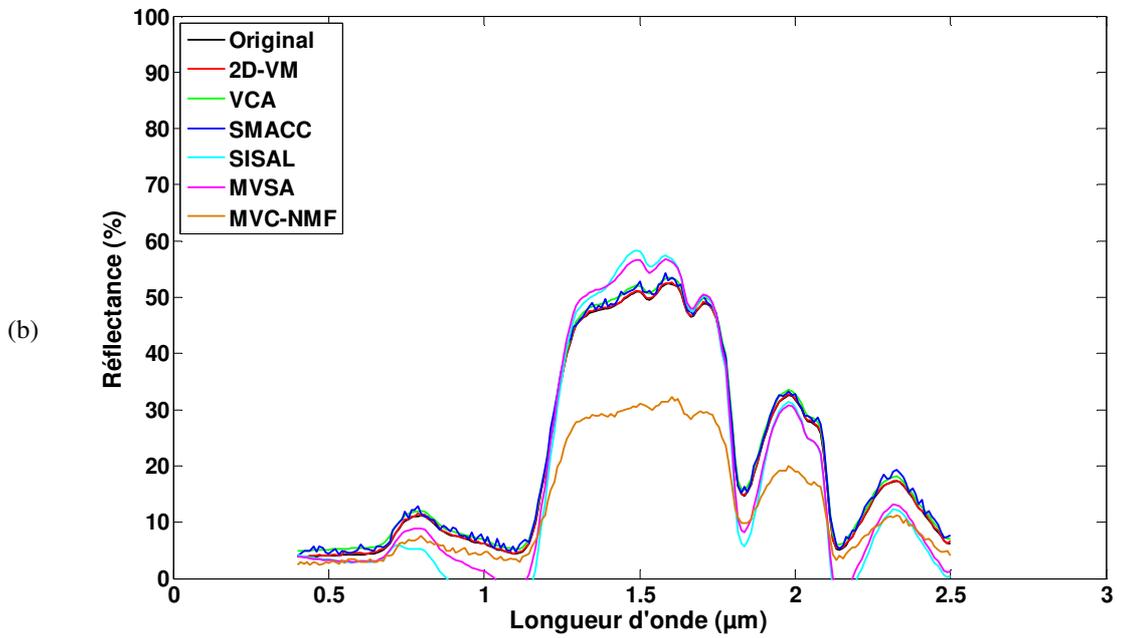
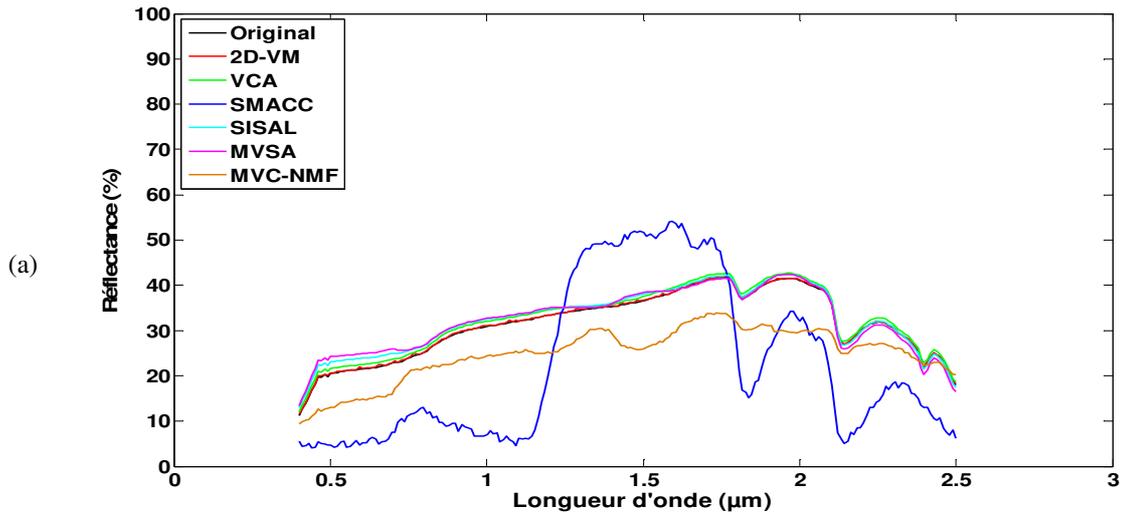
### 5.3.2 Résultats et discussion

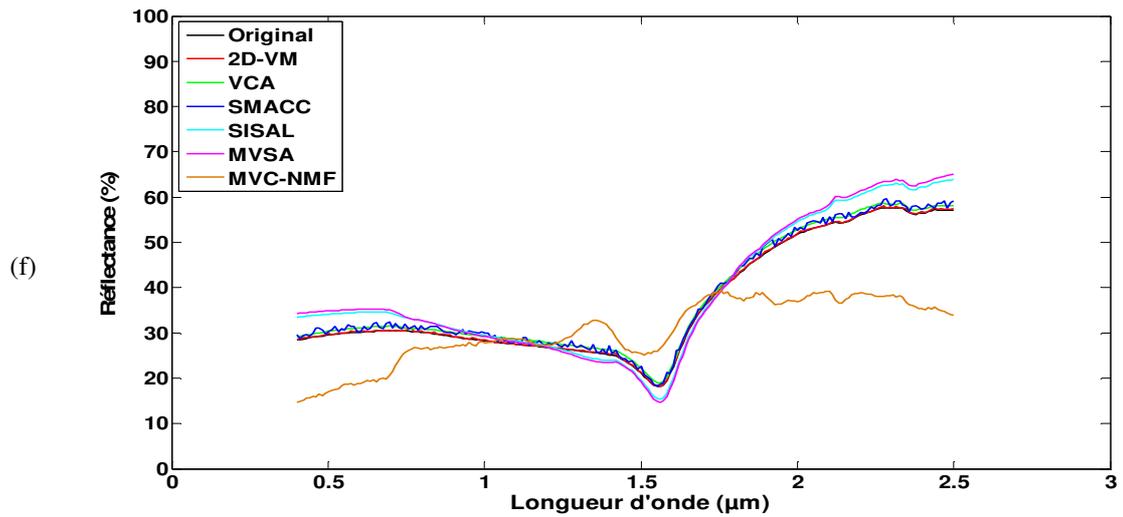
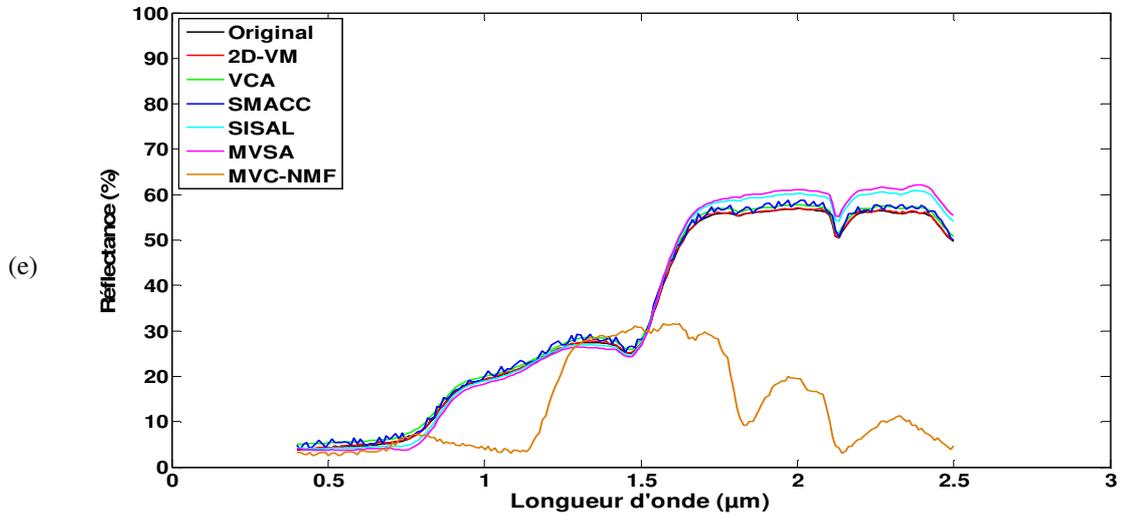
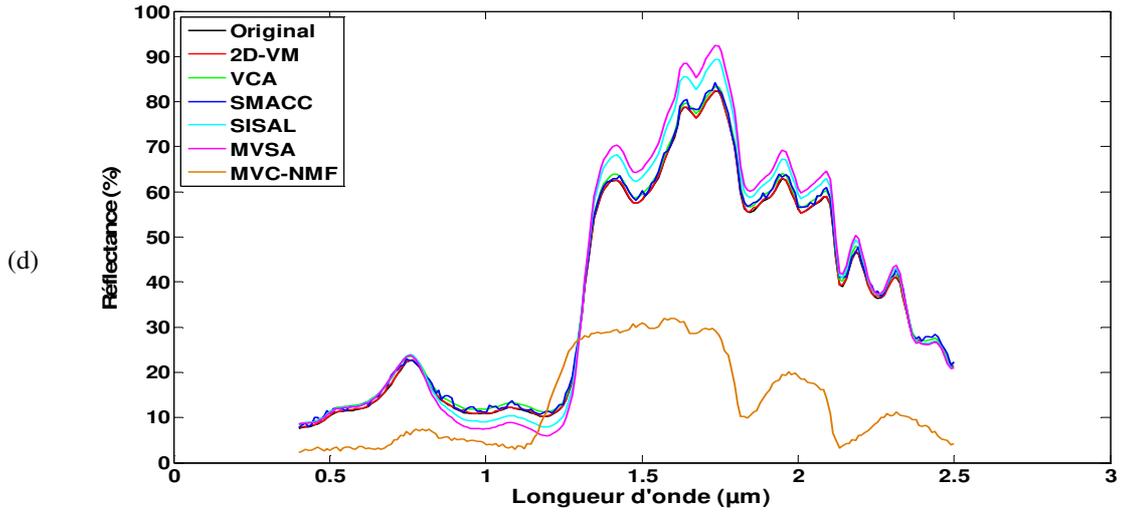
La méthode proposée est appliquée aux deux images hyperspectrales synthétiques. En plus, les méthodes : VCA [15], SMACC [7], SISAL [2], MVSA [11], et MVC-NMF [12] sont aussi appliquées aux données utilisées pour permettre une comparaison.

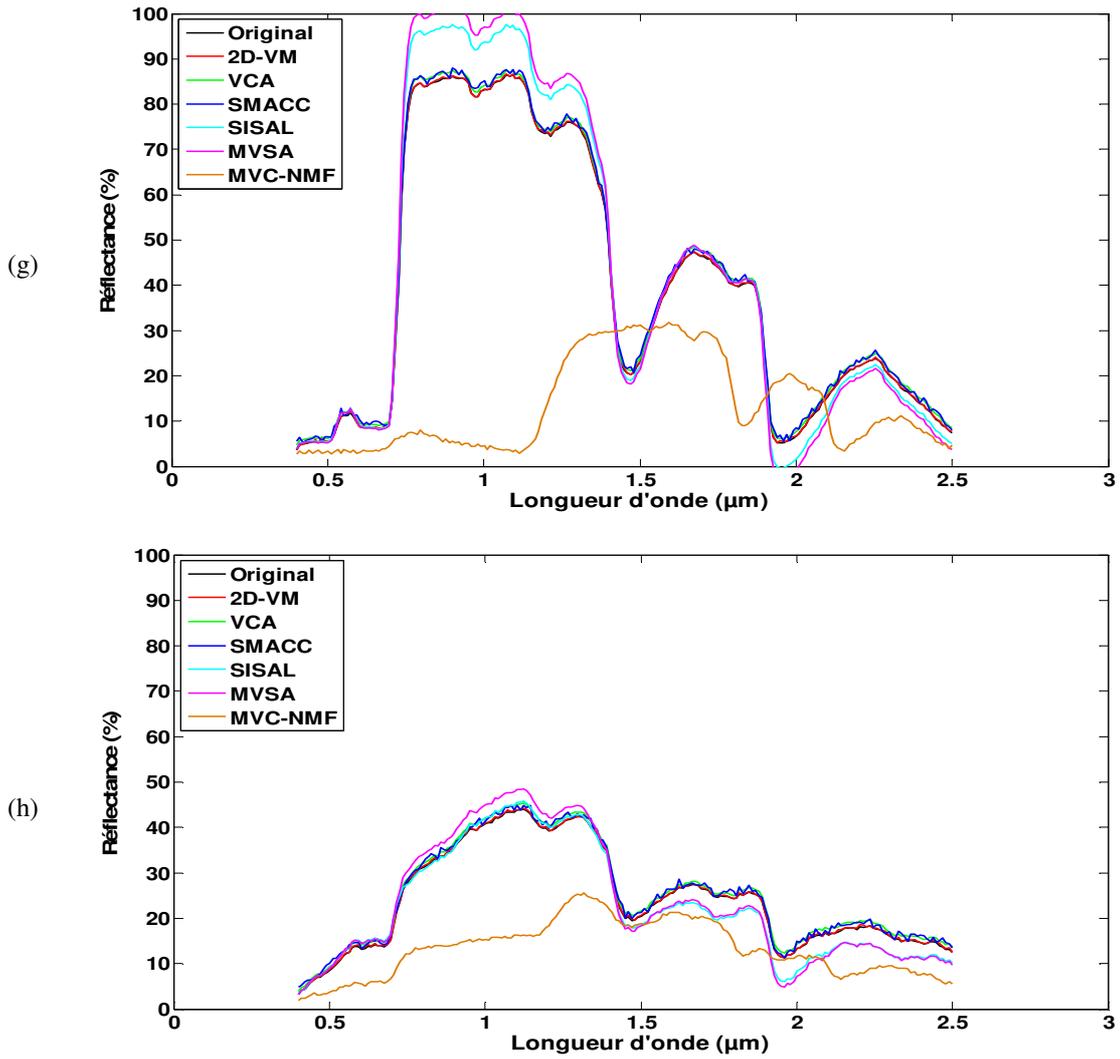
Nous rappelons que ces méthodes de la littérature sont basées sur un concept géométrique. En effet, elles exploitent le fait que le nuage de points, formant une image hyperspectrale, est contenu dans un simplexe. Les vertex du simplexe représentent les spectres des endmembers recherchés.

Les deux méthodes VCA et SMACC sont conçues pour des images contenant des pixels purs (ce qui est le cas des données qu'on manipule dans les travaux de ce chapitre). Les méthodes SISAL, MVSA et MVC-NMF sont conçues pour des images ne contenant pas nécessairement des pixels purs (cela n'est pas le cas de nos données, mais nous testons tout de même ces méthodes : qui peut le plus, peut le moins !).

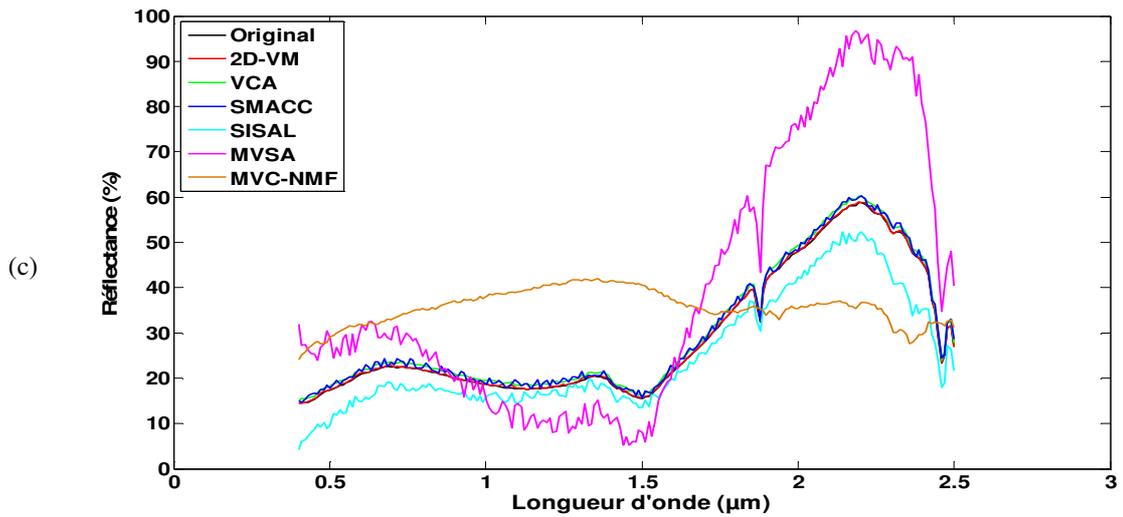
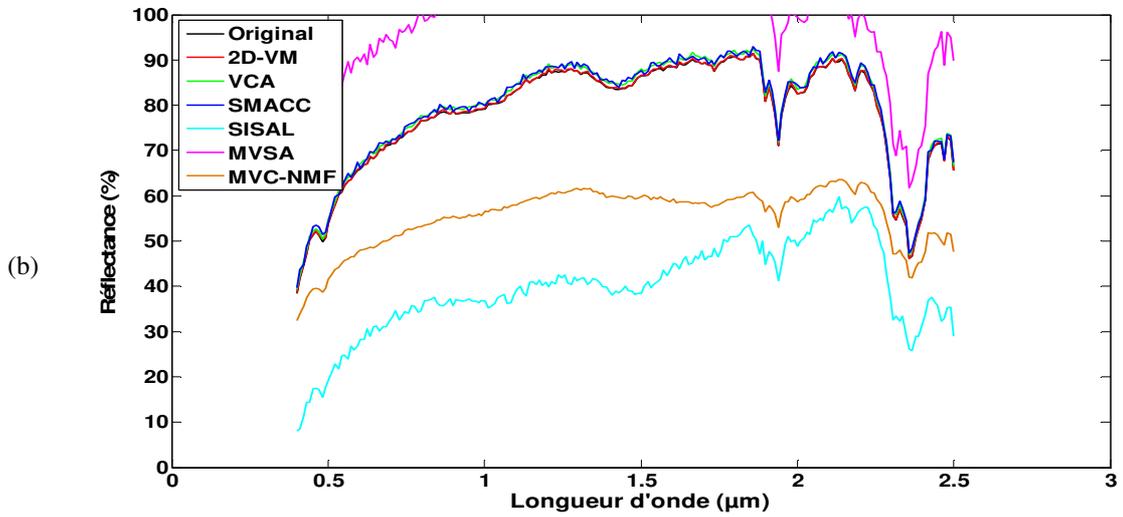
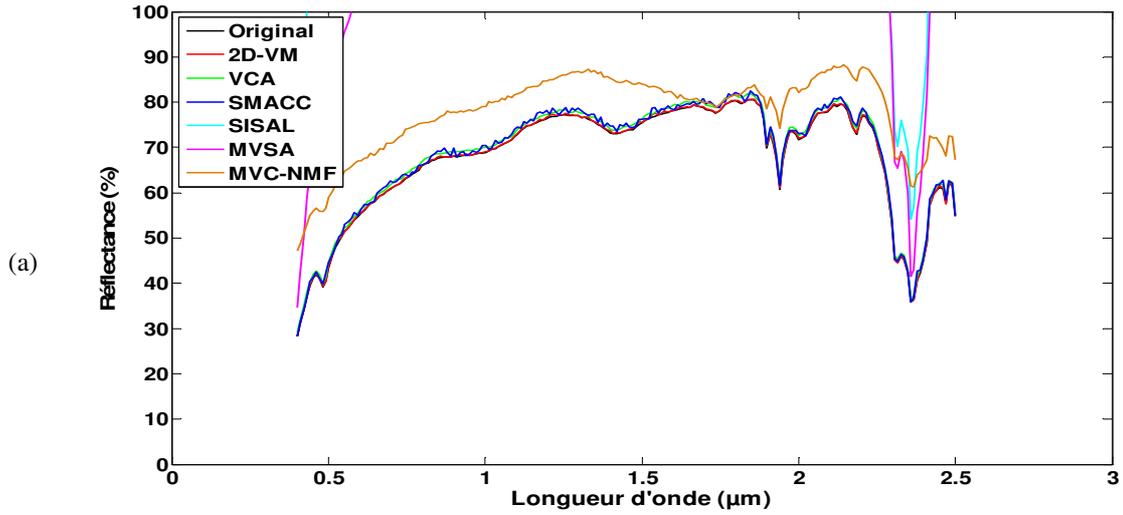
Les spectres extraits, à partir de la première image hyperspectrale synthétique, par notre méthode et les autres méthodes de la littérature sont donnés en Fig. 5.2. De même, les spectres extraits, à partir de la deuxième image hyperspectrale synthétique, sont donnés en Fig. 5.3. L'erreur quadratique moyenne normalisée pour les spectres extraits, à partir de la première image hyperspectrale synthétique, est donnée dans Tab. 5.1. Dans Tab. 5.2., nous donnons l'erreur quadratique moyenne normalisée pour les spectres extraits, à partir de la seconde image hyperspectrale synthétique. Dans Tabs. 5.3 et 5.4, nous donnons, respectivement, l'angle spectral des spectres extraits de la première et la seconde image.

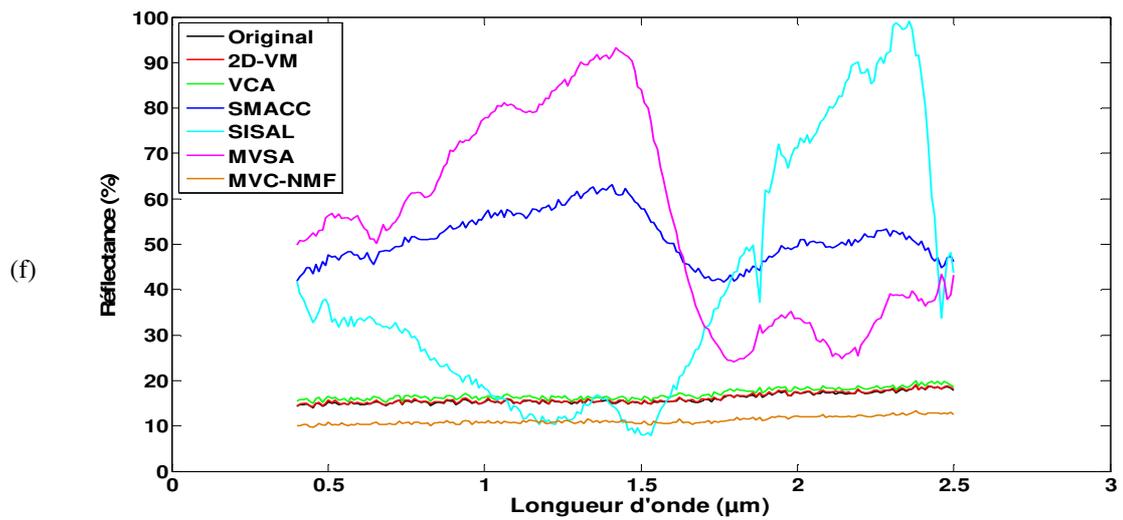
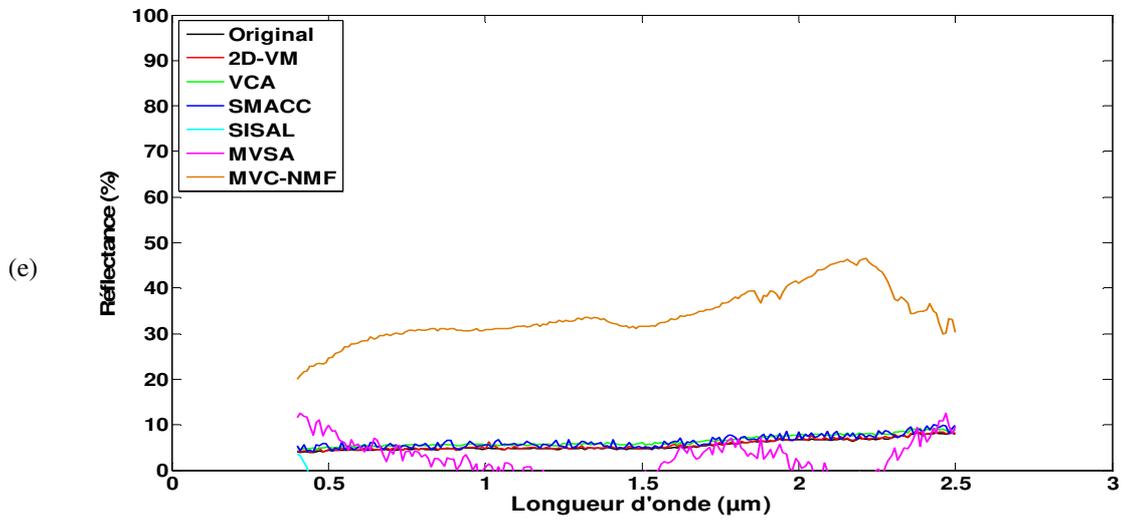
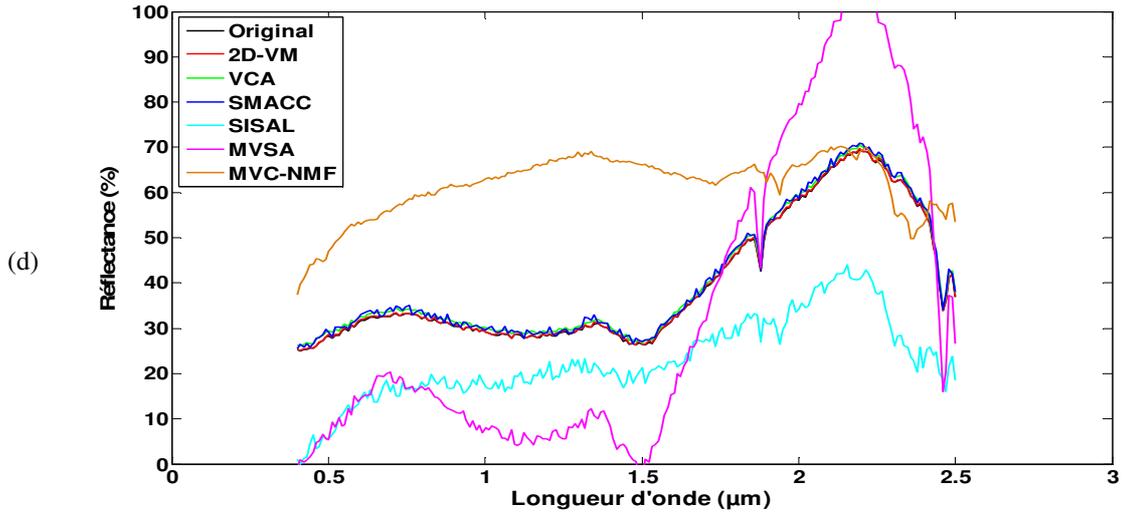


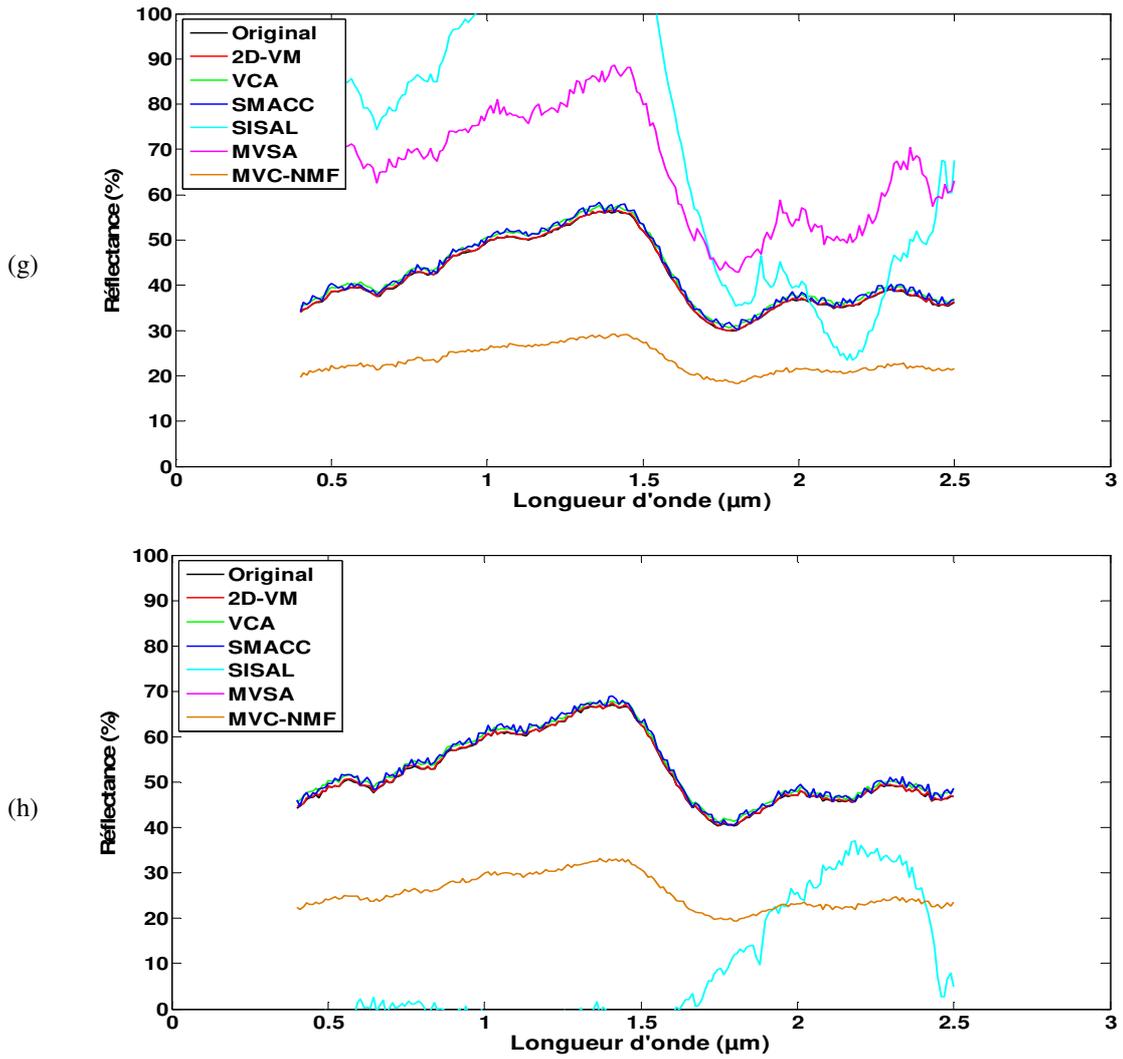




**Fig. 5.2.** Spectres extraits à partir de la première image hyperspectrale synthétique.  
 (a) endmember 1. (b) endmember 2. (c) endmember 3. (d) endmember 4. (e) endmember 5.  
 (f) endmember 6. (g) endmember 7. (h) endmember 8.







**Fig. 5.3.** Spectres extraits à partir de la deuxième image hyperspectrale synthétique.  
 (a) endmember 1. (b) endmember 2. (c) endmember 3. (d) endmember 4. (e) endmember 5.  
 (f) endmember 6. (g) endmember 7. (h) endmember 8.

Tab. 5.1. Erreur quadratique moyenne normalisée (%) pour les spectres extraits de la première image hyperspectrale synthétique.

Méthode	2D-VM	VCA	SMACC	SISAL	MVSA	MVC-NMF
Endmember 1	0,63	3,01	49,27	4,10	5,27	21,76
Endmember 2	0,65	3,35	3,73	21,03	14,75	38,90
Endmember 3	0,51	2,76	18,99	4,30	5,22	34,99
Endmember 4	0,43	2,42	2,54	7,60	10,93	65,81
Endmember 5	0,55	2,52	2,90	6,14	7,83	71,11
Endmember 6	0,46	2,54	2,93	8,41	9,71	28,70
Endmember 7	0,41	2,10	2,57	11,78	15,58	82,19
Endmember 8	0,78	3,88	3,96	10,38	12,73	50,41
Moyenne	0,55	2,82	10,86	9,22	10,25	49,23

Tab. 5.2. Erreur quadratique moyenne normalisée (%) pour les spectres extraits de la deuxième image hyperspectrale synthétique.

Méthode	2D-VM	VCA	SMACC	SISAL	MVSA	MVC-NMF
Endmember 1	0,30	1,46	1,66	130,44	106,14	16,16
Endmember 2	0,25	1,39	1,64	49,44	27,68	29,87
Endmember 3	0,58	3,22	3,46	15,96	58,03	51,31
Endmember 4	0,44	2,29	2,74	44,19	49,04	61,25
Endmember 5	4,70	17,09	18,77	591,07	89,91	516,86
Endmember 6	1,18	6,29	222,94	219,85	280,37	29,98
Endmember 7	0,39	2,37	2,62	95,87	59,22	44,82
Endmember 8	0,36	1,85	2,23	91,47	188,43	50,94
Moyenne	1,03	4,49	32,01	154,78	107,35	100,15

Tab. 5.3. Angle spectral (°) pour les spectres extraits de la première image hyperspectrale synthétique.

Méthode	2D-VM	VCA	SMACC	SISAL	MVSA	MVC-NMF
Endmember 1	0,26	0,47	29,51	1,61	2,59	4,79
Endmember 2	0,30	1,14	1,60	11,90	8,24	1,60
Endmember 3	0,21	0,69	9,22	0,73	1,23	15,07
Endmember 4	0,20	0,70	0,90	1,83	3,01	21,87
Endmember 5	0,24	0,76	1,03	1,65	2,42	37,56
Endmember 6	0,18	0,48	0,89	2,92	3,51	13,33
Endmember 7	0,19	0,67	0,96	3,28	4,49	49,77
Endmember 8	0,32	0,87	1,44	5,74	7,20	16,80
Moyenne	0,24	0,72	5,69	3,71	4,09	20,10

Tab. 5.4. Angle spectral (°) pour les spectres extraits de la deuxième image hyperspectrale synthétique.

Méthode	2D-VM	VCA	SMACC	SISAL	MVSA	MVC-NMF
Endmember 1	0,12	0,16	0,47	6,23	4,00	4,59
Endmember 2	0,10	0,12	0,41	8,42	3,17	2,94
Endmember 3	0,25	0,63	1,13	4,58	12,24	27,64
Endmember 4	0,18	0,47	0,81	11,19	25,55	18,77
Endmember 5	1,84	1,72	5,23	159,36	57,86	8,43
Endmember 6	0,42	0,64	8,13	31,34	24,67	1,02
Endmember 7	0,14	0,30	0,74	13,92	4,16	3,27
Endmember 8	0,13	0,29	0,64	64,84	172,47	0,68
Moyenne	0,40	0,54	2,19	37,48	38,01	8,42

Globalement, les Fig. 5.3 et Tabs. 5.1 et 5.3 montrent que notre méthode 2D-VM donne de bien meilleurs résultats, pour la première image hyperspectrale synthétique, par rapport aux méthodes de la littérature utilisées dans le cadre des travaux du présent chapitre. L'EQMN obtenue, en moyenne, par notre nouvelle méthode, est améliorée d'un "facteur" supérieur à 5, par rapport à l'EQMN obtenue, en moyenne, par la meilleure des méthodes de la littérature utilisées (la méthode VCA, selon les résultats obtenus dans nos tests). L'amélioration de l'angle spectral est de l'ordre de  $0,5^\circ$  ( $0,24^\circ$  en moyenne au lieu de  $0,72^\circ$ ) pour notre méthode comparée, toujours, à la méthode VCA.

Pour la seconde image hyperspectrale synthétique, les résultats obtenus (Fig. 5.4 et Tabs. 5.2 et 5.4) montrent, aussi, que la nouvelle méthode mise en place, est celle qui donne les meilleures performances. En effet, l'EQMN obtenue, en moyenne, par notre méthode 2D-VM, est améliorée d'un "facteur" supérieur à 4, par rapport à l'EQMN obtenue, en moyenne, par rapport à l'EQMN obtenue, en moyenne, par la méthode VCA (là aussi, selon nos tests, la méthode VCA est la meilleure des méthodes de la littérature utilisées). L'amélioration de l'angle spectral est de l'ordre de  $0,15^\circ$  pour notre méthode comparée à la méthode VCA.

Comme souligné ci-dessus, notre nouvelle méthode donne d'excellents résultats, et arrive à extraire correctement les spectres des endmembers, même si ceux-ci sont corrélés. Au contraire, les autres méthodes n'arrivent pas à extraire correctement les mêmes spectres. Aussi, les méthodes fondées sur l'inexistence de pixels purs dans

l'image (situation plus complexe que celle supposée ici, et naturellement nous avons espéré qu'elles fassent le "travail" correctement), échouent complètement.

## **5.4 Conclusion**

Dans ce chapitre, une nouvelle méthode non-supervisée, baptisée 2D-VM, a été proposée pour extraire des spectres à partir d'une image hyperspectrale de télédétection spatiale contenant des pixels purs. Cette méthode est basée sur un critère de variance, des signaux observés, de l'approche dite d'analyse en composantes parcimonieuses.

Comparée à différentes méthodes de la littérature, et selon les résultats obtenus dans nos travaux, la méthode proposée est très attractive pour extraire des spectres à partir des images fournies par les futurs capteurs hyperspectraux avec une très haute résolution spatiale, en plus de leur résolution spectrale.

Comme dans le Chapitre 4, nous terminons celui-ci en soulignant que la méthode proposée ici est aussi applicable, avec plus de restrictions (en considérant l'Hypothèse 3 du Chapitre 4), à une image multispectrale. Aussi, la nouvelle méthode décrite dans ce chapitre se propose d'estimer les spectres des endmembers, mais elle peut être aussi combinée avec les méthodes basées sur la contrainte de non-négativité, comme dans le Chapitre 4, pour l'estimation des cartes d'abondances.

## Références bibliographiques citées dans le Chapitre 5

- [1] F. Abrard, Y. Deville, "A time-frequency blind signal separation method applicable to underdetermined mixtures of dependent sources," *Signal Processing*, 85(7), pp. 1389-1403, 2005.
- [2] J. M. Bioucas-Dias, "A Variable Splitting Augmented Lagrangian Approach to Linear Spectral Unmixing," *In Proceedings of the First IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2009*, Grenoble, France, 2009.
- [3] J. M. Bioucas-Dias, A. Plaza, "An overview on hyperspectral unmixing: geometrical, statistical, and sparse regression based approaches," *In Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2011*, pp. 1135-1138. 2011.
- [4] R. N. Clark, G. A. Swayze, R. Wise, E. Livo, T. Hoefen, R. Kokaly, and S. J. Sutley, "USGS digital spectral library splib06a," *U.S. Geological Survey, Digital Data Series 231*, 2007, <http://speclab.cr.usgs.gov/spectral.lib06>.
- [5] P. Comon, C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*, Academic Press, 2010.
- [6] A. F. H. Goetz, G. Vane, J. E. Solomon, and B. N. Rock, "Imaging spectrometry for Earth remote sensing," *Science*, 228(4707), pp. 1147-1153, 1985.
- [7] J. Gruninger, A. J. Ratkowski, and M. L. Hoke, "The sequential maximum angle convex cone (SMACC) endmember model," *In Proceedings of the SPIE Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery X*, 5425, pp. 1-14, Orlando, Florida, USA, 2004.
- [8] A. Ifarraguerri, C. Chang, "Multispectral and Hyperspectral Image Analysis with Convex Cones," *IEEE Transactions on Geoscience and Remote Sensing*, 37(2), pp. 756-770, 1999.
- [9] A. Jourjine, S. Rickard, and Ö. Yilmaz, "Blind separation of disjoint orthogonal signals: Demixing N sources from 2 mixtures," *In Proceedings of the IEEE International Conference on Acoustic, Speech, and Signal Processing, ICASSP 2000*, pp. 2985-2988, 2000.

- [10] N. Keshava, J. F. Mustard, "Spectral Unmixing," *IEEE Signal Processing Magazine*, 19, pp. 44-57, 2002.
- [11] J. Li, J. M. Bioucas-Dias, "Minimum Volume Simplex Analysis: A Fast Algorithm to Unmix Hyperspectral Data," *In Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2008*, Boston, USA, 2008.
- [12] L. Miao, H. Qi, "Endmember Extraction from Highly Mixed Data Using Minimum Volume Constrained Nonnegative Matrix Factorization," *IEEE Transactions on Geoscience and Remote Sensing*, 45, pp. 765-777, 2007.
- [13] S. Michel, P. Gamet, and M. J. Lefevre-Fonollosa, "HYPXIM – A hyperspectral satellite defined for science, security and defence users," *In Proceedings of the Third IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2011*, Lisbon, Portugal, 2011.
- [14] Y. Moudden, J. Bobin, "Hyperspectral BSS Using GMCA With Spatio-Spectral Sparsity Constraints," *IEEE Transactions on Image Processing*, 20(3), pp. 872-879, 2011.
- [15] J. M. P. Nascimento, J. M. Bioucas-Dias, "Vertex Component Analysis: A Fast Algorithm to Unmix Hyperspectral Data," *IEEE Transactions on Geoscience and Remote Sensing*, 43(4), pp. 898-910, 2005.
- [16] M. Parente, A. Plaza, "Survey of geometric and statistical unmixing algorithms for hyperspectral images," *In Proceedings of the Second IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2010*, Reykjavik, Iceland, 2010.
- [17] J. Plaza, E. M. T. Hendrix, I. Garcia, G. Martin, and A. Plaza, "On endmember Identification in Hyperspectral Images Without Pure Pixels: A Comparison of Algorithms," *Journal of Mathematical Imaging and Vision*, 2011, DOI 10.1007/s10851-011-0276-0.

## CHAPITRE 6

### EXTRACTION DE SPECTRES A PARTIR D'UNE IMAGE

### HYPERSPECTRALE SANS PIXELS PURS, COMBINEE AVEC UNE

### IMAGE MULTISPECTRALE AVEC PIXELS PURS

---

*Résumé* - Dans ce sixième et dernier chapitre, nous proposons une nouvelle méthode pour l'extraction de spectres à partir d'une image hyperspectrale de télédétection spatiale, sans la présence de pixels purs dans cette dernière, combinée avec une image multispectrale, qui elle contient des pixels purs. Cette méthode est basée sur un concept géométrique, et est fondée sur la factorisation en matrices non-négatives, couplée avec les moindres carrés non-négatifs. Dans le présent chapitre nous exposons l'intérêt et les différentes étapes de l'approche méthodologique adoptée pour atteindre notre objectif. Par la suite, nous présentons des résultats expérimentaux sur des données synthétiques. Nous terminons ce dernier chapitre par une conclusion.

---

## DANS CE CHAPITRE

6.1. Introduction	157
6.2. Approche méthodologique proposée	158
6.2.1. Intérêt de l'approche proposée	158
6.2.2. Méthode d'extraction	158
6.3. Résultats expérimentaux	162
6.3.1. Données utilisées	162
6.3.2. Résultats et discussion	164
6.4. Conclusion	168
Références bibliographiques citées dans le Chapitre 6	169

## 6.1 Introduction

Nous commençons ce chapitre en rappelant que l'observation de la Terre par l'utilisation de l'imagerie hyperspectrale est largement utilisée ces dernières années. La classification (qui consiste à assigner chaque pixel de l'image à une classe d'occupation des sols [17]) est l'une des techniques les plus largement considérée en matière de traitement des images hyperspectrales. Or, et comme déjà expliqué auparavant, un pixel d'une image hyperspectrale est souvent constitué de plusieurs éléments purs (les endmembers) [7]. Le démixage spectral linéaire (*linear spectral unmixing*) est une approche attrayante dans ce cadre, puisqu'elle a pour objectif de décomposer linéairement chaque vecteur spectral associé à un pixel d'une image hyperspectrale en une collection de spectres des endmembers présents dans le pixel considéré, et un ensemble d'abondances correspondantes [7].

Nous rappelons aussi que la première étape du processus de démixage spectral linéaire est l'étape d'extraction des spectres des endmembers. Cette étape est liée au problème d'Identification Aveugle des Mélanges (IAM) (*Blind Mixture Identification (BMI)*), et qui fait partie de l'approche dite de Séparation Aveugle de Sources (SAS) (*Blind Source Separation (BSS)*) [5]. Les spectres extraits peuvent être ensuite utilisés pour décomposer linéairement la scène observée en un ensemble de cartes d'abondances. Ainsi, les méthodes développées jusqu'à présent [2, 15, 16], ont pour objectif de retrouver, à partir seulement des spectres observés, les spectres des endmembers et leurs abondances dans toute l'image utilisée. Nous rappelons qu'il existe une première catégorie de méthodes qui font l'hypothèse de l'existence de pixels purs dans l'image manipulée (par exemple, les méthodes SMACC [6] et VCA [14]). Bien entendu, la deuxième catégorie regroupe les méthodes n'exploitant pas l'hypothèse d'existence de pixels purs (les plus populaires et les plus performantes d'entre elles sont les méthodes MVC-NMF [13], MVSA [11], et SISAL de J. M. Bioucas-Dias [1]).

Dans ce contexte, nous proposons dans ce sixième chapitre une nouvelle méthode pour l'extraction des spectres des endmembers, à partir d'une image hyperspectrale qui peut être fortement mélangée (c'est-à-dire, ne comportant aucun

pixel pur), combinée avec une image multispectrale, de très haute résolution spatiale, de la même scène, contenant, ainsi, nécessairement des pixels purs pour chacun des endmembers présents dans la scène observée. Notre nouvelle méthode est basée sur la Factorisation en Matrices Non-négatives (FMN) (*Non-negative Matrix Factorization (NMF)*) [4], couplée avec les Moindres Carrés Non-négatifs (MCN) (*Non-negative Least squares (NLS)*) [8].

## 6.2 Approche méthodologique proposée

### 6.2.1 Intérêt de l'approche proposée

Comme introduit ci-dessus, la méthode proposée dans le présent chapitre a pour objectif d'extraire des spectres des endmembers présents dans une scène imagée par un capteur hyperspectral de moyenne résolution spatiale, en utilisant en même temps une image multispectrale, de très haute résolution spatiale, de la même scène. Ainsi, l'image hyperspectrale, de moyenne résolution spatiale, peut ne pas contenir de pixels purs pour chacun des endmembers (image hyperspectrale fortement mélangée). Par contre, l'image multispectrale, de très haute résolution spatiale, contient pour chacun des endmembers des pixels purs.

Par conséquent, la nouvelle méthode proposée tire avantage de la richesse spectrale de l'image hyperspectrale d'une part, et de l'information spatiale issue de l'image multispectrale d'autre part. Cela, peut être considéré comme une sorte de fusion de deux types d'images issues de capteurs différents, embarqués, soit sur la même plateforme, soit sur deux plateformes différentes.

### 6.2.2 Méthode d'extraction

La méthode proposée est basée sur la FMN proposée par D. D. Lee et H. S. Seung [9, 10]. Nous rappelons que la FMN permet de décomposer toute matrice non-négative  $X$  de dimension  $N \times K$ , en un produit de deux matrices non-négatives  $\hat{A}$  et  $\hat{S}$  de dimensions respectives  $N \times L$  et  $L \times K$ . Ainsi, nous obtenons l'approximation suivante :

$$X \approx \hat{A} \hat{S}. \quad (6.1)$$

Notons ici, que cette dernière approximation correspond rigoureusement au modèle (1.9) du Chapitre 1. La FMN est très facile d'utilisation et d'implémentation. Dans [12], C. J. Lin propose une méthode itérative pour obtenir l'approximation (6.1). Cette méthode consiste à utiliser des règles de mise à jour, basées sur la projection du gradient, afin de minimiser la distance Euclidienne suivante :

$$D_F(X, \hat{A} \hat{S}) = \frac{1}{2} \|X - \hat{A} \hat{S}\|_F^2. \quad (6.2)$$

La FMN est très sensible à son initialisation : elle ne fournit pas toujours une solution unique. Pour contourner ce problème d'initialisation de la FMN, nous utilisons l'information issue de l'image multispectrale de très haute résolution spatiale, et les MCN dans notre méthode que nous détaillons ci-après.

Supposons que les  $\lambda_{n=1\dots N}$  représentent les longueurs d'ondes utilisées dans l'image hyperspectrale, et les  $\zeta_{t=t_1\dots t_M}$  représentent les longueurs d'ondes utilisées dans l'image multispectrale, avec  $t_1\dots t_M \in \{1\dots N\}$ . Ainsi,  $B = [b_{ij}]$  est une matrice contenant  $M$  lignes ( $M$  est le nombre de bandes spectrales utilisées dans l'image multispectrale, naturellement  $M \ll N$ ) et  $L$  colonnes. Chaque colonne de cette matrice représente un "spectre multispectral" d'un endmember. Grâce à la résolution spatiale de l'image multispectrale, les spectres multispectraux des endmembers peuvent être sélectionnés (d'une manière automatique (méthodes proposées dans les Chapitres 4 et 5) ou manuellement) à partir de l'image multispectrale.

Chacun des spectres multispectraux est ensuite inter/extrapolé, en utilisant par exemple une approximation "spline cubique", pour obtenir des spectres hyperspectraux inter/extrapolés, avec  $N$  échantillons ( $N$  bandes spectrales).

Pour satisfaire la contrainte de non-négativité nécessaire pour la FMN, les valeurs inter/extrapolées négatives obtenues sont remplacées par zéro (ou dans des cas

pratiques, par une très petite valeur strictement positive  $\varepsilon$ ). Ainsi, nous obtenons une nouvelle matrice non-négative, qu'on note  $B' = [b'_{nj}]$  de dimension  $N \times L$ . Chaque colonne de cette matrice représente un spectre hyperspectral inter/extrapolé qui est une approximation grossière du spectre d'un endmember.

La matrice  $B'$  est ensuite utilisée comme initialisation de la matrice  $\hat{A}$  dans la FMN (c'est-à-dire,  $\hat{A}^{(0)} = B'$ ). Pour éviter une initialisation aléatoire, dans la FMN, de la matrice  $\hat{S}$ , nous utilisons les MCN pour obtenir une initialisation  $\hat{S}^{(0)}$  de cette dernière. Nous rappelons que les MCN introduits par C. L. Lawson et R. J. Hanson [8] résolvent le problème matriciel suivant :

$$\text{Minimiser } \|\hat{A}^{(0)} \hat{s}^{(0)} - x\|, \text{ sous la contrainte } \hat{s}^{(0)} \geq 0. \quad (6.3)$$

Dans cette étape, les MCN sont appliqués séparément sur chaque pixel de l'image hyperspectrale. Dans (6.3),  $\hat{A}^{(0)}$  est la matrice  $B'$  définie précédemment,  $x$  représente le vecteur spectral d'un pixel de l'image hyperspectrale, et  $\hat{s}^{(0)}$  est l'estimation du vecteur associé au pixel considéré.

Avant de lancer les règles de mise à jour, basées sur la projection du gradient, de la FMN, nous construisons les deux matrices constantes suivantes (de dimensions  $N \times L$ ) :  $C1 = [c1_{nj}]$  et  $C2 = [c2_{nj}]$ . Les termes de ces deux matrices sont définis comme suit :

$$c1_{nj} = \begin{cases} 1 & \text{si } n = t_1 \dots t_M, \forall j \\ 0 & \text{ailleurs} \end{cases}, \forall j \quad \text{et} \quad c2_{nj} = \begin{cases} 0 & \text{si } n = t_1 \dots t_M, \forall j \\ 1 & \text{ailleurs} \end{cases}. \quad (6.4)$$

Ces deux matrices sont utilisées après chaque itération de l'algorithme de la FMN pour ajuster la matrice  $\hat{A}$ , après sa mise à jour par les règles de la FMN. Cet ajustement est réalisé selon la manière suivante :

$$\hat{A} \leftarrow C1 \cdot B' + C2 \cdot \hat{A}, \quad (6.5)$$

où  $A \cdot B$  représente la multiplication matricielle élément par élément.

Cet ajustement "oblige" les spectres hyperspectraux à prendre, à chaque itération de la FMN, les mêmes valeurs que les spectres multispectraux aux longueurs d'ondes  $\xi_i$ . Cela permettra, sans doute, une meilleure approximation des spectres hyperspectraux désirés.

La contrainte de somme unitaire des abondances formulée dans l'Eq. (1.10) du Chapitre 1, est prise en considération par les MCN et la FMN, en utilisant une technique simple et efficace : nous augmentons les matrices  $X$  et  $B'$  par une ligne contenant une constante strictement positive  $\delta$ . Les MCN prennent ces deux matrices étendues comme entrées. Aussi, à chaque itération de l'algorithme de la FMN, après mise à jour et ajustement de  $\hat{A}$ , les valeurs de la dernière ligne de cette matrice sont remplacées par  $\delta$ .

Enfin, après la fin de l'algorithme de FMN avec les différentes étapes citées ci-dessus, la dernière ligne de la matrice approximée  $\hat{A}$  est enlevée. Les colonnes de la matrice obtenue représentent, ainsi, les spectres hyperspectraux désirés.

*Résumé de la méthode proposée :*

- 1- Sélection manuelle ou automatique, sur l'image multispectrale de très haute résolution spatiale, des spectres multispectraux des endmembers ;
- 2- Calcul de la matrice initiale  $B'$  par une inter/extrapolation des spectres multispectraux, et remplacement des valeurs négatives obtenues par une très petite valeur positive  $\varepsilon$  ;
- 3- Augmentation des deux matrices  $X$  et  $B'$  par une ligne contenant une valeur constante  $\delta$  ;
- 4- Calcul de la matrice initiale  $\hat{S}^{(0)}$  par l'utilisation des MCN avec comme entrées les matrices étendues de  $X$  et  $B'$  ;
- 5- Initialisation de l'algorithme de FMN par les deux matrices  $B'$  et  $\hat{S}^{(0)}$  ;
- 6- Lancement de l'algorithme de FMN : après la mise à jour d' $\hat{A}$  par l'itération définie dans [12],  $\hat{A}$  est ajustée de la manière suivante :  $\hat{A} \leftarrow C1 \cdot B' + C2 \cdot \hat{A}$ , ensuite la dernière ligne de la matrice ajustée  $\hat{A}$  est remplacée par la valeur  $\delta$  ;

- 7- Suppression de la dernière ligne (contenant la valeur  $\delta$ ) de la matrice approximée finale d' $\hat{A}$ . Les colonnes de cette dernière matrice représentent les estimées des spectres hyperspectraux désirés.

L'évaluation des performances de la méthode proposée, appliquée à des données synthétiques, est réalisée par l'utilisation de l'Angle Spectral (SA) (*Spectral Angle Mapper (SAM)*) entre les spectres originaux et les spectres extraits. Aussi, le critère basé sur l'Erreur Quadratique Moyenne Normalisée (EQMN) (*Normalized Mean Square Error (NMSE)*), entre les spectres originaux et les spectres extraits, peut être utilisé pour l'évaluation des performances de la méthode proposée. Ces deux critères sont ceux définis dans la Section 2.4 du Chapitre 2.

### 6.3 Résultats expérimentaux

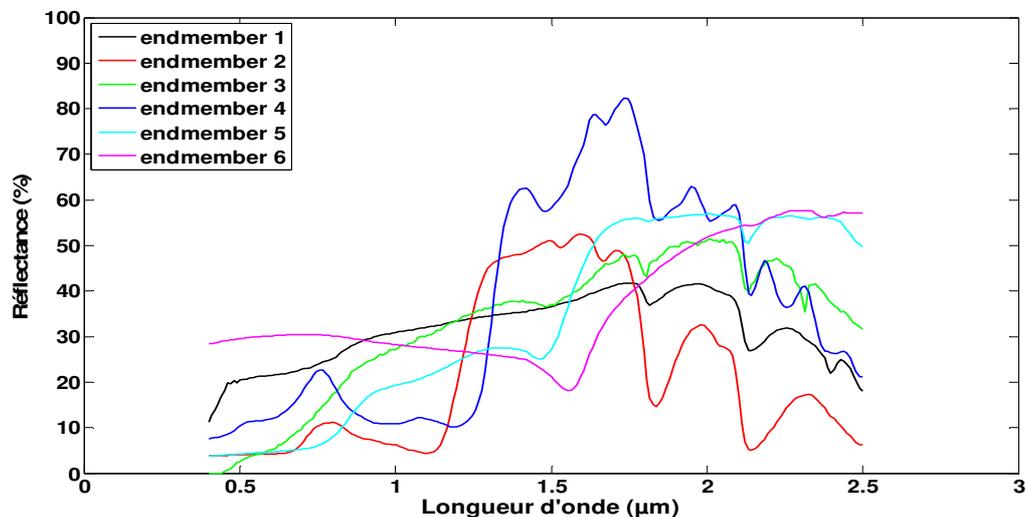
Des expériences, basées sur des données synthétiques mais réalistes, sont effectuées pour l'évaluation des performances de la méthode proposée et de cinq méthodes de la littérature.

#### 6.3.1 Données utilisées

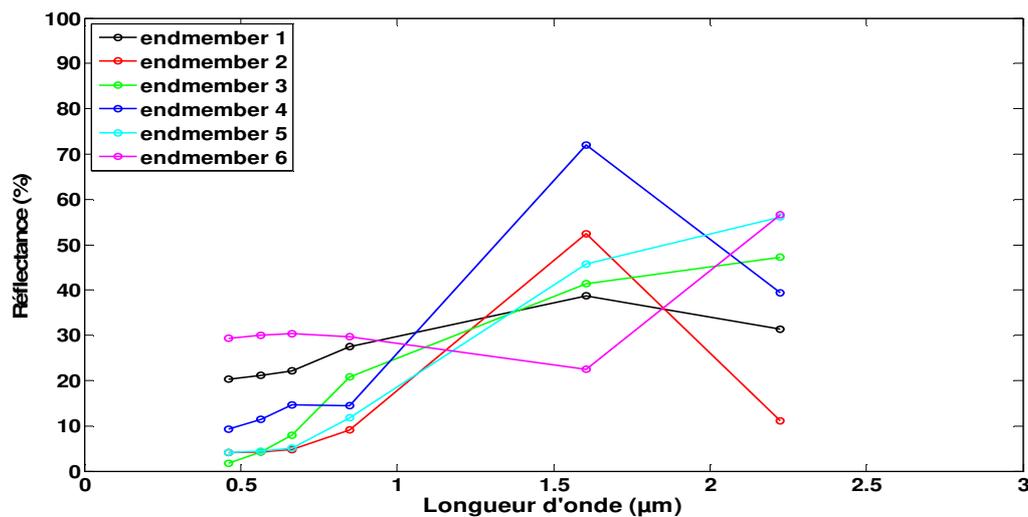
Six spectres (six endmembers) sont aléatoirement sélectionnés à partir de la bibliothèque spectrale compilée par *United States Geological Survey (USGS)*, et mesurés de 0,4 à 2,5  $\mu\text{m}$  [3] (Fig. 6.1(a)). Ces spectres hyperspectraux sont ensuite utilisés pour générer (selon l'Eq. (1.9) du Chapitre 1) une image hyperspectrale synthétique fortement mélangée. Cette image, de dimension 100x100 pixels, est créée en utilisant six cartes d'abondances (Fig. 6.2). Les cartes d'abondances sont prétraitées de telle sorte qu'on obtient des pixels fortement mélangés (chacun des pixels obtenus est au maximum à 50 % de pureté), vérifiant la contrainte de somme unitaire.

Des spectres multispectraux (avec six longueurs d'ondes) des mêmes endmembers sont extraits des spectres hyperspectraux (Fig. 6.1(b)). Les longueurs d'ondes choisies (0,48 - 0,56 - 0,66 - 0,84 - 1,60 et 2,22  $\mu\text{m}$ ) sont celles généralement

utilisées en imagerie multispectrale de télédétection spatiale (telles que les images multispectrales issues du capteur ETM+ ou TM des satellites Landsat).



(a)



(b)

Fig. 6.1. Spectres originaux. (a) Spectres hyperspectraux. (b) Spectres multispectraux.

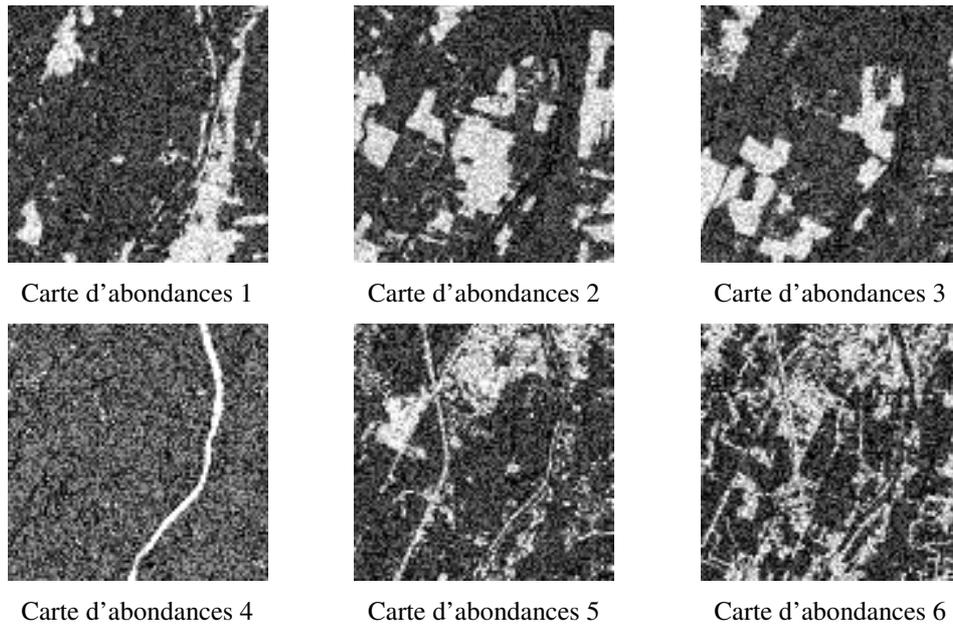
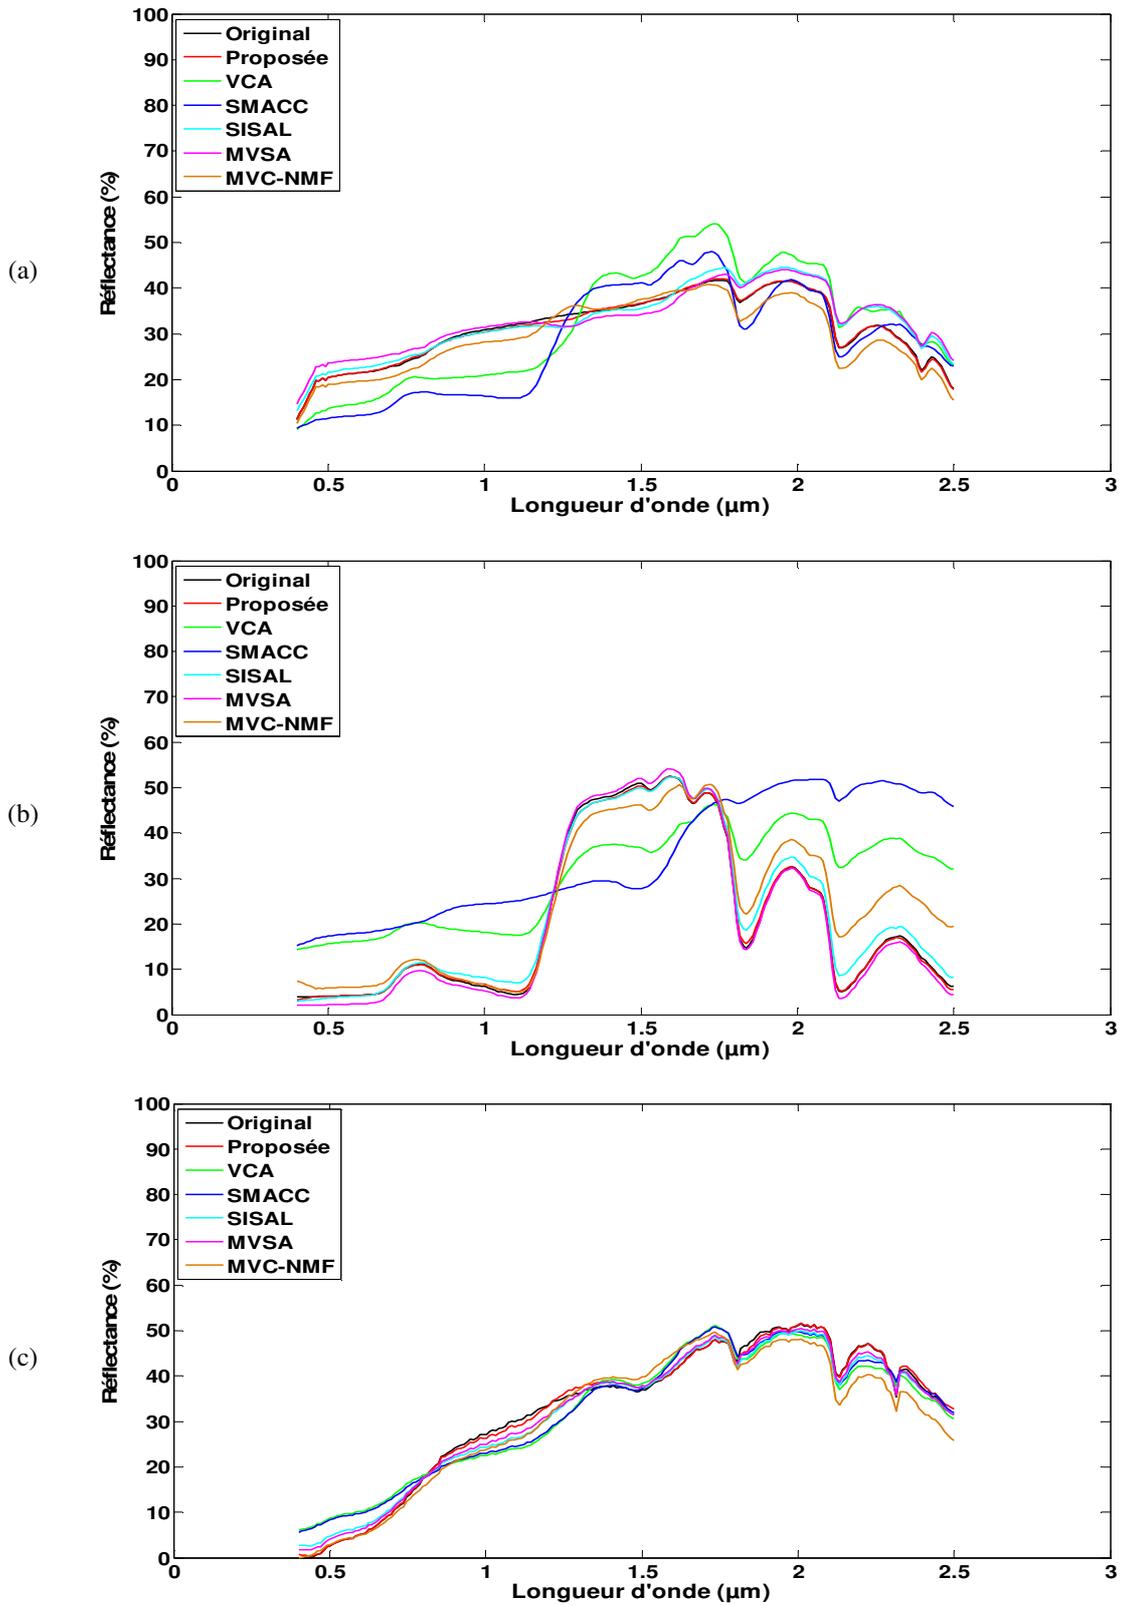


Fig. 6.2. Cartes d'abondances utilisées pour la création de l'image hyperspectrale synthétique.

### 6.3.2 Résultats et discussion

La méthode proposée est appliquée à l'image hyperspectrale synthétique, et en utilisant en même temps les spectres multispectraux. En plus, les méthodes : VCA [14], SMACC [6], SISAL [1], MVSA [11], et MVC-NMF [13] sont aussi appliquées sur l'image hyperspectrale synthétique pour permettre une comparaison. Notons ici, que ces méthodes ne sont appliquées qu'à l'image hyperspectrale : c'est-à-dire sans l'utilisation des spectres multispectraux.

Les spectres extraits par notre méthode et les autres méthodes de la littérature sont donnés dans Fig. 6.3. L'erreur quadratique moyenne normalisée pour les spectres extraits est donnée dans Tab. 5.1. Dans Tab. 5.2., nous donnons l'angle spectral des spectres extraits.



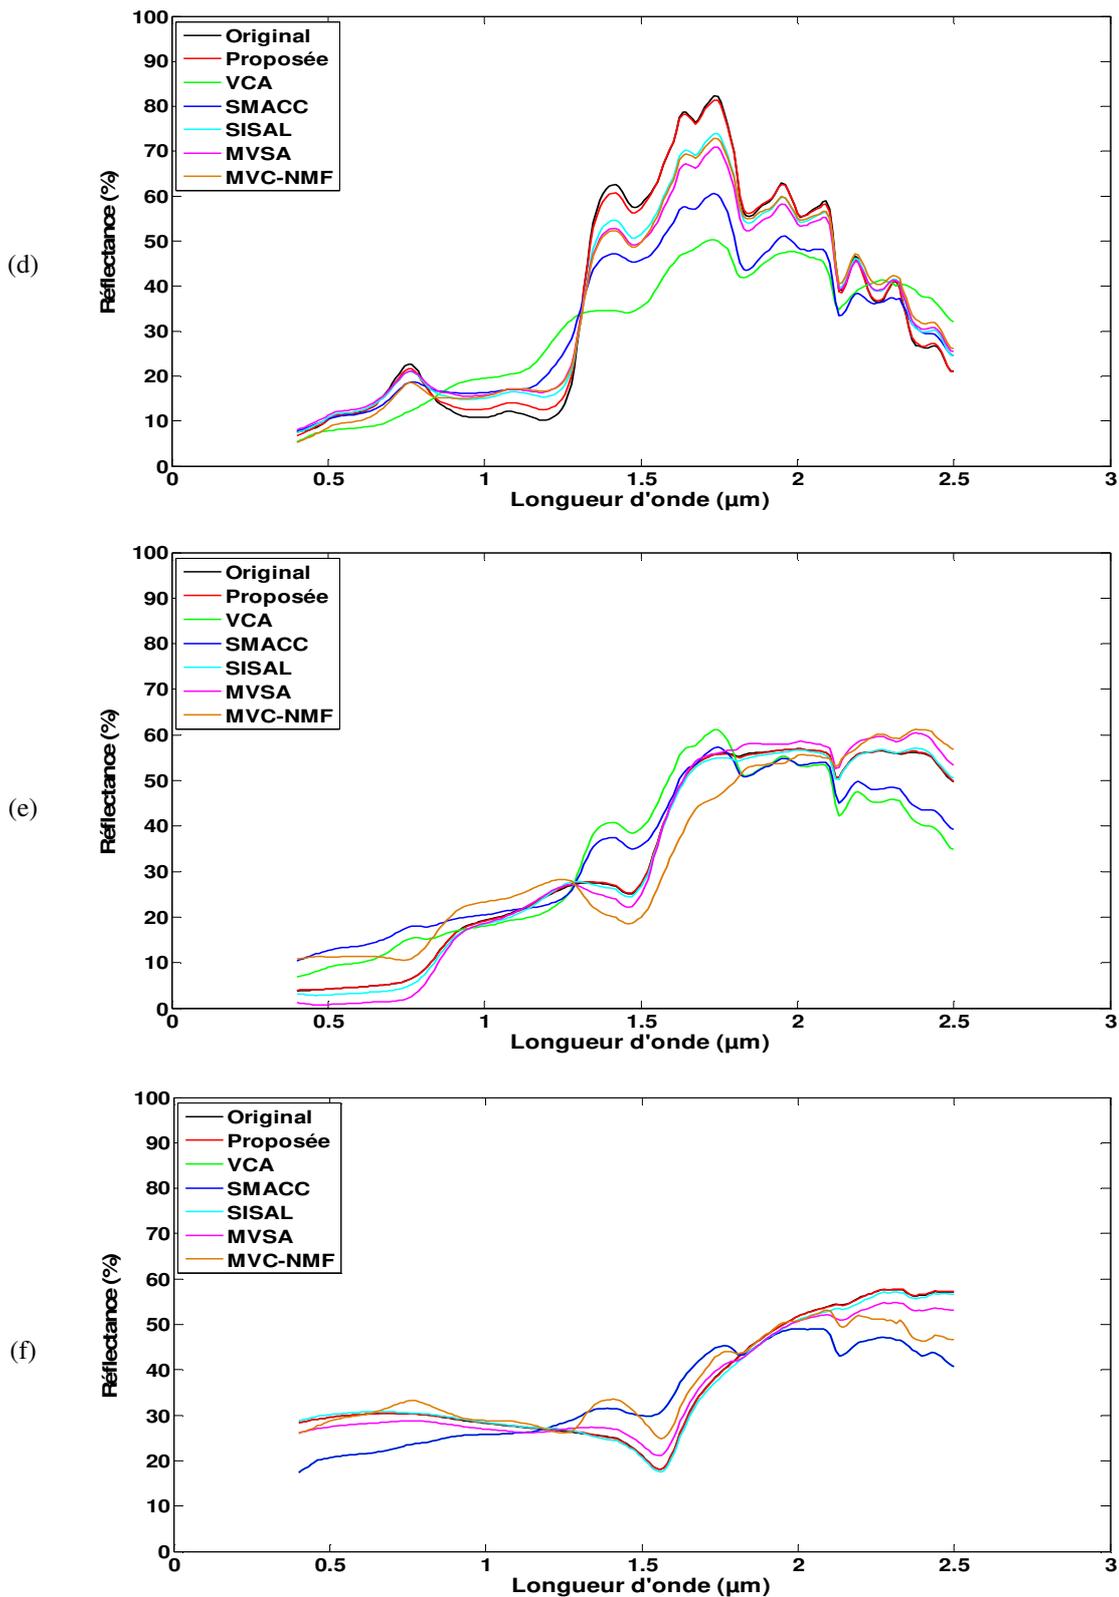


Fig. 6.3. Spectres extraits. (a) endmember 1. (b) endmember 2. (c) endmember 3.  
 (d) endmember 4. (e) endmember 5. (f) endmember 6.

Tab. 6.1. Erreur quadratique moyenne normalisée (%) pour les spectres extraits.

Méthode	Proposée	VCA	SMACC	SISAL	MVSA	MVC-NMF
Endmember 1	1,10	20,93	24,98	7,84	8,89	7,98
Endmember 2	1,60	46,95	62,36	6,83	4,38	20,97
Endmember 3	1,73	10,58	9,28	5,22	3,76	9,99
Endmember 4	2,37	45,31	27,43	10,29	13,62	12,57
Endmember 5	0,35	20,08	17,7	2,10	6,01	14,74
Endmember 6	0,28	21,83	21,83	1,67	5,48	12,01
Moyenne	1,24	27,61	27,26	5,66	7,02	13,04

Tab. 6.2. Angle spectral (°) pour les spectres extraits.

Méthode	Proposée	VCA	SMACC	SISAL	MVSA	MVC-NMF
Endmember 1	0,62	11,85	13,66	3,82	4,52	3,18
Endmember 2	0,87	27,96	38,51	3,73	2,48	11,98
Endmember 3	0,99	5,76	5,12	2,58	1,98	4,84
Endmember 4	1,34	17,07	8,94	4,68	5,92	6,00
Endmember 5	0,20	11,19	9,82	1,13	3,18	8,36
Endmember 6	0,16	10,81	10,81	0,77	2,51	6,76
Moyenne	0,70	14,11	14,48	2,79	3,43	6,85

Globalement, Fig. 6.3 et Tabs. 6.1 et 6.2 montrent que la méthode proposée est plus performante que les méthodes de la littérature utilisées dans le cadre des travaux du présent chapitre. L'EQMN obtenue, en moyenne, par notre nouvelle méthode, est améliorée d'un "facteur" proche de 5, par rapport à l'EQMN obtenue, en moyenne, par la meilleure des méthodes de la littérature utilisées (la méthode SISAL, selon les résultats obtenus dans nos tests). L'amélioration de l'angle spectral est supérieure à 2° (0,70° contre 2,79°) pour notre méthode comparée, toujours, à la méthode SISAL.

Comme souligné ci-dessus, notre nouvelle méthode donne d'excellents résultats, et arrive à extraire correctement les spectres des endmembers. Au contraire, les autres méthodes, particulièrement les méthodes fondées sur l'hypothèse d'inexistence de pixels purs, ont "du mal" à extraire correctement les mêmes spectres. En effet, ces méthodes arrivent à extraire "la forme" des spectres, mais avec des erreurs d'estimation des réflectances, ce qui peut poser certains problèmes pour l'identification des endmembers, si ces derniers appartiennent à la même "grande" classe d'occupation des sols. Ces erreurs d'estimation des réflectance sont significativement réduites par notre méthode, et cela est probablement dû à l'ajustement effectué par l'utilisation des spectres multispectraux. Aussi, les résultats obtenus montrent que les méthodes VCA et

SMACC n'arrivent pas du tout à extraire les spectres hyperspectraux des endmembers. Cela n'est pas vraiment une surprise, puisque ces dernières méthodes sont conçues pour fonctionner avec des images contenant des pixels purs, ce qui n'est pas le cas ici.

## **6.4 Conclusion**

Dans ce chapitre, une nouvelle méthode a été proposée pour extraire des spectres hyperspectraux à partir d'une image hyperspectrale de télédétection spatiale ne contenant pas de pixels purs, combinée avec une image multispectrale, de très haute résolution spatiale, contenant des pixels purs. Cette méthode est basée sur la factorisation en matrices non-négatives couplée avec les moindres carrés non-négatifs.

Comparée à différentes méthodes de la littérature appliquées seulement à l'image hyperspectrale (sans utilisation de l'image multispectrale), et selon les résultats obtenus dans nos travaux, la méthode proposée est très performante, et très attractive pour extraire des spectres à partir des images fournies par les capteurs hyperspectraux actuels, à condition de les combiner avec des images multispectrales à très haute résolution spatiale.

## Références bibliographiques citées dans le Chapitre 6

- [1] J. M. Bioucas-Dias, "A Variable Splitting Augmented Lagrangian Approach to Linear Spectral Unmixing," *In Proceedings of the First IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2009*, Grenoble, France, 2009.
- [2] J. M. Bioucas-Dias, A. Plaza, "An overview on hyperspectral unmixing: geometrical, statistical, and sparse regression based approaches," *In Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2011*, pp. 1135-1138. 2011.
- [3] R. N. Clark, G. A. Swayze, R. Wise, E. Livo, T. Hoefen, R. Kokaly, and S. J. Sutley, "USGS digital spectral library splib06a," *U.S. Geological Survey, Digital Data Series 231*, 2007, <http://speclab.cr.usgs.gov/spectral.lib06>.
- [4] A. Cichocki, R. Zdunek, A. H. Phan, and S. I. Amari, *Nonnegative Matrix and Tensor Factorization: Applications to Exploratory Multi-way Data Analysis and Blind Source Separation*, John Wiley & Sons, 2009.
- [5] P. Comon, C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*, Academic Press, 2010.
- [6] J. Gruninger, A. J. Ratkowski, and M. L. Hoke, "The sequential maximum angle convex cone (SMACC) endmember model," *In Proceedings of the SPIE Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery X*, 5425, pp. 1-14, Orlando, Florida, USA, 2004.
- [7] N. Keshava, J. F. Mustard, "Spectral Unmixing," *IEEE Signal Processing Magazine*, 19, pp. 44-57, 2002.
- [8] C. L. Lawson, R. J. Hanson, *Solving Least Squares Problems*, SIAM, 1974.
- [9] D. D. Lee, H. S. Seung, "Learning the parts of objects by non-negative matrix factorization," *Nature*, 401, pp. 788-791, 1999.
- [10] D. D. Lee, H. S. Seung, "Algorithms for Non-Negative Matrix Factorization," *Advances in Neural Information Processing Systems*, 13, pp. 556-562, MIT Press 2001.

- [11] J. Li, J. M. Bioucas-Dias, "Minimum Volume Simplex Analysis: A Fast Algorithm to Unmix Hyperspectral Data," *In Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2008*, Boston, USA, 2008.
- [12] C. J. Lin, "Projected Gradient Methods for Non-negative Matrix Factorization," *Neural Computation*, 19, pp. 2756-2779, 2007.
- [13] L. Miao, H. Qi, "Endmember Extraction from Highly Mixed Data Using Minimum Volume Constrained Nonnegative Matrix Factorization," *IEEE Transactions on Geoscience and Remote Sensing*, 45, pp. 765-777, 2007.
- [14] J. M. P. Nascimento, J. M. Bioucas-Dias, "Vertex Component Analysis: A Fast Algorithm to Unmix Hyperspectral Data," *IEEE Transactions on Geoscience and Remote Sensing*, 43(4), pp. 898-910, 2005.
- [15] M. Parente, A. Plaza, "Survey of geometric and statistical unmixing algorithms for hyperspectral images," *In Proceedings of the Second IEEE Workshop on Hyperspectral Image and Signal Processing, WHISPERS 2010*, Reykjavik, Iceland, 2010.
- [16] J. Plaza, E. M. T. Hendrix, I. Garcia, G. Martin, and A. Plaza, "On endmember Identification in Hyperspectral Images Without Pure Pixels: A Comparison of Algorithms," *Journal of Mathematical Imaging and Vision*, 2011, DOI 10.1007/s10851-011-0276-0.
- [17] B. Tso, P. M. Mather, *Classification methods for remotely sensed data*, CRC Press, 2009.

# *CONCLUSION GENERALE ET PERSPECTIVES*

L'objectif principal de cette thèse a été de proposer de nouvelles approches méthodologiques pour l'analyse et le traitement des images de télédétection spatiale. Les solutions proposées sont basées sur le développement et l'utilisation de méthodes innovantes de l'approche dite de séparation aveugle de sources pour des applications en imagerie de télédétection spatiale. En effet, les contributions de cette thèse découlent de cette dernière approche, pour prendre en compte l'effet du mélange spectral dans les pixels des images de télédétection spatiale, et par conséquent, améliorer l'analyse et le traitement de ces dernières.

Après avoir fait un tour d'horizon, dans le premier chapitre, sur certaines notions élémentaires de la télédétection spatiale, et sur des généralités de la séparation aveugle de sources, nous avons présenté, dans ce même chapitre, deux modélisations des images selon la nomenclature de la séparation de sources. Dans le second chapitre, un panorama des méthodes concernées par cette thèse a été présenté. Nous avons exposé, dans un premier temps, les trois grandes catégories des méthodes de séparation de sources, à savoir les méthodes d'analyse en composantes indépendantes, les méthodes fondées sur la factorisation en matrices non-négatives, et celles de l'analyse en composantes parcimonieuses. Dans un deuxième temps, et toujours dans le second chapitre, les méthodes les plus populaires de démixage d'images de télédétection spatiale ont été décrites. Les motifs du choix d'une seule modélisation des images, ainsi que les critères de performances des approches méthodologiques mises en place, ont aussi été exposés dans ce deuxième chapitre.

Dans les quatre derniers chapitres, les contributions méthodologiques de cette thèse ont été abordées. Chaque chapitre de ces quatre derniers, a été consacré à une contribution de cette thèse.

Ainsi, le troisième chapitre a été dédié au prétraitement des images de télédétection spatiale par les méthodes les plus classiques de séparation de sources, en vue de la classification des pixels de ces images. Les méthodes utilisées sont celles basées sur l'analyse en composantes indépendantes et sur la factorisation en matrices non-négatives. Les résultats obtenus montrent que la combinaison des techniques

classiques de séparation de sources, utilisées comme des prétraitements sur les données brutes, avec un classifieur, est d'un apport significatif pour une meilleure reconnaissance des différents thèmes d'occupation des sols.

Dans le quatrième chapitre, deux nouvelles méthodes hybrides non-supervisées, baptisées 2D-Corr-NLS et 2D-Corr-NMF, ont été proposées pour extraire des cartes d'abondances à partir d'une image multispectrale de télédétection spatiale contenant des pixels purs. Ces deux nouvelles méthodes combinent une étape (basée sur un critère de corrélation, des signaux observés, de l'analyse en composantes parcimonieuses) de détection de zones de pixels purs, le clustering, et les méthodes utilisant les contraintes de non-négativité. Un avantage de ces deux méthodes, réside dans leur applicabilité au modèle de séparation sous-déterminé défini par une image multispectrale de télédétection spatiale. Comparées à une méthode populaire de la littérature (applicable elle aussi au modèle de séparation sous-déterminé), et selon les résultats obtenus, les deux nouvelles méthodes proposées sont très attractives pour démêler les images multispectrales de télédétection spatiale.

L'extraction de spectres hyperspectraux a été abordée dans les cinquième et sixième chapitres. Dans le cinquième chapitre, l'extraction des spectres a été effectuée à partir d'une image hyperspectrale contenant des pixels purs. Ainsi, une nouvelle méthode non-supervisée, baptisée 2D-VM, a été proposée pour atteindre notre objectif. Cette nouvelle méthode est basée sur le critère de la variance, des signaux observés, de l'analyse en composantes parcimonieuses. Comparée à différentes méthodes de la littérature, et selon les résultats obtenus, la méthode proposée est celle la plus performante et qui donne les meilleurs résultats. Dans le sixième et dernier chapitre, l'extraction des spectres a été effectuée à partir d'une image hyperspectrale ne contenant pas de pixels purs, mais combinée avec une image multispectrale, de très haute résolution spatiale, de la même scène, et contenant des pixels purs. Dans cette configuration, une nouvelle méthode, basée sur la factorisation en matrices non-négatives couplée avec les moindres carrés non-négatifs, a été proposée. Cette nouvelle méthode tire avantage de la richesse spectrale de l'image hyperspectrale d'une part, et de l'information spatiale issue de l'image multispectrale d'autre part. Notre nouvelle

méthode a été comparée à différentes méthodes de la littérature, appliquées seulement à l'image hyperspectrale, et les résultats obtenus montrent une nette supériorité de notre nouvelle méthode.

Les résultats obtenus dans cette thèse peuvent avoir un impact sur la suite des travaux de recherche à entreprendre dans l'avenir. Nous donnons dans ce qui suit quelques points susceptibles d'être abordés :

1. Prétraitement, par les méthodes de séparation de sources, d'autres types d'images (hyperspectrales, radars), en vue de la classification des pixels de ces dernières.
2. Extraction de cartes d'abondances à partir d'une image hyperspectrale contenant des pixels purs, par l'utilisation des méthodes proposées dans le quatrième chapitre.
3. Mise en place de nouvelles méthodes, fondées sur l'analyse en composantes indépendantes, pour l'extraction de cartes d'abondances à partir d'images hyperspectrales avec ou sans pixels purs. Ici, la contrainte d'indépendance statistique sera utilisée sur les cartes d'abondances deux à deux et non pas sur l'ensemble des cartes d'abondances.
4. Mise en place de nouvelles méthodes, fondées sur l'analyse en composantes parcimonieuses (avec de très faibles contraintes de parcimonie), pour l'extraction de spectres/cartes d'abondances à partir d'une image hyperspectrale ne contenant pas de pixels purs.
5. Utilisation des méthodes de séparation de sources, particulièrement celles basées sur la factorisation en matrices non-négatives, pour la fusion de différents types d'images : panchromatiques, multi/hyperspectrales, radars.

---

**Articles de revues internationales**

**M. S. Karoui**, Y. Deville, S. Hosseini, and A. Ouamri, "Blind spatial unmixing of multispectral images: New methods combining sparse component analysis, clustering and non-negativity constraints," *Pattern Recognition*, 45(12), pp. 4263-4278, 2012.

**Actes de conférences internationales à comité de lecture**

**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 Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS 2012*, Munich, Germany, 2012.

I. Meganem, Y. Deville, S. Hosseini, H. Carfantan, and **M. S. Karoui**, "Extraction of stellar spectra from dense fields in hyperspectral MUSE data cubes using non-negative matrix factorization," *In Proceedings of the Third IEEE Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, WHISPERS 2011*, Lisbon, Portugal, 2011.

**M. S. Karoui**, Y. Deville, S. Hosseini, and A. Ouamri, "Spatial sparsity-based blind source separation method including non-negative matrix factorization for multispectral image unmixing," (invited paper) *In Proceedings of the 10<sup>th</sup> IEEE International Workshop on Electronics, Control, Measurement and Signals, ECMS 2011*, Liberec, Czech Republic, 2011.

**M. S. Karoui**, Y. Deville, S. Hosseini, and A. Ouamri, "Traitement des données hyperspectrales par des méthodes de séparation aveugle de sources : faisabilité et perspectives," *In Proceedings 3<sup>ème</sup> Journées d'Animation Scientifique du réseau de télédétection de l'Agence Universitaire de la Francophonie, JAS AUF 2009*, Algiers, Algeria, 2009.

**M. S. Karoui**, A. Ouamri, Y. Deville, and S. Hosseini, "Processing of hyperspectral remote sensing data by blind source separation methods: feasibility," *In Proceedings of the 6<sup>th</sup> International Summer School on Signal Processing & its Applications, ISSSPA 2009 + First Workshop in Signal and Image Processing, WSIP 2009*, Oran, Algeria, 2009.

**M. S. Karoui**, Y. Deville, S. Hosseini, A. Ouamri, and D. Ducrot, "Improvement of remote sensing multispectral image classification by using independent component analysis," *In Proceedings of the First IEEE Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, WHISPERS 2009*, Grenoble, France, 2009.

**M. S. Karoui**, Y. Deville, S. Hosseini, A. Ouamri, and D. Ducrot, "Contribution of non-negative matrix factorization to the classification of remote sensing images," *In Proceedings of the SPIE Europe Remote Sensing Conference : Image and Signal Processing for Remote Sensing XIV*, SPIE vol. 7109 71090X, Cardiff, UK, 2008.

**AUTEUR :** Moussa Sofiane KAROUI

---

**TITRE :** Méthodes de séparation aveugle de sources et application à la télédétection spatiale

---

**SOUTENANCE :** Le 17 décembre 2012 à l'USTO MB (Algérie)

---

**NATURE DE LA THESE :** Thèse en cotutelle Franco-Algérienne

---

**PARTIE FRANÇAISE :**

**Université :** Université Toulouse III - Paul Sabatier.

**Ecole doctorale :** Mathématiques, Informatique et Télécommunications.

**Discipline ou spécialité :** Signal, Image, Acoustique & Optimisation.

**Unité de recherche :** Institut de Recherche en Astrophysique et Planétologie.

**Directeurs de thèse :** Yannick Deville & Shahram Hosseini.

**PARTIE ALGERIENNE :**

**Université :** Université des Sciences et de la Technologie d'Oran - Mohamed Boudiaf.

**Ecole doctorale :** Nouvelles Technologies de l'Information et de la Communication, Signaux, Systèmes Intelligents et Robotique.

**Discipline ou spécialité :** Techniques de communication modernes.

**Laboratoire de recherche :** Laboratoire Signaux et Images.

**Directeur de thèse :** Abdelaziz Ouamri.

## RESUME

Cette thèse concerne la séparation aveugle de sources, qui consiste à estimer un ensemble de signaux sources inconnus à partir d'un ensemble de signaux observés qui sont des mélanges à paramètres inconnus de ces signaux sources.

C'est dans ce cadre que le travail de recherche de cette thèse concerne le développement et l'utilisation de méthodes linéaires innovantes de séparation de sources pour des applications en imagerie de télédétection spatiale.

Des méthodes de séparation de sources sont utilisées pour prétraiter une image multispectrale en vue d'une classification supervisée de ses pixels.

Deux nouvelles méthodes hybrides non-supervisées, baptisées 2D-Corr-NLS et 2D-Corr-NMF, sont proposées pour l'extraction de cartes d'abondances à partir d'une image multispectrale contenant des pixels purs. Ces deux méthodes combinent l'analyse en composantes parcimonieuses, le clustering et les méthodes basées sur les contraintes de non-négativité.

Une nouvelle méthode non-supervisée, baptisée 2D-VM, est proposée pour l'extraction de spectres à partir d'une image hyperspectrale contenant des pixels purs. Cette méthode est basée sur l'analyse en composantes parcimonieuses.

Enfin, une nouvelle méthode est proposée pour l'extraction de spectres à partir d'une image hyperspectrale ne contenant pas de pixels purs, combinée avec une image multispectrale, de très haute résolution spatiale, contenant des pixels purs. Cette méthode est fondée sur la factorisation en matrices non-négatives couplée avec les moindres carrés non-négatifs.

Comparées à des méthodes de la littérature, d'excellents résultats sont obtenus par les approches méthodologiques proposées.

**Mots-clés :** séparation aveugle de sources, imagerie multi/hyperspectrale de télédétection spatiale, démixage spectral/spatial, analyse en composantes indépendantes, analyse en composantes parcimonieuses, factorisation en matrices non-négatives, moindres carrés non-négatifs, classification.

## ABSTRACT

This thesis concerns the blind source separation problem, which consists in estimating a set of unknown source signals from a set of observed signals which are mixtures of these source signals, with unknown mixing coefficients.

In this thesis, we develop and use innovative linear source separation methods for applications in remote sensing imagery.

Source separation methods are used and applied in order to preprocess a multispectral image for a supervised classification of this image.

Two new unsupervised methods, called 2D-Corr-NLS and 2D-Corr-NMF, are proposed in order to extract abundance maps from a multispectral image with pure pixels. These methods are based on sparse component analysis, clustering and non-negativity constraints.

A new unsupervised method, called 2D-VM, is proposed in order to extract endmember spectra from a hyperspectral image with pure pixels. This method is based on sparse component analysis.

Also, a new method is proposed for extracting endmember spectra from a hyperspectral image without pure pixels, combined with a very high spatial resolution multispectral image with pure pixels. This method is based on non-negative matrix factorization coupled with non-negative least squares.

Compared to literature methods, excellent results are obtained by the proposed methodological approaches.

**Keywords:** blind source separation, remote sensing multi/hyperspectral imagery, spectral/spatial unmixing, independent component analysis, sparse component analysis, non-negative matrix factorization, non-negative least squares, classification.

## ملخص

هذه الأطروحة تتعلق بالفصل المكفوف للمصادر، والذي ينطوي على تقدير مجموعة غير معروفة من إشارات المصادر انطلاقاً من مجموعة من الإشارات الملحوظة والتي هي مزيج من إشارات المصادر.

في هذا الإطار، العمل البحثي لهذه الأطروحة يتعلق بتطوير واستخدام طرق مبتكرة للفصل الخطي للمصادر من أجل تطبيقات باستخدام صور الاستشعار عن بعد. طرق لفصل المصادر استخدمت من أجل تجهيز صورة متعددة الأطياف لتصنيفها الموجه.

طريقتان جديدتان غير موجّهتان تحملان اسم 2D-Corr-NLS و 2D-Corr-NMF اقترحتا من أجل استخراج خرائط التركيز انطلاقاً من صورة متعددة الأطياف تحتوي على بكسلات محضة. الطريقتان تجمع بين التحليل إلى عناصر متناثرة، التجميع و الطرق القائمة على القيود الغير سلبية.

طريقة جديدة غير موجّهة تحمل اسم 2D-VM اقترحت من أجل استخراج أطيف انطلاقاً من صورة جد متعددة الأطياف تحتوي على بكسلات محضة. الطريقة تستند على التحليل إلى عناصر متناثرة.

ايضاً، طريقة جديدة اقترحت من أجل استخراج اطيف من صورة جد متعددة الاطياف لا تحتوي على بكسلات محضة، مشتركة مع صورة متعددة الاطياف تحتوي على بكسلات محضة. و تستند هذه الطريقة الجديدة على التحليل إلى مصفوفات غير سلبية و على المربعات الصغرى الغير سلبية.

مقارنة مع الطرق الموجودة، تم الحصول على نتائج ممتازة باستعمال الطرق المنهجية المقترحة.

**كلمات المفتاح :** الفصل المكفوف للمصادر، صور الاستشعار عن بعد المتعددة/الجد متعددة الاطياف، الفصل الطيفي/الفضائي، التحليل إلى عوامل مستقلة، التحليل إلى عوامل متناثرة، التحليل إلى مصفوفات غير سلبية، المربعات الصغرى الغير سلبية، التصنيف.