الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Département : Génie Electrique Et Informatique Industrielle

Mémoire de Master

Filière : **Télécommunications**

Spécialité : **: Systèmes deTélécommunications et Réseaux**

Etablissement d'un état de l'art sur les méthodes de démélange spectral des images

Réalisé par

MAKHLOUF Chaimaa

Présent et soutenue publiquement le (02/07/2023)

Composition du Jury :

Présidente	Mme SID Akila	M.A.A	ENST
Promotrice	Mme CHOUAF Seloua	M.A.A	ENST
Examinatrice	Mme CHIALI Imane	M.C.B	ENST
Examinatrice	Mme REBAI Karima	M.C.A	ENST

Année universitaire 2022 –2023

Etablissement d'un état de l'art sur les méthodes de démélange spectral des images

MAKHLOUF Chaimaa, CHOUAF Seloua
Département Génie Électrique et Informatique Industrielle GEII
Ecole Nationale Supérieure de Technologies ENST
Alger, Algérie
Email: c_makhlouf@enst.dz , seloua.chouaf@enst.dz

***Résumé*—Cet article propose une revue de l'état de l'art sur les méthodes établies de démélange spectral des images. Il commence par présenter les notions fondamentales du démélange et introduit une classification des techniques traditionnelles, notamment les méthodes géométriques, statistiques et de régression, en mettant en évidence leurs avantages et limites. Des résultats issus d'études comparatives et des métriques d'évaluation sont également présentés. L'article met en évidence les avancées récentes, discute des défis existants et souligne l'importance du démélange spectral dans l'imagerie hyperspectrale avant de conclure.**

Mots-clés :démélange, VCA, N-FINDR, FCLS, NMF, PCA, PPI

I. Introduction

L'imagerie hyperspectrale est une technologie avancée qui permet de capturer des informations détaillées sur les propriétés spectrales des matériaux dans une scène. Avec des centaines de bandes spectrales, ces images offrent un potentiel énorme pour la caractérisation et l'analyse de diverses applications. Cependant, elles posent également des défis significatifs en raison des mélanges de matériaux présents dans les pixels de l'image.[1]

Le démélange spectral est une approche clé pour extraire des informations précises à partir d'images hyperspectrales. Il vise à identifier et à quantifier les matériaux purs qui composent chaque pixel, fournissant ainsi une estimation des proportions des différentes composantes spectrales dans l'image. Cette technique permet de résoudre le problème complexe du mélange spectral et ouvre la voie à de nombreuses applications pratiques.[2]

Dans de nombreux domaines, le démélange spectral est essentiel pour l'interprétation et l'exploitation des images hyperspectrales. Par exemple, dans le domaine de l'agriculture de précision, il permet de cartographier et de surveiller la santé des cultures, d'optimiser l'utilisation des ressources et de prédire les rendements. En matière d'environnement, il est utilisé pour la détection des pollutions, la surveillance des écosystèmes, la gestion des ressources en eau et la surveillance des changements climatiques. En défense et sécurité, le démélange spectral est crucial pour la détection des cibles, la reconnaissance des formes et la surveillance des zones sensibles.

Le démélange spectral trouve également des applications dans les sciences de la Terre, où il permet de caractériser les formations géologiques, d'étudier les processus géophysiques et de surveiller les changements environnementaux. En médecine et en biologie, il est utilisé pour l'imagerie médicale hyperspectrale, facilitant ainsi la détection précoce des anomalies et la caractérisation des tissus biologiques

Dans cet article, nous aborderons les principaux points liés au démélange spectral des images. Nous discuterons des différentes méthodes utilisées, de leurs avantages et limites, ainsi que des critères de comparaison pour guider la sélection de la méthode appropriée. Nous examinerons également les défis du démélange spectral et les perspectives futures, notamment le développement de modèles plus précis et l'utilisation de techniques d'apprentissage automatique avancées. Ce contenu permettra d'obtenir une vision d'ensemble du démélange spectral et de son importance dans divers domaines.

II. Techniques de démélange spectral

Lors de la classification des méthodes de démélange spectral en familles, il est important de prendre en compte plusieurs critères. Il convient de noter que certaines méthodes peuvent chevaucher plusieurs familles en fonction de leurs caractéristiques et de leur flexibilité. Ainsi, la classification des méthodes de démélange spectral nécessite une évaluation approfondie et l'analyse de plusieurs aspects pour les regrouper de manière précise et cohérente. Cela permet de mieux comprendre les différentes approches et de choisir la méthode la plus adaptée en fonction des objectifs et des contraintes de l'application.

Parmi ces critères, on peut citer :

Le Principe fondamental : Il s'agit du principe de base sur lequel repose la méthode. Par exemple, les méthodes basées sur la linéarité supposent une relation linéaire entre les signatures spectrales des matériaux et le spectre observé, tandis que les méthodes géométriques utilisent des concepts géométriques pour estimer les fractions.

L'Approche mathématique : Les méthodes peuvent utiliser des approches mathématiques différentes pour estimer les fractions de matériaux. Par exemple, certaines méthodes utilisent des techniques de régression, d'autres sont basées sur des modèles statistiques ou des principes physiques.

Les Contraintes et connaissances a priori : Certaines méthodes peuvent prendre en compte des contraintes spécifiques ou des connaissances a priori sur les matériaux ou les fractions. Par exemple, les méthodes basées sur la connaissance de l'abondance supposent des fractions constantes ou utilisent des endmembers purs prédéfinis.

L'Utilisation de l'information spatiale : Certains algorithmes intègrent également des informations spatiales dans le processus de démélange, en considérant des caractéristiques de voisinage ou des relations spatiales entre les pixels.

L'Approche supervisée ou non supervisée : Certaines méthodes nécessitent des informations d'étiquetage préalables pour les matériaux purs, tandis que d'autres sont capables de démélanger les fractions sans ces informations supplémentaires.

Complexité computationnelle : Les différentes méthodes peuvent varier en termes de complexité computationnelle et de ressources requises pour leur implémentation.

En considérant ces différents critères, il devient possible de mieux appréhender les méthodes de démélange spectral et de choisir celle qui convient le mieux à la problématique spécifique à laquelle on est confronté.

Dans cet article, nous avons choisi de classer les méthodes de démélange spectral dans des familles géométriques, statistiques et de régression. Ces méthodes regroupent des approches qui partagent des caractéristiques similaires et des principes fondamentaux communs.

A. *La famille des méthodes géométriques*

Exploitent les relations géométriques entre les signatures spectrales des matériaux et le spectre observé pour effectuer le démélange. Elles se basent sur l'idée que les signatures spectrales des matériaux purs peuvent être représentées comme des points dans un espace vectorie [3] Les méthodes géométriques les plus courantes sont la méthode Vertex Component Analysis (VCA), Noise-adjusted Fuzzy-logic-based Iterative Endmember SElection algorithm for Linear Unmixing (N-FINDR) et Fully Constrained Least Squares (FCLS)

1) *Méthode des sommets VCA (Vertex Component Analysis)*

Cette méthode a été proposé en 2005 par Nascimento et al.[4] . elle cherche à identifier les endmembers purs en trouvant les sommets d'un espace géométrique appelé simplexe. À partir de ces endmembers purs, les fractions de matériaux sont estimées. VCA repose sur l'hypothèse que les pixels purs se trouvent aux sommets de l'espace des signatures spectrales. Bien que VCA soit considéré comme rapide et efficace, il présente des limitations dans les scènes avec peu de pixels purs ou une représentation incorrecte [4]

2) *La Nouvelle Méthode d'Identification des Endmembers par Recherche Itérative Ajustée au Bruit N-FINDR (Noise-adjusted Fuzzy-logic-based Iterative Endmember)*

N-FINDR est une technique de démêlage spectral des images qui permet d'extraire les signatures spectrales des différents matériaux présents dans l'image.présenté dans [5] Elle fonctionne de manière itérative en sélectionnant les endmembers les plus purs jusqu'à ce que tous les endmembers soient extraits. L'algorithme utilise une approche floue pour attribuer les pixels à chaque endmember en tenant compte du bruit et des interférences. Les proportions des différents matériaux sont calculées à partir d'une matrice de concordance, permettant de visualiser les classes de matériaux sur une carte de l'image. La méthode N-FINDR est rapide, robuste et précise, mais elle peut être sensible à la sélection initiale des endmembers [5]

3) *Méthode des Moindres Carrés Contraints FCLS (Fully Constrained Least Squares)*

FCLS est une méthode de démélange spectral utilisée pour estimer les proportions des différentes substances dans un pixel d'une image hyperspectrale. Elle repose sur l'idée que le spectre mesuré dans chaque pixel est une combinaison linéaire des spectres purs des substances, appelés endmembers. [6] La méthode FCLS résout un système d'équations linéaires pour trouver les proportions optimales des substances, en imposant des contraintes de non-négativité et de somme à un sur les proportions. [7] Cela garantit des résultats précis et robustes. FCLS utilise un algorithme de programmation quadratique pour résoudre ce problème d'optimisation et fournir des estimations de démélange spectral de haute qualité.[7]

B. *La famille des méthodes statistiques*

Les méthodes statistiques, telles que la factorisation de matrices non négatives (NMF), l'analyse en composantes principales (PCA) et l'indice de pureté des pixels (PPI), constituent une catégorie importante parmi les techniques de démélange spectral. Elles reposent sur des concepts et des techniques statistiques et probabilistes pour estimer les fractions de matériaux présentes dans une scène. Ces méthodes peuvent être adaptées en fonction des hypothèses, des modèles et des contraintes spécifiques à la scène et aux données disponibles. Elles sont largement utilisées dans le domaine du traitement d'images hyperspectrales pour l'analyse et la décomposition des mélanges spectraux.

1) *La factorisation de matrices non négatives (NMF)*

La factorisation de matrices non négatives (NMF) est une technique de décomposition matricielle largement utilisée dans le traitement d'images hyperspectrales pour extraire des sources spécifiques à partir de données complexes. Elle repose sur la décomposition d'une matrice en deux matrices non négatives : une matrice de base et une matrice de poids.[8] Dans le contexte du démélange spectral, la matrice de données représente les spectres de chaque pixel, tandis que les matrices de base et de poids représentent respectivement les spectres de chaque matériau et les coefficients de mélange associés à chaque pixel. La méthode NMF cherche à décomposer la matrice de données en une somme pondérée des matrices de base et de poids, permettant ainsi de démêler les différents matériaux présents dans l'image composite.[8]

2) *L'analyse en composantes principales (PCA)*

La méthode de l'Analyse en Composantes Principales (PCA) réduit la dimensionnalité des données spectrales en projetant les spectres sur les composantes principales les plus significatives.[9] Cela permet de simplifier l'analyse et de mettre en évidence les variations les plus importantes entre les pixels de l'image. Les fractions de matériaux peuvent ensuite être estimées à partir de ces composantes principales. La PCA est une technique couramment utilisée dans le démélange spectral des images hyperspectrales.[9]

3) *L'indice de pureté des pixels (PPI)*

La méthode PPIrepose sur l'idée que les pixels purs, c'est-à-dire les pixels ne contenant qu'un seul matériau, ont des signatures spectrales plus extrêmes et distinctes que les pixels mélangés. [10]

elle utilise l'indice de pureté des pixels pour identifier les pixels purs dans l'image, ce qui permet d'estimer les coefficients d'abondance des autres matériaux présents. La méthode PPI est simple à mettre en œuvre et ne nécessite pas de connaissances préalables sur les matériaux de l'image. Elle fonctionne également bien dans des conditions de faible rapport signal sur bruit. Cependant, elle peut être moins précise que d'autres méthodes plus avancées, notamment dans les scènes avec beaucoup de pixels mélangés ou en cas de mélange non linéaire. De plus, elle ne fournit pas d'estimations des abondances pour les pixels purs détectés, mais seulement une liste de ces pixels. [10]

C. *La famille des méthodes basées sur la régression*

Les méthodes de régression, telles que la régression bayésienne, la régression non négative et la régression robuste, sont utilisées pour estimer les proportions des matériaux dans le démélange spectral. Elles permettent de modéliser et d'estimer les fractions de matériaux en tenant compte des caractéristiques des données et des contraintes spécifiques du problème de démélange.

1) *La régression bayésienne*

La méthode de régression bayésienne est une approche qui utilise des principes de probabilité bayésienne pour estimer les fractions de matériaux dans le démélange spectral. Elle intègre des informations a priori sur les distributions des fractions et utilise des techniques d'inférence bayésienne pour obtenir les estimations.[3] Cela permet de prendre en compte à la fois les données observées et les connaissances préalables, offrant ainsi une approche plus robuste et plus précise pour l'estimation des proportions des matériaux[11].

2) *La régression robuste*

La méthode de régression robuste est une approche qui est utilisée pour estimer les fractions de matériaux de manière robuste aux valeurs aberrantes ou aux perturbations. Elle se base sur des techniques de régression qui accordent moins de poids aux observations atypiques ou nuisibles, ce qui permet d'obtenir des estimations plus fiables et résistantes aux perturbations.[12]

3) *La régression non négative*

La méthode de régression non négative est une approche qui utilise une régression spécifique permettant de modéliser la relation entre les spectres observés et les fractions de matériaux. Elle impose la contrainte que les fractions de matériaux et les coefficients de régression doivent être des valeurs positives, ce qui garantit des résultats physiquement significatifs.[13]

III. Évaluation et comparaison des techniques de démélange spectral

L'évaluation et la comparaison des techniques de démélange spectral sont des étapes essentielles pour évaluer l'efficacité et les performances de ces méthodes. Voici quelques points clés à considérer lors de l'évaluation et de la comparaison des techniques de démélange spectral :

A. *Choix des métriques d'évaluation*

Il existe différentes métriques d'évaluation qui permettent de mesurer la précision et la qualité des résultats de démélange. Certaines métriques couramment utilisées incluent l'erreur quadratique moyenne (EQM), l'erreur relative, la corrélation entre les fractions estimées et les fractions réelles, et la distance spectrale entre les spectres estimés et les spectres réels. Il est important de sélectionner les métriques appropriées en fonction des objectifs de l'étude et des caractéristiques des données.

L'indice de Mélange Spectral (SMI) mesure le degré de linéarité du mélange.

L'indice d'Abondance Spectrale (SAI) évalue la qualité des estimations des fractions de mélange.

L'erreur Quadratique Moyenne (RMSE) mesure la différence entre les estimations et les fractions réelles.

L'erreur Relative Globale (GEE) compare les fractions estimées aux fractions de référence.

La corrélation Spectrale (SC) mesure la similarité entre les signatures spectrales estimées et réelles.

Ces métriques fournissent une évaluation globale de la précision du démélange spectral en termes de linéarité, d'exactitude et de similarité spectrale.

B. *Jeux de données*

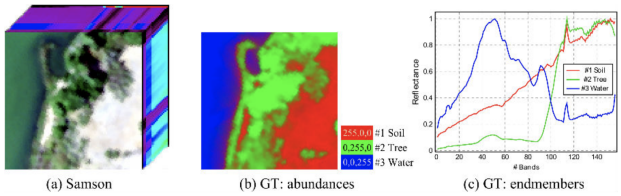
Les jeux de données utilisés pour l'évaluation et la comparaison des techniques de démélange spectral peuvent être réels ou synthétiques.

Les jeux de données réels sont souvent basés sur des images hyperspectrales acquises par des capteurs satellitaires ou aéroportés. l'étendue, la constitution et la variabilité des scènes représentées permettent d'enrichir les études menées.

Les jeux de données synthétiques quant à eux, sont générés de manière contrôlée en utilisant des modèles de mélange spécifiques. elles sont issus de simulation qui permet de créer des données avec des modèles de mélanges adaptés aux besoins et à la hauteur de la complexité que l'on se propose de lever par l'étude entreprise.

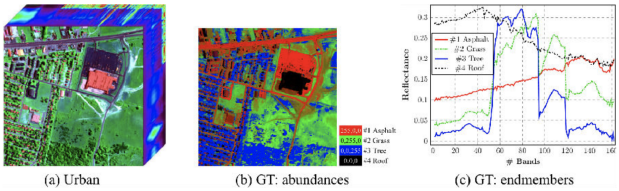
Il est recommandé d'utiliser une combinaison de jeux de données réels et synthétiques pour évaluer les performances des techniques dans différentes conditions.

Exemples d'images réelles



(a) Samson (b) GT: abundances (c) GT: endmembers

FIGURE 1 – Jeu de données samson



(a) Urban (b) GT: abundances (c) GT: endmembers

FIGURE 2 – Jeu de données urban

La figure 3 présente un outil logiciel permettant la création d'images synthétiques pouvant être utilisées pour le démélange

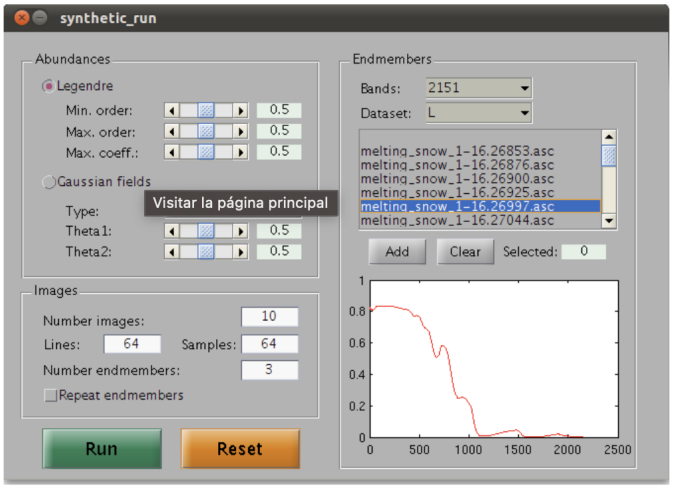


FIGURE 3 – Outil logiciel de simulation

C. *Comparaison des résultats*

Les résultats obtenus par différentes techniques de démélange spectral peuvent être comparés en utilisant des tableaux et des graphiques. Les tableaux peuvent présenter les valeurs des métriques d'évaluation pour chaque méthode, ce qui

permet une comparaison quantitative. Les graphiques peuvent être utilisés pour visualiser les fractions de matériaux estimées, les cartes de démélange, les courbes de convergence, etc. Ces outils visuels aident à comprendre les différences entre les techniques et à évaluer leur pertinence pour des applications spécifiques.

Dans la section qui suit, des exemples pratiques et extraits de travaux cités dans la littérature [Ref] sont présentés à titre d'illustration.[14]

IV. Exemple d'étude expérimentale [14]

Afin de mener les expériences qui seront présentées par cette section, le jeu de données Samson a été utilisé.

1) SAMSON dataset

Pour le jeu de données Samson, les auteurs ont choisi une taille de patch de (5x5) et une dimensionnalité d'entrée de 24 pour leur modèle de démélange spectral profond. Les résultats quantitatifs des expériences de démélange menées sur le jeu de données Samson sont présentés dans le tableauI Ces résultats montrent le total de RMSE obtenu pour la méthode FCLS est de 0,1387 tandis que celui obtenu pour la méthode NMF est de 0,1866. Ces résultats indiquent que la méthode FCLS produit des résultats de démélange spectral plus précis que la méthode NMF.

Méthodes	FCLSU	NMF
Soil	0.1766	0.1466
Tree	0.2011	0.1492
Water	0.0653	0.2063
Overall	0.1387	0.1866

Table I – Root Mean Square Error (RMSE)

Le tableau 1 représente l'erreur quadratique moyenne des éléments purs des jeux de données Samson obtenues par les deux techniques de démélange.(FCLS et NMF)

Ces résultats permettent de comparer les performances des deux méthodes en termes de précision, où des valeurs d'erreur plus faibles indiquent une meilleure approximation des données. En comparant ces résultats, on constate que la méthode FCLSU présente de meilleurs résultats, car son erreur quadratique moyenne est plus faible que celle de la méthode NMF.

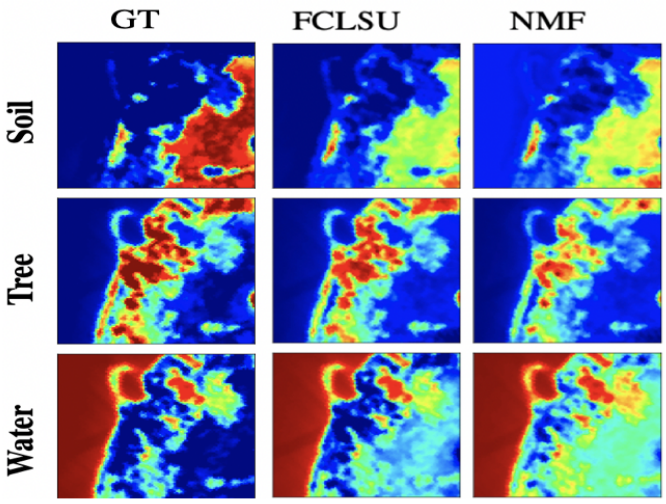


Figure 4 – Jeu de données Samson - Comparaison des cartes d'abondance obtenus par les méthodes FCLSU et NMF [14]

La Figure 4 présente une comparaison des cartes d'abondance obtenues par les méthodes FCLSU et NMF de démélange, en utilisant le jeu de données Samson. obtenues dans l'article [14]

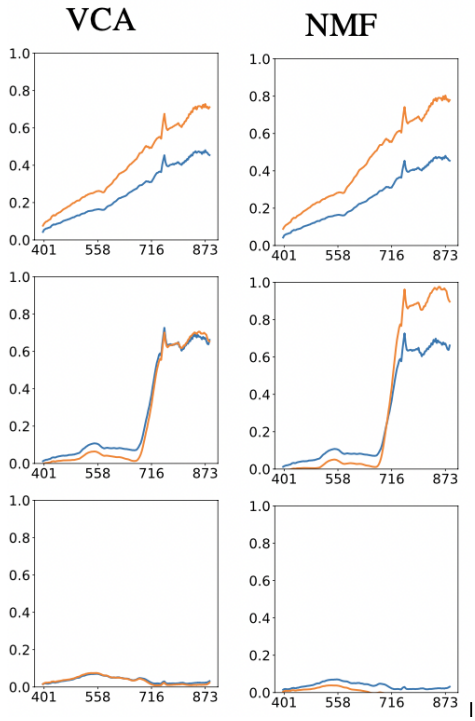


Figure 5 – Jeu de données Samson - Comparaison des spectres des éléments purs obtenus par les méthodes VCA et NMF [14]

La Figure 5 présente une comparaison des spectres des éléments purs obtenues par les méthodes VCA et NMF de démélange, en utilisant le jeu de données Samson. obtenues dans l'article [14]

V. Avancées récentes et défis actuels

Au cours des dernières années, plusieurs avancées significatives ont été réalisées dans le domaine du démélange spectral. Certaines de ces avancées comprennent l'utilisation de méthodes d'apprentissage automatique telles que les réseaux de neurones profonds et l'apprentissage non supervisé pour améliorer la précision des estimations de fractions de mélange. Les techniques de fusion de données, telles que l'intégration de données hyperspectrales avec des données d'imagerie à haute résolution spatiale, ont également permis d'obtenir des résultats plus précis et détaillés, tel que

La méthode de démélange hyperspectral à l'aide d'un autoencodeur de réseau neuronal :

Cette méthode utilise un autoencodeur de réseau neuronal pour estimer les fractions d'abondance des matériaux dans les images hyperspectrales. L'autoencodeur est un modèle de réseau neuronal qui apprend à compresser les données d'entrée et à les reconstruire. Dans cette méthode, l'autoencodeur est entraîné à apprendre la relation non linéaire entre les spectres observés et les fractions d'abondance correspondantes. Une fois l'autoencodeur entraîné, il peut être utilisé pour estimer les fractions d'abondance des nouveaux spectres hyperspectraux. Cette approche permet de traiter les mélanges spectraux complexes et d'obtenir des résultats précis. Les expériences menées sur des ensembles de données synthétiques et réelles ont montré l'efficacité de cette méthode. En résumé, cette méthode utilise un autoencodeur de réseau neuronal pour résoudre le problème de démélange hyperspectral de manière précise et efficace.comme mentionné dans [15]

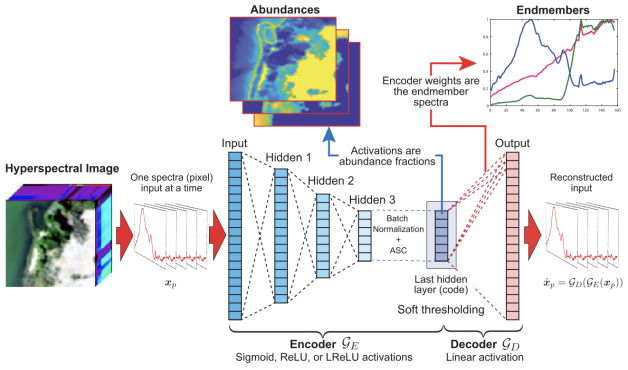


FIGURE 6 – Une représentation graphique de la méthode proposée. L'autoencodeur est entraîné sur tous les spectres de l'HSI pendant un certain nombre d'époques. Après l'entraînement, les cartes d'abondance peuvent être extraites en tant qu'activations de la dernière couche cachée pour chaque spectre d'entrée, et les poids du décodeur sont les spectres de membres constitutifs [15]

De plus, de nouvelles approches et techniques émergentes ont été développées pour relever les défis spécifiques du démélange spectral, tels que la détection et l'estimation des matériaux rares, la prise en compte des non-linéarités dans les mélanges spectraux, et la modélisation de la dépendance spatiale des fractions de mélange. Ces avancées ont ouvert de nouvelles perspectives de recherche et ont permis d'explorer des applications plus complexes du démélange spectral

Perspectives futures et directions de recherche prometteuses.

Les avancées récentes dans le domaine du démélange spectral ont ouvert la voie à de nombreuses perspectives futures et directions de recherche prometteuses.

Modèles d'apprentissage automatique avancés : Les techniques d'apprentissage automatique, telles que les réseaux de neurones profonds, les méthodes d'apprentissage profond et l'apprentissage par renforcement, continueront à jouer un rôle essentiel dans le développement de nouvelles approches de démélange spectral. L'utilisation de ces modèles plus avancés permettra de capturer des relations complexes entre les données hyperspectrales et les fractions de mélange, améliorant ainsi la précision des estimations.

VI. Conclusion

Le démélange spectral des images est un domaine en constante évolution, avec de nouvelles techniques proposées régulièrement. Chaque méthode a ses avantages et ses limites, et il est crucial de choisir la méthode la mieux adaptée au contexte et aux objectifs de l'application. Des comparaisons rigoureuses entre les techniques, en utilisant des critères tels que le temps de calcul, la précision de la démixtion et la robustesse aux erreurs de mesure, peuvent guider la sélection de la méthode appropriée.

Dans cet article, nous avons examiné différentes méthodes de démélange spectral, telles que l'analyse en composantes principales, la régression bayésienne, la régression non négative, la régression robuste, ainsi que les avancées récentes, comme l'utilisation des réseaux de neurones autoencodeurs. Chaque méthode présente des approches et des principes différents, offrant des solutions variées pour le démélange spectral.

Cependant, malgré les avancées dans le domaine, le démélange spectral présente encore des défis importants à relever. La complexité des modèles de mélange, la sélection des matériaux purs, l'estimation précise des fractions de mélange et le besoin de données de référence restent des problématiques à adresser.

En résumé, le démélange spectral joue un rôle crucial dans l'analyse des données hyperspectrales et offre de nom-

breuses applications potentielles dans divers domaines scientifiques, environnementaux, médicaux et technologiques. Les recherches continues dans ce domaine contribueront à améliorer notre compréhension des scènes hyperspectrales et à exploiter pleinement leur potentiel pour des applications pratiques.

RÉFÉRENCES

[1] José M. BIOUCAS-DIAS et al. "Hyperspectral Unmixing Overview : Geometrical, Statistical, and Sparse Regression-Based Approaches". In : *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5.2 (avr. 2012), p. 354-379. ISSN : 1939-1404, 2151-1535. DOI : 10.1109/JSTARS.2012.2194696. (Visité le 17/06/2023).

[2] Yang SHAO et al. "Spectral Unmixing of Hyperspectral Remote Sensing Imagery via Preserving the Intrinsic Structure Invariant". In : *Sensors* 18.10 (oct. 2018). Number : 10 Publisher : Multidisciplinary Digital Publishing Institute, p. 3528. ISSN : 1424-8220. DOI : 10.3390/s18103528. (Visité le 17/06/2023).

[3] Jiaojiao WEI et Xiaofei WANG. "An Overview on Linear Unmixing of Hyperspectral Data". In : *Mathematical Problems in Engineering* 2020 (25 août 2020). Publisher : Hindawi, e3735403. ISSN : 1024-123X. DOI : 10.1155/2020/3735403. (Visité le 21/06/2023).

[4] J.M.P. NASCIMENTO et J.M.B. DIAS. "Vertex component analysis : a fast algorithm to unmix hyperspectral data". In : *IEEE Transactions on Geoscience and Remote Sensing* 43.4 (avr. 2005), p. 898-910. ISSN : 0196-2892. DOI : 10.1109/TGRS.2005.844293. (Visité le 17/06/2023).

[5] Michael E. WINTER. "N-FINDR : an algorithm for fast autonomous spectral end-member determination in hyperspectral data". In : SPIE's International Symposium on Optical Science, Engineering, and Instrumentation. Sous la dir. de Michael R. DESCOUR et Sylvia S. SHEN. Denver, CO, 27 oct. 1999, p. 266-275. DOI : 10.1117/12.366289. (Visité le 17/06/2023).

[6] Jie YU et al. "Comparison of linear and nonlinear spectral unmixing approaches : a case study with multispectral TM imagery". In : *International Journal of Remote Sensing* 38.3 (fév. 2017), p. 773-795. ISSN : 0143-1161, 1366-5901. DOI : 10.1080/01431161.2016.1271475. (Visité le 17/06/2023).

[7] D.C. HEINZ et CHEIN-I-CHANG. "Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery". In : *IEEE Transactions on Geoscience and Remote Sensing* 39.3 (mars 2001), p. 529-545. ISSN : 01962892. DOI : 10.1109/36.911111. (Visité le 17/06/2023).

[8] Xin-Ru FENG et al. "Hyperspectral Unmixing Based on Nonnegative Matrix Factorization : A Comprehensive Review". In : *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 15 (2022). Conference Name : IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, p. 4414-4436. ISSN : 2151-1535. DOI : 10.1109/JSTARS.2022.3175257.

[9] Yannick DEVILLE et al. "Application and Extension of PCA Concepts to Blind Unmixing of Hyperspectral Data with Intra-class Variability". In : *Advances in Principal Component Analysis : Research and Development*. Journal Abbreviation : Advances in Principal Component Analysis : Research and Development. 1er déc. 2018, p. 225-252. ISBN : 978-981-10-6703-7. DOI : 10.1007/978-981-10-6704-4_9.

[10] J. BOARDMAN. "Automating spectral unmixing of AVIRIS data using convex geometry concepts". In : *1* (1993), p. 11-14.

[11] Saïd MOUSSAOUI et al. "Bayesian analysis of spectral mixture data using Markov Chain Monte Carlo Methods". In : *Chemometrics and Intelligent Laboratory Systems* 81.2 (avr. 2006), p. 137-148. ISSN : 01697439. DOI : 10.1016/j.chemolab.2005.11.004. URL : https://linkinghub.elsevier.com/retrieve/pii/S0169743905001747 (visité le 21/06/2023).

[12] Chang LI et al. "Hyperspectral Unmixing with Robust Collaborative Sparse Regression". In : *Remote Sensing* 8 (7 juill. 2016). DOI : 10.3390/rs8070588.

[13] Daniel D. LEE et H. Sebastian SEUNG. "Learning the parts of objects by non-negative matrix factorization". In : *Nature* 401.6755 (oct. 1999), p. 788-791. ISSN : 0028-0836, 1476-4687. DOI : 10.1038/44565. URL : https://www.nature.com/articles/44565 (visité le 21/06/2023).

[14] Preetam GHOSH et al. "Deep Hyperspectral Unmixing using Transformer Network". In : *IEEE Transactions on Geoscience and Remote Sensing* 60 (2022), p. 1-16. ISSN : 0196-2892, 1558-0644. DOI : 10.1109/TGRS.2022.3196057. arXiv : 2203.17076[cs,eess]. URL : http://arxiv.org/abs/2203.17076 (visité le 17/06/2023).

[15] Burkni PALSSON et al. "Hyperspectral Unmixing Using a Neural Network Autoencoder". In : *IEEE Access* 6 (2018). Conference Name : IEEE Access, p. 25646-25656. ISSN : 2169-3536. DOI : 10.1109/ACCESS.2018.2818280.