

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE MOULOU D MAMMERRI, TIZI-OUZOU
FACULTE DE GENIE ELECTRIQUE ET DE L'INFORMATIQUE
DEPARTEMENT D'ELECTRONIQUE



THESE DE DOCTORAT

SPECIALITE : ELECTRONIQUE

OPTION : Télédétection

Présenté par :

M^{elle} ZIKIOU Nadia

THEME :

**Classification et compression de textures
hyperspectrales par représentations parcimonieuses**

Devant le jury d'examen composé de :

Mr. AMEUR Soltane	Professeur UMMTO	Président
Mr. LAHDIR Mourad	Professeur UMMTO	Rapporteur
Mr. HAMICHE Hamid	Professeur UMMTO	Examineur
Melle. CHERIFI Dalila	M.C.A à l'UMBB	Examinatrice
Mr. BELHOCINE Mahmoud	DR Habilité au CDTA, Alger	Examineur
Mr. KEMIH Karim	Professeur Univ. De Jijel	Examineur
Mr. HELBERT David	HDR Univ. de Poitiers, France	Invité

Soutenu le : 15 / 10 / 2020

Remerciements

Tout d'abord, je tiens à remercier le bon Dieu de m'avoir aidée à mener ce travail à terme.

Le travail présenté dans cette thèse a été réalisé au laboratoire LAMPA (Laboratoire d'Analyse et de Modélisation des Phénomènes Aléatoires) de l'Université Mouloud MAMMARI de Tizi-Ouzou, Algérie.

J'offre ma plus sincère gratitude à mon promoteur, Monsieur **Mourad LAHDIR**, Professeur à l'UMMTO, qui m'a soutenue tout au long de ma thèse avec sa patience et ces connaissances tout en me permettant de travailler à ma manière. Je ne pouvais tout simplement pas souhaiter un meilleur promoteur.

Je suis très reconnaissante envers Monsieur **David HELBERT**, HDR à l'Université de Poitiers en France, pour ses efforts, ses encouragements et sa collaboration durant mon travail de doctorat. À bien des égards, j'ai beaucoup appris de lui.

Je remercie Monsieur **Soltane AMEUR**, Professeur à l'UMMTO, d'avoir accepté de présider mon jury de thèse et pour son intérêt et ses suggestions concernant mon travail.

J'adresse mes sincères remerciements à Monsieur **Hamid HAMICHE**, Professeur à l'UMMTO d'avoir accepté de faire partie de mon jury de thèse.

Je remercie vivement Madame **Dalila CHERIFI**, Maître de conférences A à l'université de Boumerdès, d'avoir accepté de faire partie de mon jury de thèse.

J'adresse mes sincères remerciements à Monsieur **Karim KEMIH**, Professeur à l'université de JIJEL, de m'avoir fait l'honneur de faire partie de mon jury de thèse.

Je tiens à remercier Monsieur **Mahmoud BELHOCINE**, DR Habilité au CDTA d'Alger, pour l'honneur qu'il me fait de participer à mon jury de thèse.

Je voudrais remercier tous mes enseignants et mes collègues du laboratoire LAMPA

pour leur attention et leurs précieuses orientations.

J'adresse mes sincères remerciements à Monsieur **Mourad LAGHROUCHE**, Professeur à l'UMMTO, pour ces conseils et son soutien.

Je remercie vivement Madame **Zohra AMEUR**, Professeur à l'UMMTO, pour son attention et sa disponibilité. Qu'elle veuille apercevoir ici l'expression de ma profonde gratitude.

Un merci spécial à Madame **Leila LAHDIR**, MAA à l'UMMTO, pour ses conseils, ses orientations et pour le temps qu'elle a bien voulu consacrer pour m'écouter. Qu'elle veuille apercevoir ici mes termes les plus sincères de remerciements et l'expression de ma profonde affection.

Je remercie Monsieur **Abdellah ZIKIOU**, Chercheur Permanent au CRBT de Constantine, de m'avoir donné l'opportunité d'élargir mon horizon et ma vision de la recherche scientifique, d'apprendre beaucoup de nouvelles choses dans ce domaine et de toujours m'encourager à aller de l'avant. Petit frère! "Très grande" était ton aide.

Je remercie mes parents, mes soeurs et ma tante qui ont fait preuve d'une grande patience. Je les remercie pour leur amour, leur aide et leur soutien.

Je remercie mes collègues (particulièrement Melle **Lila BENTAYEB**, PSFEP2) et mes stagiaires (particulièrement mes stagiaires de la MEIB) de l'INSFP de Oued Aissi pour leur patience, leurs encouragements et de me fournir un environnement agréable et créatif lors de mes recherches.

A toutes les personnes qui ont contribué directement ou indirectement à la réalisation de ce projet.

Dédicaces

À la mémoire de notre défunte Yasmine pour les souvenirs qu'elle a laissés

À notre petite Yasmine pour l'espoir qu'elle a ramené.

Résumé

L'imagerie hyperspectrale enregistre des centaines de bandes spectrales étroites et contiguës reçues dans chaque position spatiale de l'image. Comme chaque matériau manifeste une signature spectrale différente, l'imagerie hyperspectrale permet la classification précise des images, ce qui est une tâche importante dans beaucoup de domaines. Cependant, la grande dimension de ces images complique l'analyse des données.

Dans ce travail, nous proposons et développons des nouvelles méthodes pour la compression et la classification des données hyperspectrales. Une représentation parcimonieuse de la texture hyperspectrale basée sur la transformée en ondelettes discrète 3D et une méthode de régression est utilisée pour la compression des images hyperspectrales. Les ondelettes et la régression SVM sont deux outils efficaces pour la compression des données de grande dimension et pour l'analyse contextuelle d'images. En effet, les résultats de compression obtenus sont d'un apport considérable. D'un autre côté, la méthode aboutie à de bonnes performances de classification des images hyperspectrales compressées. Cependant, une meilleure sélection des pixels représentatifs peut améliorer davantage les résultats de classification des images hyperspectrales. La transformée en ondelettes spectrales sur graphes (SGWT) permet d'extraire les caractéristiques de texture d'un graphe pondéré d'une image hyperspectrale. Nous avons proposé une méthode de classification basée sur cette transformée pour extraire les pixels représentatifs de l'image. Une classification SVM est ensuite appliquée aux coefficients SGWT obtenus. Les résultats ont montré l'efficacité de la méthode en termes de robustesse et de précision.

Mot clés : Télédétection, Images hyperspectrales, Compression, Classification de textures hyperspectrales, Représentation parcimonieuse, Traitement de signal sur graphes.

Table des matières

1	Introduction	1
1.1	Contexte des travaux de recherche	2
1.2	Objectifs de la thèse	4
1.3	Contributions principales de la thèse	5
1.4	Publications	6
1.5	Organisation de la thèse	7
2	Imagerie hyperspectrale	9
2.1	Préambule	10
2.2	Aperçu sur les images hyperspectrales	10
2.3	Caractéristiques des images hyperspectrales	11
2.3.1	Réflectance spectrale	11
2.3.2	Radiance spectrale	13
2.4	Les capteurs hyperspectraux	14
2.5	Traitement des images hyperspectrales	18
2.5.1	Réduction de dimension	18
2.5.2	Extraction de caractéristiques spectrales-spatiales	18
2.5.3	Le débruitage des images hyperspectrales	19
2.5.4	La classification des images hyperspectrales	19
2.5.5	La compression des images hyperspectrales	20
2.6	Discussion	22
3	Représentation parcimonieuse et traitement de signal sur graphes	23
3.1	Préambule	24
3.2	Représentation parcimonieuse	24
3.2.1	Définition	24
3.2.2	Approximation parcimonieuse	25
3.3	Généralités sur le traitement de signal sur graphes	31

3.3.1	Définition d'un signal sur graphes	31
3.3.2	Matrice d'adjacence	32
3.3.3	Matrice de Laplace	32
3.3.4	Transformée de Fourier sur graphe	33
3.4	Transformée en ondelette spectrales sur graphes	34
3.4.1	Les ondelettes spectrales sur graphes	34
3.4.2	Structure des ondelettes spectrales sur graphes	35
3.4.3	Comparaison entre les ondelettes classiques et les ondelettes spectrales sur graphes	40
3.5	Discussion	42
4	Compression des images hyperspectrales par représentation parcimonieuse	43
4.1	Préambule	45
4.2	État de l'art	45
4.3	Approche proposée pour la compression des images hyperspectrales	47
4.3.1	Schéma proposé	47
4.3.2	La transformée en ondelettes	48
4.3.3	Codage par modulation différentielle d'impulsions	49
4.3.4	La régression par les machines à vecteurs de support pour la compression d'images	50
4.3.5	Quantification et codage entropique	52
4.3.6	Algorithme de compression proposé	52
4.3.7	La décompression	53
4.4	Tests et résultats	54
4.4.1	Les données utilisée	54
4.4.2	Paramètres d'évaluation	56
4.4.3	Discussion sur les noyaux	59
4.4.4	Discussion sur les filtres d'ondelettes	62
4.4.5	Comparaison des résultats	64

4.4.6	Temps de calcul	68
4.4.7	Performances de classification de l'approche proposée	69
4.5	Impact sur les réflectances compressées	72
4.6	Discussion	74
5	Classification des images hyperspectrales par transformée en onde-	
	lettes spectrales sur graphes	76
5.1	Préambule	77
5.2	État de l'art	77
5.3	Approche proposée pour la classification de la texture hyperspectrale . .	79
5.3.1	Le schéma proposé	79
5.3.2	Mesure de similarité et transformée en ondelettes sur graphes . .	79
5.3.3	La classification par les machines à vecteurs de support	83
5.3.4	Algorithme proposée pour la classification de la texture hyper-	
	spectrale	84
5.4	Tests et résultats	85
5.4.1	Les paramètres de la méthode de classification proposée	85
5.4.2	Les images hyperspectrales utilisées en tests	85
5.4.3	Discussion des résultats selon les distances	88
5.4.4	Discussion des résultats selon le voisinage	89
5.4.5	Les performance de classification	91
5.5	Discussion	97
6	Conclusion	99
6.1	Contributions de la thèse	100
6.2	Perspectives	101
	Bibliographie	

Table des figures

1.1	Les approches proposées pour la compression et la classification des données hyperspectrales.	5
2.1	Représentation d'un cube d'une image hyperspectrale.	12
2.2	Image "Université de Pavie". (a) Composite couleur à trois bandes (650, 558 et 478 nm). (b) Ensemble d'échantillons d'apprentissage. (c) Un affichage des données de six pixels appartenant à trois classes d'asphalte, de prairies et de briques en fonction du nombre de bandes spectrales (longueur d'onde) [11].	12
3.1	Les familles d'ondelettes. (a) : Les ondelettes db4, (b) : Les ondelettes de symlets, (c) : Les ondelettes CDF5/3, (d) : Les ondelettes CDF9/7.	30
3.2	Construction des coefficients d'ondelettes spectrales sur graphes	36
3.3	Sélection des pixels représentatifs.	37
3.4	Exemple de décomposition à plusieurs échelles de la transformée en ondelettes spectrales sur graphes sur l'image KSC. (a) : Coefficients d'échelle, (b) : Coefficients d'ondelettes à l'échelle 1, (c) : Coefficients d'ondelettes à l'échelle 2, (d) : Coefficients d'ondelettes à l'échelle 3.	39
3.5	Comparaison entre décompositions par la transformée de paquets d'ondelettes (WPT) et SGWT : (a) Image originale de Pavia University (sous-bande 100), (b) 1-niveau de décomposition WPT, (c) 2-niveaux de décomposition WPT, (d) Coefficients d'échelles de la SGWT, (e) Coefficients de SGWT à l'échelle 1, (f) Coefficients de SGWT à l'échelle 2	41
4.1	Le schéma de l'approche de compression proposée.	48
4.2	Les données de compression des capteurs aériens : (a) Scène 0 de Yellowstone (512×512) ; (b) Image Cuprite (256×256), (c) Image Indiana Pines (128×128) et (d) Image Washington DC (256×256).	56

4.3	Les données de compression du capteur embarqué : (a) Image Mt. St. Helens (768×256); (b) Image Erta Ale (768×256).	57
4.4	Résultats de la compression pour Yellowstone : (a) Image originale de Yellowstone, images reconstruites avec CR proche de 26 avec les noyaux (b) Gaussien, (c) Polynomial et (d) Linéaire. . . .	60
4.5	Résultats de compression pour la scène Cuprite : (a) Image originale de la scène Cuprite, images reconstruites avec un CR proche de 27 avec les noyaux (b) Gaussien, (c) Polynomial et (d) Linéaire. 60	60
4.6	Résultats de compression pour la scène d'Indiana Pines : (a) Image originale, images reconstruites avec un CR proche de 39 avec les noyaux (b) Gaussien, (c) Polynomial and (d) Linéaire.	61
4.7	Les résultats de compression de l'image Washington DC : (a) Image originale, images reconstruites avec un CR proche de 27 avec les noyaux (b) Gaussien, (c) Polynomial and (d) Linéaire.	61
4.8	Résultats de compression de l'image M.S.Helens : (a) Image originale, images reconstruites avec un CR proche de 23 avec les noyaux (b) Gaussien (PSNR=49.47 dB), (c) Polynomial (PSNR=46.62 dB) et (d) Linéaire ((PSNR=45.61 dB).	62
4.9	Résultats de compression de l'image Erta Ale : (a) Image originale, images reconstruites avec CR proche de 22 avec les noyaux (b) Gaussien (PSNR= 38.46 dB), (c) Polynomial (PSNR= 36.58 dB) et (d) Linéaire ((PSNR= 32.51 dB).	64
4.10	Images reconstruites avec les noyaux linéaire et polynomial : Linéaire : (a) Yellowstone (subband 91), (b) Cuprite (subband 6), (c) Indiana Pines (subband 183 (g) M.S.Helens (subband 40) Polynomial : (d) Yellowstone (subband 91), (e) Cuprite (subband 6), (f) Washington DC (subband 160) (h) Erta Ale (subband 93).	66

4.11	Comparaison des performances de différentes méthodes de compression (3D-SPECK [126, 125, 124], PCA+JPEG2000 [127, 125, 128, 124], PWSR and SSASR [124], JPEG-BIFR [129, 124], 3D-DCT [130, 125] et 3D-DCT+SVM [125]) sur trois IHS. (a) :Cuprite. (b) : Indiana Pines. (c) :Washington DC.	67
4.12	Comparaison de l'OA% avec des méthodes de compression connues sur Indiana Pines.	70
4.13	Réflectance des images originales et compressées par 3D-DWT +SVR et leurs différence (ligne avec symboles) et des images originales et compressées par 2D-DWT + SVR et leurs différence (ligne continue) : Yellowstone(CR=42.12), (a) sol , (b) rail , (c) immeuble; Washington DC (CR=42.60), (d) champ, (e) immeuble, (f) sol.	73
5.1	Schéma de l'approche de classification proposée	80
5.2	Une décomposition multi-échelle sur la 5 ^{ème} bande de l'image "Pavia U". (a) : Fonction d'échelle, (b)-(d) : Les coefficients SGWT , échelles 1-3 . . .	83
5.3	Résultats de l'image Indian Pines. (a) : Image originale, (b) : Carte vérité-terrain, (c) : Résultats de classification avec SGWT-SVM	93
5.4	Résultats de l'image KSC. (a) : Image originale, (b) : Carte vérité-terrain, (c) : Résultats de classification avec SGWT-SVM.	94
5.5	Résultats de l'image Université de Pavie. (a) : Image originale, (b) : Carte vérité-terrain, (c) : Résultats de classification avec SGWT-SVM	95
5.6	Résultats de l'image Centre de Pavie. (a) : Image originale, (b) : Carte vérité-terrain, (c) : Résultats de classification avec SGWT-SVM	96
5.7	OA du classificateur SGWT-SVM en variant le nombre d'échantillons d'apprentissage par classe.	96
5.8	OA de différentes méthodes de classification en variant le nombre d'échantillons d'apprentissage. (a) : Indian Pines, (b) : Centre de Pavie, (c) : Université de Pavie, (d) : KSC.	97

Liste des tableaux

2.1	Caractéristiques techniques des principaux capteurs hyperspectraux. . . .	17
4.1	Les résultats de l’approche pour les noyaux SVR : Gaussien (G), polynomial (P) et linéaire (L).	63
4.2	Résultats de compression de l’approche proposée avec différents filtres d’ondelettes	65
4.3	Temps d’exécution (s) de la 3D-Ondelettes + SVR	68
4.4	Comparaison des temps d’exécution (s) sur Indiana Pines	68
4.5	Performances de classification de 3D-DWT + SVR appliquée sur les images Yellowstone, Cuprite, Indiana Pines et Washington DC	70
4.6	Test de McNemar’s (Z) de la méthode 3D-DWT + SVR face aux méthodes SVM et 2D-DWT + SVM.	71
5.1	Les différentes classes de la scène Indian Pines et leurs nombres d’échantillons	86
5.2	Les différentes classes de la scène KSC et leurs nombres d’échantillons . .	87
5.3	Les différentes classes de la scène Pavia U et leurs nombres d’échantillons	88
5.4	Les différentes classes de la scène Pavia U et leurs nombres d’échantillons	88
5.5	Résultats expérimentaux pour les mesures de distances Euclidienne (ED), de Kolmogorov (KD), d’angle spectral (SA), de divergence d’information spectrale (SID) et de corrélation croisée normalisée (NCC).	90
5.6	OA (%), AA (%), κ et le temps de calcul du classificateur SGWT-SVM avec différents T - voisinage pixels	91
5.7	Les paramètres des classificateurs comparés.	92
5.8	Les performances de classification utilisant les différentes techniques sur l’image Indian Pines.	93
5.9	Les performances de classification utilisant les différentes techniques sur l’image KSC.	93

5.10 Les performances de classification utilisant les différentes techniques sur l'image Université de Pavie.	94
5.11 Les performances de classification utilisant les différentes techniques sur l'image Centre de Pavie.	95

Liste des abréviations

1D	Une Dimension
2D	Deux Dimensions
3D	Trois Dimensions
AA	Average Accuracy (Précision Moyenne)
AC	Approximation Coefficients (Coefficients des Approximations)
ACP	Analyse en Composantes Principales
ACI	Analyse en Composantes Indépendantes
ARCHER	Airborne Real-time Cueing Hyperspectral Enhanced Reconnaissance
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
BP	Basis Pursuit (Poursuite de base)
BPDN	Basis Pursuit Denoising (Débruitage poursuite de base)
CALIC	Context-Based Adaptive Lossless Image Codec (Codec d'image adaptatif sans perte basé sur le contexte)
CCSDS	Consultative Committee for Space Data Systems (Comité consultatif des systèmes de données spatiales)
CDF	Cohen-Daubechies-Feauveau
CNN	Convolutional Neural Network (Réseaux de Neurones Convolutifs)
C-CNN	Classification-Convolutional Neural Network (Classification réseaux de Neurones Convolutifs)
DAFE	Discriminative Analysis Feature Extraction
DBFE	Decision Boundary Feature Extraction
DC	Detail Coefficients (Coefficients des Détails)
DCT	Discrete Cosine Transform (Transformée cosinus discrète)
DPCM	Differential Pulse Code Modulation (Modulation de Code d'Impulsion Différentielle)
DWT	Discrete Wavelet Transform (Transformée en Ondelettes Discrète)
DWTI	Discrete Wavelet Transform Inverse (Transformée en Ondelettes Discrète Inverse)
EBCOT	Embedded Block Coding with Optimal Truncation Points (Codage de Blocs Intégré avec Troncature Optimisée)
ED	Euclidean Distance (Distance Euclidienne)
ELM	Extreme Learning Machine (Machine d'Apprentissage Extrême)
EZW	Embedded Zerotrees of Wavelet Transforms (Ondelette Zerotree Intégrée)

FISTA	Fast Iterative Shrinkage/Thresholding Algorithm (Algorithme de Rétrécissement / Seuillage Itératif Rapide)
HYDICEHY	Hyperspectral Digital Imagery Collection Experiment
IFOV	Instant Field of View (Champ de Vision Instantané)
ISTA	Iterative Shrinkage/Thresholding Algorithm (Algorithme de Rétrécissement / Seuillage Itératif)
JPEG	Joint photographic experts Group (Groupe Mixte d'Experts en Photographie)
KD	Kolmogorov Distance (Distance de Kolmogorov)
LOCO	Low COmplexity LOssless COmpression for Images (Compression Sans Perte de Faible Complexité pour les Images)
LASSO	Least Absolute Shrinkage and Selection Operator (Opérateur de Retrait et de Sélection le Moins Absolu)
MP	Matching Pursuit
NCC	Normalized Cross Correlation (Corrélation Croisée Normalisée)
NWFE	Nonparametric Weighted Feature Extraction (Extraction d'Entités Pondérées Non Paramétriques)
OA	Overall Accuracy (Précision Globale)
OMP	Orthogonal Matching Pursuit
PPF	Pixel Pair Features (Caractéristiques de la Paire de Pixels)
PSNR	Peak Signal to Noise Ratio (Rapport de Crête Signal sur Bruit)
RMG	Random Multi Graph (Multi-Graphes Aléatoires)
ROSI	Reflective Optics System Imaging Spectrometer
R-PCA	Randomized-Principal Component Analysis (Analyse Aléatoire des Composants Principaux)
RWA	Regression Wavelets Analysis (Analyse en Ondelettes de Régression)
SA	Spectral Angle (Angle spectral)
SAE	Stacked AutoEncoders (Encodeurs automatiques empilés)
SCP	Spectral Section Part (Partie de Section Spectrale)
SGWT	Spectral Graph Wavelet Transform (Transformée en Ondelettes Spectrales sur Graphes)
SID	Spectral Information Divergence (Divergence Spectrale de l'Information)
SNR	Signal to Noise Ratio (Rapport Signal sur Bruit)
SPA	Spatial Counterpart (Contrepartie Spatiale)
SPPF	Spatial Pixel Pair Features (Caractéristiques de la Paire de Pixels Spatiaux)
SSRN	Spectral-Spatial Residual Network (Réseau Résiduel Spectral-Spatial)
SVM	Support Vector Machine (Machine à Vecteurs de Support)
SVR	Support Vector Regression (Rgression à Vecteurs de Support)
TKL	Karhunen-Loeve Transform (Transformée de Karhunen-Loeve)

Chapitre 1

Introduction

Sommaire

1.1	Contexte des travaux de recherche	2
1.2	Objectifs de la thèse	4
1.3	Contributions principales de la thèse	5
1.4	Publications	6
1.5	Organisation de la thèse	7

CE chapitre est une présentation de la thèse, donnant le contexte des travaux de recherche et le matériel de base nécessaire. Les objectifs de la thèse et les principales contributions sont ensuite décrits. Ces contributions sont discutées plus en détail dans les chapitres 4 et 5, qui présentent de nouvelles méthodes en compression et en classification des données hyperspectrales [1, 2].

1.1 Contexte des travaux de recherche

L'imagerie hyperspectrale est définie comme "l'acquisition simultanée d'images dans de nombreuses bandes spectrales étroites et contiguës" [3, 4, 5]. Ainsi, l'imagerie hyperspectrale concerne la mesure, le traitement et l'analyse des spectres acquis à partir d'une scène donnée à courte, moyenne ou longue distance par un capteur aéroporté ou satellite. Les données d'image résultant de l'imagerie hyperspectrale sont considérées comme un cube de données tridimensionnel (3D). Ces dernières sont utilisées dans diverses applications d'agronomie, de géologie, d'archéologie, de la reconnaissance ou pour la recherche planétaire et l'astronomie. La détection des pollutions environnementales, les incendies et la détection des changements climatiques sont des exemples d'un nombre incalculable d'applications.

La résolution spatiale, spectrale, radiométrique et temporelle des données hyperspectrales augmente régulièrement avec de nouvelles technologies, ce qui se traduit par une plus grande précision et permet de nouvelles applications. Sur le plan technique, il existe une augmentation considérable du débit de données géré par les systèmes d'imagerie hyperspectrale. Parmi ces systèmes, il existe des capteurs d'imagerie hyperspectrale aéroportés tels que Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)¹, HYperspectral Digital Imagery Collection Experiment (HYDICE)² et Reflective Optics System Imaging Spectrometer (ROSIS)³. Il existe également des capteurs spatioportés tels que Hyperion (USA, 2000)⁴ et Spectromètre imageur compact à haute résolution (CHRIS,

1. <https://aviris.jpl.nasa.gov/>

2. <https://www.spiedigitallibrary.org/>

3. <https://www.spiedigitallibrary.org/>

4. <https://earthobservatory.nasa.gov/features/E01Tenth/page3.php>

UK, 2001)⁵. Les capteurs hyperspectraux couvrent généralement une plage de 0,4 à 2,5 μm utilisant 115 à 512 canaux spectraux, avec une résolution spatiale variant de 0,75 à 20 $m/pixel$ pour les capteurs aéroportés et de 5 à 506 $m/pixel$ pour les capteurs satellites.

Un grand nombre de canaux spectraux implique une dimension élevée des données et présente des défis pour l'analyse et la classification des images. Une compression des données s'avère nécessaire. Les premières méthodes de compression et de classification d'images hyperspectrales étaient basées sur des techniques existantes développées pour des images multispectrales [6, 7, 8]. La plupart des méthodes couramment utilisées conçues pour l'analyse du niveau de gris, de la couleur ou des images multispectrales ne conviennent pas aux images hyperspectrales. Par conséquent, pour tirer pleinement parti des riches informations fournies par l'information spectrale et spatiale, le développement de nouveaux algorithmes plus efficace est nécessaire [9].

La compression de données hyperspectrales a suscité un intérêt particulier dans le traitement et l'analyse d'images hyperspectrales dû au volume énorme de ces données. En plus, il existe une redondance importante dans le domaine spectral. D'un autre côté, bien qu'une image hyperspectrale puisse être considérée comme un cube d'image 3D, elle ne conduit pas nécessairement à une technique de compression efficace en étendant simplement les méthodes de compression d'image bidimensionnelles (2D) existantes. Ainsi, on doit concevoir des schémas de compression efficaces afin d'atteindre un taux de compression élevé sans perte d'informations importante.

Motivés par ces faits, dans cette thèse, nous explorons les possibilités d'exploiter les riches informations spatiales et spectrales des images hyperspectrales pour la compression et la classification des données.

Nous proposons une méthode de compression d'image hyperspectrale basée sur une représentation parcimonieuse des données. Le principe de la méthode est d'appliquer la transformée en ondelettes discrète 3D et la régression des vecteurs supports (SVR) sur l'image hyperspectrale. Cette méthode permet de réduire les redondances spectrales et spatiales tout en préservant les informations les plus pertinentes de l'image.

5. <https://earth.esa.int/eogateway/>

Cependant, une meilleure méthode de sélection des pixels représentatifs peut améliorer davantage les résultats de classification des images hyperspectrales. En effet, l'étude est approfondie pour proposer une méthode de classification des images hyperspectrales efficace. De nombreux algorithmes pour la classification d'images hyperspectrales proposés ont été étudiés dans la littérature [10, 11]. Cela prouve l'intérêt croissant pour l'analyse des données hyperspectrales. En particulier, les machines à vecteurs supports (SVM) ont montré de bonnes performances en termes de précision de classification pour classer des données de grande dimension lorsqu'un nombre limité d'échantillons d'apprentissage est disponible. La plupart des méthodes de classification traitent chaque pixel indépendamment sans tenir compte des corrélations entre pixels spatialement adjacents. Cependant, si la classification 'pixel par pixel' permet la caractérisation précise des matériaux détectés, elle ne prend pas en compte les informations contextuelles. Nous proposons une méthode de classification de textures hyperspectrales basée sur la transformée en ondelettes spectrales sur graphes (SGWT) et SVM. Nous étudions également l'effet des différentes mesures de similarité utilisées dans le processus de la SGWT sur l'extraction des pixels représentatif et sur l'efficacité de la sélection des caractéristiques.

1.2 Objectifs de la thèse

L'objectif principal de cette thèse est de développer de nouvelles méthodes pour la compression et la classification des données hyperspectrales. Les approches développées devraient être efficaces en termes de performances de compression et de précision de classification. Sur la base de la discussion de la section précédente, nous avons défini les objectifs suivants :

- Combiner les approches d'Ondelettes et de régression par vecteurs de support pour la compression des images hyperspectrales.
- Développer une méthode de classification de textures hyperspectrales en utilisant la transformée en ondelettes spectrales sur graphes et les SVM. La méthode consiste à :

- Mesurer la similarité entre les pixels pour une meilleure sélection des pixels représentatifs
 - Appliquer la transformée en ondelettes spectrales sur graphes pour obtenir les coefficients SGWT
 - Classifier les coefficients SGWT en utilisant les SVM
- Réduire les charges de calcul en explorant les possibilités de calcul parallèle hautes performances sur les processeurs de base.

1.3 Contributions principales de la thèse

Les principales contributions de cette thèse sont résumées sur la figure 1.1, qui décrit les nouvelles méthodes de compression et de classification des données hyperspectrales.

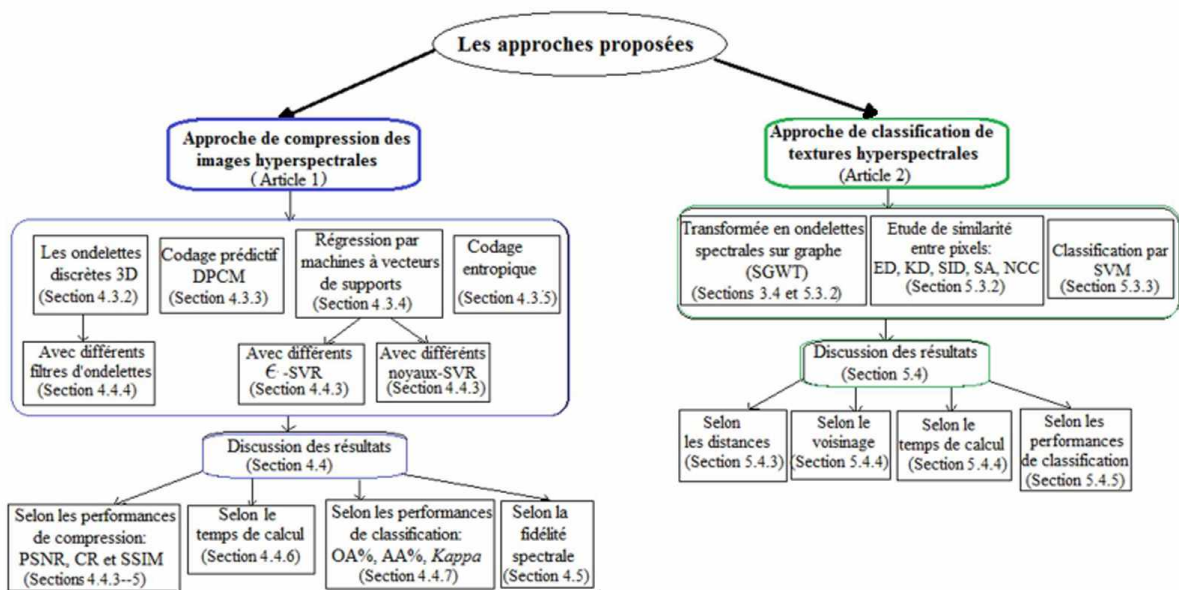


FIGURE 1.1 – Les approches proposées pour la compression et la classification des données hyperspectrales.

Les principales contributions de la thèse résidents dans :

- La généralisation de la méthode de compression "Ondelettes-SVR" sur les données 3D (3D-DWT-SVR) ;

- L'exploitation de l'information spectrale des images hyperspectrales avec la méthode 3D-DWT-SVR pour une meilleure fidélité de textures hyperspectrales reconstruites ;
- La généralisation de la transformée en ondelettes spectrales sur graphes sur les données 3D ;
- La mesure de la similarité entre les pixels des images hyperspectrales pour une meilleure sélection des pixels représentatifs en utilisant cinq différentes mesures de distances ;
- L'utilisation de la méthode SGWT-SVM pour la classification de textures hyperspectrales en appliquant les SVM sur les coefficients obtenus de la mesure de similarité et de l'application de la transformée en ondelettes spectrales sur graphes multi-échelles.

1.4 Publications

La thèse est composée de plusieurs publications présentant d'importantes parties de notre travail :

- Zikiou, N., Lahdir, M., Ameer, S. (2014). Application des Curvelets et Régression SVM pour la Compression d'Images. IT4OD proceeding, pp. 188-194. Ce papier a été cité dans la section 3.4.3 de la thèse. Nous avons utilisé les curvelets et la régression SVM pour la compression de six images tests. Les résultats ont montrés que les curvelets sont plus efficaces que les ondelettes discrètes 2D pour ce genre d'applications.
- Zikiou, N., Lahdir, M., Ameer, S. (2014, November). Color image compression based on wavelet transform and support vector regression. In International Image Processing, Applications and Systems Conference, IEEE, pp. 1-6. Cet article indexé par IEEEXplore porte sur la compression des images couleurs en effectuant la

méthode Ondelettes-2D-SVR. Les résultats ont montrés de bonnes performances de compression.

- Zikiou, N., Lahdir, M., Helbert, D. (2019). Support vector regression-based 3D-wavelet texture learning for hyperspectral image compression. *The Visual Computer*, pp. 1-18. Cet article décrit la méthode de compression des images hyperspectrales proposée au chapitre 4. La méthode et les résultats sont donnés dans le chapitre 4 et montrent des résultats compétitifs avec d'autres méthodes connues dans le domaine.
- Zikiou, N., Lahdir, M., Helbert, D. (2020). Hyperspectral image classification using graph-based wavelet transform. *International Journal of Remote Sensing*, 41(7), pp. 2624-2643. Cet article décrit la méthode proposée de classification de texture hyperspectrales. Elle est détaillée en chapitre 5. Les résultats sont très prometteurs et ouvrent des perspectives pour l'utilisation de la méthode dans d'autres applications pour ce type de données.

1.5 Organisation de la thèse

Le reste de cette thèse est organisé comme suit :

Dans le deuxième chapitre, nous présentons un aperçu sur les images hyperspectrales, leurs caractéristiques et les capteurs hyperspectraux. Nous terminons le chapitre par un état de l'art des principales méthodes proposées pour le traitement des images hyperspectrales.

Dans le chapitre 3, nous présentons une étude théorique sur la représentation parcimonieuse et le traitement de signal sur graphes.

Nous détaillons, dans le chapitre 4, la méthode proposée de compression d'images hyperspectrales. Nous discutons également de certains travaux connexes dans ce sujet. Les résultats d'évaluation de notre méthode de compression et les discussions des résultats sont présentés dans ce chapitre.

Dans le chapitre 5, nous présentons la méthode de classification de textures hyper-

spectrales basée sur la transformée en ondelettes spectrales sur graphes. Ce chapitre comprend les détails des travaux connexes dans ce sujet, les résultats d'évaluation et de comparaison avec diverses méthodes de classification d'images hyperspectrales et les discussions connexes.

Nous terminons par une conclusion dans le chapitre 6, où nous discutons les principaux résultats et proposons quelques suggestions pour des travaux futurs.

Chapitre 2

Imagerie hyperspectrale

Sommaire

2.1	Préambule	10
2.2	Aperçu sur les images hyperspectrales	10
2.3	Caractéristiques des images hyperspectrales	11
2.3.1	Réflectance spectrale	11
2.3.2	Radiance spectrale	13
2.4	Les capteurs hyperspectraux	14
2.5	Traitement des images hyperspectrales	18
2.5.1	Réduction de dimension	18
2.5.2	Extraction de caractéristiques spectrales-spatiales	18
2.5.3	Le débruitage des images hyperspectrales	19
2.5.4	La classification des images hyperspectrales	19
2.5.5	La compression des images hyperspectrales	20
2.6	Discussion	22

2.1 Préambule

Dans ce chapitre, nous présentons un aperçu du domaine de la télédétection, en se concentrant sur les images hyperspectrales et les défis liés à leur analyse. Les caractéristiques de ces images ainsi que les capteurs utilisés sont ensuite décrits. Un état de l'art sur les techniques spectrales et spatiales les plus largement utilisées développées au cours des dernières années en traitement des images hyperspectrales est également présenté.

2.2 Aperçu sur les images hyperspectrales

La télédétection de la Terre comprend la collecte de données difficilement acquises par les observations en surface sur l'environnement, la géologie, le climat et d'autres caractéristiques de la Terre au moyen de capteurs positionnés dans l'air ou en orbite terrestre. Une distinction importante entre les systèmes largement utilisés à cette fin concerne la couverture du spectre électromagnétique. Les progrès de l'exploration aéronautique et spatiale conduisent inévitablement à l'intégration de ces technologies à la télédétection. La spectroscopie d'imagerie, une technique majeure pour la télédétection, est capable d'acquérir des images dans des bandes contiguës, des dizaines ou des centaines de bandes spectrales à travers les intervalles visible et infrarouge solaire du spectre électromagnétique. Les ensembles de données d'images résultantes sont appelés images hyperspectrales. L'imagerie hyperspectrale caractérise la réflexion de la lumière sur les objets. Elle utilise les principes fondamentaux des inter-relations entre la couleur, la fréquence et la longueur d'onde de la lumière naturelle [12]. L'imagerie multispectrale, en revanche, contient généralement un petit nombre de bandes spectrales de longueurs d'ondes relativement larges [12, 13]. De plus, les systèmes d'imagerie multispectrale ont souvent leurs bandes spectrales largement espacées de manière irrégulière, tandis que les systèmes d'imagerie hyperspectrale ont des bandes spectrales qui sont adjacentes les unes aux autres et régulièrement espacées [14]. Les spectromètres d'imagerie hyperspectrale sont capables de capturer des images contenant à la fois des informations

spatiales et spectrales à des résolutions relativement fines. Les données obtenues se sont révélées utiles pour identifier différents matériaux et produire des cartes thématiques qui montrent la distribution spatiale de ces matériaux. Cette propriété a conduit à de larges applications de l'imagerie hyperspectrale dans différents domaines, en adaptant le traitement utilisé pour extraire les informations pertinentes. Les images hyperspectrales contiennent un grand volume de données. Le traitement et l'analyse de ce type de données, telle que l'extraction d'informations, nécessitent de comprendre les caractéristiques des données hyperspectrales capturées et les capteurs hyperspectraux utilisés.

2.3 Caractéristiques des images hyperspectrales

Les images hyperspectrales sont généralement disposées sous la forme d'un cube de données tridimensionnel. Les données hyperspectrales peuvent être vues comme un ensemble de "vecteurs de pixels", chacun consistant en un groupe de composants spectraux pour le même emplacement spatial. Chaque composante d'un "vecteur pixel" correspond à l'énergie reçue à une longueur d'onde particulière. En considérant un espace tridimensionnel (x, y, λ) , où x et y sont des coordonnées spatiales et λ la coordonnée spectrale, chaque pixel est l'intégrale du rayonnement dans un petit volume (cube) (voir la Figure 2.1). On peut également considérer le cube de données hyperspectrales comme étant composé d'un groupe d'images 2D co-enregistrées, chaque image correspond à une longueur d'onde particulière. Ces images sont souvent appelées "images de bande" ou simplement "bandes".

2.3.1 Réflectance spectrale

La réflectance est une mesure qui révèle la propriété d'un matériau particulier. Elle est donnée par le rapport entre la quantité d'énergie quittant une cible (ϕ_r) et la quantité d'énergie frappant la cible (ϕ_o). Il s'agit d'un nombre fractionnaire compris entre 0 et 1. La réflectance varie avec la longueur d'onde pour la plupart des matériaux car la lumière à une certaine longueur d'onde qui est réfléchi, diffusée ou absorbée différemment. Sur la Figure 2.2 [11], on montre des spectres de différents matériaux. La forme de la courbe

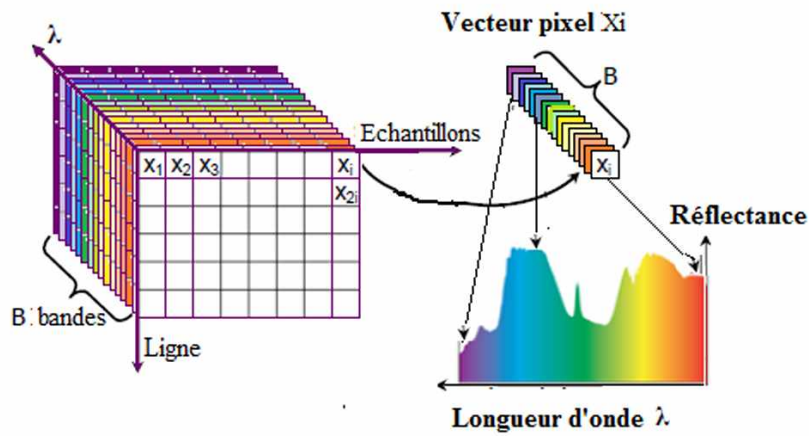


FIGURE 2.1 – Représentation d'un cube d'une image hyperspectrale.

spectrale, la position et la résistance des bandes d'absorption sont souvent utilisées pour distinguer les différents matériaux de surface. La réflectance est donnée par l'équation :

$$\rho = \frac{\phi_r(\lambda)}{\phi_o(\lambda)} \quad (2.1)$$

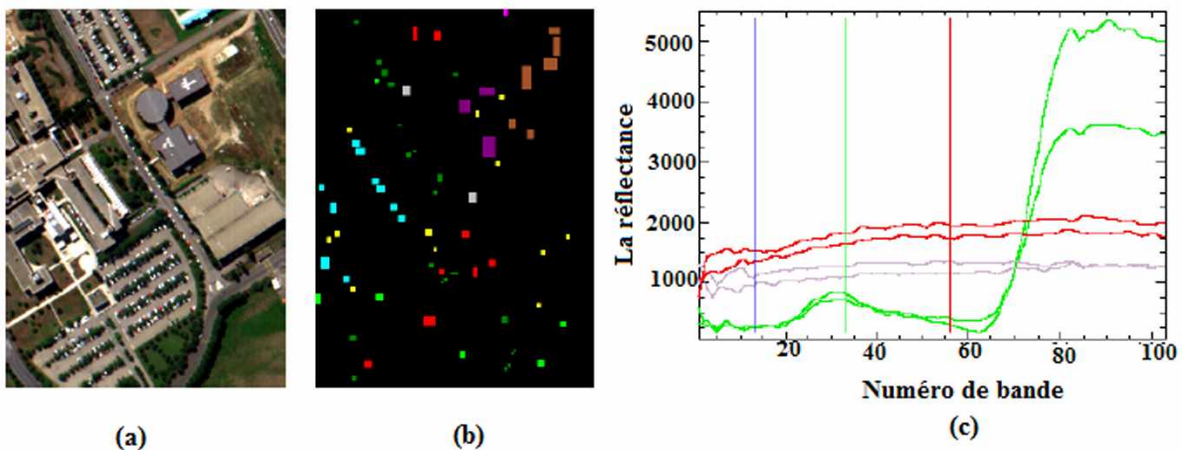


FIGURE 2.2 – Image "Université de Pavie". (a) Composite couleur à trois bandes (650, 558 et 478 nm). (b) Ensemble d'échantillons d'apprentissage. (c) Un affichage des données de six pixels appartenant à trois classes d'asphalte, de prairies et de briques en fonction du nombre de bandes spectrales (longueur d'onde) [11].

2.3.2 Radiance spectrale

La radiance (not $L_{e,\Omega}(\lambda)$) décrit généralement la quantité de lumière que le spectromètre imageur détecte par rapport à l'objet observé. Il s'agit de la quantité directement mesurée par un spectromètre. Le rayonnement indique la quantité d'énergie émise ou réfléchi par une surface reçue par un spectromètre imageur regardant la cible sous un certain angle. Alors que la radiance reflète la quantité totale d'émission ou de réflectance, la radiance spectrale indique la quantité de radiance à une seule longueur d'onde. Les données de la radiance contiennent des informations pertinentes pour la composition du matériau de chaque pixel. La radiance est donnée par l'équation :

$$L_{e,\Omega}(\lambda) = \frac{\partial^2 \Phi_e(\lambda)}{\partial s \partial \Omega \cos \theta_s} \quad (2.2)$$

- ∂ est le symbole de dérivé partiel ;
- Φ_e est le flux rayonnant émis, réfléchi, transmis ou reçu ;
- Ω est une unité d'angle solide ;
- ∂s est une unité de surface.

La quantité $\partial^2 G = \partial s \cdot \partial \Omega \cdot \cos \theta_s$ est appelée débit. Le flux spectral reçu sur un détecteur dont la surface est s et dont le champ de vision ayant un angle solide Ω peut s'écrire :

$$\Phi(\lambda) = \int_s \int_\Omega L(\lambda) \cos \Theta_s \partial s \partial \Omega = \int \int_G L(\lambda) \partial_G^2 \quad (2.3)$$

Cependant, ces informations sont généralement perturbées dans les données collectées par divers aspects. Ceux-ci comprennent des facteurs environnementaux tels que la météo, l'éclairage solaire, les passages atmosphériques vers le bas et vers le haut, et les effets de contiguïté, ainsi que les influences caractéristiques des capteurs. Ces facteurs doivent être compensés efficacement par la combinaison de l'étalonnage du capteur [15] et la normalisation de l'atmosphère [16]. Plusieurs stratégies couramment utilisées pour convertir les données de radiance AVIRIS en données de réflectance sont discutées dans [17].

2.4 Les capteurs hyperspectraux

La grande variété de capteurs hyperspectraux disponibles, qui fournissent des données au format image ou signal, permet d'aborder un grand nombre d'applications avec des avantages remarquables. Cela implique le développement de techniques avancées de traitement et d'interprétation des données qui dépendent du capteur et de l'application. En général, chaque famille de capteurs est caractérisée par des propriétés telles que les résolutions spatiales, spectrales, radiométriques et temporelles, qui sont strictement liées à leur mise en oeuvre physique et adaptées à une application précise.

- **La résolution spatiale** : La taille minimale d'un objet que le capteur est capable de distinguer du sol représente la résolution spatiale et dépend de l'altitude du capteur et de son angle de vue (c'est-à-dire l'angle sous-tendu par le capteur), qui est défini en termes de champ de vision instantané (IFOV). En imagerie numérique, la résolution est limitée par la taille des pixels.
- **La résolution spectrale** : est la longueur d'onde minimale à laquelle l'instrument est sensible.
- **La résolution radiométrique** : est définie comme l'énergie minimale pouvant être détectée par le système de détection. La résolution radiométrique intrinsèque d'un capteur dépend du rapport signal/bruit du détecteur. Dans une image numérique, la résolution radiométrique est limitée par le nombre de niveaux de quantification discrets utilisés pour numériser la valeur d'intensité continue.

Les spectromètres d'imagerie actuels diffèrent dans les méthodes de collecte des données. Ces méthodes se concentrent sur deux aspects principaux, à savoir le balayage spatial et la sélection spectrale. Du point de vue spatial, il existe un certain nombre de façons fondamentales dont les capteurs forment des images (2D). Pour différentes approches, la complexité du plan focal et les exigences de stabilité de la plate-forme diffèrent pour les capteurs [18, 13]. Dans ce qui suit, nous décrivons brièvement les trois approches du balayage spatial.

- **Les scanners Whiskbroom** : couvrent le champ de vision par un mouvement angulaire mécanisé d'un miroir de balayage, ou par la rotation mécanique du capteur. Les lignes d'image sont collectées à l'aide d'un balayage transversal et l'image entière est obtenue en utilisant le mouvement vers l'avant de la plate-forme porteuse.
- **Les scanners Pushbroom** : acquièrent une série d'échantillons unidimensionnels orthogonaux à la ligne de vol de la plate-forme, avec une dimension spatiale le long de la piste construite par le mouvement vers l'avant de la plate-forme. La composante spectrale est obtenue en dispersant le rayonnement entrant sur un réseau de surface. Ce type de scanners ne nécessite pas l'utilisation d'un miroir mobile, car un réseau linéaire de détecteurs génère une ligne d'image à travers le champ de vision simultanément.
- **Les caméras à roue filtrante** : sont des capteurs opto-mécaniques qui modifient la sensibilité spectrale de divers canaux à l'aide d'une roue à filtre rotative dans le chemin optique. Une telle caméra repose sur l'utilisation d'un réseau de détecteurs bidimensionnel dans le plan focal pour acquérir un cadre monochromatique du champ de vision à un moment donné. Les composantes spectrales sont obtenues en faisant tourner la roue de filtre sur différents filtres passe-bande.

Selon la plate-forme sur laquelle le capteur est placé, on peut classer les capteurs hyperspectraux en capteurs aéroportés ou spatioportés (sur un satellite). Un capteur aéroporté est capable de prendre des données partout et en tout temps (dans la mesure où les conditions atmosphériques permettent le vol de l'avion). Un capteur spatioporté n'a pas cette flexibilité car sa géométrie de visée et son horaire d'acquisition des données sont contrôlés par son orbite. Cependant, les radars spatioportés ont l'avantage de pouvoir acquérir des images plus rapidement au-dessus de plus grandes régions que les radars aéroportés, avec une géométrie de visée consistante.

Les récents progrès dans la technologie des capteurs ont conduit au développement d'une nouvelle génération de capteurs hyperspectraux capables de fournir des images

avec une résolution spatiale améliorée. A titre d'exemple, l'AVIRIS, conçu et exploité par le Jet Propulsion Laboratory de la NASA en Californie, aux États-Unis, est utilisé depuis la fin des années 1980 dans un grand nombre d'expériences scientifiques et de campagnes sur le terrain. Déployé sur ER-2 ou WB-57 de la NASA, volant jusqu'à 20 km au-dessus du sol, AVIRIS est capable de collecter des données avec une résolution spatiale de 20 m sur une bande estimée à 11 km. Il peut également être appliqué à une altitude inférieure pour une résolution au sol plus fine. Une image acquise par des capteurs Hyperion (montés sur un satellite EO-1) a une résolution spatiale de 30 m, tandis que ROSIS (spectromètre aéroporté) peut fournir des images avec une résolution spatiale de 1,7 m si l'acquisition est prise à l'altitude de 3 km. HYDICE peut fournir un cube de données de 210 bandes spectrales avec une résolution spatiale de 30 m. Le Tableau 2.1 résume quelques capteurs connus dans le domaine, tout en indiquant les principales caractéristiques spectrales.

TABLE 2.1 – Caractéristiques techniques des principaux capteurs hyperspectraux.

Capteur	Plate-forme	Fabriquant	N^{bre} bandes	Résolution spectrale	Gamme spectrale
Hyperion	Spatioporté	NASA GSFC	220	10 nm	0.4 – 2.5 μm
MODIS	Spatioporté	NASA	36	40 nm	0.4 – 14.3 μm
CHRIS	Spatioporté	Proba ESA	63	1.25 nm	0.415 – 1.05 μm
AVIRIS	Aéroporté	NASA JPL Aerial	224	10 nm	0.4 – 2.5 μm
HYDICE	Aéroporté	Naval Research Lab Aerial	210	7.6 nm	0.4 – 2.5 μm
PROBE-1	Aéroporté	Earth Search Science Aerial	128	12 nm	0.4 – 2.45 μm
CASI 1500	Aéroporté	ITRES Research Ltd Aerial	288	2.5 nm	0.4 – 1.05 μm
SASI 600	Aéroporté	ITRES Research Ltd Aerial	100	15 nm	0.95 – 2.45 μm
TASI 600	Aéroporté	ITRES Research Ltd Aerial	64	250 nm	8 – 11.5 μm
HyMap	Aéroporté	Intergrated Spectronics Aerial	125	17 nm	0.4 – 2.5 μm
ROSIS-3	Aéroporté	DLR Aerial	115	4 nm	0.43 – 0.85 μm
EPS-H		Corporation			
GER	Aéroporté	Aerial GER Corporation	133	0.67 nm	0.43 – 12.5 μm
DAIS 7915	Aéroporté	Aerial Spectral	79	15 nm	0.43 – 12.3 μm
AISA Dual	Aéroporté	Imaging Aerial	500	2.9nm	0.4 – 2.45 μm
MIVIS	Aéroporté	Daedalus Aerial	102	20 nm	0.43 – 12.7 μm
AVNIR	Aéroporté	OKSI Aerial	60	10 nm	0.43 – 1.03 μm

2.5 Traitement des images hyperspectrales

Le traitement des images hyperspectrales est un domaine qui nécessite beaucoup de ressources matérielles et logicielles. Plusieurs approches dans ce domaine ont été récemment proposées pour la classification, la compression, l'identification et la caractérisation des objets des images hyperspectrales. Certaines tâches spécifiques liées au traitement de ces images sont couramment utilisées.

2.5.1 Réduction de dimension

Chaque matériau a sa caractéristique d'absorption spectrale unique. Cependant, des informations discriminantes peuvent n'exister que dans une partie des longueurs d'onde. Par exemple, la différence de spectres entre la végétation et le sol se situe principalement dans le domaine visible mais pas dans le domaine infrarouge lointain. Même si la réflectance spectrale n'est pas similaire, les informations spectrales peuvent être redondantes étant donné que de nombreuses bandes contiguës sont fortement corrélées. De plus, les bruits provenant de l'environnement d'imagerie et des instruments contaminent souvent certaines bandes. Par conséquent, les bandes hyperspectrales brutes doivent être pré-traitées pour les applications de télédétection. En tant que tâche importante, "la réduction de la dimension" tente de réduire les redondances dans les domaines spectral et spatial sans perte d'informations significatives. Elle est implémentée de manière explicite ou implicite dans une application spécifique. Une des approches de réduction de dimension les plus utilisées est l'analyse en composantes principales (ACP) ou la transformée de Karhunen-Loève (TKL).

2.5.2 Extraction de caractéristiques spectrales-spatiales

Alors que les caractéristiques spectrales traditionnelles sont extraites sous forme de réponses au niveau d'un seul pixel dans les images hyperspectrales, les méthodes d'extraction des caractéristiques spectrales-spatiales utilisent le voisinage spatial pour calculer les caractéristiques. Des exemples typiques incluent des caractéristiques de texture

telles que l'ondelette discrète 3D [20], l'ondelette Gabor 3D [21], l'ondelette de diffusion 3D [22] et les modèles binaires locaux [23]. Les profils morphologiques, alternativement, utilisent des opérateurs de fermeture, d'ouverture et géodésiques pour améliorer les structures spatiales des objets [24]. Les autres caractéristiques spectrales et spatiales incluent les harmoniques sphériques [25] et les descripteurs invariants affines [26]. Les caractéristiques hétérogènes peuvent être fusionnées en utilisant des approches de sélection ou de réduction des caractéristiques [27].

2.5.3 Le débruitage des images hyperspectrales

Le débruitage d'image hyperspectrale permet de réduire les bruits aléatoires introduits par le capteur, les effets de photons et les erreurs d'étalonnage. Plusieurs approches ont été exploitées à cet effet, par exemple la diffusion anisotrope, les ondelettes et les méthodes de codage parcimonieuses [28]. Dans la plupart des cas, le débruitage peut être effectué en appliquant un filtre local avec un noyau conçu ou appris sur toute l'image.

2.5.4 La classification des images hyperspectrales

La classification d'images se réfère au processus d'identification des divers objets, matériaux ou éléments d'intérêt ayant des propriétés communes qui sont regroupés dans ce qu'on appelle "classes" de couverture présentes sur le terrain de la zone d'intérêt étudiée. Le produit de ce processus est une carte thématique, où les pixels sont caractérisés par une étiquette donnée, généralement représentée par une couleur ou un symbole, utilisée pour identifier de manière unique les éléments d'une classe. Plusieurs approches sont proposées dans ce domaine. On peut souligner "l'approche de reconnaissance des motifs par pixel". L'idée de base de cette méthode est que chaque pixel d'image est considéré comme un motif et son spectre est considéré comme l'ensemble initial de caractéristiques. Étant donné que cet ensemble de fonctionnalités est souvent redondant, des étapes d'extraction/sélection des caractéristiques sont effectuées afin de réduire la dimension de l'ensemble de caractéristiques et de maximiser la séparabilité entre les classes. Différentes techniques d'extraction d'entités ont été proposées et explorées à

cette fin, telles que l'extraction d'entités d'analyse discriminante (DAFE), l'extraction d'entités décisionnelles (DBFE) et l'extraction d'entités pondérées non paramétriques (NWE) [29]. On peut également trouver des approches de classification d'images qui reposent sur la relation spatiale entre les pixels pour la construction de modèles. Un moyen direct de le faire est de calculer la similitude entre un pixel et ses pixels adjacents [30]. Le champ aléatoire de Markov, par exemple, traite l'image hyperspectrale comme des données dépendantes et utilise des informations spectrales dans le voisinage local pour faciliter la prédiction des classes de pixels [31]. Des structures spatiales similaires sont explorées dans des champs aléatoires conditionnels [32], la modélisation hypergraphique [33] et l'analyse multi-échelles [34]. Les informations spatiales peuvent également être explorées dans la construction de noyaux composites dans des machines à vecteurs supports [35]. Les approches d'apprentissage supervisé, telles que les K-plus proches voisins, l'analyse discriminante linéaire, l'analyse bayésienne, les machines à vecteurs supports sont largement utilisées dans ces tâches de classification [36]. Néanmoins, certaines approches adoptent des stratégies d'apprentissage semi-supervisées ou actives [37].

A souligner que pour la classification des images hyperspectrales, il n'y a que peu de données étiquetées disponibles pour la formation et les tests, en raison du manque d'ensembles de données de référence et du coût élevé de la collecte de données de vérité au sol. Par conséquent, toutes les méthodes d'apprentissage supervisé ne conviennent pas à une telle tâche, en particulier celles qui nécessitent une grande quantité de données de formation.

2.5.5 La compression des images hyperspectrales

L'objectif de la compression des données d'image est de réduire la quantité de mémoire ou de bande passante nécessaire pour stocker et transmettre des images. Elle peut être motivée par un canal de transmission à bande passante limitée, la nécessité de réduire l'effort de transmission, le temps de transmission limité, les coûts de transmission élevés ou la capacité de stockage limitée. La compression des données est, en général,

possible car les informations contiennent souvent des informations redondantes ou non pertinentes. La compression sans perte est obtenue si les informations d'origine peuvent être reconstruites exactement sans déviation. La compression avec perte est généralement obtenue en supprimant les informations non pertinentes. Si la perte d'informations est négligeable par rapport à l'observateur ou à l'application, on parle de compression quasi sans perte.

Les techniques de compression sans perte consistent à la fois en une corrélation spatiale et spectrale des images [38]. La décorrélation spatiale est réalisée par plusieurs modèles prédictifs linéaires ou non linéaires tels que le codage d'image adaptatif sans perte basé sur le contexte (CALIC) [39], prédicteur de compression sans perte à faible complexité pour les images (LOCO-I) sur JPEG-LS [40], régression linéaire [44], transformée en ondelettes discrètes 2D et la décomposition de Tucker (TD-DWT) [43], Fast Lossless (FL) dans le Comité consultatif pour les systèmes de données spatiales (CCSDS) [41], la modulation différentielle à code d'impulsion (DPCM) [42].

Pour les techniques de compression avec perte, la décorrélation spectrale est effectuée par plusieurs algorithmes bien connus basés sur la transformation tels que l'analyse en composantes principales (ACP) [45], l'analyse en ondelettes de régression (RWA) [46], l'ACP suivie de la transformation en cosinus discret (ACP-DCT)[47], Représentation parcimonieuse (SR) [38] etc.

2.6 Discussion

Nous avons présenté dans ce chapitre les principes fondamentaux et les travaux connexes des images hyperspectrales, des capteurs hyperspectraux et des approches connues utilisées pour le traitement et l'analyse des données hyperspectrales détectées. Des termes tels que la réflectance, la radiance et les résolutions spatiale et spectrale sont introduits. Nous avons également présenté les propriétés des capteurs hyperspectraux les plus connus pour la détection des données hyperspectrales et un état de l'art des différentes méthodes de traitement des images hyperspectrales récemment développées.

Chapitre 3

Représentation parcimonieuse et traitement de signal sur graphes

Sommaire

3.1	Préambule	24
3.2	Représentation parcimonieuse	24
3.2.1	Définition	24
3.2.2	Approximation parcimonieuse	25
3.3	Généralités sur le traitement de signal sur graphes	31
3.3.1	Définition d'un signal sur graphes	31
3.3.2	Matrice d'adjacence	32
3.3.3	Matrice de Laplace	32
3.3.4	Transformée de Fourier sur graphe	33
3.4	Transformée en ondelette spectrales sur graphes	34
3.4.1	Les ondelettes spectrales sur graphes	34
3.4.2	Structure des ondelettes spectrales sur graphes	35
3.4.3	Comparaison entre les ondelettes classiques et les ondelettes spectrales sur graphes	40
3.5	Discussion	42

3.1 Préambule

Dans ce deuxième chapitre, nous allons rappeler quelques généralités sur la représentation parcimonieuse, et plus précisément sur les modèles utilisés dans ce domaine, avant d'évoquer les bases théoriques du traitement sur graphes et des ondelettes spectrales sur graphes. Dans une première partie, nous présentons un état de l'art sur la représentation parcimonieuse qui s'est avérée être un outil puissant dans le traitement d'image. Dans les deux autres parties du chapitre, nous détaillons les notions du domaine de traitement du signal sur graphes et une nouvelle méthode multi-échelle basée sur les ondelettes sur graphes.

3.2 Représentation parcimonieuse

3.2.1 Définition

Dans les traitements du signal et de l'image, la modélisation des données est une étape cruciale pour effectuer diverses opérations telles que la compression et la restauration. L'un des plus grands enjeux de ces traitements est de trouver l'information utile au sein des espaces de données redondantes de grandes dimensions. Les modèles basés sur la représentation parcimonieuse sont considérés comme viables dans ce domaine. Ces modèles adhèrent à la règle de la parcimonie, ce qui signifie de représenter un phénomène avec le moins de variables possible [19]. Une représentation parcimonieuse permet donc de représenter de façon optimale des données redondantes grâce à une sélection souple des composantes disponibles. Cela permet de réduire la taille des données tout en gardant l'information utile avec un taux fidélité/perte maîtrisable.

En utilisant une représentation parcimonieuse, nous supposons qu'une image $I \in R^M$ est générée par une combinaison linéaire de quelques éléments d'un dictionnaire sur-complet $D \in R^{M \times K}$ ($M < K$) qui contient K colonnes ou prototypes d'atomes. Autrement dit, la représentation de I est $I = D\alpha$. Le vecteur $\alpha \in R^K$ correspond aux coefficients de la représentation parcimonieuse de I [48]. Clairement, $I = D\alpha$ définit

un système linéaire sous-déterminé avec plus d'inconnues que les équations. Par conséquent, s'il a une solution, il existe une infinité de α s qui peuvent correspondre à I . Afin de restreindre les choix à une solution bien définie, le problème est transformé en un problème d'optimisation [49]

$$\operatorname{argmin}_{\alpha} J(\alpha) \text{ tel que } I = D\alpha \quad (3.1)$$

où ($J(\alpha)$) contrôle les activités des coefficients en α .

3.2.2 Approximation parcimonieuse

La représentation parcimonieuse d'un signal est approximée par la combinaison linéaire de quelques éléments de dictionnaire. De nombreux travaux ont été proposés pour la conception de dictionnaires susceptibles d'atteindre l'objectif de parcimonie. Particulièrement, deux grandes familles sont largement connues dans ce domaine. La première famille regroupe les approches s'appuyant sur les modèles mathématiques de données. Cela conduit à différentes sortes de transformées telle que la DCT et les ondelettes [50, 51, 52, 53, 54, 55, 56]. Les autres approches sont celles pour lesquelles le dictionnaire est appris à partir des données.

3.2.2.1 Décomposition parcimonieuse sur des dictionnaires

Il est connu que cette solution a l'avantage de simplicité et du moindre coût. Cependant, le problème de synthétiser au mieux un signal en privilégiant un certain comportement de ces coefficients a été posé. Pour résoudre ce problème, la solution de chercher un comportement parcimonieux a été proposée. Il faut donc résoudre le problème :

$$\min \|\alpha\| \text{ tel que } \|y - \phi\alpha\| < \varepsilon \quad (3.2)$$

c'est-à-dire minimiser le nombre de coefficients tout en contrôlant l'erreur de reconstruction :

$$\min_{\alpha} [\|y - \phi\alpha\|_2^2 \text{ tel que } \|\alpha\|_b = K \quad (3.3)$$

Minimiser l'erreur de reconstruction revient à fixer un budget de K atomes. Deux approches sont connues dans la littérature, i.e. Une approche gloutonne et une approche variationnelle.

Algorithmes gloutons Le principal défaut des algorithmes de minimisation classiques (norme l_p) est leurs complexité. Le résultat final obtenu avec ces algorithmes est parcimonieux. Cependant, ils engendrent un coût très important dû aux très grand nombre des coefficients non-nuls de I . Avec les algorithmes gloutons, on n'utilise que l'ordre de K atomes à chaque itération.

- **Seuillage dur** : C'est l'algorithme le moins coûteux. Il consiste à sélectionner les K atomes dont le produit scalaire avec le signal, en valeur absolue, est le plus grand. Il faut ensuite calculer l'amplitude des coefficients par projection orthogonale sur le sous-dictionnaire ϕ_K . L'inconvénient de cet algorithme est son mauvais fonctionnement dès que le dictionnaire comporte des atomes qui se ressemblent.
- **Matching Pursuit (MP)** : Cet algorithme évite le problème posé par le seuillage dur en remplaçant la sélection simultanée des K atomes les plus corrélés par une sélection séquentielle. A chaque itération de l'algorithme, on ne sélectionne qu'un atome et on l'enlève du signal. L'inconvénient principal de cet algorithme est que si ϕ n'est pas orthogonal, alors en soustrayant un atome on peut rajouter une composante sur un atome déjà enlevé. On peut donc sélectionner un atome plusieurs fois, voire même effectuer un nombre infini d'itérations pour annuler le résidu même si on a déjà identifié le bon support.
- **Orthogonal Matching Pursuit (OMP)** : Afin d'éviter qu'un atome soit sélectionné plusieurs fois, il existe une version orthogonale du matching pursuit. Cette version est basée sur l'idée de remplacer l'étape de mise à jour du signal par une projection orthogonale sur l'espace engendré par les atomes sélectionnés. L'algorithme converge alors en au plus N itérations, où N est la taille du dictionnaire. Cette version a l'inconvénient d'être plus coûteuse en temps de calcul.

Approche variationnelle Consiste à construire une fonctionnelle "proche" du problème original, tout en étant facilement optimisable. On trouve alors la méthode du Basis Pursuit (BP) de Chen et Donoho [57], le Basis Pursuit Denoising (BPDN) [58] ou problème LASSO qui peut-être optimisé avec les algorithmes de type "seuillage itératif" ISTA (Iterative Shrinkage/Thresholding Algorithm) [59, 60] et FISTA (Fast Iterative Shrinkage/Thresholding Algorithm) [61].

3.2.2.2 Transformée en ondelettes

La transformée en ondelettes est un outil mathématique efficace pour l'analyse temps-fréquence dans le traitement du signal et la reconnaissance des formes. Une ondelette est une fonction normalisée ψ dans $L^2(\mathbb{R})$ avec une moyenne nulle [62]. Une ondelette discrète est le produit scalaire d'une séquence de longueur finie et d'une base d'ondelettes discrètes avec un facteur d'échelle s_0^a et un facteur de translation b :

$$\psi_{b,a}(n) = \frac{1}{\sqrt{s_0^a}} \psi\left(\frac{n-b}{s_0^a}\right). \quad (3.4)$$

Les coefficients d'ondelettes $W_f(b, a)$ d'une séquence $f(n)$ sont obtenus en projetant f sur la famille $\psi_{b,a}(n)$:

$$W_f(b, a) = \langle f(n), \psi_{b,a}^* \rangle = \sum_{n=0}^N f(n) \cdot \psi_{b,a}^*(n), \quad (3.5)$$

où $\psi_{b,a}^*$ désigne le conjugué de $\psi_{b,a}$ et $\langle \cdot, \cdot \rangle$ le produit scalaire. Le paramètre a détermine la région de fréquence. Un grand $|a|$ indique les basses fréquences, tandis qu'un petit $|a|$ indique les hautes fréquences [63]. Notez que pour la transformée en ondelettes discrète dyadique $s_0 = 2$. L'analyse en multi-résolution [64] permet d'analyser un signal en différentes bandes de fréquences, ce qui permet une vue de la plus fine à la plus grossière. La théorie de la multirésolution conçoit la transformée en ondelettes discrètes DWT comme une séquence d'application de filtres sur un signal. Celui-ci sera

constitué des approximations (basses fréquences) et des détails (composantes hautes fréquences). La reconstruction parfaite est théoriquement possible en faisant passer les approximations (AC) et les détails (DC) par un sur-échantillonnage (up-sampling) puis un filtrage en utilisant respectivement les filtres passe bas de reconstruction et les filtres passe haut de reconstruction. Ceci permet de donner en somme le vecteur d'origine $f(n)$. Cette étape est appelée décomposition/reconstruction en banc de filtres. Elle est caractéristique aux signaux unidimensionnels. Pour une décomposition en multi-niveaux du signal, Mallat ([64]) a proposé un algorithme qui permet de décomposer le signal $f(n)$ en plusieurs niveaux en se basant sur un processus d'analyse itératif. Les modèles d'ondelettes peuvent se généraliser à n'importe quelle dimension $n > 0$. L'analyse multi-résolution des espaces vectoriels des ondelettes 2D et 3D satisfont une extension des propriétés d'ondelettes 1D.

Familles d'ondelettes Les familles d'ondelettes peuvent être caractérisées par quatre propriétés principales : existence de filtres associés, orthogonalité ou biorthogonalité, support compact ou non, ondelettes réelles ou complexes (pour ondelettes sans filtres). Les ondelettes à filtre sont associées à des analyses multi-résolution orthogonales ou biorthogonales ce qui permet le calcul de la transformée discrète et les calculs rapides en utilisant l'algorithme de Mallat. Les ondelettes sans filtre, en revanche, sont plus utiles pour la transformée en ondelettes continues. En général, les ondelettes à support compact n'ont pas de forme analytique (c'est-à-dire qu'on sait comment calculer la fonction, mais on ne peut pas l'exprimer avec une équation mathématique connue).

- Ondelette de Daubechies : Cette famille d'ondelettes (dbN) Daubechies [65], est la première qui permet de manipuler des ondelettes orthogonales à support compact de régularité arbitraire, on dit que N est l'ordre de l'ondelette dbN . Cette famille contient l'ondelette de Haar ($db1$), qui est la plus simple et certainement la plus ancienne des ondelettes. Elle est discontinue et ressemble à un échelon. Hormis $db1$, les ondelettes de cette famille, de l'ordre de 2 à 10 ($db2, db3, , db10$), n'ont pas une formule analytique. L'ondelette $db4$ est présentée sur la Figure 3.1(a). Les ondelettes dbN sont asymétriques, en particulier pour les faibles valeurs de N ,

sauf pour l'ondelette de Haar, leur régularité augmente avec l'ordre et l'analyse avec cette famille est orthogonale.

- Ondelettes de Symlets : Les symlets ($symN$) constituent une famille d'ondelettes presque symétrique, proposée par I. Daubechies en modifiant la construction des dbN . A part la symétrie, les autres propriétés des deux familles sont similaires. Sur la Figure 3.1(b), on représente les symlets 8.
- Ondelettes CDF5/3 : Les ondelettes biorthogonales 5/3 font partie de la famille des ondelettes biorthogonales symétriques de Cohen-Daubechies-Feauveau (CDF). Elles sont dénommées ainsi car la largeur du support de leurs filtres passe-bas est de $p = 5$ échantillons à l'analyse et $\hat{p} = 3$ à la synthèse. De plus, elles possèdent $N = \hat{N} = 2$ moments nuls. De part leur relative simplicité et la symétrie qu'elles offrent, les ondelettes 5/3 présentées en Figure 3.1(c) sont assez utilisées en codage d'image.
- Ondelettes CDF9/7 : Tout comme les ondelettes 5/3, les ondelettes biorthogonales 9/7 font partie de la famille des ondelettes biorthogonales symétriques CDF. Les filtres passe-bas associés aux ondelettes 9/7 possèdent ainsi $p = 9$ coefficients à l'analyse, $p = 7$ coefficients à la synthèse. Les ondelettes biorthogonales 9/7 sont illustrées en Figure 3.1(d) et possèdent $N = 4$ moments nuls à l'analyse et $\hat{N} = 2$ à la synthèse. Les ondelettes 9/7 possèdent un grand nombre de moments nuls pour un support relativement court. Elles sont de plus symétriques et très proches de l'orthogonalité. C'est une caractéristique importante en codage qui lui permet d'assurer que l'erreur de reconstruction soit très proche de l'erreur de quantification, en terme d'erreur quadratique moyenne. C'est une transformée très utilisée pour la décorrélation d'images naturelles et en codage d'image [66, 67]. Elle est également utilisée par le codec JPEG-2000 [68]. Une étude assez complète des propriétés théoriques des ondelettes biorthogonales 5/3 et 9/7 est présentée dans [70].




FIGURE 3.1 – Les familles d’ondelettes. (a) : Les ondelettes db4, (b) : Les ondelettes de symlets, (c) : Les ondelettes CDF5/3, (d) :Les ondelettes CDF9/7.

Le traitement du signal a historiquement pour objectifs de débruiter des signaux, de détecter l’information pertinente a partir d’un ensemble de données ou d’utiliser les connaissances "a priori" que l’on peut avoir sur les données pour rendre l’analyse plus fine. Le traitement de signal est de plus en plus sollicité pour étudier des données toujours plus volumineuses et complexes. Étant donné qu’une partie non-négligeable de ces données est collectée automatiquement et sans buts précis, nous avons affaire à des données de moins en moins structurées, parsemées d’informations inutiles. L’augmentation de la taille des données, alliée à la diminution de leur structure, posent de nouvelles questions fondamentales dans le domaine du traitement du signal. Plusieurs méthodes sont utilisées pour palier à ces problèmes. Les représentations parcimonieuses consistent à représenter un signal par un vecteur parcimonieux contenant seulement

quelques coefficients non nuls en utilisant une combinaison linéaire d'une matrice dite dictionnaire. Cependant, l'utilisation des représentations parcimonieuses nécessite de coder ces coefficients non nuls ainsi que les indices des atomes du dictionnaire auxquels ils correspondent. Ce qui implique d'augmenter la taille du dictionnaire afin d'améliorer sa capacité de représentation. Ceci ne convient pas aux données intégrées dans des espaces de grande dimension. Nous nous intéressons à un type de grandes données en pleine expansion : des données structurées sous forme de réseaux modélisés par des graphes.

3.3 Généralités sur le traitement de signal sur graphes

3.3.1 Définition d'un signal sur graphes

Selon [71], un graphe G est une paire ordonnée $(V(G), E(G))$ composée d'un ensemble de noeuds $V(G)$ et d'un ensemble de liens $E(G)$ connectant les noeuds entre eux. Si u et v sont deux noeuds et e est le lien qui les connecte, on appelle u et v les extrémités de e . On note le nombre de noeuds et de liens dans le graphe par $v(G)$ et $e(G)$, respectivement. Ces deux paramètres sont appelés "degré" et "taille" du graphe G . Selon le nombre de liens qui relie deux noeuds, on définit :

- Une boucle : un lien qui connecte un noeud à lui même
- Liens parallèles : deux noeuds peuvent être connectés par plusieurs liens
- Un graphe simple : qui ne contient ni liens parallèles ni boucles.

On dit d'un graphe qu'il est non-orienté si pour tout lien (ij) , (ji) existe aussi. Sinon, on dit que c'est un graphe orienté.

Un signal sur graphe f est défini sur les noeuds d'un graphe donné $G = (V, E)$ par :

$$f : \begin{cases} V \rightarrow R \\ i \rightarrow f(i) \end{cases} \quad (3.6)$$

3.3.2 Matrice d'adjacence

Une matrice d'adjacence notée A d'un graphe G est la matrice qui code les connexions entre les noeuds V . Si on note N le nombre de noeuds du graphe, A est de taille $N \times N$ et donnée dans [69] par :

$$A_{ij} = \begin{cases} 1 & \text{si le lien } (ij) \text{ existe} \\ 0 & \text{sinon} \end{cases} \quad (3.7)$$

Ces liens des graphes ont deux états : soit ils existent, soit ils n'existent pas. On dit que ces graphes sont binaires (leurs matrices d'adjacence sont composées uniquement de 0 et de 1).

Dans le cas où chaque lien est associé à un poids qui code l'intensité de l'interaction entre les deux noeuds reliés, on dit que ces graphes sont pondérés. Nous notons W la matrice d'adjacence pondérée d'un tel graphe, où $W_{ij} \in R$ est le poids du lien connectant le noeud i au noeud j . La matrice d'adjacence est donnée par :

$$A_{ij} = \begin{cases} W_{ij} & \text{si } (i,j) \in E \\ 0 & \text{sinon} \end{cases} \quad (3.8)$$

La matrice d'adjacence d'un graphe non orienté est symétrique [69].

3.3.3 Matrice de Laplace

La matrice laplacienne d'un graphe pondérée est une matrice positive, symétrique et semi-définie, définie comme :

$$L = D - A \quad (3.9)$$

où D est une matrice de taille $N \times N$. Elle est définie comme une matrice diagonale avec des éléments diagonaux égaux aux degrés et des zéros ailleurs. Les degrés représentent la somme des poids de toutes les arêtes incidentes de chaque sommet. A est la matrice d'adjacence symétrique de G de taille $N \times N$. D est définie comme suit [69] :

$$D_{ii} = \sum_j A_{i,j} \quad (3.10)$$

Pour chaque fonction réelle $f : V \rightarrow R$ donnée sur les sommets du graphe G est considérée comme un vecteur dans R^N . La valeur de la fonction f sur chaque sommet du graphe définit chaque coordonnée. Il est notifié comme $f \in R^N$, où $f(i)$ est la valeur sur le sommet i^{me} . L'équation (3.9) peut être satisfaite pour tout $f \in R^N$, elle est donnée par :

$$(Lf)(i) = \sum_{i \sim j} w_{i,j} \times (f(i) - f(j)) \quad (3.11)$$

où la somme sur $i \sim j$ indique la sommation des j sommets connectés au sommet i et $w_{i,j}$ désigne le poids du bord reliant i et j . La matrice Laplacienne L a un ensemble complet de vecteurs propres qui sont notés X_l pour $l = 0, \dots, N - 1$ avec des valeurs propres λ_l .

$$LX_l = \lambda_l X_l. \quad (3.12)$$

Les valeurs propres ne sont pas négatives.

3.3.4 Transformée de Fourier sur graphe

Les exponentielles complexes $e^{iw x}$ définissant la transformée de Fourier sont des fonctions propres de l'opérateur Laplacien unidimensionnel $\frac{d}{dx^2}$. La transformée de Fourier inverse :

$$f(x) = \frac{1}{\pi} \int \hat{f}(w) e^{iw x} dw \quad (3.13)$$

peut donc être considérée comme l'expansion de f en termes de fonctions propres de l'opérateur Laplacien. Le graphe de la transformée de Fourier est défini en analogie précise avec la déclaration précédente. Le graphe Laplacien L étant une matrice symétrique, il possède un ensemble complet de vecteurs propres orthonormaux. Comme L est symétrique, chacun des λ_l est réel. Pour le graphe Laplacien, les valeurs propres sont toutes non négatives, et 0 apparaît comme une valeur propre avec une multiplicité égale au nombre de composantes connectées du graphe[72]. Désormais, supposant que

le graphe G est connecté, on peut donc ordonner les valeurs propres telles que :

$$0 = \lambda_0 < \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_{N-1} \quad (3.14)$$

Pour toute fonction $f \in R^N$ définie sur les sommets de G , sa transformée de Fourier sur graphe \hat{f} est défini par :

$$\hat{f}(l) = \langle X_l, f \rangle = \sum_{n=1}^N X_n^* f(n) \quad (3.15)$$

La transformée inverse se lit comme :

$$f(n) = \sum_{l=0}^{N-1} \hat{f}(l) X_l(n) \quad (3.16)$$

La relation de Parseval est valable pour la transformée de Fourier sur graphe, en particulier pour tout $f, h \in R$:

$$\langle f, h \rangle = \langle \hat{f}, \hat{g} \rangle \quad (3.17)$$

3.4 Transformée en ondelette spectrales sur graphes

3.4.1 Les ondelettes spectrales sur graphes

Une traduction des filtres spectraux de graphes lisses est accomplie en multipliant chaque filtre par un vecteur propre Laplacien graphique dans le domaine de Fourier. La transformée de Fourier sur graphe \hat{f} pour toute fonction $f \in R^N$, définie sur les sommets du graphe pondéré G , est donnée par l'équation (3.15). Pour générer la transformée en ondelettes spectrales sur graphes (SGWT), une fonction noyau $g : R^+ \rightarrow R^+$ dans le domaine spectral est introduit, comme : $g(0) = 0$ et $\lim_{x \rightarrow \infty} g(x) = 0$. La représentation spectrale d'un opérateur $T_g = g(L)$ d'ondelettes est obtenue en modulant chaque mode de Fourier, comme :

$$\widehat{T}_g f(l) = g(\lambda l) f(l) \quad (3.18)$$

A l'échelle J , cet opérateur est obtenu par T_g^J . La fonction d'échelle $\phi_{J,n}(m)$ localisée dans le sommet n à l'échelle J pour capturer les composantes résiduelles passe-bas h est définie comme :

$$\phi_{J,n}(m) = \sum_{l=0}^{N-1} h(J\lambda_l) X_l^*(n) X_l(m) \quad (3.19)$$

La SGWT d'une fonction sur les sommets $f \in R^N$ à l'échelle J et le sommet n est ainsi défini comme suit :

$$W_f(J, n) = \sum_{k=0}^{N-1} g(J\lambda_k) \widehat{f}_{(k)} X_k(n) \quad (3.20)$$

Par conséquent, une fonction linéaire W_f est générée avec N pixels représentatifs présentés dans des ensembles de coefficients d'échelle $(J + 1)$. Cela correspond aux noyaux des filtres passe-bas h et passe-bande J . On souligne que, la décomposition directe nécessite une consommation de temps élevée. Pour résoudre ce problème, les auteurs de [73] ont proposé d'utiliser l'approximation polynomiale de Chebyshev. Les coefficients générés par l'analyse multi-échelles permettent une bonne connaissance des caractéristiques locales et la similitude des graphes entre sommets à différentes échelles.

3.4.2 Structure des ondelettes spectrales sur graphes

Dans cette partie, nous détaillons les différentes étapes pour la construction des coefficients d'ondelettes spectrales sur graphes. Sur la Figure 3.2, nous résumons ces différentes étapes.

- **Extraction de données** L'une des motivations de la classification des images est de caractériser les caractéristiques de la texture en utilisant une approche ponctuelle. Cela signifie de représenter un contenu d'image par un ensemble de pixels d'intérêt au lieu de tous les pixels d'image, comme le cas des approches par-

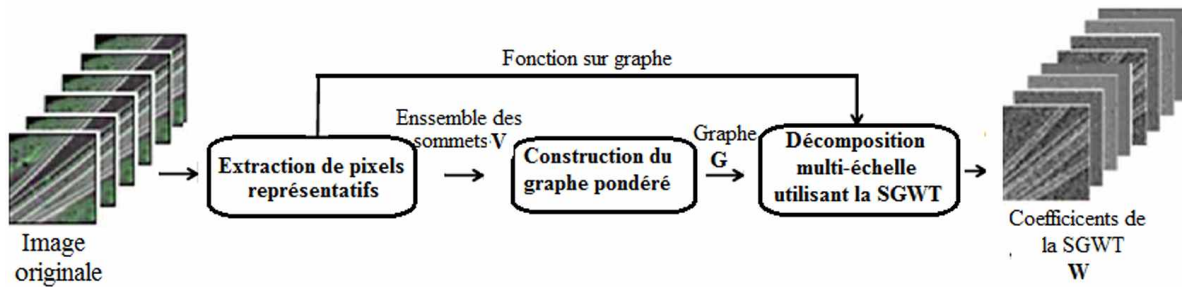


FIGURE 3.2 – Construction des coefficients d’ondelettes spectrales sur graphes

cimonieuses. Le principal avantage d’une telle représentation d’image clairsemée est de réduire le temps de traitement, ce qui est très important face à des données de grande taille comme les images hyperspectrales. Cependant, des problèmes concernant la perte d’informations de l’image peuvent survenir. Par conséquent, un compromis entre le niveau de perte d’informations de l’image et la réduction des coûts de calcul doit être pris en compte. Plusieurs méthodes d’extraction de pixels représentatifs ont été proposées dans la littérature. Dans [74], les auteurs ont proposé de fixer une fenêtre de recherche selon une distribution de probabilités qui permet de sélectionner les pixels locaux maximaux et minimaux afin d’optimiser le nombre d’échantillons représentatifs. Une approche basée sur un choix optimal d’une fenêtre de recherche selon une distribution de probabilités a été discuté dans [75].

- **Construction du graphe pondéré** Le calcul des poids de bord de graphe nous permet de construire la matrice d’adjacence du graphe. Étant donné que chaque sommet possède lui-même un vecteur de description, les poids de bord associés à la similitude des sommets peuvent être définis en général de deux manières. L’une consiste à utiliser un seuil pour ne conserver que les arêtes fortes entre les sommets tandis que l’autre consiste à connecter chaque sommet à ses voisins les plus proches en termes de mesure de distance entre leurs vecteurs de description. La seconde méthode est en général la plus utilisée dans la littérature ; car il semble plus simple de contrôler le nombre d’arêtes de chaque sommet que de fixer un seuil

d'élimination des arêtes faibles. Ainsi, les poids de bord sont calculés comme suit :

$$w(i, j) = \begin{cases} e^{-\gamma [\text{dist}(\delta(i), \delta(j))]^2} & \text{Si } j \in N_k(i) \\ 0 & \text{Sinon} \end{cases} \quad (3.21)$$

où $\text{dist}(\delta(i), \delta(j))$ est la distance entre les spectres des pixels comparés $(\delta(i))$, $(\delta(j))$ des noeuds (les sommets) i et j .

La Figure 3.3 montre un schéma représentant la sélection des pixels représentatifs.




FIGURE 3.3 – Sélection des pixels représentatifs.

- **Décomposition multi-échelle en utilisant la SGWT** Après avoir calculé la matrice d'adjacence, la transformée en ondelettes sur graphes est principalement effectuée dans le domaine spectral via la décomposition propre en valeurs et vecteurs propres de la matrice Laplacienne L . Étant donné qu'une telle décomposition nécessite un temps de calcul très élevé, en particulier face à de grandes tailles graphiques, les auteurs dans [73] ont proposé un calcul rapide utilisant l'approximation polynomiale tronquée de Chebyshev. Les auteurs ont également confirmé que cette approximation est fortement efficace dans le cas d'une matrice Lapla-

cienne parcimonieuse qui est appropriée à la méthode de construction du graphe basée sur la mesure de distance entre les pixels. L'implémentation de la SGWT nécessite la conception de filtres passe-bas et passe-bande, ou même passe-haut, dans le domaine spectral des graphes. Pham et al [76] ont souligné que le choix des noyaux de filtre n'est limité par aucune contrainte de reconstruction de signal. Cet avantage donne plus de possibilités lors de la sélection de filtres successifs pour capturer les fréquences attendues le long de l'axe et produire ensuite des coefficients d'ondelettes souhaitables. Étant donné la matrice d'adjacence A et le nombre de niveaux de décomposition J , les étapes d'implémentation de la SGWT sont résumées comme suit :

- Calculer la matrice graphique Laplacienne $L = D - A$ et estimer la borne supérieure λ_{max} du domaine spectral du graphe ;
- Calculer l'ensemble d'échelles J qui décidera des niveaux d'étirement des noyaux de filtre sur le domaine fréquentiel. Ensuite, concevoir l'ensemble de filtres comprenant un passe-bas $h(\cdot)$ et j - passe-bande g^{t_j} correspondant à chaque échelle t_j ;
- Calculer l'approximation polynomiale de Chebyshev pour la fonction de décomposition et les ondelettes ;
- Calculer tous les coefficients SGWT consistant en un ensemble de coefficients de fonction d'échelle $S_f(n)$ et J -ensembles de coefficients d'ondelettes $W_f(t_j, n)$ en supposant que la fonction des sommets $f(n)$ est la valeur d'intensité au sommet n .

Par conséquent, avec un ensemble de N pixels représentatifs liés par un graphe pondéré, l'analyse SGWT génère $(J + 1)$ ensembles de coefficients qui contiennent les notions de caractéristiques locales ainsi que la similitude entre les sommets du graphe à différentes échelles.

La Figure 3.4 montre un exemple de décomposition multi-échelles SGWT appliquée sur l'image KSC captée par AVIRIS. Chaque sommet est connecté à ses 4 voisins les plus

proches sur le plan d'image, avec une échelle de décomposition $J = 3$ et une distance Euclidienne.




FIGURE 3.4 – Exemple de décomposition à plusieurs échelles de la transformée en ondelettes spectrales sur graphes sur l'image KSC. (a) : Coefficients d'échelle, (b) : Coefficients d'ondelettes à l'échelle 1, (c) : Coefficients d'ondelettes à l'échelle 2, (d) : Coefficients d'ondelettes à l'échelle 3.

Nous soulignons que les méthodes d'extraction de données et l'utilisation de la distance Euclidienne, vues précédemment, peuvent ne pas conclure aux résultats les plus efficaces. Ceci est dû à la méthode de sélection des pixels représentatifs qui peut négliger certaines caractéristiques de l'image. Celles-ci peuvent s'avérer importantes pour l'analyse de données. En effet, les pixels représentatifs doivent être choisis en se basant sur une étude de similitude plus raffinée afin de préserver au mieux les données de l'image, d'où la nécessité d'une étude de similarité plus approfondie entre les pixels de l'image.

3.4.3 Comparaison entre les ondelettes classiques et les ondelettes spectrales sur graphes

Depuis l'introduction de la théorie des ondelettes pour les fonctions intégrables carrées, de nombreux auteurs ont introduit des extensions et des transformations associées pour les signaux dans des espaces de dimension supérieure. Les ondelettes classiques sont construites en traduisant et en mettant à l'échelle une seule ondelette "mère". Les coefficients de transformation sont ensuite donnés par les produits internes de la fonction d'entrée avec ces formes d'onde traduites et mises à l'échelle. En prenant des produits séparables d'ondelettes unidimensionnelles, on peut construire des familles orthogonales d'ondelettes dans n'importe quelle dimension [52]. Une grande famille de transformées multi-échelles alternatives a été développée et largement utilisée pour le traitement d'images, notamment les pyramides Laplaciennes [77], les ondelettes orientées [78], les ondelettes complexes à deux arbres [79], les curvelets [80, 81] et les bandelettes [82]. Des transformées en ondelettes ont également été définies pour certaines variétés non euclidiennes, notamment la sphère [83, 84] et d'autres sections coniques [85]. Cependant, cela donne des ondelettes avec un biais souvent indésirable pour les directions des axes de coordonnées. De plus, cette approche produit un certain nombre d'ondelettes exponentielles dans la dimension de l'espace et ne convient pas aux données intégrées dans des espaces de grande dimension. Étendre directement cette construction à des graphes arbitraires pondérés est problématique, car le problème de définir la mise à l'échelle et la traduction sur un graphe irrégulier est posé. Ce problème a été abordé par Hammond et al dans [73] en travaillant dans le domaine des graphes spectraux, c'est-à-dire en utilisant la base constituée des fonctions propres du graphe Laplacien L . Cet outil de la théorie des graphes spectraux [72], fournit une analogie de la transformée de Fourier pour les fonctions sur les graphes pondérés. L'opérateur en ondelettes à l'échelle unitaire est donné comme une fonction valorisée par l'opérateur $T_g = g(L)$ pour un noyau générateur g . L'application de cet opérateur à un signal d'entrée f permet d'avoir les coefficients d'ondelettes spectrales sur graphes de f à une échelle t . A souligner que le calcul directement via une diagonalisation complète de l'opérateur Laplacien est irréalisable

pour les problèmes de taille dépassant quelques milliers de sommets. D'où l'introduction d'une méthode pour calculer approximativement la transformée directe à travers des opérations effectuées directement dans le domaine des sommets qui évite la nécessité de diagonaliser le Laplacien. En rapprochant le noyau g avec un polynôme de Chebyshev de faible dimension, on peut calculer une transformation directe approximative d'une manière qui accède au Laplacien uniquement par multiplication matrice-vecteur. Cette approche est efficace en termes de calcul si la matrice laplacienne est parcimonieuse, comme c'est le cas pour de nombreux graphiques pratiquement pertinents. Sur la Figure 3.5, nous résumons ces différentes étapes.




FIGURE 3.5 – Comparaison entre décompositions par la transformée de paquets d'ondelettes (WPT) et SGWT : (a) Image originale de Pavia University (sous-bande 100), (b) 1-niveau de décomposition WPT, (c) 2-niveaux de décomposition WPT, (d) Coefficients d'échelles de la SGWT, (e) Coefficients de SGWT à l'échelle 1, (f) Coefficients de SGWT à l'échelle 2

En résumé, les auteurs de [73] ont souligné la différence entre les transformées en ondelettes orthogonales classiques et la SGWT. Cela se résume principalement dans

la sélection d'un masque de sommets à chaque échelle du sous-échantillonnage SGWT, contrairement aux transformées en ondelettes classiques qui décomposent la transformée à des niveaux spatiaux plus grossiers.

3.5 Discussion

Ce chapitre a présenté les principes fondamentaux et les travaux connexes de la représentation parcimonieuse en traitement d'images, les notions de traitement de signal sur graphes et la transformée en ondelettes sur graphes. Les concepts vus dans ce chapitre sont nécessaires pour certaines applications de compression et de classification. En effet, une approche de compression basée sur les ondelettes est présentée dans le troisième chapitre. Une autre approche de classification basée sur la transformée en ondelettes spectrales sur graphes est ensuite présentée dans le quatrième chapitre. Ces deux approches sont appliquées sur des images hyperspectrales.

Chapitre 4

Compression des images hyperspectrales par
représentation parcimonieuse

Sommaire

4.1	Préambule	45
4.2	État de l'art	45
4.3	Approche proposée pour la compression des images hyperspectrales	47
4.3.1	Schéma proposé	47
4.3.2	La transformée en ondelettes	48
4.3.3	Codage par modulation différentielle d'impulsions	49
4.3.4	La régression par les machines à vecteurs de support pour la compression d'images	50
4.3.5	Quantification et codage entropique	52
4.3.6	Algorithme de compression proposé	52
4.3.7	La décompression	53
4.4	Tests et résultats	54
4.4.1	Les données utilisées	54
4.4.2	Paramètres d'évaluation	56
4.4.3	Discussion sur les noyaux	59
4.4.4	Discussion sur les filtres d'ondelettes	62
4.4.5	Comparaison des résultats	64
4.4.6	Temps de calcul	68
4.4.7	Performances de classification de l'approche proposée	69
4.5	Impact sur les réflectances compressées	72
4.6	Discussion	74

4.1 Préambule

L'imagerie hyperspectrale, qui consiste en l'acquisition simultanée d'images dans de nombreuses différentes bandes spectrales, présente une information spatiale-spectrale très riche. Les bandes spectrales permettent de distinguer les différentes substances dans l'image. L'analyse spectrale a pour but de rechercher des objets, d'identifier des matériaux ou de détecter des processus. Le principe consiste à comparer les formes d'ondes des spectres d'images à ceux des spectres de substances connus à l'aide d'informations spectrales adéquates. Ceci permet de distinguer avec précision les différents types de substances qui existent dans l'image. Cependant, en raison de l'énorme volume de données hyperspectrales, ces dernières ne peuvent pas être manipulées et stockées qu'avec des algorithmes de compression efficaces. Les techniques de compression d'images se divisent en deux grandes catégories : la compression sans perte et la compression avec perte. Bien que la compression sans perte soit souvent utilisée pour conserver les informations complètes des images d'origine, elle fournit un taux de compression inférieur à celui de la compression avec perte. Cela constitue un désavantage pour la transmission et le stockage sur le canal. L'objectif de notre travail présenté dans ce chapitre, est de proposer une approche de compression efficace tout en préservant l'information spectrale, qui est très utile pour l'analyse des données. L'approche adoptée est une technique de compression d'images hyperspectrales avec perte basé sur la régression des coefficients d'ondelettes 3D [1].

4.2 État de l'art

La compression et la restauration des images hyperspectrales ont fait l'objet de nombreux travaux depuis des années. Plusieurs approches de représentation parcimonieuse ont été proposées et appliquées dans ce domaine [86, 87, 88, 89]. La transformée en ondelettes est connue pour sa robustesse et sa flexibilité pour des applications de compression. De nombreux algorithmes efficaces de compression d'images 3D basés sur des transformée en ondelettes ont été proposés [90, 91, 92, 93, 94, 95, 96, 98, 99, 97]. Dans

[100, 101, 102], les auteurs suggèrent une technique pour la compression d'images 2D basée sur la combinaison de DWT et de machine à vecteurs de supports (SVM). Ils suppriment les artefacts et améliorent la qualité de l'image 2D. La transformée en ondelettes génère des coefficients d'approximation (AC) et des coefficients des détails (DC). Les coefficients d'approximation représentent les valeurs des pixels de l'image, tandis que les coefficients de détails sont répartis en sous-bandes horizontales, verticales et diagonales. De plus, la transformée en ondelettes fournit un compromis fondamental entre la localisation fréquentielle et temporelle. Bien que ces méthodes soient très efficaces pour la compression des images 2D en niveaux de gris et en couleurs, de nombreux articles tels que [103, 104] soulignent que la plupart de ces méthodes de codage ne prennent pas en considération les caractéristiques spectrales des images hyperspectrales (IHS). Cela peut poser des problèmes lors de l'identification des classes et des objets en 3D et pourrait notamment affecter les résultats d'analyse. [103, 104] présentent des algorithmes de compression IHS basés sur des tenseurs à trois ordres en considérant simultanément les représentations spatiales et spectrales des cubes de données. Cependant, la corrélation spectrale (la redondance entre les bandes) est généralement considérée comme plus forte que celle de la corrélation spatiale. Dans [105], les auteurs ont proposé un algorithme efficace de compression sans perte basé sur la classification. Cet algorithme est basé sur la sélection de bandes contenant le plus d'informations et de leurs appliquer les K-means afin d'obtenir une carte de classification. L'introduction ensuite d'un modèle de régression multilinéaire permet de construire les informations pertinentes de chaque classe. Dans [46], une approche basée sur l'analyse par régression des coefficients d'ondelettes est proposée pour le codage sans perte des images hyperspectrales. Le schéma proposé permet de réduire les redondances dans l'image. Selon les résultats, cette approche donne de meilleures performances que celles obtenues par de nombreuses autres techniques connues; telles que l'ACP. Dans notre cas, nous proposons une approche de compression avec perte des images hyperspectrales basée sur la régression des coefficients d'ondelettes 3D en utilisant les SVM. La transformée en ondelettes 3D est appliquée sur les cubes des données hyperspectrales pour une représentation parcimonieuse des données. Une régression par les séparateurs à vaste marge est ensuite appliquée sur les

détails des ondelettes et fournit les vecteurs de support et leurs poids. Ceci permet de représenter les caractéristiques de texture en ondelettes. Pour assurer le meilleur taux de compression possible après régression, un codage entropique basé sur les codages RLE et arithmétique est utilisé. En outre, et pour préserver les informations spatiales pertinentes de l'image, les coefficients des approximations d'ondelettes sont codés par un codage sans perte appelé codage par modulation différentielle d'impulsions (DPCM). Les redondances spectrales et spatiales sont ainsi considérablement réduites.

4.3 Approche proposée pour la compression des images hyperspectrales

4.3.1 Schéma proposé

L'application de la transformée en ondelettes 3D sur les images hyperspectrales fournit les approximations (AC) et les détails (DC). Nous effectuons trois niveaux de décomposition pour garantir la qualité de l'image et un temps d'exécution optimal. Les coefficients des approximations donnent les valeurs des pixels et les coefficients des détails affichent les détails horizontaux, verticaux et diagonaux de l'image. Ces différents coefficients seront traités en fonction de leur importance. Une quantification d'adaptation, appelée "deadzone", est utilisée sur ces coefficients. Elle permet de quantifier l'ensemble des valeurs de source considérées comme étant faibles en une seule et même valeur (généralement égale à zéro). Les coefficients des approximations, présents dans la sous-bande la plus basse de la décomposition d'ondelettes, sont codés par un codage prédictif (DPCM) afin de préserver la plus grande quantité d'énergie de l'image présente dans cette sous-bande. On applique les SVM sur chaque vecteur des coefficients de chaque sous-cube des détails (DC) afin de représenter les données d'origine et d'éliminer les redondances. Les vecteurs de support et leurs poids sont ensuite codés par un codeur entropique. Le but de cette procédure est de préserver au mieux les informations spectrales des images. Celles-ci présentent une grande importance pour l'analyse des données hyperspectrales. D'un autre côté, l'approche permet de préserver l'information

spatiale à l'aide du codeur DPCM. Le schéma de la Figure 4.1 présente la technique proposée.

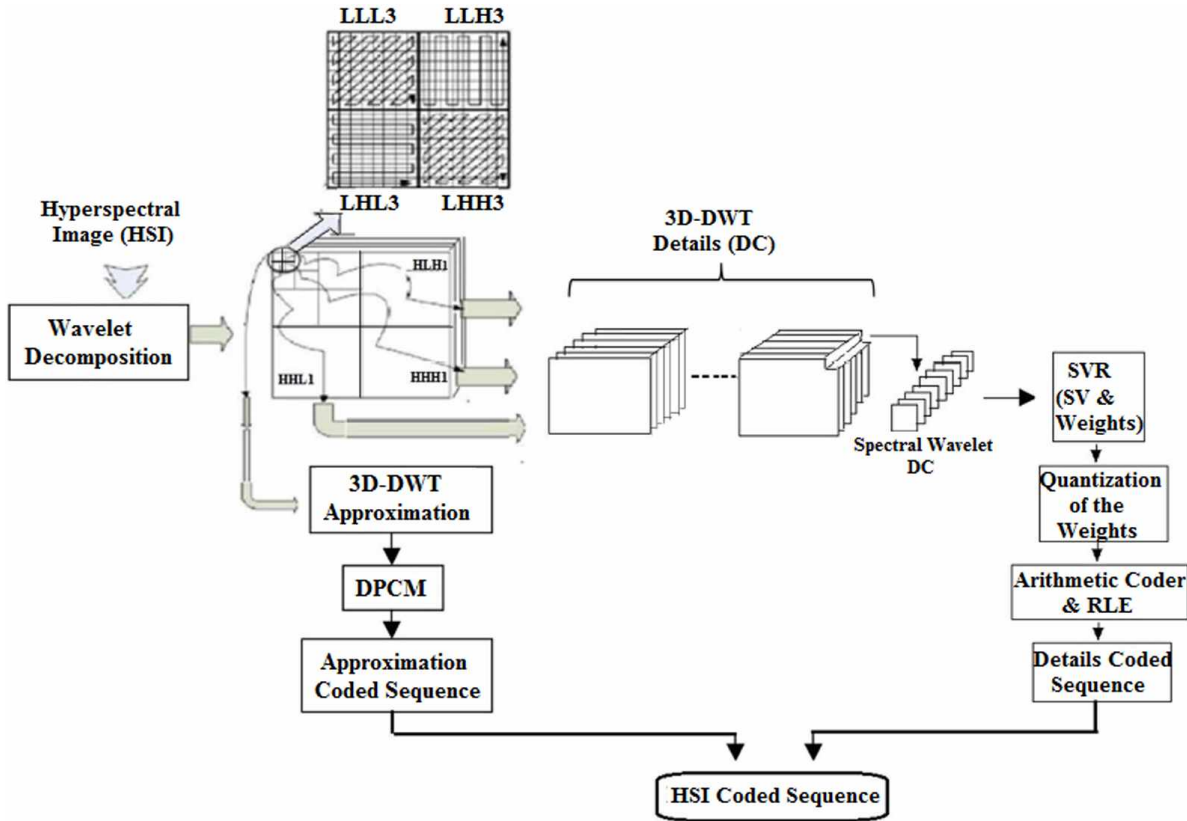


FIGURE 4.1 – Le schéma de l'approche de compression proposée.

4.3.2 La transformée en ondelettes

Comme nous l'avons présenté dans le chapitre précédent, la transformée en ondelettes est un outil mathématique efficace pour l'analyse temps-fréquence utilisée en traitement de signal et la reconnaissance de formes (voir [62, 63]). En traitement d'image, un algorithme de décomposition 2D permettant de calculer une transformée discrète en ondelettes consiste à choisir un filtre passe-bas et un filtre passe-haut, appelé paire de filtres d'analyse [106]. Le filtre d'analyse divise les données en composantes basse fréquence et haute fréquence. Les données peuvent être sous-échantillonnées par deux. Pour une image hyperspectrale, les transformations 1D dans la troisième direction sont ajoutées. Dans une transformation 3D, huit cubes de sous-bandes sont créés au premier

niveau de décomposition. La sous-bande passe-bas au sommet de la pyramide contient des coefficients approximatifs, qui sont les informations les plus significatives de l'image. Les sous-bandes haute fréquence contiennent les bords de l'image basse résolution. La taille des composantes haute fréquence du DWT est en outre augmentée par l'interpolation bicubique 3D avec un facteur 2. Les coefficients d'ondelettes de la sous-bande basses fréquences (AC) et des sous-bandes hautes fréquences (DC) d'une image, au niveau de résolution l , dans les trois dimensions (x, y, z) sont définis comme suit :

$$A_n^{(l)}(x, y, z) = \frac{1}{2}(A_{2n}^{(l-1)} + A_{2n+1}^{(l-1)}) \quad (4.1)$$

$$D_n^{(l)}(x, y, z) = \frac{1}{2}(A_{2n}^{(l-1)} - A_{2n+1}^{(l-1)}) \quad (4.2)$$

Les codages par transformée en ondelettes offrent de nombreux avantages intéressants par rapport à beaucoup d'autres méthodes de compression. Ils ont été largement utilisés dans des travaux de recherche dans le domaine, tels que EZW [107], SPIHT[66], SPECK[109, 110]et EBCOT[111]. Dans cette étude, nous utilisons les filtres biorthogonaux CDF 9/7 de Cohen Daubechies Feauveau [112]. Cette transformée est lune des transformées les plus utilisées en compression d'images [108, 109, 110, 111, 113]; elle produit des coefficients d'ondelettes à virgule flottante. Les filtres CDF 5/3, Db4 et Symlets [114, 115] sont également utilisés dans nos tests afin de discuter de leurs apports aux résultats.

4.3.3 Codage par modulation différentielle d'impulsions

La plus basse sous-bande d'ondelettes contient l'information pertinente de l'image, d'où l'intérêt d'utiliser un codage sur cette sous-bande qui doit permettre d'inclure une grande partie de l'énergie de l'image. Le DPCM est un codage qui utilise la redondance des valeurs des échantillons, basé sur le fait que la plupart des signaux sources montrent une corrélation significative entre les échantillons successifs, ce qui implique un débit binaire inférieur. Une prédiction linéaire est utilisée pour prédire les coefficients

en minimisant la valeur de l'erreur au carré attendue dans la sous-bande. La fonction de prédiction linéaire des coefficient en ondelettes approximatifs est la suivante :

$$\hat{A}_{x,y,z} = \sum_{i=1}^{M_z} (p_{z,s,i} A_{x,y,z} + p_{z,s,0}). \quad (4.3)$$

où $A_{x,y,z}$ et $\hat{A}_{x,y,z}$ représente la valeur du pixel de la sous-bande AC et la valeur prédictive dans la bande z avec l'emplacement spatial (x, y) , respectivement. M_z est la longueur de prédiction utilisée et $p_{z,s,i}$ représente les coefficients de prédiction pour le cluster s à la bande z .

4.3.4 La régression par les machines à vecteurs de support pour la compression d'images

4.3.4.1 La régression par SVM

La méthode des machines à vecteurs de support (SVM) est une méthode récente d'apprentissage automatique. Grâce à sa bonne capacité de généralisation, elle a été couramment utilisé dans de nombreux domaines. Bien que la méthode ait été initialement conçu pour résoudre des problèmes de classification, les techniques de vecteurs de support (SV) peuvent être appliquées avec succès dans la régression. Dans notre travail, nous avons appliqué l'apprentissage SVM aux problèmes de régression. En régression, la machine d'apprentissage reçoit un ensemble de points d'apprentissage. La fonction réelle est approchée dans une erreur ou une marge de tolérance prédéfinie, en choisissant le plus petit nombre de points d'apprentissage appelés vecteurs de support. Pour chaque vecteur de support, il existe un poids correspondant (W) [116]. Soit l'ensemble des données :

$$\mathcal{C} = \{(\mathbf{x}_1, \mathbf{y}_1), \dots, (\mathbf{x}_N, \mathbf{y}_N)\} \quad (4.4)$$

où \mathbf{x}_i ($1 \leq i \leq N$) est un vecteur dans l'espace d'entrée, qui représente dans notre cas le vecteur spectral en ondelettes pour chaque coefficient des sous-bandes de détails (DC)

et, $\mathbf{y}_i \in \mathbb{R}$ le vecteur cible correspondant. Le nombre d'échantillons d'apprentissage est égal à N . Pour prédire les données \mathbf{x} , on apprend la fonction de régression $g(\mathbf{x})$:

$$g(\mathbf{x}) = \langle w, \phi(\mathbf{x}) \rangle + B, \quad (4.5)$$

où $w \in \mathbb{R}^N$ est le vecteur de poids dans l'espace de la fonction du noyau, $\phi(\mathbf{x})$ est la fonction du noyau des données \mathbf{x} , et $b \in \mathbb{R}$ est le bias. La solution est obtenue en reformulant et résolvant un problème d'optimisation convexe proposé par Vapnik [117]. Le modèle de prévision final peut être formulé comme suit :

$$g(\mathbf{x}) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) k(\mathbf{x}_i, \mathbf{x}) + B. \quad (4.6)$$

où $k(., .)$ est une fonction du noyau, des coefficients α_i et α_i^* sont les supports SV. En compression de données, le nombre réduit de vecteurs de support (SV) permet un taux de compression plus élevé.

4.3.4.2 Le noyau SVM

La machine à vecteurs de support est un noyau de produit scalaire. La fonction du noyau consiste à mapper les entrées dans l'espace de petite dimension vers un espace de fonctions de grande dimension. Les données cibles peuvent ensuite être classées à l'aide de l'hyperplan. La fonction $k(x)$ du noyau SVM doit satisfaire aux conditions de Mercer [118]. En théorie, les noyaux SVM les plus connus sont des fonctions de bases polynomiale, gaussienne, linéaire, sigmoïdale ou radiale. Le noyau polynomial et la fonction de base du radian gaussien sont définis comme suit :

- Un noyau polynomial :

$$k(\mathbf{x}_i, \mathbf{x}_j) = [\langle \mathbf{x}_i, \mathbf{x}_j \rangle + c]^q, \quad (4.7)$$

où q est le degré de la fonction polynomiale et $c \in [0, +\infty[$. A noter qu'un noyau linéaire peut être défini avec $q = 1$.

- Fonction gaussienne de base radiale :

$$k(\mathbf{x}_i, \mathbf{x}_j) = e^{-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2}, \quad (4.8)$$

avec γ un paramètre libre. Nous avons choisi d'utiliser le modèle ϵ -SVR avec trois noyaux de SVM (linéaire, polynomial et gaussien). Ce modèle est la formulation originale de SVM pour la régression (SVR). Ce modèle utilise le paramètre $\epsilon \in [0, +\infty[$ pour appliquer une pénalité à l'optimisation pour les points qui n'étaient pas correctement prédits.

4.3.5 Quantification et codage entropique

Les coefficients de pondération non nuls ne sont pas des nombres entiers. Ils doivent donc être quantifiés avant l'application du codage arithmétique. Nous utilisons un quantificateur à virgule flottante à cette fin. Pour réduire la taille physique de la séquence quantifiée, nous appliquons le codage par plages (RLE). Ce codeur remplace les séquences des mêmes valeurs de données dans un fichier par une valeur unique de nombres de comptes. Pour obtenir une compression significative, le codeur arithmétique classique est utilisé [119]. Il transforme la séquence de données quantifiées en un train de bits en transmettant les coefficients de pondération les plus probables en moins de bits. Le flux binaire de chaque sous-bande des détails de l'image hyperspectrale, pour les trois niveaux de décomposition en ondelettes, est enregistré. La séquence de codage des détails de l'ensemble de données hyperspectrales est obtenue en prenant tous les trains de bits enregistrés.

4.3.6 Algorithme de compression proposé

Après la régression SVM, les vecteurs de support et leurs poids sont codés ensemble par le codage entropique. Les principales étapes de l'algorithme de codage sont brièvement décrites dans l'algorithme 1.

Algorithm 1 Algorithme de codage basé sur 3D-DWT-SVM

Entree : L'image hyperspectrale H

Sortie : La séquence codée S_f

Effectuer 3 – *niveaux* de décomposition d'ondelette 3D pour générer les coefficients $A_n^{(l)}(x, y, z)$ et $D_n^{(l)}(x, y, z)$

Coder les coefficients de la plus basse sous-bande de décomposition ($A_n^{(3)}$) en utilisant le DPCM

Pour les données des sous-bandes de détails

Normaliser les coefficients d'ondelettes

Vectoriser les coefficients $D(x, y)$ le long de la dimension z

Pour chaque vecteur de coefficients $D(x, y, \cdot)$

Appliquer un apprentissage SVM et combiner les vecteurs supports et leurs poids

Quantifier les poids

Coder en utilisant le codage entropique

Fin Pour

Fin Pour

4.3.7 La décompression

La décompression de la méthode "3D-DWT-SVR" contient principalement le processus de reconstruction. En première étape, un décodage entropique inverse basé sur le codage RLE inverse et le codage arithmétique inverse est appliqué à la séquence codée des coefficient d'ondelettes des bandes DC. Ensuite, une normalisation inverse est appliquée aux coefficient décodés. D'un autre côté, nous appliquons un décodage DPCM sur les approximations afin de reconstruire la bande des approximations d'ondelettes. Cette dernière contient l'information pertinente de l'image. Nous utilisons, en dernière étape, la transformée en ondelette 3D inverse pour reconstruire l'image hyperspectrale. Les étapes de décompression sont brièvement présentées dans l'algorithme 2.

Algorithm 2 La décompression

Entree : Séquence codée S_f

Sortie : Image hyperspectrale reconstruite H

Décoder le train de bits codé par le décodage entropique

Appliquer une normalisation inverse sur les coefficients des sous-bandes des détails (DC)

Décoder les approximations codées par le décodage DPCM

Reconstruire l'image hyperspectrale en utilisant la transformée en ondelettes 3D inverse

4.4 Tests et résultats

Pour démontrer l'efficacité de la méthode proposée, de nombreuses expériences ont été réalisées sur des images hyperspectrales, calibrées et non calibrées, acquises par les capteurs AVIRIS, HYDICE et HYPERION. Dans cette section, les résultats obtenus sont montrés et discutés.

4.4.1 Les données utilisées

Nous considérons quatre images hyperspectrales aériennes : la scène 0 non calibrée de Yellowstone, la scène 1 de Cuprite et Indiana Pines acquises par le capteur AVIRIS et l'image Washington DC acquise par le capteur HYDICE. Pour estimer la robustesse de notre méthode, un système embarqué de données hyperspectrale est utilisé. Ainsi, deux autres images hyperspectrales acquises par le capteur HYPERION sont considérées ; St. Helens et Erta Ale. Le choix de ces images est dû à la diversité des informations présentes afin d'analyser l'effet de l'apprentissage SVM sur différents ensembles de données (eau, agglomération, sol, ...). Les descriptions détaillées de ces ensembles de données HSI sont présentées sur les Fig. 4.2 et Fig. 4.3.

Scène 0 non calibrée de Yellowstone L'image a été acquise en 2006. Elle contient 224 bandes spectrales avec une résolution de 512 x 614 pixels pour chaque bande et 16 bits par pixel par bande (bppb). Cette image AVIRIS peut être téléchargée à partir du site Web de la NASA¹. La figure 4.2 (a) montre la bande 71st de l'image Yellowstone.

Image Cuprite L'image Cuprite a été acquise en 1996, elle est incluse dans standard AVIRIS des images de luminance énergétique calibrées de 1997. Cette image a une résolution spatiale de 20 m et contient 224 bandes spectrales comprises entre 0,4 et 2,5 μ m. Les bandes bruitées (1, 2, 109-112, 156-167) sont supprimées en les tests. La figure 4.2 (b) montre la bande 2 de l'image Cuprite.

1. <http://aviris.jpl.nasa.gov/html/aviris.freedata.html>

Image Indiana Pines Cette image hyperspectrale a été acquise sur le site d’essai agricole d’Indiana Pines, dans le nord-ouest de l’Indiana, en 1992. Elle contient 220 bandes sur la plage spectrale allant de 0,4 à 2,5 μ m avec 145 par 145 pixels pour chaque bande. Cet ensemble de données hyperspectrales peut être téléchargé à partir du site Web². Nous avons supprimé les bandes bruitées pendant l’expérience, à savoir 2,3, 104-108, 150-165, 219 et 220. La quatrième bande de cette image est représentée sur la figure 4.2 (c).

Image Washington DC Cette image hyperspectrale a été acquise sur le Washington DC Mall. On peut la télécharger à partir du site Web³. Elle comprend 191 bandes spectrales de 0,4 à 2,4 nm et une taille spatiale de 1280 sur 307. La bande 10 de cette image est illustrée sur la Fig. 4.2 (d).

Mt. St. Helens Cette image a été acquise en 2009 par le capteur HYPERION, fournie par la mission EO-1, NASA / USGS. Cette image a une résolution spatiale de 30 m et contient 242 bandes spectrales avec une résolution de 3242 *fois* 256 pixels pour chaque bande et 12 bpppb. Cette image peut être téléchargée à partir de⁴. L’image est montrée sur la Fig. 4.3 (a).

Image Erta Ale L’image Erta Ale a été acquise en 2010 par le capteur HYPERION. Comme l’image Mt. de St. Helens, la Erta Ale a une résolution spatiale de 30 m avec 242 bandes spectrales et 12 bpppb. Chaque bande correspond à une résolution de 3187 *fois* 256 pixels. L’image peut être téléchargée à partir de⁵ (Fig. 4.3 (b)).

Pour nos expériences, nous utilisons des cubes de données de différentes tailles. Les tailles des sous-images de test sont 512 x 512 pour Yellowstone, 256 x 256 pour Cuprite, 128 x 128 pour Indiana Pines et 256 x 256 pour Washington DC, comme indiqué sur la figure 4.2. Pour le mont St. Helens et les images Erta Ale, une taille de 768 \times 256 est utilisée (Fig. 4.3).

2. http://www.ehu.eus/ccwintco/uploads/2/22/Indian_pines.mat

3. http://cobweb.ecn.purdue.edu/~biehl/Hyperspectral_Project.zip

4. <https://coding.jpl.nasa.gov/hyperspectral/>

5. <https://coding.jpl.nasa.gov/hyperspectral/>




FIGURE 4.2 – Les données de compression des capteurs aériens : (a) Scène 0 de Yellowstone (512×512); (b) Image Cuprite (256×256), (c) Image Indiana Pines (128×128) et (d) Image Washington DC (256×256).

4.4.2 Paramètres d'évaluation

Notre algorithme est implémenté avec MATLAB et nous avons utilisé LibSVM⁶ pour *epsilon*-SVR. Pour évaluer la performance de notre approche, les mesures suivantes sont

6. <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>.




FIGURE 4.3 – Les données de compression du capteur embarqué : (a) Image Mt. St. Helens (768×256); (b) Image Erta Ale (768×256).

adoptées comme critères pour mesurer l'erreur de reconstruction :

- Débit binaire quantifié en bit par pixel (bpp) :

$$\text{Débit binaire} = \frac{\text{Nombre de bits par pixel dans l'image originale}}{\text{CR}}, \quad (4.9)$$

où CR est le rapport de compression qui est donné par :

$$\text{CR} = \frac{\text{Taille de l'image originale en bits}}{\text{Taille de la séquence compressée en bits}} \quad (4.10)$$

- Taux de distorsion (SNR) :

$$\text{SNR} = 10 \log_{10} \frac{\|H\|^2}{\|H - \widehat{H}\|^2}; \quad (4.11)$$

où H est l'image originale et \widehat{H} est l'image reconstruite.

- Erreur quadratique moyenne (MSE) :

$$\text{MSE}(\mathbf{u}, \mathbf{v}) = \frac{1}{M} \sum_{u,v} \|\mathbf{u} - \mathbf{v}\|^2; \quad (4.12)$$

- Rapport de crête signal-bruit (PSNR) :

$$\text{PSNR}(\mathbf{u}, \mathbf{v}) = 10 \log_{10} \frac{(2^r - 1)^2}{\text{MSE}(\mathbf{u}, \mathbf{v})} \quad (4.13)$$

$L = 2^r - 1$ est la plage dynamique des valeurs en pixels et r indique la profondeur maximale de bits.

- Indice de similarité structurelle (SSIM) [120, 121] :

$$\text{SSIM}(\mathbf{u}, \mathbf{v}) = \frac{(2\mu_{\mathbf{u}}\mu_{\mathbf{v}} + c_1)(2\sigma_{\mathbf{uv}} + c_2)}{(\mu_{\mathbf{u}}^2 + \mu_{\mathbf{v}}^2 + c_1)(\sigma_{\mathbf{u}}^2 + \sigma_{\mathbf{v}}^2 + c_2)} \quad (4.14)$$

où \mathbf{u} et \mathbf{v} dénote les vecteurs d'images originales de taille M , $\mu_{\mathbf{u}}$ et $\mu_{\mathbf{v}}$ la moyenne de \mathbf{u} et \mathbf{v} , $\sigma_{\mathbf{u}}$ et $\sigma_{\mathbf{v}}$ l'écart type de \mathbf{u} et \mathbf{v} . $c_1 = (k_1L)^2$ et $c_2 = (k_2L)^2$ sont deux variables pour éviter l'instabilité avec un dénominateur faible. k_1 et k_2 sont mis à

0,01 et 0,03 [120, 121].

- Test de McNemar : Pour évaluer la différence statistique entre deux classificateurs, le test de McNemar est effectué. Ce test statistique normalisé décrit si deux classificateurs sont significativement différents. La valeur Z du test de McNemar est donnée par [122] :

$$Z = \frac{fr_{12} - fr_{21}}{\sqrt{fr_{12} + fr_{21}}} \quad (4.15)$$

où fr_{12} représente les échantillons correctement classés par le premier classificateur et ceux incorrectement classés par le second. Selon l'état de la technique, la valeur de Z qui reflète une différence significative d'un classificateur par rapport à un autre, est estimée entre 1,96 [122] et 2,58 [123].

4.4.3 Discussion sur les noyaux

Pour évaluer l'impact du choix du noyau sur les résultats de la compression, le schéma de compression est testé sur les bases de données avec les noyaux gaussien (G), polynomial (P) et linéaire (L). Pour fixer les paramètres SVR optimaux, nous fixons empiriquement des valeurs qui maximisent les PSNR estimés. Pour le noyau polynomial, le degré q est fixé à 0,6 et le décalage c est mis à 0,1. Pour le noyau gaussien, γ est fixé à 0.9129.

Les résultats visuels pour l'une des sous-bande des images reconstruites de chaque base de données sont présentés sur les Fig. 4.4 pour Yellowstone (sous-bande 71), Fig. 4.5 pour Cuprite (sous-bande 66), Fig. 4.6 pour Indiana Pines (sous-bande 4), Fig. 4.7 pour Washington DC (sous-bande 11), Fig. 4.8 pour Mt. St. Helens (sous-bande 19) et Fig. 4.9 pour l'image Erta Ale (sous-bande 21). Les images originales peuvent être comparées aux images reconstruites avec les trois noyaux SVR. En comparant visuellement les images reconstruites, il est observé que presque toutes les régions des scènes des images sont complètement reconstruites et présentent une bonne qualité visuelle. Cependant, nous avons également observé que de nombreuses sous-bandes d'images reconstituées, avec des noyaux polynôme et linéaire, présentent des distorsions significatives (voir Fig. 4.10), en particulier lorsque le *epsilon* est supérieur à 0,0001. Ces résultats sont cohérents

avec ceux donnés par le Tableau 4.1. Les images reconstruites avec le noyau gaussien présentent moins de bruit et montrent plus de détails que les autres images reconstruites (voir Fig. 4.10).

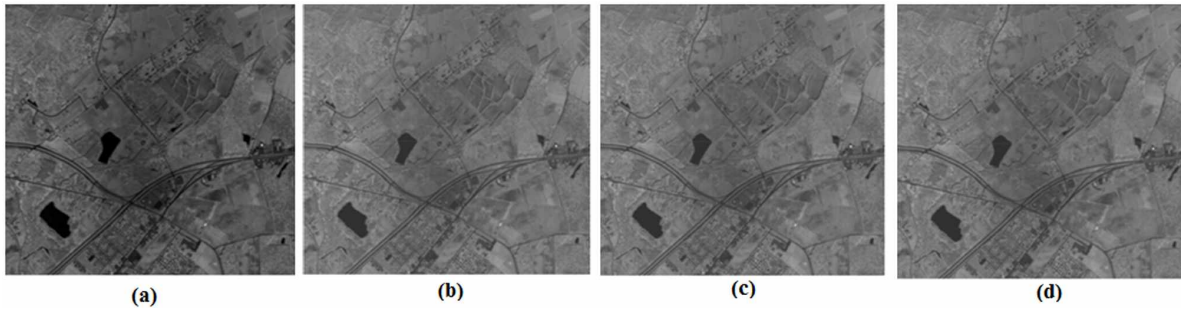


FIGURE 4.4 – Résultats de la compression pour Yellowstone : (a) Image originale de Yellowstone, images reconstruites avec CR proche de 26 avec les noyaux (b) Gaussien, (c) Polynomial et (d) Linéaire.




FIGURE 4.5 – Résultats de compression pour la scène Cuprite : (a) Image originale de la scène Cuprite, images reconstruites avec un CR proche de 27 avec les noyaux (b) Gaussien, (c) Polynomial et (d) Linéaire.

Dans le Tableau 4.1, les résultats expérimentaux montrent que notre algorithme de compression atteint des taux de compression élevés avec une bonne qualité d'image. En effet, avec l'image Yellowstone, nous obtenons un $PSNR = 40.68$ dB pour $SSIM = 0.75$ et $CR = 26.44$ correspondant à 0.6 *bpp*. Pour l'image Cuprite, nous obtenons un $PSNR = 43.62$ dB pour $SSIM = 0.93$ et $CR = 26,95$ correspondant à 0.59 *bpp*, pour Indiana Pines un $PSNR = 44,14$ dB pour $SSIM = 0,85$ et $CR = 27.02$ correspondant à 0.59 *bpp* et pour Washington DC un $PSNR = 40,76$ dB pour $SSIM = 0,83$ et $CR = 26,95$ correspondant à 0.59 *bpp*. Les résultats pour l'image Hyperion M.S. Helens indiquent un $PSNR = 49,47$ dB pour $SSIM = 0,89$ et $CR = 22.12$, ce qui correspond à




FIGURE 4.6 – Résultats de compression pour la scène d’Indiana Pines : (a) Image originale, images reconstruites avec un CR proche de 39 avec les noyaux (b) Gaussien, (c) Polynomial and (d) Linéaire.

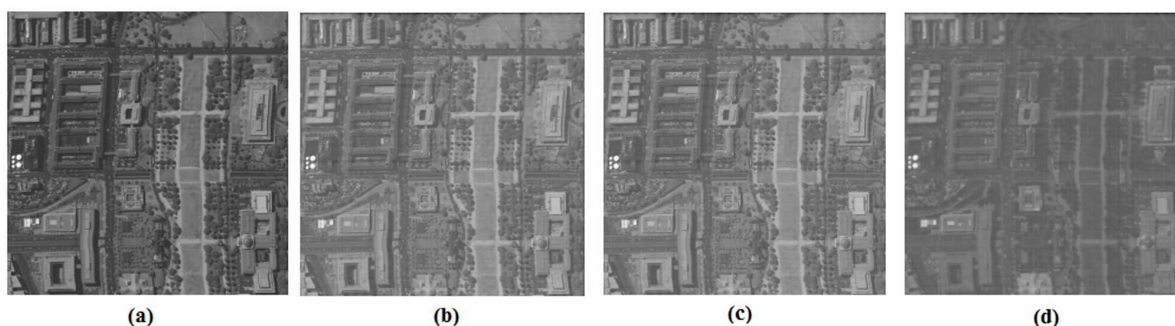


FIGURE 4.7 – Les résultats de compression de l’image Washington DC : (a) Image originale, images reconstruites avec un CR proche de 27 avec les noyaux (b) Gaussien, (c) Polynomial and (d) Linéaire.

0.72 *bpp*. Pour Hyperion Erta Ale, on obtient un $PSNR = 38,46$ dB pour $SSIM = 0,86$ et $CR = 20,85$, ce qui correspond à 0.76 *bpp*.

En faisant varier les hyper-paramètres des noyaux gaussien et polynomial utilisés par les SVMs, on observe que les PSNR et SSIM augmentent lorsque ϵ -SVR diminue conformément à une loi qui peut être approximativement exponentielle (Tableau 4.1). Le noyau gaussien converge vers les meilleurs PSNR et SSIM plus rapidement que les deux autres noyaux. En effet, comme le montre le tableau. 4.1, les résultats de toutes les images hyperspectrales aéroportées, testées avec un noyau gaussien, atteignent les meilleures valeurs pour ϵ -SVR = 0.001, et dépassent ceux atteints par les noyaux polynomial et linéaire avec environ 1dB de PSNR et 0.05 de SSIM respectivement. Pour les deux images spatioportées, les meilleurs PSNR et SSIM donnés par les noyaux polynomial et linéaire sont inférieurs à ceux donnés par le noyau gaussien d’environ 3

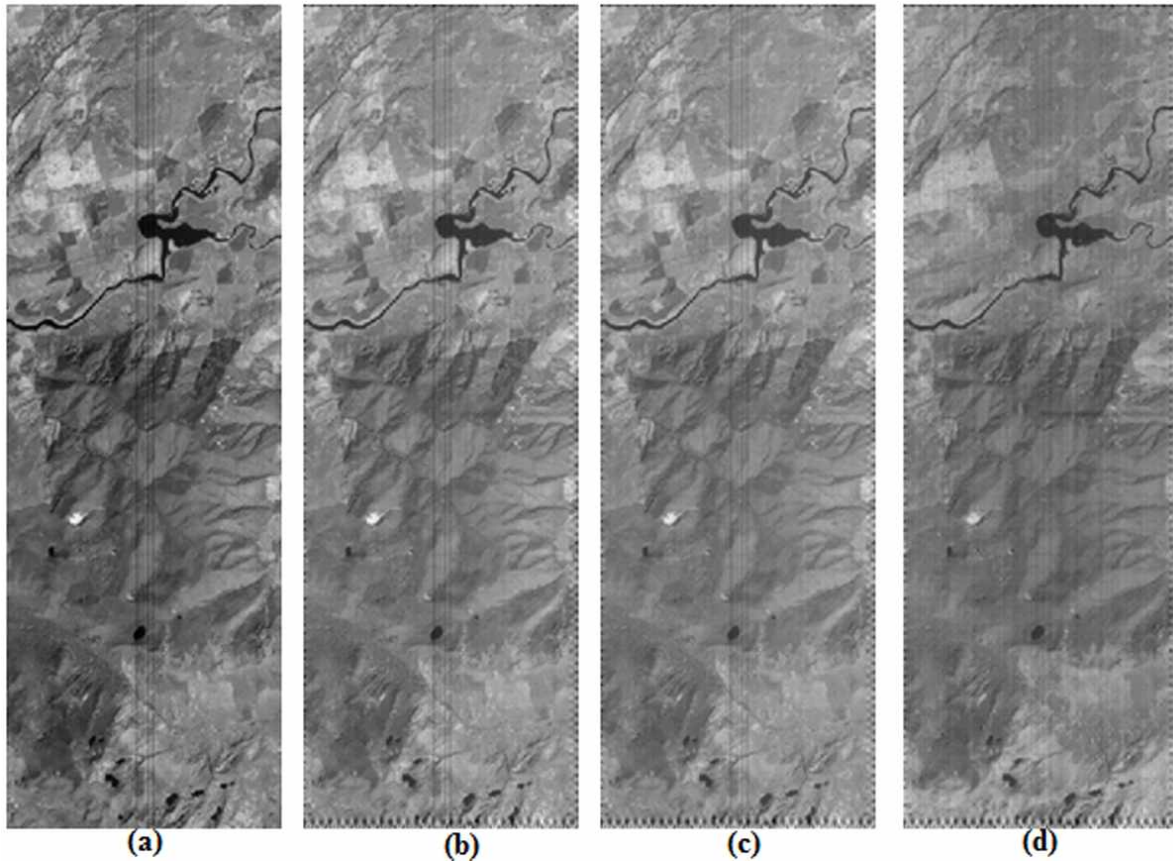


FIGURE 4.8 – Résultats de compression de l'image M.S.Helens :
(a) Image originale, images reconstruites avec un CR proche de 23 avec les noyaux
(b) Gaussien (PSNR=49.47 dB), (c) Polynomial (PSNR=46.62 dB) et (d) Linéaire (PSNR=45.61 dB).

dB.

En général, nous pouvons constater que le choix des noyaux SVM gaussien et polynomial conduit à des résultats de compression intéressants. En termes de qualité, on peut en conclure que cette approche préserve la majeure partie de l'information.

4.4.4 Discussion sur les filtres d'ondelettes

Le tableau 4.2 montre les résultats de notre approche de compression en utilisant quatre fonctions différentes de transformées en ondelettes. Les PSNRs 26,09 dB, 29,04 dB, 29,70 dB, 27,72 dB, 19,72 dB et 20,06 dB représentent les PSNRs minimums avec le filtre d'ondelettes Db4 et correspondent aux images Yellowstone, Cuprite, Indiana Pines,

TABLE 4.1 – Les résultats de l’approche pour les noyaux SVR : Gaussien (G), polynomial (P) et linéaire (L).

Image	Noyaux	ϵ -SVR	0.1	0.05	0.01	0.003	0.001	0.00001	1 e- 6
Yellow.	L	PSNR	23.32	31.18	31.18	33.98	29.73	39.90	40.68
		Débit	0.47	1.57	1.06	2.21	1.59	0.61	1.21
		SSIM	0.07	0.11	0.29	0.48	0.64	0.74	0.74
	P	PSNR	22.06	24.10	30.46	35.09	38.24	40.68	40.68
		Débit	0.38	0.52	0.59	0.60	0.60	0.60	0.60
		SSIM	0.05	0.09	0.25	0.48	0.67	0.75	0.75
	G	PSNR	26.01	29.49	31.65	40.65	40.68	40.68	40.68
		Débit	0.46	0.51	0.52	0.60	0.60	0.60	0.60
		SSIM	0.12	0.17	0.51	0.74	0.75	0.75	0.75
Cuprite	L	PSNR	29.84	31.19	36.65	40.72	42.64	43.62	43.62
		Débit	0.40	0.48	0.57	0.59	0.59	0.59	0.59
		SSIM	0.07	0.10	0.35	0.66	0.83	0.92	0.92
	P	PSNR	29.18	30.62	36.84	41.00	42.92	43.62	43.62
		Débit	0.36	0.46	0.57	0.59	0.59	0.59	0.59
		SSIM	0,06	0,09	0,37	0,69	0,86	0,93	0,93
	G	PSNR	29.20	32.06	39.16	43.57	43.62	43.62	43.62
		Débit	0.33	0.49	0.58	0.59	0.59	0.59	0.59
		SSIM	0.08	0.15	0.51	0.93	0.93	0.93	0.93
Indiana	L	PSNR	21.51	23.78	29.26	31.32	31.96	32.14	32.14
		Débit	0.42	0.51	0.58	0.59	0.59	0.59	0.59
		SSIM	0.11	0.17	0.47	0.70	0.81	0.84	0.84
	P	PSNR	32.87	35.26	41.18	43.36	44.04	44.14	44.14
		Débit	0.39	0.50	0.41	0.60	0.59	0.59	0.59
		SSIM	0.09	0.16	0.48	0.72	0.83	0.85	0.85
	G	PSNR	32.70	35.97	42.39	44.12	44.14	44.14	44.14
		Débit	0.36	0.50	0.58	0.59	0.59	0.59	0.59
		SSIM	0.12	0.21	0.59	0.85	0.85	0.85	0.85
Washing.	L	PSNR	26.88	28.50	33.84	37.97	39.79	40.76	40.76
		Débit	0.40	0.50	0.58	0.59	0.59	0.59	0.59
		SSIM	0.07	0.11	0.33	0.58	0.73	0.82	0.82
	P	PSNR	26.29	27.93	34.00	38.12	40.15	40.76	40.76
		Débit	0.36	0.48	0.58	0.59	0.59	0.59	0.59
		SSIM	0.05	0.09	0.33	0.60	0.77	0.83	0.83
	G	PSNR	25.83	28.66	36.11	40.72	40.76	40.76	40.76
		Débit	0.34	0.50	0.58	0.59	0.59	0.59	0.59
		SSIM	0.05	0.11	0.44	0.82	0.83	0.83	0.83
Helens	L	PSNR	21.38	21.60	21.68	22.06	33.62	33.75	45.61
		Débit	0.45	0.56	0.58	0.61	0.61	0.69	0.72
		SSIM	0.18	0.25	0.26	0.34	0.37	0.60	0.85
	P	PSNR	22.79	22.79	22.79	22.99	34.61	34.70	46.62
		Débit	0.60	0.60	0.60	0.61	0.61	0.69	0.72
		SSIM	0.10	0.10	0.10	0.36	0.82	0.83	0.86
	G	PSNR	24.42	24.50	24.58	47.25	49.47	49.47	49.47
		Débit	0.48	0.59	0.60	0.69	0.72	0.72	0.72
		SSIM	0.26	0.29	0.31	0.80	0.89	0.89	0.89
Erta.	L	PSNR	20.18	20.19	20.19	22.70	22.71	23.52	32.51
		Débit	0.45	0.59	0.59	0.66	0.71	0.71	0.72
		SSIM	0.21	0.21	0.43	0.43	0.68	0.71	0.82
	P	PSNR	21.91	21.91	21.93	22.71	22.73	24.87	36.58
		Débit	0.42	0.50	0.59	0.73	0.75	0.75	0.76
		SSIM	0.22	0.22	0.43	0.55	0.69	0.76	0.82
	G	PSNR	22.47	22.50	22.76	24.74	38.48	38.48	38.46
		Débit	0.43	0.59	0.62	0.66	0.76	0.76	0.76
		SSIM	0.23	0.23	0.54	0.68	0.86	0.86	0.86




FIGURE 4.9 – Résultats de compression de l'image Erta Ale : (a) Image originale, images reconstruites avec CR proche de 22 avec les noyaux (b) Gaussien (PSNR= 38.46 dB), (c) Polynomial (PSNR= 36.58 dB) et (d) Linéaire (PSNR= 32.51 dB).

Washington DC, MSHelens et Erta Ale respectivement. Les PSNRs 42,41 dB, 47,62 dB, 44,14 dB, 44,76 dB, 49,47 dB et 38,46 dB sont obtenus avec un filtre d'ondelettes CDF 7/9 pour les images Yellowstone, Cuprite, Indiana Pines, Washington DC, MSHelens et Erta Ale respectivement. Le filtre d'ondelettes CDF 7/9 surpasse les autres fonctions d'ondelettes.

4.4.5 Comparaison des résultats

Nous avons comparé le SNR obtenu avec notre méthode de compression avec ceux obtenus dans[124] pour les images Indiana Pines et Washington DC et avec ceux dans[125] pour l'image Cuprite. La figure 4.11 montre les résultats de comparaison de notre algo-

TABLE 4.2 – Résultats de compression de l’approche proposée avec différents filtres d’ondelettes

Image	PSNR (dB) pour l’approche proposée					
	Fonction d’ondelettes	CDF 9/7	CDF 5/3	Db4	Sym	
Yellowstone	Débit binaire	0.1	28.20	27.49	26.09	26.78
		0.25	31.81	30.25	29.85	30.09
		0.5	39.79	39.64	38.57	38.87
		0.75	42.34	41.75	41.29	41.35
		1	42.41	41.81	41.41	41.60
Cuprite	Débit binaire	0.1	35.20	30.80	29.04	29.78
		0.25	40.06	39.35	38.94	39.11
		0.50	45.16	40.09	37.88	39.71
		0.75	46.78	44.06	41.95	42.48
		1	47.62	44.13	42.03	42.53
Indiana Pines	Débit binaire	0.1	34.02	30.55	29.70	30.52
		0.25	40.7	39.14	38.82	39.02
		0.50	42.39	42.30	41.76	42.10
		0.75	44.11	43.52	43.39	43.41
		1	44.14	43.60	43.42	43.5
Washington DC	Débit binaire	0.1	32.66	30.80	27.72	28.44
		0.25	40.11	39.35	31.09	31.51
		0.50	41.66	40.09	37.39	39.47
		0.75	44.72	44.06	41.93	42.22
		1	44.76	44.13	42.09	42.53
M.S. Helens	Débit binaire	0.1	22.42	22.06	19.72	19.92
		0.25	24.22	23.71	21.33	22.76
		0.50	24.50	23.80	21.58	22.76
		0.75	49.47	34.06	24.35	33.52
		1	49.47	42.23	36.62	41.79
Erta Ale	Débit binaire	0.1	20.72	20.47	20.06	20.20
		0.25	22.40	21.70	20.06	20.26
		0.50	22.50	21.92	20.52	21.64
		0.75	38.46	36.66	25.32	23.59
		1	38.46	36.69	25.36	24.15




FIGURE 4.10 – Images reconstruites avec les noyaux linéaire et polynomial :
Linéaire : (a) Yellowstone (subband 91), (b) Cuprite (subband 6), (c) Indiana Pines (subband 183) (g) M.S.Helens (subband 40)
Polynomial : (d) Yellowstone (subband 91), (e) Cuprite (subband 6), (f) Washington DC (subband 160) (h) Erta Ale (subband 93).

ritme et des autres approches appliquées aux images hyperspectrales Cuprite (256 x 256 x 128), Indiana Pines (145 x 145 x 200) et Washington DC (280 x 307 x 191). A noter que les dimensions prises des images sont similaires à celles prises par les références citées ci-dessous. Les performances de compression, obtenues par la méthode proposée "3D-DWT + SVR", sont considérablement améliorées en les comparant aux résultats d'autres méthodes telles que : 3D-SPECK [126, 125, 124], PCA + JPEG2000 [127, 125], SSASR [124], JPEG-BIFR [129, 124], 3D-DCT [130, 125] et 3D-DCT + SVM [125].

La comparaison de notre approche avec les approches 3D-DCT + SVM et SSASR démontre des résultats compétitifs en termes de performances et surpasse les autres approches. L'approche développée permet d'obtenir des taux de compression élevés avec une bonne qualité d'image décodée.




FIGURE 4.11 – Comparaison des performances de différentes méthodes de compression (3D-SPECK [126, 125, 124], PCA+JPEG2000 [127, 125, 128, 124], PWSR and SSASR [124], JPEG-BIFR [129, 124], 3D-DCT [130, 125] et 3D-DCT+SVM [125]) sur trois IHS. (a) :Cuprite. (b) : Indiana Pines. (c) :Washington DC.

4.4.6 Temps de calcul

Les temps d'exécution de notre méthode sont évalués dans cette section. Les temps de calcul, des images hyperspectrales testées, est indiqué dans le tableau. 4.3. Pour toutes les images, les temps d'exécutions augmentent avec les débits binaires. Les temps d'exécution pris dépendent des tailles des images et des distributions de données dans celles-ci.

TABLE 4.3 – Temps d'exécution (s) de la 3D-Ondelettes + SVR

Taux (bpp)	Yellowstone	Cuprite	Indiana	Washington	M.S.Helens	Erta Ale
0.1	122.82	54.06	7.02	49.15	284.70	227.75
0.2	178.52	190.11	8.50	154.06	303.64	258.60
0.3	191.37	132.63	26.28	190.16	357.17	269.84
0.4	324.28	262.42	52.29	235.16	417.22	294.61
0.5	402.81	318.40	65.20	325.98	771.30	416.80
0.6	917.50	772.94	160.34	540.67	820.42	522.77
0.7	1376.25	998.41	870.95	770.04	1253.36	1049.90
0.8	1634.76	1293.23	895.05	802.81	1313.34	1078.81
0.9	1658.71	1606.71	967.15	950.27	2247.12	2084.01
1	1985.88	1645.34	1032.01	1608.60	2747.97	2613.50

De plus, les résultats de l'approche proposée appliquée à Indiana Pines, sont comparés à ceux donnés par [124] (Table. 4.4). Les méthodes de [124] sont exécutées avec des processeurs Intel Core de 2,50 GHz et 16 Go de RAM. Les méthodes PWSR et SSASR [124] sont implémentées sur la plateforme MATLAB et 3D-SPECK [126, 125, 124] et JPEG. Les méthodes [128, 124] sont implémentées par le code *C/C++*.

TABLE 4.4 – Comparaison des temps d'exécution (s) sur Indiana Pines

Code	Méthode	Débit binaire									
		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
<i>C/C++</i>	3D SPECK	20.3	2.24	2.58	2.84	3.21	2.52	2.72	4.07	4.35	4.67
	JPEG-BIFR	1.88	1.74	1.68	2.08	1.97	2.06	1.93	2.04	1.98	1.91
	JPEG-2000	2.28	2.06	2.12	2.20	2.43	2.54	2.87	2.90	2.82	3.06
MATLAB	PWSR	6.19	8.61	12.2	16.9	21.3	28.5	36.1	43.0	50.8	60.7
	SSASR	7.13	7.61	8.57	9.35	10.1	11.0	12.3	13.9	15.3	17.1
	3D-DWT+ SVR	7.02	8.50	26.28	52.29	65.20	160.34	870.96	895.06	967.15	1032.01

Les résultats montrent que le temps de calcul obtenu en utilisant notre approche, pour différents débits binaires, est très efficace pour les plus bas débits binaires et aug-

mente considérablement pour les débits binaires de 0.5 à 1. Cela est dû au nombre de SVs qui augmente lorsque les paramètres SVR sont modifiés . Cependant, le temps d'exécution peut être considérablement amélioré avec l'utilisation d'un processeur plus performant et de processus de calculs parallèles.

4.4.7 Performances de classification de l'approche proposée

Pour évaluer l'effet de notre méthode sur les performances de classification, nous utilisons la classification rbf-SVM comme dans [129, 131, 128, 124]. Nous appliquons la classification sur les images originales et reconstruites sur les quatre images hyperspectrales aéroportées. Celles-ci contiennent une grande variété d'informations. Les images de vérité au sol d'Indiana Pines (avec 16 classes et 10366 échantillons) et de Washington DC (avec 7 classes et 7869 échantillons) sont disponibles en ligne⁷. Pour les scènes de Yellowstone et Cuprite, nous avons utilisé ENVI pour créer les pixels étiquetés. Le nombre de classes de l'image vérité-terrain de l'image Cuprite est fixé à 12 en réduisant le nombre de minéraux qui représentent des propriétés similaires (initialement, l'image Cuprite représente 14 classes)⁸. Pour la référence au sol de Yellowstone, nous avons considéré 5 classes. Le nombre d'échantillons d'apprentissage des données hyperspectrales est fixé à environ 5 % pour chaque classe. Le reste des échantillons représente les échantillons de test.

Dans le Tableau 4.5, nous donnons la précision globale (OA), la précision moyenne (AA) et le coefficient kappa κ pour des débits binaires de 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9 et 1.0 (bppb) des quatre images hyperspectrales. Dans le même tableau, les résultats des performances de classification avec le classificateur SVM appliqué sur les images hyperspectrales originales et les données compressées en 2D-ondelettes + SVR sont fournis. Cette dernière méthode de compression consiste à effectuer une 2D-Ondelettes et une SVR sur toutes les bandes (bande par bande) de l'image hyperspectrale [132]. Les meilleurs résultats de classification obtenus avec la méthode 2D-DWT + SVR appa-

7. http://www.ehu.eus/ccwintco/index.php?Title=Hyperspectral_Remote_Sensing_Scenes,
<http://lesun.weebly.com/hyperspectral-data-set.html>

8. http://www.escience.cn/people/feiyunZHU/Dataset_GT.html

TABLE 4.5 – Performances de classification de 3D-DWT + SVR appliquée sur les images Yellowstone, Cuprite, Indiana Pines et Washington DC

Données	Mesure	Originale Image	2D DWT +SVR	3D-DWT + SVR									
				Débit binaire									
				0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
Yellowstone	OA %	91.20	91.35	91.02	91.55	90.86	91.31	90.37	89.78	91.17	89.40	88.84	89.28
	AA %	87.58	88.85	87.75	88.97	87.18	88.02	85.97	85.20	87.34	84.36	83.17	84.11
	κ	0.84	0.85	0.84	0.85	0.83	0.84	0.82	0.81	0.84	0.80	0.79	0.80
Cuprite	OA %	78.43	77.77	75.54	75.63	75.01	78.59	72.72	78.32	77.93	77.38	78.07	77.23
	AA %	77.26	76.45	74.12	74.17	73.15	77.28	70.43	77.02	76.67	75.94	76.83	75.74
	κ	0.73	0.72	0.69	0.69	0.68	0.73	0.68	0.72	0.72	0.71	0.72	0.71
Indiana	OA %	82.45	83.67	83.57	81.99	81.28	84.20	82.65	83.81	81.66	83.82	83.21	84.14
	AA %	76.21	77.43	78.69	78.81	76.89	80.76	77.51	77.21	77.35	80.31	75.66	78.48
	κ	0.79	0.81	0.80	0.79	0.78	0.81	0.79	0.80	0.79	0.81	0.80	0.81
Washington	OA %	79.72	80.08	72.41	76.23	75.15	76.10	80.34	78.71	77.61	78.48	78.07	77.27
	AA %	74.57	75.73	57.33	66.60	68.68	70.14	75.87	72.21	57.02	71.76	70.66	66.15
	κ	0.78	0.79	0.65	0.69	0.73	0.74	0.79	0.77	0.76	0.76	0.76	0.75

raissent pour des débits binaires de 0,5 bppb pour Yellowstone, 0,1 bppb pour Cuprite et 1 bppb pour les ensembles de données Indiana et Washington. Les résultats de la classification sont présentés dans le tableau 4.5.

Nous comparons les résultats obtenus par la méthode proposée sur Indiana Pines avec ceux de [128]. La comparaison est illustrée sur la Fig. 4.12.

Les résultats du tableau 4.5 montrent que les meilleures performances de classifica-




FIGURE 4.12 – Comparaison de l'OA% avec des méthodes de compression connues sur Indiana Pines.

tion apparaissent pour un débit binaire de 0,4 bppb pour les images Cuprite et Indiana Pines et pour des débits binaires de 0,2 et 0,5 bppb pour les images Yellowstone et Washington DC. Sur la figure 4.12, on peut voir que, sauf pour les débits binaires de 0,1, 0,2 et 0,3 bppb, pour lesquels PCA + JPEG2000 et AR + PCA + JPEG2000 surpassent considérablement les autres approches. La méthode 3D-DWT + SVR proposée dépasse toutes les méthodes comparées, en particulier pour les débits binaires de 0,4 à 1 bppb. Les résultats donnés par 3D-DWT + SVR montrent l'efficacité de la méthode à des fins de classification. De plus, on peut observer que les performances de classification pour les images compressées dépassent celles des images originales. Ce phénomène est observé pour toutes les images testées. On peut également observer que la méthode proposée surpasse la 2D-DWT + SVR en terme de précision de la classification. Pour confirmer l'exactitude de l'approche proposée pour les tâches de classification, nous appliquons également le test de McNemar à la méthode. Le tableau 4.6 donne les résultats du test de McNemar sur les méthodes 3D-DWT + SVR, SVM et 2D-DWT + SVM. Les résultats montrent que la valeur de Z du test de McNemar est supérieure à 2, ce qui signifie que la classification basée sur notre méthode est supérieure à celle des deux autres.

TABLE 4.6 – Test de McNemar's (Z) de la méthode 3D-DWT + SVR face aux méthodes SVM et 2D-DWT + SVM.

Données	3D-DWT-SVR <i>vs</i> SVM	3D-DWT-SVR <i>vs</i> 2D-DWT-SVM
Yellowstone	6.70	2.23
Cuprite	13.03	3.87
Indiana	2.82	3.74
Washington	16.76	3.87

Des classificateurs remarquables basés sur les réseaux de neurones conventionnels (CNN) ont récemment été proposés pour la classification des images hyperspectrales [133, 134, 135, 136]. Ces classificateurs ont démontré leur efficacité dans le domaine de la classification des images hyperspectrales et ont surpassé de nombreuses méthodes de classification efficaces connues.

Nous comparons la précision de la classification de notre méthode avec celle des

classificateurs basés sur les CNN, données par [137]. Ces méthodes sont appliquées sur l'image Indiana Pines avec 200 échantillons d'entraînements. Les résultats indiquent une précision de classification de 87,01 % pour CNN [133], 93,9 % pour CNN-PPF [135], 94,24 % pour CD-CNN [138] et 98,54 % pour DR-CNN [137]. Cela présente des différences de 2,81 %, 9,7 %, 10,04 % et 14,34 % par rapport à notre méthode.

4.5 Impact sur les réflectances compressées

Nous compressons les images Yellowstone et Washington DC d'Aviris avec des spectres compris entre 460 *nm* et 2130 *nm* et des taux de compression égaux à 42,12 et 42,60 respectivement. La régression est effectuée avec un noyau gaussien. Nous mesurons les PSNRs de différentes régions des images et nous comparons les spectres obtenus avec ceux des images originales. Nous vérifions également les PSNRs et les spectres obtenus avec la méthode 2D-DWT +SVR. En effet, en utilisant la 3D-DWT +SVR, nous obtenons des PSNRs de 30.21 dB (sol), 39.32 dB (rail), 31.57 dB (immeubles) pour l'image Yellowstone et des PSNRs de 27.13 dB (champ), 47.37 dB (immeubles), 33.62 dB (sol) pour l'image Washington DC. Pour la méthode 2D-TO +SVR nous obtenons des PSNRs de 30.78 dB (sol), 34.31 dB (rail), 36.26 dB (immeubles) pour Yellowstone et 30.62 dB (champ), 45.25 (immeubles), 37.44 dB (sol) pour Washington DC.

La Figure 4.13 montre la variation du spectre sur des blocs de pixels sélectionnés arbitrairement : sol, rail et immeubles de l'image Yellowstone et du champ, immeubles et sol de l'image Washington DC. Pour toutes les images hyperspectrales, les variations du spectre de l'image compressée avec la méthode 3D-DWT + SVR sont presque identiques à celles de l'image originale. Bien qu'il puisse y avoir des différences entre les données originales et compressées, il est raisonnable de conclure que les informations spectrales sont préservées à l'aide de notre méthode de compression. En plus d'un taux de compression élevé, le PSNR entre les spectres compressés et les spectres originaux correspondants est correct. Ainsi, les résultats confirment ceux présentés précédemment et démontrent l'efficacité de la méthode pour les applications orientées classification. Cela peut permettre une bonne séparation des classes et une présentation de la quasi-totalité des informa-

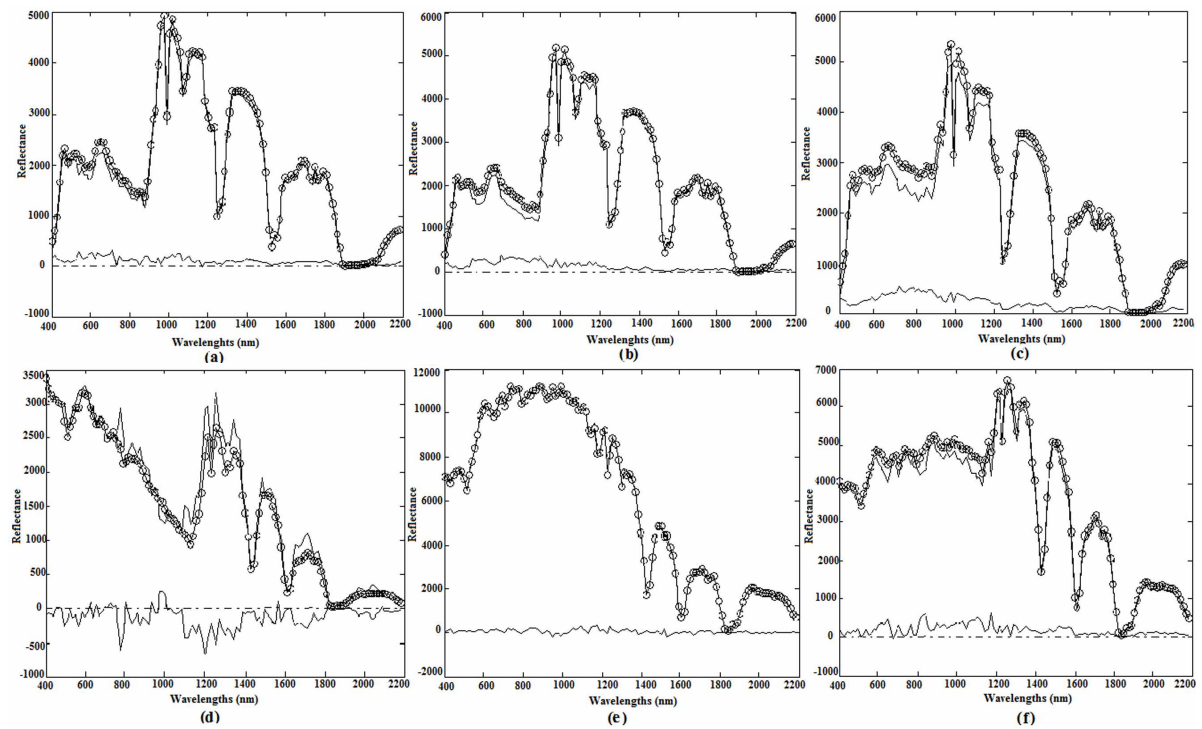


FIGURE 4.13 – Réflectance des images originales et compressées par 3D-DWT +SVR et leurs différence (ligne avec symboles) et des images originales et compressées par 2D-DWT + SVR et leurs différence (ligne continue) : Yellowstone(CR=42.12), (a) sol , (b) rail , (c) immeuble; Washington DC (CR=42.60), (d) champ, (e) immeuble, (f) sol.

tions présentes dans l'image. En outre, une comparaison de la variation du spectre avec la méthode 2D-DWT + SVR sur les blocs sélectionnés et la différence entre les résultats donnés par 3D-DWT + SVR et 2D-DWT + SVR sont présentées sur la Fig.4.13. Les résultats montrent que la méthode proposée présente plus de fidélité spectrale que la méthode 2D-DWT + SVR.

4.6 Discussion

Une méthode efficace de compression des images hyperspectrale, basée sur la transformation en ondelettes 3D et l'apprentissage du spectre avec une régression par machines à vecteurs de support, est proposée dans ce chapitre pour exploiter efficacement les redondances spectrale et spatiale dans les images hyperspectrales. Pour démontrer l'efficacité de notre approche, des expériences approfondies sur six images hyperspectrales, acquises par les capteurs AVIRIS, HYDICE et HYPERION, ont été réalisées. Les résultats des tests expérimentaux valident l'efficacité de la méthode en termes de qualité des images. En effet, l'approche permet d'obtenir des taux de compression élevés tout en préservant la plus grande partie des informations présentes dans les images. Comparée à d'autres techniques de compression connues telles que 3D-SPECK, SSASR et 3D-DCT + SVM, la méthode 3D-DWT + SVR améliore considérablement les performances de compression.

Les résultats obtenus en appliquant la 2D-DWT +SVR pour la compression de données hyperspectrales sont plus efficaces que ceux de 3D-DWT +SVR en termes de performances de distorsion. Dans notre cas, nous avons obtenu pour ϵ - SVR inférieur à 0,0001 avec un noyau gaussien, des PSNRs moyens proches de 42,38 dB, 46,58 dB, 46,10 dB, 41,29 dB, 49,47 dB et 38,46 dB avec un débit d'environ 0,7 bppb pour Yellowstone, Cuprite, Indiana, Washington DC, MSHelens et Erta Ale, respectivement. Ainsi, une amélioration du PSNR d'au moins 0,53 dB est observée. Cependant, l'augmentation des performances de compression n'améliore pas nécessairement l'analyse spécifique des données. En effet, pour démontrer l'efficacité de la méthode proposée dans les applications basées sur la classification, nous avons évalué les performances de la classification. Les

résultats de la classification et le test de McNemars montrent que la méthode proposée surpasse la précision de la méthode 2D-DWT +SVR. De plus, la réflectance spectrale sur les bandes de données compressées avec la 3D-DWT + SVR montre que les variations sont presque identiques à celles des image originales.

Nous pouvons souligner trois avantages majeurs de la méthode proposée. Premièrement, à partir de l'évaluation des performances de compression, la 3D-DWT + SVR donne des taux de compression élevés avec une bonne qualité d'image reconstruite. Un autre avantage de la méthode apparaît dans les performances de la classification qui surpassent celles obtenues par les méthodes comparées. De plus, la méthode offre de meilleures performances pour les données compressées que celles des données originales sans compression. Le troisième avantage est que par l'utilisation de la méthode, on obtient une fidélité spectrale, ce qui est très utile dans des applications spécifiques telles que la détection d'anomalies ou l'analyse de données.

L'inconvénient majeur de cette méthode réside dans le temps requis pour son exécution, en particulier pour la résolution de niveaux élevés, qui est principalement due au traitement temporel du modèle SVR. L'utilisation du calcul parallèle et des codes de version *C/C++* sont des perspectives pour une amélioration future du temps d'exécution de la méthode. D'un autre côté, nous pensons qu'une meilleure sélection des échantillons, autre que la régression par vecteurs de support des coefficients d'ondelettes des bandes DC, peut améliorer les résultats obtenus par cette méthode. Nous proposons donc une méthode de classification de textures hyperspectrales basée sur une sélection des pixels représentatifs par mesure de similarité avec la transformée en ondelettes spectrales sur graphes et les machines à vecteurs supports. Nous détaillons cette méthode dans le chapitre 5. D'autres travaux utilisant la transformation de Paquets-d'ondelettes et des classificateurs basés sur les CNN pour améliorer les performances de compression et de classification constituent une perspective intéressante à considérer.

Chapitre 5

Classification des images hyperspectrales par transformée en ondelettes spectrales sur graphes

Sommaire

5.1	Préambule	77
5.2	État de l'art	77
5.3	Approche proposée pour la classification de la texture hyperspectrale	79
5.3.1	Le schéma proposé	79
5.3.2	Mesure de similarité et transformée en ondelettes sur graphes	79
5.3.3	La classification par les machines à vecteurs de support . . .	83
5.3.4	Algorithme proposée pour la classification de la texture hyperspectrale	84
5.4	Tests et résultats	85
5.4.1	Les paramètres de la méthode de classification proposée . . .	85
5.4.2	Les images hyperspectrales utilisées en tests	85
5.4.3	Discussion des résultats selon les distances	88
5.4.4	Discussion des résultats selon le voisinage	89
5.4.5	Les performance de classification	91
5.5	Discussion	97

5.1 Préambule

Des méthodes de traitement sur graphes sont développées pour extraire efficacement les informations de données. En particulier, ces méthodes sont adoptées pour la classification de données de grande dimension, en exploitant des informations résidant sur des graphes pondérés. Dans cette partie de la thèse, nous proposons une nouvelle méthode de classification de texture hyperspectrale basée sur la transformée en ondelettes spectrales sur graphes. Cette transformée récente permet d'extraire les caractéristiques de texture d'un graphe pondéré d'une image hyperspectrale. Ce graphe est constitué de pixels représentatifs dispersés. Des mesures de similarité entre ces pixels représentatifs sont effectuées afin de décorrélérer les pixels proches et d'améliorer ainsi la précision de classification. La classification de la texture hyperspectrale est obtenue en appliquant les machines à vecteurs de support (SVM) sur les coefficients des ondelettes sur graphe [2].

5.2 État de l'art

Les images hyperspectrales fournissent des informations très détaillées sur les distributions spectrales et spatiales de différents matériaux. La richesse de l'information du spectre mesurée par les capteurs hyperspectraux permet de distinguer les différentes classes présentes dans l'image, ce qui est très utile pour l'analyse et la reconnaissance des objets. Cependant, la grande dimension des images hyperspectrales reste problématique pour la classification en raison du grand nombre de sous-bandes spectrales contiguës et de la faible formation étiquetée disponible. Par ailleurs, les fortes variations de texture hyperspectrale à classer ne nécessitent aucune condition stationnaire de classification. De nombreuses méthodes, récemment proposées, ont été utilisées pour surmonter ces problèmes. Les auteurs dans [20], ont proposé une méthode de classification hyperspectrale basée sur la transformée en ondelettes 3D, un descripteur de texture spectral-spatial et une régression logistique structurée pour l'extraction des caractéristiques et la classification des pixels. La connaissance de la structure des caractéristiques, permise par cette

méthode et les méthodes à base d'ondelettes présentées dans [139, 22], rend la sélection des caractéristiques plus efficace. Une représentation parcimonieuse de caractéristiques hyperspectrales introduisant une fonction de noyau dans [140, 141], ont également montré de bonnes performances de classification des images hyperspectrales. Machine à vecteurs de support [142, 143, 144] est une autre approche efficace en termes de robustesse face à la grande dimension de l'espace de fonctions. Un algorithme de classification semi-supervisée est proposé dans [145] afin d'éviter le risque de saturation des échantillons d'apprentissage en utilisant une extension de SVM dans le graphe Laplacien (LapSVM). Pour améliorer la précision de la classification des images hyperspectrales, les auteurs dans [146] ont introduit une méthode basée sur la fusion de l'apprentissage supervisé (SVM) et non supervisé (fuzzy c-means clustering). Dans d'autres travaux [147, 148], des approches basées sur des graphes ont été suggérées pour résoudre les problèmes de classification. Les méthodes d'apprentissage approfondi (Deep learning) ont également suscité un grand intérêt pour la classification hyperspectrale [149, 150, 151, 152] et ont démontré d'excellentes performances dans le domaine. Le réseau de neurones à convolution profonde (CNN) a été utilisé avec efficacité dans l'extraction de caractéristiques de texture hyperspectrales [133, 134, 153]. Plusieurs méthodes basées sur les CNN ont été utilisées pour améliorer les performances de la classification hyperspectrale, comme dans [135, 123, 137]. La transformée en ondelettes spectrales sur graphes (SGWT) est une transformée prospective sur graphe développée par Hammond et al dans [73] et utilisée avec succès dans de nombreuses applications de classification [154, 76], de débruitage des images [155] et d'enregistrement des images non rigides [156]. Cette transformée explore les signaux localisés sur un graphe de Fourier d'un graphe non dirigé. L'une des raisons pour lesquelles la SGWT excelle dans l'extraction des caractéristiques est la grande flexibilité de la description d'un grand nombre de données. Dans notre travail, publié dans [2], nous proposons une classification de la texture hyperspectrale basée sur la classification par SVM des coefficients de la SGWT. L'une des principales contributions de ce travail consiste à étudier la SGWT adaptée à la classification des données hyperspectrales et à évaluer les résultats de cette méthode en termes de précision et robustesse de la classification. La SGWT-adaptée-hyperspectrale est basée sur une structure qui représente des

informations spectrales et spatiales contenues dans une image hyperspectrale. Une autre contribution consiste à observer l'effet des différentes mesures de similarité utilisées dans le processus SGWT, sur l'extraction de pixels représentatifs et donc sur l'efficacité de la sélection des caractéristiques. La méthode proposée est évaluée à la fois sur le capteur de données du spectromètre imageur aéroporté dans le visible/infrarouge (AVIRIS) et le capteur de données du spectromètre imageur à système optique réfléchissant (ROSIS).

5.3 Approche proposée pour la classification de la texture hyperspectrale

5.3.1 Le schéma proposé

Le diagramme de la Figure 5.1 décrit les différentes étapes de notre procédure de classification hyperspectrale. La première étape consiste à appliquer la SGWT sur l'image hyperspectrale pour générer les coefficients de la transformée en ondelettes spectrales sur graphes. Dans cette étape, nous faisons varier les mesures de distance pour le calcul de la distance sur graphe, à savoir la distance euclidienne (ED), la distance de Kolmogorov (KD), l'angle spectral (SA), la divergence spectrale de l'information (SID) et la corrélation croisée normalisée (NCC) afin de montrer l'effet de chacune sur la précision de la classification. L'étape suivante comprend la classification SVM des coefficients extraits par la SGWT.

5.3.2 Mesure de similarité et transformée en ondelettes sur graphes

Pour créer des graphes pondérés à partir de données hyperspectrales, nous mesurons la similarité entre le spectre d'un pixel et les spectres de ces T -voisinage pixels. Par conséquent, des pixels représentatifs sont sélectionnés sur la base d'une mesure de similarité entre ces pixels. Dans ce travail, nous utilisons une équation de pondération des arêtes basée sur le calcul de similarité entre les sommets donnée par [74], définie

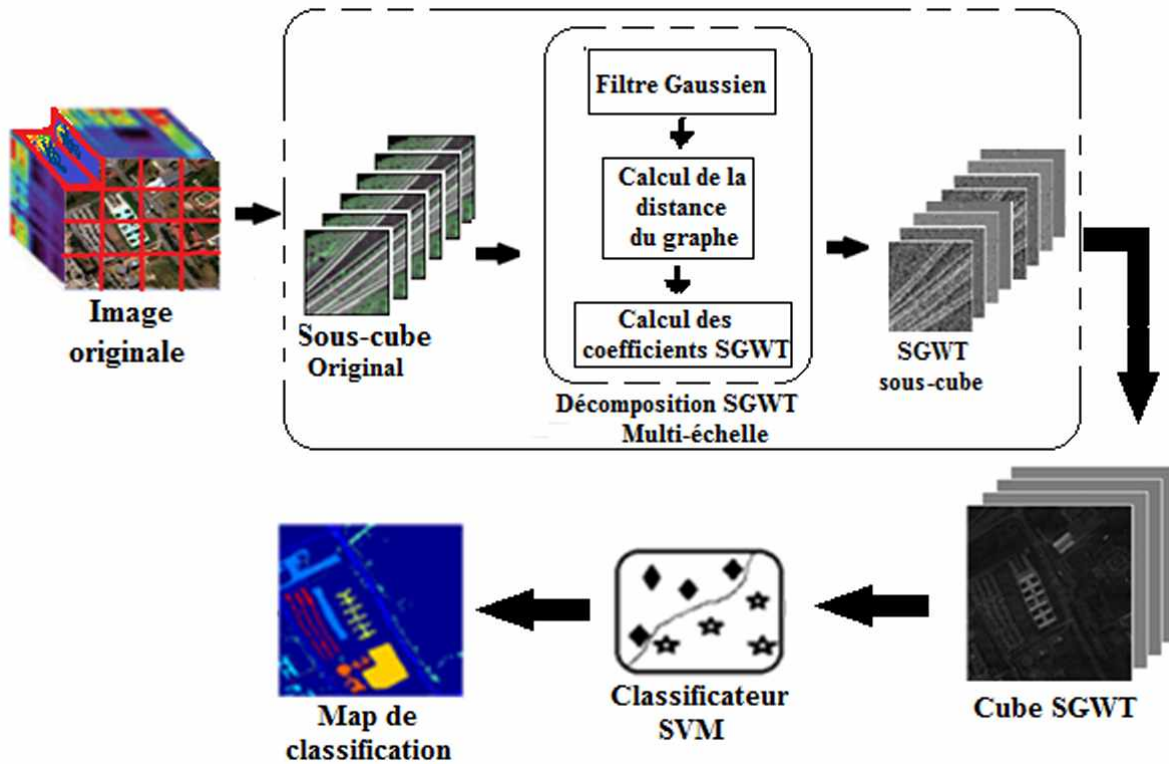


FIGURE 5.1 – Schéma de l'approche de classification proposée

comme suit :

$$w(i, j) = \begin{cases} e^{-\gamma[\text{dist}(\delta(i), \delta(j))]^2} & \text{Si } j \in \mathcal{N}_k(i) \\ 0 & \text{Sinon} \end{cases} \quad (5.1)$$

où $\text{dist}(\delta(i), \delta(j))$ est la distance entre les spectres des pixels comparés $(\delta(i))$, $(\delta(j))$ des noeuds (les sommets) i et j , et γ est fixé à 1 [76].

Le calcul de similarité spectrale entre les pixels connectés permet d'identifier les différentes classes dans l'image. Pour montrer l'effet de ces mesures de distance sur les résultats de la classification, nous avons choisi cinq mesures de similarité qui sont fréquemment utilisées à des fins de classification. Ainsi, nous introduisons la distance euclidienne (ED) [157, 158], la distance de Kolmogorov (KD) [161], l'angle spectral (SA) [158, 159, 161], la divergence des informations spectrales (SID) [160, 161] et la corrélation croisée normalisée (NCC) [162].

La distance Euclidienne : La distance euclidienne mesure la similarité entre deux observations au même moment t . Dans le cadre de notre travail, la mesure sert à estimer la distance entre deux spectres .i.e. le spectre à classer et les spectres des pixels du T -voisinage. La distance euclidienne (ED) de deux vecteurs $\mathbf{d}_{1_i} = (\mathbf{d}_{1_1}, \dots, \mathbf{d}_{1_n})$ et $\mathbf{d}_{2_i} = (\mathbf{d}_{2_1}, \dots, \mathbf{d}_{2_n})$ de dimensions n est définie par l'équation :

$$\mathbf{d}_{\text{ED}}(\mathbf{d}_{1_i}, \mathbf{d}_{2_i}) = \sqrt{\sum_{i=1}^n (\mathbf{d}_{1_i} - \mathbf{d}_{2_i})^2}. \quad (5.2)$$

La distance de Kolmogorov : La distance de Kolmogorov-Smirnov est une mesure de distance commune qui calcule la différence maximale entre les distributions cumulatives de deux spectres. La distance Kolmogorov-Smirnov de deux vecteurs \mathbf{d}_{1_i} et \mathbf{d}_{2_i} de dimensions n est définie par l'équation :

$$\mathbf{d}_{\text{KD}}(\mathbf{d}_{1_i}, \mathbf{d}_{2_i}) = \max(|P_{\mathbf{d}_{1_i,1}}, P_{\mathbf{d}_{2_i,1}}|, \dots, |P_{\mathbf{d}_{1_i,2}}, P_{\mathbf{d}_{2_i,2}}|). \quad (5.3)$$

où $P_{\mathbf{d}_{1_i}}$ et $P_{\mathbf{d}_{2_i}}$ sont les distributions cumulative de \mathbf{d}_{1_i} et \mathbf{d}_{2_i} .

L'angle spectral : L'angle spectral est une autre mesure de distance utilisée dans la classification des données hyperspectrales pour évaluer la similarité entre deux spectres. L'angle spectral (SA) donne l'angle formé entre le spectre à classer et le spectre de voisinage. Le SA de deux vecteurs \mathbf{d}_{1_i} et \mathbf{d}_{2_i} de dimensions n est définie par l'équation :

$$\text{SA}(\mathbf{d}_{1_i}, \mathbf{d}_{2_i}) = \arccos \left(\frac{\langle \mathbf{d}_{1_i}, \mathbf{d}_{2_i} \rangle}{\|\mathbf{d}_{1_i}\|_2 \|\mathbf{d}_{2_i}\|_2} \right). \quad (5.4)$$

où $\langle . \rangle$ représente le produit scalaire des vecteurs et $\| . \|$ représente la norme Euclidienne.

La divergence de l'information spectrale : La divergence spectrale de l'information (SID) mesure la similarité spectrale entre deux vecteurs \mathbf{d}_{1_i} et \mathbf{d}_{2_i} de dimensions n . Plus les valeurs de SID sont grandes, plus les différences entre les deux spectres sont

grandes. Elle est définie par l'équation :

$$\text{SID}(\mathbf{d}_{1_i}, \mathbf{d}_{2_i}) = D(\mathbf{d}_{1_i} \parallel \mathbf{d}_{2_i}) + D(\mathbf{d}_{2_i} \parallel \mathbf{d}_{1_i}). \quad (5.5)$$

D est la divergence de l'information, $D(\mathbf{d}_{1_i} \parallel \mathbf{d}_{2_i})$ et $D(\mathbf{d}_{2_i} \parallel \mathbf{d}_{1_i})$ représentent les entropies relatives de \mathbf{d}_{1_i} par rapport \mathbf{d}_{2_i} et de \mathbf{d}_{2_i} par rapport \mathbf{d}_{1_i} respectivement.

La corrélation croisée normalisée : La corrélation croisée normalisée (NCC) mesure le degré de similarité entre deux images comparées. La NCC n'est pas invariante aux changements linéaires de l'amplitude des variations d'éclairage et de contraste. Les valeurs NCC obtenues mènent à des valeurs dans l'intervalle $[0, 1]$, où 1 indique la meilleure similarité. La NCC de deux vecteurs \mathbf{d}_{1_i} et \mathbf{d}_{2_i} de dimensions n est donnée par l'équation :

$$\text{NCC} = \frac{\sum_{i=1}^n \mathbf{d}_{1_i} \mathbf{d}_{2_i}}{\sqrt{\sum_{i=1}^n \mathbf{d}_{1_i}^2 \sum_{i=1}^n \mathbf{d}_{2_i}^2}}. \quad (5.6)$$

L'algorithme 3 résume les étapes de l'implémentation de la SGWT sur l'image hyperspectrale.

Algorithm 3 SGWT

Entrée : Cube de données hyperspectrales ($N' \times M' \times S'$)

Sortie : Les coefficients de la SGWT ($N' \times M' \times S' \times (l' + 1)$)

Diviser le cube original de données hyperspectrales en ($N_1 \times M_1 \times S'$) sous-cubes

Pour chaque sous-cube

Calculer la matrice d'adjacence des graphes pondérés \mathbf{A}

Calculer le graph Laplacien \mathbf{L}

Concevoir la fonction du filtre de la transformée en ondelettes spectrales sur graphes

Pour Chaque élément du polynôme de Chebyshev calculé

Calculer tout les coefficients de la SGWT

Fin Pour

Fin Pour

Sur la Figure 5.2, un exemple d'une décomposition SGWT multi-échelle appliquée sur une région de la 5^{ème} bande de l'image hyperspectrale "Pavia U" avec $J = 3$ et $T -$

voisinage = 4 (les quatre voisins les plus proches).




FIGURE 5.2 – Une décomposition multi-échelle sur la 5^{ème} bande de l'image "Pavia U". (a) : Fonction d'échelle, (b)-(d) : Les coefficients SGWT , échelles 1-3

Les coefficients obtenus de la SGWT seront classifiés à l'aide du classificateur SVM, qui est présenté juste après.

5.3.3 La classification par les machines à vecteurs de support

Nous avons expliqué dans le chapitre 4 la méthode des SVMs, que nous avons utilisée dans des application de régression. Dans cette partie du travail, nous utilisons la méthode pour résoudre un problème de classification. La méthode des SVMs est une méthode de classification supervisée efficace basée sur de petits échantillons sélectionnés dans l'ensemble de données. L'auteur dans [117] a proposé cette méthode comme une méthode d'apprentissage statistique. La classification SVM permet une séparation optimale de l'hyperplan par la formation d'échantillons appropriés et le test de l'ensemble de données des variables d'entrée. La méthode SVM est conçue initialement pour la classification binaire, mais qui a été étendu pour traiter la classification multi-classes. D'autre part, si les données d'apprentissage ne sont pas linéairement séparables, une fonction du noyau est utilisée pour classifier les échantillons. Dans notre cas, les caractéristiques extraites de la SGWT ne sont pas linéairement séparables. Par conséquent, une classification SVM basée sur un noyau est utilisée pour la classification. De plus, la méthode SVM décompose les caractéristiques extraites de l'ensemble de données sur des sous-régions

pour obtenir une bonne classification par la fonction du noyau SVM. La classification est effectuée en minimisant la fonction suivante :

$$\frac{1}{2}(\mathbf{a}^T \mathbf{a} + \mathbf{b}^2) - C \sum_{I=1}^M \xi_I \quad (5.7)$$

soumise à des contraintes :

$$y_I(\mathbf{a}^T k(S_I) + \mathbf{b}) \geq 1 - \xi_I, \quad \xi_I \geq 0, I = 1, \dots, M \quad (5.8)$$

où C est un paramètre de régularisation positif, α est le vecteur de coefficients, b est le biais et ξ_I sont appelées variables lentes introduites pour mesurer la non séparabilité des données. L'étiquette de classe $y \in \pm 1$ et S_I est l'espace de caractéristiques défini pour l'index I de 1 à M cas d'entraînement. Nous avons défini dans le chapitre 3 la fonction de base radiale (RBF) ϕ qui est la fonction du noyau SVM utilisée pour notre approche. Elle est définie par :

$$\phi = \exp(-\gamma|\mathbf{X}_I - \mathbf{X}_J|^2) \quad (5.9)$$

.

5.3.4 Algorithme proposée pour la classification de la texture hyperspectrale

Les performances de la méthode SGWT-SVM sont calculées en utilisant les SVM appliquées aux coefficients SGWT. Le modèle SVM est construit en sélectionnant des pixels représentatifs de la classe de vérité-terrain considérée, qui fournit les groupes de données de test et d'entraînement. Toutes les étapes de classification proposée par notre méthode "SGWT-SVM" sont données par l'Algorithme 4.

Algorithm 4 La méthode de classification proposée SGWT-SVM

Entrée : Le cube de données hyperspectrales ($N' \times M' \times S'$)
Sortie : L'image classifiée ($N' \times M'$)
Calcul du cube de données SGWT ($N' \times M' \times S'$)($l' + 1$)
Charger l'image vérité-terrain $\mathbf{G}_t(N' \times M')$
Normaliser les données de l'image, où les données normalisées $\in [-1, 1]$
Créer des groupes de test et d'apprentissage
Construire le modèle SVM pour les coefficients SGWT
Calculer les paramètres de performance de la classification

5.4 Tests et résultats

5.4.1 Les paramètres de la méthode de classification proposée

Pour nos tests, nous utilisons 200 échantillons d'apprentissage par classe et nous éliminons les classes contenant de petits échantillons d'apprentissage [135, 123]. Pour l'approche proposée SGWT-SVM, tous les programmes sont mis en oeuvre en utilisant les langages Matlab et GNU Octave. Les outils de la SGWT (<http://wiki.epfl.ch/sgwt>) et LibSVM (<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>) sont utilisés pour le calcul numérique. La SGWT a été mise en oeuvre avec un nombre de 3 échelles et un filtre gaussien. Pour la construction du graphe, nous définissons des pixels à 4-voisins et un degré polynomial de Chebyshev égal à 100. Le modèle SVM est utilisé avec un noyau de fonction de base radiale, un facteur de régularisation $C = 1$ et une validation croisée de 10. Notez que ces paramètres sont définis de manière empirique pour obtenir le meilleur compromis possible entre exactitude de classification et temps de calcul.

5.4.2 Les images hyperspectrales utilisées en tests

Pour évaluer l'efficacité de la méthode proposée, quatre ensembles de données hyperspectrales disponibles en ligne ([http://www.ehu.es/ccwintco/index.php?Title=Scènes de téledétection hyperspectrale](http://www.ehu.es/ccwintco/index.php?Title=Scènes+de+téledétection+hyperspectrale)) sont utilisés, à savoir Indian Pines, KSC, l'université de Pavie (Pavia University) et le centre de Pavie (Pavia Centre), comme illustré dans les Figures 5.3 (a), 5.4 (a), 5.5 (a) et 5.6 (a). Pour cette évaluation, nous adoptons

les métriques de classification : précision globale (OA), précision moyenne (AA) et coefficient kappa (κ). Nous comparons les performances, en terme de précision, de notre méthode à celles d'autres méthodes de classification très connues.

Image Indian Pines : Comme indiqué précédemment (dans le chapitre 3), cette image a été acquise dans le nord-ouest de l'Indiana en 1992 par la National Aeronautics and Space Administration (NASA) avec un capteur de spectromètre imageur aéroporté/infrarouge (AVIRIS). Elle génère 220 bandes spectrales allant de 0,38 μ m à 2,5 μ m, dont lesquelles 20 bandes présentant du bruit, sont supprimées pour les expériences. La taille de l'image spatiale est de 145 \times 145 avec une résolution de 20 m par pixel. Cet ensemble de données hyperspectrales comprend 16 classes de vérités-terrain et 10366 pixels étiquetés. Nous utilisons de manière optimale 9 classes, comme indiqué dans le Tableau 5.1 [20, 163]. Les Figures 5.3 (a) et (b) représentent l'image originale d'Indiana et sa carte vérité-terrain respectivement.

TABLE 5.1 – Les différentes classes de la scène Indian Pines et leurs nombres d'échantillons

	Classe	Échantillons	Apprentissage	Test
1	Notil de maïs	1434	200	1228
2	Mintill-maïs	834	200	630
3	Herbe-pâturage	497	200	283
4	Herbe-Arbres	747	200	530
5	Foin	489	200	278
6	Notil de Soja	968	200	772
7	Mintill-Soja	2468	200	2255
8	Soja	614	200	393
9	Bois	1294	200	1065

Image KSC : La base de données "Kennedy Space Centre" a été acquise en Floride en 1996 par la NASA avec un capteur AVIRIS. Après avoir supprimé les bandes spectrales les plus bruyantes, 176 bandes sont utilisées pour les expériences avec une image de taille spatiale de 512×614 . Cette image contient 13 classes d'occupation du sol avec 5211 pixels étiquetés [20, 164]. Comme pour l'image Indian Pines, nous utilisons uniquement les classes contenant le plus grand nombre d'échantillons; elles sont données dans le Tableau 5.2. Les Figures 5.4 (a) et (b) montrent respectivement l'image originale KSC et sa carte vérité-terrain.

TABLE 5.2 – Les différentes classes de la scène KSC et leurs nombres d'échantillons

	Classe	Échantillons	Apprentissage	Test
1	Brique	761	200	561
2	Marais Graminoïde	431	200	231
3	Marais Spartina	520	200	320
4	Marais des quenouilles	404	200	203
5	Marais salin	419	200	218
6	Vasières	503	200	302
7	Eau	927	200	726

Image Pavia U : Ce troisième ensemble de données utilisé dans nos tests, Pavia U, a été acquis sur l'Université de Pavie par le capteur ROSIS (Reflective Optics System Imaging Spectrometer) en 2001. Il génère 115 bandes spectrales de 0,43 à 0,8 μ m, il contient 12 bandes bruyantes que nous avons supprimé lors des tests. La taille de chaque bande est de 641×340 avec une résolution de 1,3m par pixel. Cette base contient 9 classes présentées dans le Tableau 5.3 [20, 164]. Les Figures 5.5 (a) et (b) montrent respectivement l'image originale de Pavia U et sa carte vérité-terrain.

Image Pavia C : Semblable aux données de Pavia U, les données du centre de Pavie (Pavia C) sont acquises par un capteur ROSIS couvrant le centre-ville de Pavie en Italie. Il contient également 115 bandes spectrales de 0,43 à 0,86 μ m, avec 13 bandes supprimées. Seule une taille de 1096×715 de la scène du Pavia C est généralement utilisée pour les tests. Le reste des informations est rejeté. Dans le Tableau 5.4, nous

TABLE 5.3 – Les différentes classes de la scène Pavia U et leurs nombres d'échantillons

	Classe	Échantillons	Apprentissage	Test
1	Asphalte	6631	200	6431
2	Prairie	18649	200	18449
3	Gravier	2099	200	1899
4	Arbre	3064	200	2864
5	Tôles peintes	1345	200	1145
6	Sol	5029	200	4829
7	Bitume	1330	200	1130
8	Briques auto-bloquantes	3682	200	3482
9	Ombres	947	200	747

montrons les 9 classes de cet ensemble de données [165]. Sur les Figures 5.6 (a) et (b), l'image originale de Pavia C et sa carte vérité-terrain sont montrées respectivement.

TABLE 5.4 – Les différentes classes de la scène Pavia U et leurs nombres d'échantillons

	Classe	Échantillons	Apprentissage	Test
1	Eau	65971	200	65771
2	Arbre	7598	200	7398
3	Asphalte	3090	200	2890
4	Brique auto-bloquante	2685	200	2485
5	Bitume	6584	200	6384
6	Carrelage	9248	200	9048
7	Ombres	7287	200	7087
8	Prairie	42826	200	42626
9	Sol	2863	200	2663

5.4.3 Discussion des résultats selon les distances

Afin de vérifier l'impact des différentes mesures de distance présentées dans la section 5.3.2 sur les performances de classification, nous comparons la précision globale (OA), la précision moyenne (AA) et le coefficient Kappa (κ) donnés par chaque distance des quatre ensembles de données. Les résultats présentés dans le Tableau 5.5 montrent des performances de classification élevées avec les mesures de distance testées pour tous les ensembles de données. Cependant, on peut observer que les mesures des performances de classification obtenues avec les distances SA, SID et NCC sont supérieures à celles

obtenues avec les distances ED et KD. En effet, les trois paramètres d'évaluation obtenus avec les distances ED et KD sont inférieurs à ceux obtenus avec les autres distances. A fortiori concernant l'ensemble de données "Indian Pines", qui donne des performances d'environ 10 % de moins que les performances des autres mesures de distances. Pour les mesures de distances SA, SID et NCC, les résultats sont très appréciables et représentent des performances compétitives entre celles-ci selon les différentes distributions de données.

La distance SID surpasse les autres distances calculées pour toutes les mesures de classification (OA, AA et κ) sur deux distributions de données (Indian Pines et Pavia C). Par conséquent, nous poursuivons nos tests, pour la section suivante (5.4.4), en utilisant cette distance. À souligner que dans les ensembles de données Indian Pines et Pavia U, la sélection de 200 échantillons d'apprentissage n'a pas atteint les meilleures précisions de classification. La sélection d'environ 20 % échantillons d'apprentissage pour chaque classe de ces ensembles de données améliore considérablement les performances de classification. Les résultats des tests de classification pour tous les ensembles de données avec toutes les mesures de distances, sont présentés dans le Tableau 5.5.

5.4.4 Discussion des résultats selon le voisinage

Pour évaluer l'influence du nombre de T -voisinage pixels pris sur les résultats de classification, nous sélectionnons différents T -voisinage pixels testés sur les quatre ensembles de données hyperspectrales en utilisant la distance SID. Nous avons donc testé l'influence de quatre T pixels sélectionnés dans le voisinage ($T = 1, 2, 4, 8$). Nous mesurons également le temps de calcul pris par chaque sélection. A noter que les expériences ont été effectuées en utilisant un calcul parallèle avec GPU Matlab Image Processing Toolbox afin de réaliser le processus de calcul des sous-cubes de la SGWT. Toutes les

Chapitre 5. Classification des images hyperspectrales par transformée en ondelettes spectrales sur graphes

TABLE 5.5 – Résultats expérimentaux pour les mesures de distances Euclidienne (ED), de Kolmogorov (KD), d’angle spectral (SA), de divergence d’information spectrale (SID) et de corrélation croisée normalisée (NCC).

Données	Nombre d’échantillons	Résultats	ED	KD	SA	SID	NCC
Indian Pines	200 échantillons d’apprentissage	OA	85.08	85.19	94.50	95.21	95.09
		AA	78.07	79.94	96.21	96.61	95.96
		κ	82.32	82.48	93.42	94.27	94.12
	20% échantillons d’apprentissage	OA	87.82	87.99	96.65	98.77	96.58
		AA	88.39	87.00	96.35	98.90	96.52
		κ	0.85	0.85	0.94	0.98	0.94
KSC	200 échantillons d’apprentissage	OA	99.20	99.56	99.65	99.65	99.73
		AA	99.60	99.49	99.75	99.98	99.80
		κ	0.99	0.99	0.99	1.00	0.99
Pavia U	200 échantillons d’apprentissage	OA	90.82	91.74	96.14	96.68	97.72
		AA	92.82	96.16	96.62	97.41	98.01
		κ	0.88	0.87	0.95	0.95	0.97
	20% échantillons d’apprentissage	OA	97.23	98.07	99.65	99.48	99.41
		AA	97.53	98.13	99.47	99.42	99.24
		κ	0.97	0.98	0.99	0.99	0.99
Pavia C	200 échantillons d’apprentissage	OA	98.13	98.37	98.14	99.72	98.47
		AA	95.55	96.17	96.30	99.60	97.35
		κ	0.97	0.97	0.97	0.99	0.98

expériences sont exécutées avec Intel Xeon E5620 de 2.40 *GHz* et de 32 *Go* de RAM. A partir des résultats affichés dans le Tableau 5.6, pour tous les ensembles de données testés, les performances de classification augmentent avec le nombre pris de pixels de voisinage. En effet, on peut observer une amélioration d’au moins 0.14 % de l’OA avec l’augmentation de T pour tous les ensembles de données. A l’exception de l’ensemble de données Pavia U, pour lequel on peut souligner que le nombre sélectionné le plus élevé T -voisinage, ne permet pas d’obtenir de meilleures performances, c’est à dire que les 8-voisinage pixels donnent moins de performance de classification que ceux donnés par les 4-voisinage pixels. De même, la complexité de calcul du classificateur proposé augmente lorsque les T -voisinage pixels augmentent. Comme indiqué dans le Tableau 5.6, les 8-voisinage pixels nécessitent plus de temps de calcul. On peut en conclure que le temps de calcul est dominé par le nombre sélectionné des T -voisinage pixels. Par conséquent, dans nos expériences, des 4-voisinage pixels sont utilisés comme entrée de notre classificateur proposé SGWT-SVM afin de minimiser le temps de consommation tout en préservant les performances de classification.

TABLE 5.6 – OA (%), AA (%), κ et le temps de calcul du classificateur SGWT-SVM avec différents T - voisinage pixels

Données	Mesures	T - voisinage			
		$T = 1$	$T = 2$	$T = 4$	$T = 8$
Indian Pines	OA	81.59	97.56	98.77	99.30
	AA	86.69	97.77	98.90	99.24
	κ	0.78	0.97	0.98	0.99
	Temps	187.68	171.76	237.16	352.84
KSC	OA	97.49	98.35	99.85	99.87
	AA	94.37	95.62	99.25	99.90
	κ	0.94	0.96	0.99	0.99
	Temps	252.66	265.68	339.09	441.74
Pavia U	OA	97.91	98.29	99.65	99.10
	AA	97.57	97.75	99.47	98.62
	κ	0.97	0.97	0.99	0.98
	Temps	417.36	445.70	469.10	556.55
Pavia C	OA	93.51	98.8	99.72	99.86
	AA	71.21	76.65	99.60	99.75
	κ	0.61	0.79	0.96	0.99
	Temps	584.95	625.85	655.98	793.30

5.4.5 Les performance de classification

Pour évaluer l'efficacité de la méthode de classification proposée SGWT-SVM, nous utilisons pour chaque distribution la mesure de distance la plus performante, c'est-à-dire la SID pour les ensembles de données Indian Pines et Pavia centre, NCC pour l'ensemble de données KSC et SA pour l'ensemble de données Université de Pavie. Nous comparons les résultats avec ceux fournis par plusieurs autres méthodes telles que SVM, ELM, SPPF Framework [123], 3D-DWT-SVM-rbf, 3D-DWT-Mixée-lasso [20], CNN [135], CNN-PPF [135, 165], C-CNN [165] et R-PCA CNN [165, 166] appliqués aux ensembles de données Indian Pines et Pavia U. Pour les données hyperspectrales KSC, nous comparons nos résultats avec ceux présentés dans [20, 136]. Pour Pavia C, les résultats sont comparés à [133, 135, 165, 166]. Les paramètres de réglage des méthodes comparées au classificateur proposé SGWT-SVM sont répertoriés dans le Tableau 5.7.

Les résultats de la comparaison sont présentés dans les tableaux 5.8, 5.9, 5.10 et 5.11 pour les ensembles de données Indian Pines, KSC, Pavia U et Pavia C respectivement.

TABLE 5.7 – Les paramètres des classificateurs comparés.

Méthode	Paramètres			
Méthode par DWT	Filtre d'ondelettes	Sélection des paramètres	Parcimonie ($\lambda = 0.5^x$)	Données d'entraînement
3D-DWT	Haar	Avec	$x = 7$ (IN)	25 (%) (IN)
SVM-rbf		Validation	$x = 5$ (KSC)	25 (%) (KSC)
(Quian et al 2013)		croisée	$x = 4$ (PU)	100%(PU)
Méthodes par CNN	Taux d'apprentissage	Dimension des données	Taille de la fenêtre	Données d'entraînement
PPF-CNN [135]	0.001 (IN) 0.01 (PU)	10	5×5	200
SPPF-Framework [123]	-	10	3×3	200
C-CNN [165]	0.01	100	5×5	200
SSRN [136]	0.0003 (IN)	24 (IN)	7×7	20% (IN)
	0.0003 (PU)	24 (PU)		10% (PU)
	0.0001(KSC)	16 (KSC)		70% (KSC)

On peut observer que le classificateur SGWT-SVM dépasse les autres classificateurs présentés en termes de précision de classification. Par exemple, dans Indian Pines, SGWT-SVM atteint un OA de 98.90 %, ce qui représente environ 1 % et 2 % par rapport aux classificateurs 3D-DWT-SVM et C-CNN (97.99 % et 96.76 %) respectivement. Comme dans Indian Pines, dans les ensembles de données de Pavia U et KSC, le classificateur proposé obtient de meilleurs résultats comparé à tous les autres classificateurs et atteint des précisions de classification les plus élevées. A l'instar de ces ensembles de données, SGWT-SVM atteint avec l'image hyperspectrale Pavia C des précisions plus élevées que les quatre autres méthodes comparées (SVM-RBF, CNN, R-PCA-CNN et CNN-PPF) et présente des performances compétitives avec la méthode C-CNN.

Les Figures 5.3 (c), 5.4 (c), 5.5 (c) et 5.6 (c) montrent les résultats de la classification du SGWT-SVM proposé sur Indian Pines, KSC, Pavia U et Pavia C. Les résultats confirme considérablement ceux donnés dans les tableaux 5.8, 5.9, 5.10 et 5.11. Effective-

TABLE 5.8 – Les performances de classification utilisant les différentes techniques sur l’image Indian Pines.

	SVM [123]	ELM [123]	CNN [135]	R-PCA- CNN [165], [166]	CNN- PPF [135], [165]	SPPF [123]	3D-DWT Avec- Lasso[20]	C-CNN [165]	3DTO SVM-rbf [20]	SGWT -SVM
1	78.26	79.40	78.58	82.39	92.99	94.22	-	96.28	-	96.26
2	81.27	85.08	85.23	85.41	96.66	97.94	-	92.26	-	100.0
3	98.59	96.47	95.75	95.24	98.58	100.0	-	99.3	-	98.61
4	98.68	99.06	99.81	99.25	100.0	99.43	-	99.25	-	100.0
5	100.0	100.0	99.64	100.0	100.0	100	-	100.0	-	100.0
6	76.94	86.66	89.63	82.76	96.24	95.85	-	92.84	-	97.24
7	65.10	69.84	81.55	96.2	87.80	92.20	-	98.21	-	99.18
8	84.99	89.31	95.42	82.14	98.98	98.47	-	92.45	-	98.86
9	98.78	98.40	98.59	99.81	99.81	99.81	-	98.98	-	100.0
AA	86.96	89.36	90.60	91.47	96.78	97.55	95.90	96.62	97.35	98.77
AO	80.72	83.80	86.44	91.09	94.34	95.92	96.78	96.76	97.99	98.90




FIGURE 5.3 – Résultats de l’image Indian Pines. (a) : Image originale, (b) : Carte vérité-terrain, (c) : Résultats de classification avec SGWT-SVM

TABLE 5.9 – Les performances de classification utilisant les différentes techniques sur l’image KSC.

	SVM [136]	SAE [136]	3D-DWT SVM-rbf [20]	CNNL [136]	CNN [136]	3D-DWT Avec Lasso[20]	SPC [136]	SPA [136]	SSRN [136]	SGWT -SVM
1	86.16	92.04	-	95.20	98.48	-	99.19	99.18	99.88	100.0
2	42.55	85.59	-	87.53	92.16	-	92.60	95.39	99.00	100.0
3	67.69	72.12	-	73.35	81.84	-	85.49	93.45	98.26	100.0
4	65.12	94.10	-	97.28	98.21	-	98.09	98.67	99.54	100.0
5	67.82	94.57	-	98.05	99.04	-	99.53	99.43	99.70	100.0
6	93.40	98.91	-	99.40	99.85	-	99.96	99.96	99.96	99.02
7	100	98.39	-	98.72	98.89	-	99.86	99.63	99.80	99.59
AA	65.64	89.76	93.23	92.57	95.09	96.74	96.56	97.81	99.33	99.80
AO	80.29	92.99	94.05	95.45	97.08	97.65	97.90	98.63	99.61	99.73

ment, la majorité des classes de toutes les images hyperspectrales testées, sont fortement générées. La méthode proposée permet d’obtenir des régions bien séparées, y compris celles avec des pixels non étiquetés.

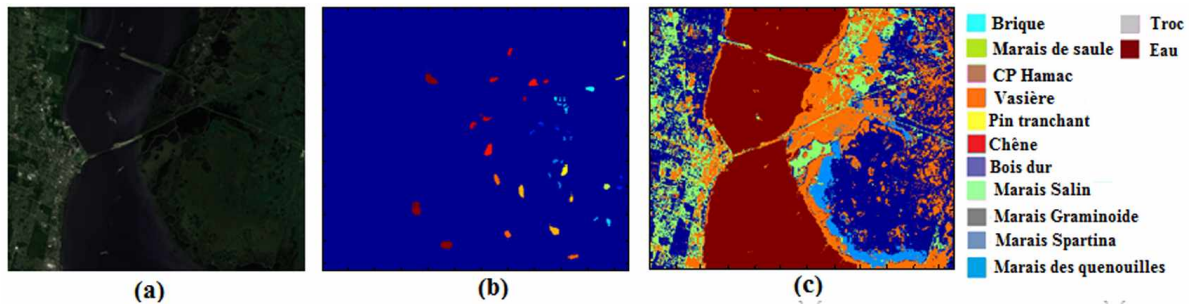


FIGURE 5.4 – Résultats de l’image KSC. (a) : Image originale, (b) : Carte vérité-terrain, (c) : Résultats de classification avec SGWT-SVM.

TABLE 5.10 – Les performances de classification utilisant les différentes techniques sur l’image Université de Pavie.

	SVM [123]	ELM [123]	CNN [135]	R-PCA- CNN [165], [166]	CNN- PPF [135], [165]	SPPF [123]	3D-DWT Avec- Lasso [20]	C-CNN [165]	3D-DWT- SVM-rbf [20]	SGWT -SVM
1	82.69	82.71	88.38	92.43	93.89	97.42	-	97.4	-	98.29
2	87.65	91.23	91.27	94.84	91.71	95.76	-	99.4	-	99.62
3	79.36	79.20	85.88	90.89	83.46	94.05	-	94.84	-	98.95
4	94.24	93.02	97.24	93.99	97.07	97.52	-	99.16	-	99.83
5	99.83	99.30	99.91	100.0	100.0	100.0	-	100.0	-	100.0
6	89.36	91.51	96.41	92.86	95.92	99.13	-	98.7	-	99.91
7	89.38	92.92	93.62	93.89	97.35	96.19	-	100.0	-	99.76
8	81.68	86.79	87.45	91.18	87.71	93.62	-	94.57	-	98.69
9	99.87	99.87	99.57	99.33	99.73	99.60	-	99.87	-	100.0
AA	89.34	90.73	93.36	94.38	94.09	97.03	97.56	98.22	98.63	99.47
OA	87.25	89.55	92.27	93.87	92.73	96.48	98.15	98.41	98.81	99.65

Pour tester la robustesse de l’approche proposée, nous faisons varier le nombre d’échantillons d’apprentissage par classe de 50 à 200 avec un intervalle de 50. Les résultats illustrés sur la Figure 5.7 montrent que la précision de la classification augmente avec le nombre de données d’entraînements. A noter que même avec un petit nombre d’échantillons d’apprentissage (50, 100), l’approche permet d’obtenir une précision élevée avec toutes les images hyperspectrales utilisées. Cela démontre clairement la robustesse du SGWT-SVM.

Pour démontrer davantage l’efficacité et la généralisation de la méthode proposée, nous avons illustré sur la Figure 5.8, la précision globale de différentes méthodes de classification avec différents nombres d’échantillons d’apprentissage. Une sélection de 1 à 10 échantillons d’entraînement par classe est effectuée pour les images Indian Pines, Pavia

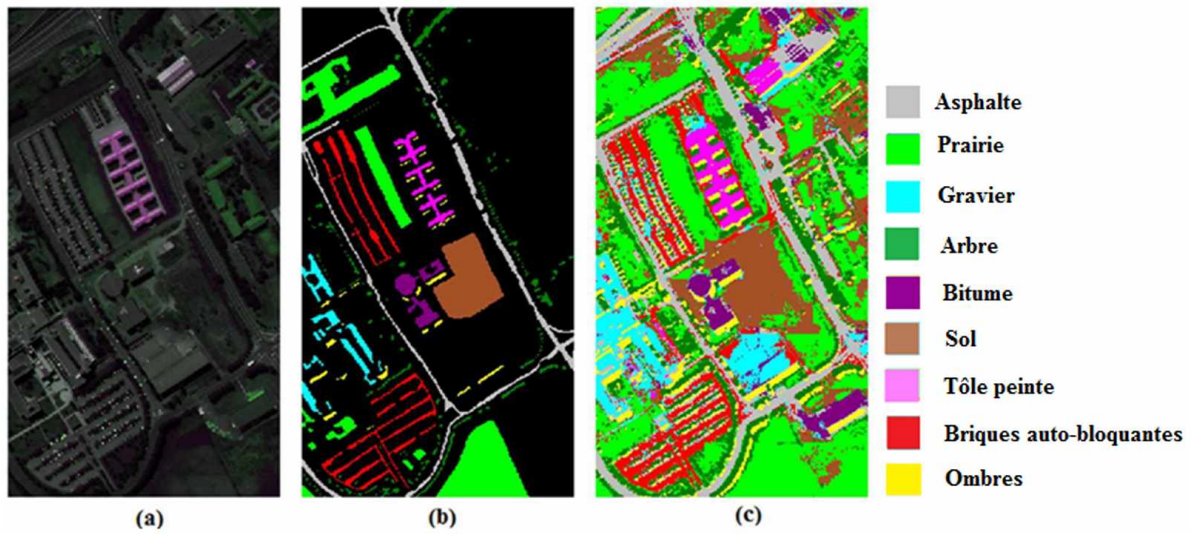


FIGURE 5.5 – Résultats de l’image Université de Pavie. (a) : Image originale, (b) : Carte vérité-terrain, (c) : Résultats de classification avec SGWT-SVM

TABLE 5.11 – Les performances de classification utilisant les différentes techniques sur l’image Centre de Pavie.

	SVM [165]	CNN [133], [165]	R-PCA-CNN [165], [166]	CNN-PPF [135], [165]	C-CNN [165]	SGWT-SVM
1	99.81	99.94	99.91	98.94	100.0	100.0
2	92.23	93.34	94.58	98.04	99.18	99.30
3	95.22	93.01	95.36	97.44	99.45	99.20
4	94.85	90.34	96.02	99.11	99.64	99.7
5	96.01	93.00	94.94	98.75	99.81	100.0
6	96.66	95.09	97.13	98.82	99.27	99.07
7	90.63	92.30	93.64	93.69	99.28	99.22
8	98.59	99.33	99.03	99.72	99.92	100.0
9	99.96	99.55	99.47	100.0	100.0	100.0
AA	95.99	95.10	96.68	98.28	99.62	99.60
OA	98.09	98.15	98.53	98.85	99.83	99.72

C et Pavia U. Les résultats obtenus sont comparés à ceux donnés dans [165] (Figures 5.8 (a), 5.8 (b), 5.8 (c)). Pour l’image KSC, et similaire à [136], 1 % à 20 % d’échantillons d’apprentissage sont sélectionnés (Figure 5.8 (d)). Les résultats montrent que, pour toutes les images, SVM-SGWT surpasse les autres méthodes comparées en termes de performance de classification, même avec un petit nombre d’échantillons d’apprentissage. En effet, une amélioration d’au moins 0,3 % est observée avec toutes les images.

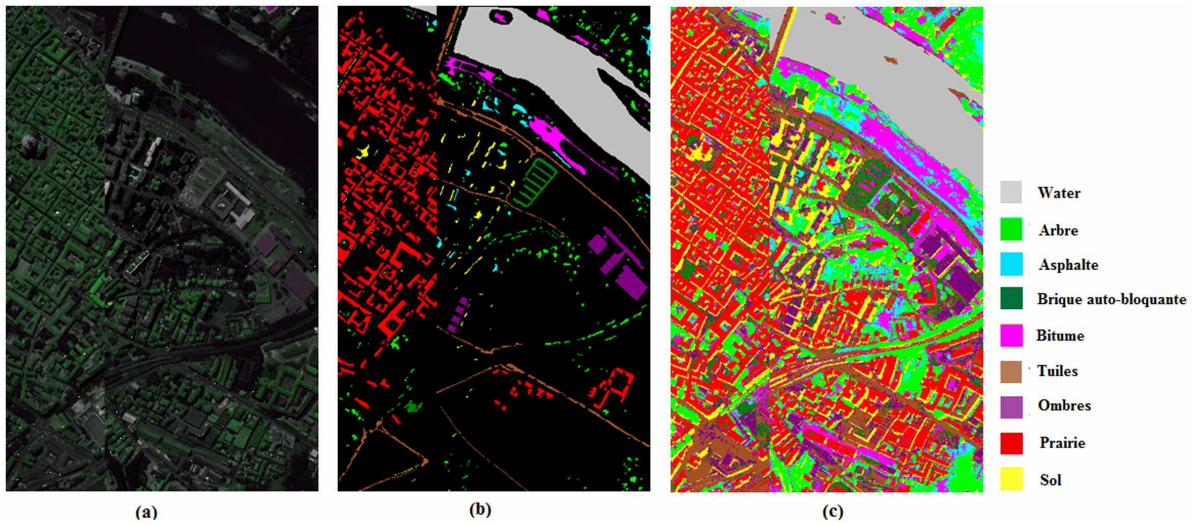


FIGURE 5.6 – Résultats de l’image Centre de Pavie. (a) : Image originale, (b) : Carte vérité-terrain, (c) : Résultats de classification avec SGWT-SVM

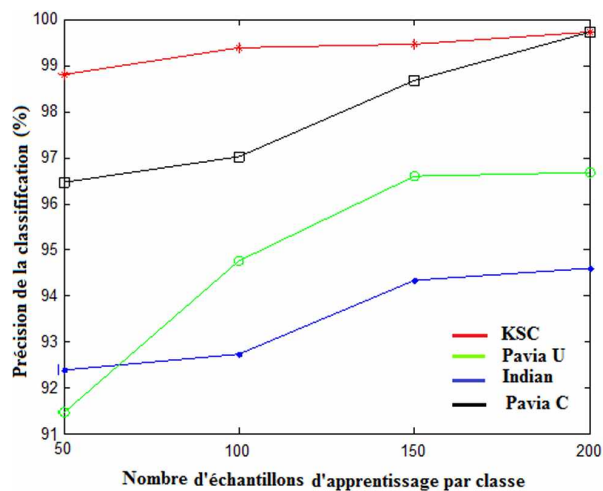


FIGURE 5.7 – OA du classificateur SGWT-SVM en variant le nombre d’échantillons d’apprentissage par classe.

Il a été démontré que les méthodes de classification fondées sur l’apprentissage en profondeur sont extrêmement efficaces pour la classification des images hyperspectrales. Cependant, les résultats donnés par l’approche proposée, qui considère la structure de données avec une sélection appropriée de composants connectés, dépassent clairement plusieurs méthodes de classification d’images hyperspectrales célèbres basées sur CNN. A noter que seules cinq mesures de similarité sont testées dans ce travail. L’utilisation d’autres tests de similarité peut améliorer les résultats de la classification. Compte

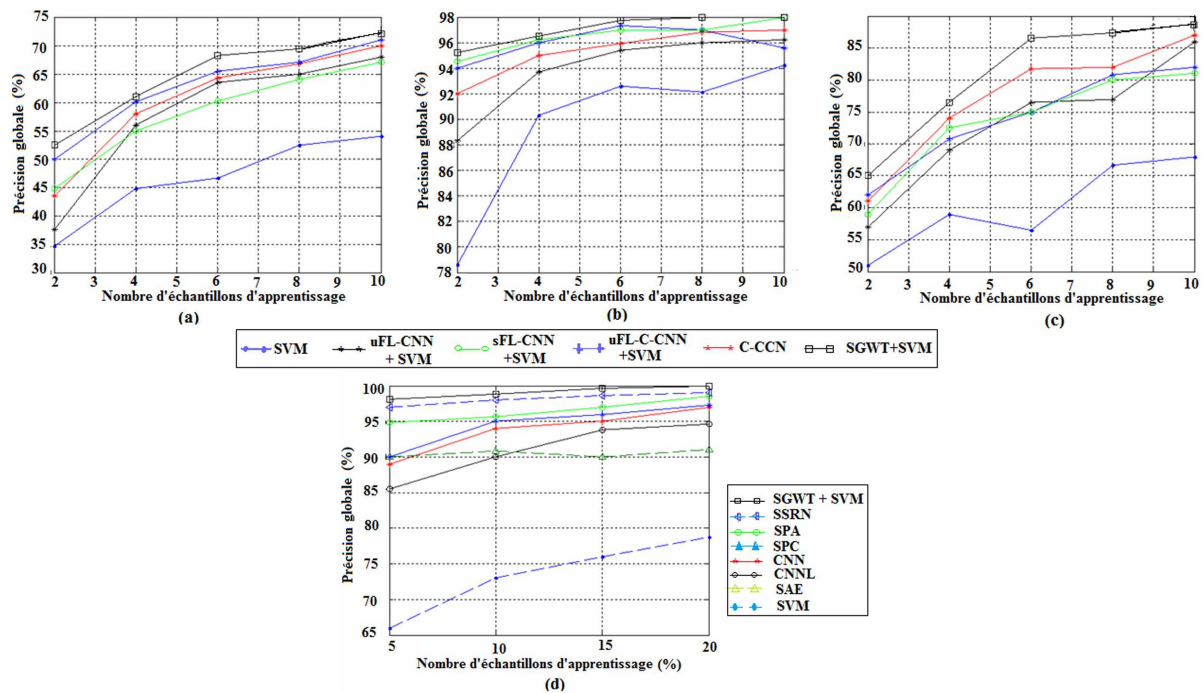


FIGURE 5.8 – OA de différentes méthodes de classification en variant le nombre d'échantillons d'apprentissage. (a) : Indian Pines, (b) : Centre de Pavie, (c) : Université de Pavie, (d) : KSC.

tenue des performances de classification obtenues et du fait que le classificateur proposé peut extraire davantage des caractéristiques discriminantes, on peut en conclure que le classificateur SGWT-SVM peut exceller dans le domaine de classification des images hyperspectrales.

5.5 Discussion

Dans ce chapitre, une méthode de classification basée sur la transformée en ondelettes spectrales sur graphes est développée pour la classification des images hyperspectrales. La méthode proposée est basée sur la classification des coefficients obtenus par la SGWT avec le modèle SVM. Dans notre approche, nous avons également évalué différentes mesures de similarités spectrales pour une meilleure sélection des pixels représentatifs et identifier ainsi les classes de l'image. De plus, en fonction des résultats de la mesure de similarité, le choix de la mesure de distance entre les pixels connectés peut affecter les performances de la classification. Il est observé que les mesures de similarité SA, SID et

NCC ont de meilleurs résultats par rapport aux mesures ED et KD et conduisent à des résultats de classification appréciables. Les résultats de l'approche proposée appliquée à quatre images hyperspectrales fournies par les capteurs AVIRIS et ROSIS démontrent l'efficacité et la robustesse de celui-ci. Ainsi, les précisions de classification obtenues avec notre méthode, même avec un nombre modeste d'échantillons d'apprentissage, montrent des performances compétitives par rapport aux meilleures techniques récentes présentées dans l'état de l'art de la classification des images hyperspectrales. Des travaux futurs sur les problèmes de débruitage, de démixage et de compression peuvent être proposés. Une autre perspective intéressante consiste à utiliser une nouvelle méthode de classification, autre que les SVMs, telle que la méthode RMG (Random multi-graphs) [167, 168]. Cela peut améliorer les performances de classification.

Chapitre 6

Conclusion

Sommaire

6.1	Contributions de la thèse	100
6.2	Perspectives	101

Ce chapitre conclut la thèse présentant une discussion générale sur le travail et les résultats obtenus, en passant en revue les principales contributions. Enfin, des orientations prometteuses pour les développements futurs des travaux sont présentées.

Grâce aux avancées technologiques en télédétection, la qualité et la disponibilité de données hyperspectrales se sont améliorées de manière significative. Le développement d'algorithmes efficaces et robustes pour l'analyse de ces données est donc devenu d'un intérêt majeur. Couplant la haute résolution spectrale à une résolution spatiale croissante des récents capteurs, les images hyperspectrales permettent de distinguer pratiquement la majeure partie des matériaux. Cependant, en raison de ces données hautement corrélées, les images hyperspectrales sont incontestablement congruentes pour la classification et la cartographie de la couverture terrestre. Le problème de la classification, visant à détecter et identifier les différentes couvertures terrestres qui caractérisent une zone géographique sélectionnée, est un processus complexe qui implique différentes procédures dont le but est d'extraire et d'analyser toutes les informations spectrales et spatiales utiles que contiennent les images hyperspectrales. D'où la nécessité de développer des méthodologies de classification des images hyperspectrales qui permettent une identification des matériaux avec précision. D'un autre côté, le volume élevé des données est problématique lors de la transmission et le stockage. D'énormes volumes de données générées quotidiennement ne peuvent être traités et stockés qu'à l'aide d'algorithmes de compression efficaces.

6.1 Contributions de la thèse

Dans cette thèse, les principes fondamentaux de l'imagerie hyperspectrale, un état de l'art sur les méthodes de traitement des images hyperspectrales et du traitement de signal sur graphes ont d'abord été présentés. Une méthode de compression des données d'images hyperspectrales aéroportées et spatioportées en intégrant une représentation parcimonieuse dans le but de préserver l'information pertinente lors de la reconstruction a été également présenté. Ensuite, une nouvelle approche de classification des images

hyperspectrales a été proposée. Notre thème s’est déroulé donc sous deux aspects.

Le premier aspect est basé sur la compression des images hyperspectrales en intégrant une régression SVM pour appliquer un apprentissage sur les données spectrales après avoir appliqué la transformée en ondelettes discrète 3D. Ceci a pour but de préserver l’information spectrale qui s’est avérée utile pour des applications post-reconstruction telles que la classification et l’analyse des données. Un codage entropique est ensuite appliqué pour assurer un bon taux de compression après régression. La méthode proposée s’est avérée efficace et suffisamment robuste. En effet les taux de compression et les performances de classification obtenus sont compétitifs avec d’autres méthodes récentes dans le domaine. En particulier, il est à noter que cette méthode présente une fidélité spectrale, qui est substantiellement utile dans des applications spécifiques telles que la détection d’anomalies ou l’analyse de données.

Le deuxième aspect consiste à proposer une méthode de classification de la texture hyperspectrale basée sur une transformée en ondelettes spectrales sur graphes. Cette récente transformée permet d’extraire les caractéristiques de la texture à partir d’un graphe pondéré construit en utilisant des pixels représentatifs parcimonieux d’une image hyperspectrale. Différentes mesures de similarité spectrale entre les pixels représentatifs ont été testées pour décorréler les pixels proches et améliorer ainsi la précision de la classification. Un classificateur simple tel que SVM, appliqué aux coefficients de la transformée en ondelettes spectrales sur graphes, a conduit à d’excellentes performances de classification. Ainsi, les précisions de classification obtenues avec notre méthode, même avec un nombre modeste de données d’entraînement, montrent des performances compétitives avec celles des meilleures techniques récentes présentées dans l’état de l’art de la classification des images hyperspectrales.

6.2 Perspectives

Comme perspectives pour la méthode de compression proposée, l’utilisation de codes de calcul parallèle et de versions *C/C++* sont à envisager pour améliorer les temps d’exécution de la méthode. D’autres travaux utilisant la transformée en paquets-ondelettes

et un classificateur basé sur les CNN pour améliorer les performances de compression et de classification sont des perspectives intéressantes à considérer.

Pour la méthode de classification basée sur les ondelettes sur graphes, de futurs travaux sur les problèmes de débruitage, de démixage et de compression peuvent être proposés. Une autre perspective intéressante est d'utiliser une nouvelle méthode de classification, autre que les SVMs, telle que la méthode des multi-graphes aléatoires (RMG). Cela peut améliorer les performances de classification. Il serait également intéressant de développer des approches qui permettront d'assurer la confidentialité des données hyperspectrales transmises. Au cours des deux dernières décennies, la confidentialité des données basée sur le Chaos a atteint un succès significatif [169, 170, 171, 172, 173]. Cela peut assurer un bon niveau de sécurité avec une faible complexité matérielle et une faible puissance lors de la transmission des données hyperspectrales. Le thème principal de notre travail a été d'exploiter les riches informations spatiales et spectrales des images hyperspectrales pour la compression et la classification des données. Pour cela, la théorie et les méthodes de représentation parcimonieuse et du traitement de signal sur graphes s'avèrent directes et efficaces. Nous espérons que les travaux futurs permettront de généraliser ou d'étendre les travaux de cette thèse au traitement et à l'analyse de types plus larges de signaux et d'images.

Bibliographie

- [1] N. Zikiou, M. Lahdir, D. Helbert, "Support vector regression-based 3D-wavelet texture learning for hyperspectral image compression," *The Visual Computer*, 36, pp. 14731490, 2020.
- [2] N. Zikiou, M. Lahdir, D. Helbert, "Hyperspectral image classification using graph-based wavelet transform," *International Journal of Remote Sensing*, 41(7), pp. 2624-2643, 2020.
- [3] J. Liang, "Spectral-spatial Feature Extraction for Hyperspectral Image Classification," 2016.
- [4] M. Lahdir, "New approach to image compression based on wavelet and fractal for Me-teosat image application.", Doctoral Thesis, University Mouloud Mammeri UMMTO, Tizi-Ouzou Algeria, 2007.
- [5] N. Zikiou, "Application dun apprentissage SVM pour le codage d'images hyperspec-trales", Thèse de Magisters, Université Mouloud Mammeri, 2014.
- [6] K. Mikolajczyk, C. Schmid, Performance evaluation of local descriptors, *IEEE tran-sactions on pattern analysis and machine intelligence*, 27(10), pp. 1615–1630, 2005.
- [7] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet classification with deep convo-lutional neural networks, *Advances In Neural Information Processing Systems*, pp. 1–9, 2012.
- [8] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Kar-pathy, A. Khosla, M. Bernstein, A. C. Berg, L. Fei-Fei, "Imagenet large scale visual recognition challenge," *International Journal of Computer Vision*, 115(3), pp. 211–252, 2015.
- [9] M. Kristian, D. Krutz, B. Juurlink, "Reconfigurable architecture for real-time image

- compression on-board satellites", *Journal of Applied Remote Sensing*, 9(1), 2015 : 097497.
- [10] F. Nicola, "Advanced Spectral and Spatial Techniques for Hyperspectral Image Analysis and Classification", Diss. University of Trento, 2015.
- [11] Y. Tarabalka, "Classification of hyperspectral data using spectral-spatial approaches," Thèse de doctorat, 2010.
- [12] M. Borengasser, W.S. Hungate, R. Watkins, "Hyperspectral Remote Sensing Principles and Applications," CRC Press, 2007.
- [13] C. I. Chang, "Hyperspectral imaging systems. In Chang," C. I., editor, *Hyperspectral Data Exploitation : Theory and Application*, John Wiley and Sons, Inc, pp. 19–59, 2007.
- [14] H. Wang, "Sparse Representation Based Hyperspectral Image Compression and Classification," Thèse de doctorat, 2018.
- [15] R. O. Green, J. E. Conel, J. S. Margolis, V. Carrere, C.J. Bruegge, M. Rast, G. Hoover, "In-flight validation and calibration of the spectral and radiometric characteristics of the airborne visible/infrared imaging spectrometer," In *Proc. SPIE 1298, Imaging Spectroscopy of the Terrestrial Environment*, 1990.
- [16] R. O. Green, J. E. Conel, D.A. Roberts, "Estimation of aerosol optical depth, pressure elevation, water vapor, and calculation of apparent surface reflectance from radiance measured by the airborne visible/infrared imaging spectrometer (AVIRIS) using a radiative transfer code," In *Proc. SPIE 1937, Imaging Spectrometry of the Terrestrial Environment*, 1993.
- [17] W. H. Farrand, R. B. Singer, E. Merényi, "Retrieval of apparent surface reflectance from AVIRIS data : A comparison of empirical line, radiative transfer, and spectral mixture methods," *Remote Sensing of Environment*, 47(3), pp.311–321, 1994.

- [18] M. E. Schaepman, "Imaging spectrometers". In Warner, T. A., Nellis, M. D., and Foody, G. M., editors, *The SAGE Handbook of Remote Sensing*, SAGE Publication, pp.166–178, 2009.
- [19] J. Mairal, F. Bach, J. Ponce, "Sparse modeling for image and vision processing," *Foundations and Trends. in Computer Graphics and Vision*, 8(2-3), pp. 85–283, 2014.
- [20] Y., Qian, M. Ye, J., Zhou. "Hyperspectral image classification based on structured sparse logistic regression and three-dimensional wavelet texture features," *IEEE Transactions on Geoscience and Remote Sensing*, 51(4), pp. 2276–2291, 2013.
- [21] S. Jia, L. Shen, Q. Li, "Gabor feature-based collaborative representation for hyperspectral imagery classification," *IEEE Transactions on Geoscience and Remote Sensing*, 53(2), pp. 1118–1129, 2015.
- [22] Y. Tang, Y. Lu, H. Yuan, "Hyperspectral image classification based on threedimensional scattering wavelet transform," *IEEE Transactions on Geoscience and Remote Sensing*, 53(5), pp. 2467–2480, 2015.
- [23] W. Li, C. Chen, H. Su, Q. Du, "Local binary patterns and extreme learning machine for hyperspectral imagery classification," *IEEE Transactions on Geoscience and Remote Sensing*, 53(7), pp. 3681–3693, 2015.
- [24] M. Fauvel, J. A. J. Benediktsson, J. Chanussot, J. R. Sveinsson, "Spectral and spatial classification of hyperspectral data using svms and morphological profiles," *IEEE Transactions on Geoscience and Remote Sensing*, 46, pp. 3804–3814, nov 2008.
- [25] F. Nina Paravecino, V. Manian, "Spherical harmonics as a shape descriptor for hyperspectral image classification," in *Proc. SPIE 7695, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVI*, pp. 76951E, 2010.
- [26] P. Khuwuthyakorn, A. Robles-Kelly, J. Zhou, "Affine invariant hyperspectral image descriptors based upon harmonic analysis," in *Machine Vision Beyond the Visible Spectrum* (R. Hammoud, G. Fan, R. McMillan, and K. Ikeuchi, eds.), Springer, 2011.

- [27] X. Jia, B. C. Kuo, M. Crawford, "Feature mining for hyperspectral image classification," *Proceedings of the IEEE*, 101(3), pp. 676–697, 2013.
- [28] M. Ye, Y. Qian, J. Zhou, "Multi-task sparse nonnegative matrix factorization for joint spectral-spatial hyperspectral imagery denoising," *IEEE Transactions on Geoscience and Remote Sensing*, 53(5), pp. 2621–2639, 2015.
- [29] S. Velasco Forero, J. Angulo, "Spatial structures detection in hyperspectral images using mathematical morphology," in *2nd Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, pp. 1–4, 2010.
- [30] H. Pu, Z. Chen, B. Wang, G. Jiang, "A novel spatial-spectral similarity measure for dimensionality reduction and classification of hyperspectral imagery," *IEEE Transactions on Geoscience and Remote Sensing*, 52(11), pp. 7008–7022, 2014.
- [31] Y. Tarabalka, M. Fauvel, J. Chanussot, J. A. Benediktsson, "SVM- and MRFbased method for accurate classification of hyperspectral images," *IEEE Geoscience and Remote Sensing Letters*, 7(4), pp. 736–740, 2010.
- [32] P. Zhong, R. Wang, "Learning conditional random fields for classification of hyperspectral images," *IEEE Transactions on Image Processing*, 19(7), pp. 1890–1907, 2010.
- [33] R. Ji, Y. Gao, R. Hong, Q. Liu, D. Tao, X. Li, "Spectral-spatial constraint hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, 52(3), pp. 1811–1824, 2014.
- [34] L. Fang, S. Li, X. Kang, J. Benediktsson, "Spectral-spatial hyperspectral image classification via multiscale adaptive sparse representation," *IEEE Transactions on Geoscience and Remote Sensing*, 52(12), pp. 7738–7749, 2014.
- [35] G. Camps-Valls, L. Gomez-Chova, J. Munoz-Mari, J. Vila-Frances, J. CalpeMaravilla, "Composite Kernels for Hyperspectral Image Classification," *IEEE Geoscience and Remote Sensing Letters*, 3, pp. 93–97, jan 2006.

- [36] J. Bioucas Dias, A. Plaza, G. Camps-Valls, P. Scheunders, N. Nasrabadi, J. Channussot, "Hyperspectral remote sensing data analysis and future challenges," *IEEE Geoscience and Remote Sensing Magazine*, 1(2), pp. 6–36, 2013.
- [37] J. Li, J. Bioucas-Dias, A. Plaza, "Spectral-spatial classification of hyperspectral data using loopy belief propagation and active learning," *IEEE Transactions on Geoscience and Remote Sensing*, 51(2), pp. 844–856, 2013.
- [38] W. Fu, S. Li, L. Fang, J. A. Benediktsson, "Adaptive SpectralSpatial Compression of Hyperspectral Image With Sparse Representation," *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), pp. 1–12, 2017
- [39] X.Wu, N. Memon, "Context-Based, Adaptive, Lossless Image Coding," *IEEE Transactions on Communications*,45(4), pp. 437–444, 1997.
- [40] M. J. Weinberger, G. Seroussi and G. Sapiro, "The LOCO-I Lossless Image Compression Algorithm : Principles and Standardization into JPEG-LS," *IEEE Transactions on Image Processing*, 9(8), pp. 1309–1324, 2000.
- [41] G. Lopez, E. Napoli, A.G.M. Strollo, "FPGA Implementation of the CCSDS-123.0-B1Lossless Hyperspectral Image Compression Algorithm Prediction Stage," 8th IEEE International Conference on Application of Information and Communication Technologies, 2014.
- [42] J. Mielikainen, P. Toivanen, "Lossless compression of hyperspectral images using a quantized index to lookup tables," *IEEE Geoscience and Remote Sensing Letter*, 5(3), pp. 474–478, 2008.
- [43] K. Rajan, V. Murugesan, Hyperspectral Image Compression Based on DWT and TD with ALS Method, *The International Arab Journal of Information Technology*, 13(4), pp. 435–442, 2016.
- [44] M. A. Mamun, X. Jia, M. Ryan, "Sequential Multispectral Images Compression for Efficient Lossless Data Transmission," 2nd IITA International Conference on Geoscience and Remote Sensing, 2010.

- [45] Q. Shi, X. Hou, X. Qian, "Hyperspectral Image Compression Based on DLWT and PCA, ACM 15th International Conference on Internet Multimedia Computing and Service. 2015.
- [46] N. Amrani, J. Serra-Sagristá , V. Laparra, M.W. Marcellin, J. Malo, "Regression Wavelet Analysis for Lossless Coding of Remote-Sensing Data," *IEEE Trans. Geoscience and Remote Sensing*, 54(9), pp. 5616–5627, September 2016.
- [47] H. L. Merav, H. Ofer, R. R. Stanley, H. S. Revital "Compression of Hyperspectral Images Containing a Sub-pixel Target," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), pp. 2246–2255, 2014.
- [48] M. Aharon, M. Elad, A. Bruckstein, "K-SVD : An algorithm for designing overcomplete dictionaries for sparse representation," *IEEE Transactions on signal processing*, 54(11), pp. 4311–4322, 2006.
- [49] M. Elad, "Sparse and redundant representations : from theory to applications in signal and image processing," Springer Science and Business Media, 2010.
- [50] I. Daubechies, "Orthonormal bases of compactly supported wavelets. *Communications on pure and applied mathematics*," 41(7), pp. 909–996, 1988.
- [51] M. N. Do, M. Vetterli, "The contourlet transform : an efficient directional multiresolution image representation," *IEEE Transactions on image processing*, 14(12), pp. 2091–2106, 2005.
- [52] S. Mallat, "A wavelet tour of signal processing : the sparse way", 2009.
- [53] K. Hannoun, H. Hamiche, M. Lahdir, M. Laghrouche, S. Kassim, "A DWT Domain Watermarking Scheme Based On a Discrete-Time Chaotic System", 5th IFAC Conference on Analysis and Control of Chaotic Systems, Eindhoven, Netherlands, 2018.
- [54] Z. Ameer, S. Ameer, A. Adane, H. Sauvageot, K. Bara, "Cloud classification using

- the textural features of Meteosat images," *International journal of remote sensing*, 25(21), 4491-4503, 2004.
- [55] D. Alouache, Z. Ameer, D. Kachi, "Catadioptric images compression using an adapted neighborhood and the shape-adaptive DCT," *Multimedia Tools and Applications*, 79(9), 6781-6797, 2020.
- [56] M. Cherifi, M. Lahdir, S. Ameer, "Meteosat image sequence coding in the Radon field," *Optik*, 182, 1228-1243, 2019.
- [57] S. S. Chen, D. L. Donoho, M.A. Saunders, "Atomic decomposition by basis pursuit," *SIAM review*, 43(1), pp. 129–159, 2001.
- [58] P.R. Gill, A. Wang, A. Molnar, "The in-crowd algorithm for fast basis pursuit denoising," *IEEE Transactions on Signal Processing*, 59(10), pp. 4595–4605, 2011.
- [59] A.T. Puig, A. Wiesel, G. Fleury, A.O. Hero, A. O. "Multidimensional shrinkage-thresholding operator and group LASSO penalties," *IEEE Signal Processing Letters*, 18(6), pp. 363–366, 2011.
- [60] I. Bayram, I.W.Selesnick,"A subband adaptive iterative shrinkage/thresholding algorithm," *IEEE Transactions on Signal Processing*, 58(3), pp. 1131–1143, 2009.
- [61] A. Beck, M. Teboulle, "A fast iterative shrinkage-thresholding algorithm for linear inverse problems," *SIAM journal on imaging sciences*, 2(1), pp. 183-202, 2009.
- [62] Y. Meyer, "Wavelets and applications," Paris [etc.] : Masson, Berlin [etc.] : 'Springer-Verlag', 1992.
- [63] Y. Qian, M. Ye, "Hyperspectral imagery restoration using nonlocal spectral-spatial structured sparse representation with noise estimation," *IEEE Journal of, Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2), pp. 499–515, 2013.
- [64] S. G. Mallat," *Multiresolution representations and wavelets*", 1988.

- [65] I. Daubechies, "The wavelet transform, time-frequency localization and signal analysis," *IEEE transactions on information theory*, 36(5), pp.961–1005, 1990.
- [66] A. Said, W.A. Pearlman, "A new, fast, and efficient image codec based on set partitioning in hierarchical trees". *IEEE Transactions on circuits and systems for video technology*, 6(3), pp. 243-250, 1996.
- [67] J. D. Villasenor, B. Belzer, J. Liao, "Wavelet filter evaluation for image compression," *IEEE Transactions on image processing*, 4(8), pp. 1053-1060, 1995.
- [68] H. Man, A. Docef, F. Kossentini, "Performance analysis of the JPEG 2000 image coding standard. *Multimedia Tools and Applications*," 26(1), pp. 27-57, 2005.
- [69] N. Leonardi, D. Van De Ville, "Wavelet frames on graphs defined by fMRI functional connectivity," In *Biomedical Imaging : From Nano to Macro*, 2011 IEEE International Symposium on, IEEE, pp. 2136–2139, 2011.
- [70] M. Unser, T. Blu, "Mathematical properties of the JPEG2000 wavelet filters," *IEEE Transactions on Image Processing*, 12(9), pp. 1080-1090, 2003.
- [71] J. A. Bondy, V. Chvatal, A method in graph theory. *Discrete Mathematics*, 15(2), pp. 111-135, 1976.
- [72] F.K. Chung, "Spectral Graph Theory," *CBMS Reg. Conf. Ser. Math.*, vol. 92, AMS Bookstore, 1997.
- [73] Hammond D K., Vandergheynst P., and Gribonval R., "Wavelets on graphs via spectral graph theory," *Applied and Computational Harmonic Analysis*, 30(2), pp.129–150, 2011.
- [74] M. T. Pham, G. Mercier, J. Michel, "Wavelets on graphs for very high resolution multispectral image texture segmentation," *Geoscience and Remote Sensing Symposium (IGARSS)*, IEEE International, pp. 2273–2276, 2014.
- [75] D. I. Shuman, M. J. Faraji, P. Vandergheynst, " A multiscale pyramid transform for graph signals," *IEEE Transactions on Signal Processing*, 64(8), pp.2119–2134, 2015.

- [76] M.T. Pham, G. Mercier., J. Michel, "Textural features from wavelets on graphs for very high resolution panchromatic Pléiades image classification," *Revue française de photogrammétrie et de télédétection*, 208, pp. 131–136, 2014.
- [77] P.J. Burt, E.H. Adelson, "The Laplacian pyramid as a compact image code," *IEEE Trans. Commun.*, 31 (4), pp. 532–540, 1983.
- [78] E.P. Simoncelli, W.T. Freeman, E.H. Adelson, D.J. Heeger, "Shiftable multi-scale transforms," *IEEE Trans. Inform. Theory*, 38 (2), pp.587–607, special issue on wavelets, 1992.
- [79] N. Kingsbury, "Complex wavelets for shift invariant analysis and filtering of signals," *Appl. Comput. Harmon. Anal.*, 10 (3), pp. 234–253, 2001.
- [80] E. Candes, D. Donoho, "New tight frames of curvelets and optimal representations of objects with piecewise C² singularities," *Comm. Pure Appl. Math.*, 57, pp. 219–266, 2003.
- [81] N., Zikiou, M., Lahdir, S., Ameer, "Application des Curvelets et Régression SVM pour la Compression d'Images". *IT4OD proceeding*, pp. 188-194, 2014.
- [82] G. Peyre, S. Mallat, "Orthogonal bandlet bases for geometric images approximation," *Comm. Pure Appl. Math.*, 61 (9), pp. 1173–1212, 2008.
- [83] J. Antoine, P. Vandergheynst, "Wavelets on the 2-sphere : A group-theoretical approach," *Appl. Comput. Harmon. Anal.*, 7 (3), pp. 262–291, 1999.
- [84] Y. Wiaux, J.D. McEwen, P. Vandergheynst, O. Blanc, "Exact reconstruction with directional wavelets on the sphere," *Mon. Not. R. Astron. Soc.* , 388, pp. 770, 2008.
- [85] J.P. Antoine, I. Bogdanova, P. Vandergheynst, "The continuous wavelet transform on conic sections," *Int. J. Wavelets Multiresolut. Inf. Process.*, 6 (2), pp. 137–156, 2008.

- [86] I. Prathap, R. Anitha, "Watermark Detection in Spatial and Transform Domains Based on Tree Structured Wavelet Transform," International Symposium on Security in Computing and Communication , Springer, Berlin, Heidelberg, pp. 230-238, September 2014.
- [87] B. Andries, J. Lemeire, A. Munteanu, "Scalable texture compression using the wavelet transform," The Visual Computer, vol. 33, no. 9, pp. 1121-1139, 2017.
- [88] P. Joshi, S. Prakash, S. Rawat, "Continuous wavelet transform-based no-reference quality assessment of deblocked images," The Visual Computer, 34(12), pp. 1739-1748, 2018.
- [89] L. He, Y. Wang, Z. Xiang, "Wavelet frame-based image restoration using sparsity, nonlocal, and support prior of frame coefficients," The Visual Computer, 35(2), pp. 151–174, 2019.
- [90] D. Venugopal, S. Mohan, S. Raja, "An efficient block based lossless compression of medical images" Optik-International Journal for Light and Electron Optics, 127(2), pp. 754–758, 2016.
- [91] Khiari Hili, N., Lelandais, S., Montagne, C., Roumes, C., Hamrouni, K., Plantier, J., " Bio-inspired image enhancement derived from a rank order coding model," IET Image Processing, 10(5), pp. 409–417, 2016.
- [92] P. Govindan, J. Saniie, "Processing algorithms for three-dimensional data compression of ultrasonic radio frequency signals," IET Signal Processing, 9(3), pp. 267–276, 2015.
- [93] M. S. Lee, S. K. Ueng, J. J. Lin, "Wavelets-based smoothness comparisons for volume data," IET Image Processing, 9(12), pp. 1057–1063, 2015.
- [94] K. J. Cheng, J. C. Dill, "An improved EZW hyperspectral image compression," Journal of Computer and Communications, 2(02), pp. 31–36, 2014.

- [95] D. S. Sujithra, T. Manickam, D. S. Sudheer, "Compression of hyperspectral image using discrete wavelet transform and Walsh Hadamard transform," *International Journal of Advanced Research in Electronics and Communication Engineering (IJA-RECE)*, 2, pp. 314–319, 2013.
- [96] F. Aul í-Llin as, M. W. Marcellin, J. Serra-Sagrsta, J.Bartrina-Rapesta, "Lossy-to-lossless 3D image coding through prior coefficient lookup tables", *Information Sciences*, 239, pp. 266–282, 2013.
- [97] J. Delcourt, A. Mansouri, T. Sliwa, Y. Voisin, "An Evaluation Framework and a Benchmark for Multi/Hyperspectral Image Compression," *Intelligent Computer Vision and Image Processing : Innovation, Application, and Design*, pp. 56–66, 2013.
- [98] G. Hegde, P. Vaya, "Systolic array based motion estimation architecture of 3D DWT sub band component for video processing," *International Journal of Signal and Imaging Systems Engineering*, 5(3), pp. 158–166, 2012.
- [99] M. Lahdir, A. Nait-ali, S. Ameer, "Fast Encoding-Decoding of 3D Hyperspectral Images Using a Non-Supervised Multimodal Compression Scheme," *Journal of Signal and Information Processing*, 2(4), pp. 316–321, 2011.
- [100] R. Jiao, Y. Li, Q. Wang, B. Li, "SVM regression and its application to image compression," *Springer Berlin Heidelberg. Advances in Intelligent Computing*, pp. 747–756, 2005.
- [101] Y. Li, H. Hu, "Image compression using wavelet support vector machines," *International Conference on Intelligent Computing*. Springer, Berlin, Heidelberg, pp. 922–929, August 2007.
- [102] .S. Fazli, S. Toofan, Z. Mehrara, " JPEG2000 Image Compression Using SVM and DWT," *International Journal of Science and Engineering Investigations*, 1, pp. 53–57, 2012.
- [103] L. Zhang, L. Zhang, D. Tao, X. Huang, B. Du, "Compression of hyperspectral remote sensing images by tensor approach," *Neurocomputing*, 147, pp. 358–363, 2015.

- [104] L. Fang, N. He, H. Lin, "CP tensor-based compression of hyperspectral images," *Journal of the Optical Society of America A*, 34(2), pp. 252–258, 2017.
- [105] B. Huang, Y. Nian, J. Wan, "Distributed lossless compression algorithm for hyperspectral images based on classification," *Spectroscopy Letters*, 48, pp. 528–535, 2015.
- [106] S. G. Mallat, "A theory for multiresolution signal decomposition : the wavelet representation," *IEEE Trans. Pattern Analysis and Machine Intelligence*, 11(7), pp. 674–693, 1989.
- [107] J. M. Shapiro, "Embedded image coding using zerotrees of wavelet coefficients," *IEEE Trans. Signal Processing.*, 41(12), pp. 3445–3462, 1993.
- [108] A. Said, W. A. Pearlman, "A new, fast, and efficient image codec based on set partitioning in hierarchical trees," *IEEE Trans. Circuits and Systems for Video Technology*, 6(3), pp. 243–250, 1996.
- [109] A. Islam, W. A. Pearlman, "Embedded and efficient low-complexity hierarchical image coder," *International Society for Optics and Photonics. Electronic Imaging'99*, pp. 294-305, 1998.
- [110] W. A. Pearlman, A. Islam, N. Nagaraj, A. Said, " Low-complexity image coding with a set-partitioning embedded block coder," *IEEE Trans. Circuits and Systems for Video Technology*, 14(11), pp. 1219–1235, 2004.
- [111] D. Taubman, "High performance scalable image compression with EBCOT," *IEEE trans. Image Processing*, 9(7), pp.1158–1170, 2000.
- [112] S.G. Mallat, "Multifrequency channel decompositions of images and wavelet models," *IEEE Trans. Acoustics, Speech and Signal Processing*, 37(12), pp. 2091–2110,1989.

- [113] B. J. Kim, W.A. Pearlman, "An embedded wavelet video coder using three-dimensional set partitioning in hierarchical trees (SPIHT)," Proc. Int. Conf. Data Compression Conference, DCC'97, IEEE, pp. 251–260, 1997.
- [114] B. E. Reddy, K. V. Narayana, "A lossless image compression using traditional and lifting based wavelets," Signal and Image Processing, 3(2), pp. 213–222, 2012.
- [115] M. S. Abdullah, N.Subba Rao, " Image Compression using Classical and Lifting based Wavelets," International Journal of Advanced Research in Computer and Communication Engineering, 2(8), pp. 3193–3198, 2013.
- [116] Q. Wu, "A hybrid-forecasting model based on Gaussian support vector machine and chaotic particle swarm optimization," Expert Systems with Applications, 37(3), pp. 2388–2394, 2010.
- [117] V. Vapnik, "The nature of statistical learning theory," in Springer Science Business Media, 2013.
- [118] J. Mercer, " Functions of positive and negative type, and their connection with the theory of integral equations," Philosophical transactions of the royal society of London, Series A, containing papers of a mathematical or physical character, 209, pp. 415–446, 1909.
- [119] P. G.Howard, J. S.Vitter, "Arithmetic Coding for Data Compression," Proc IEEE., vol. 82, 6, pp. 857–865, 1994.
- [120] Z. Wang, A. C. Bovik, H. R. Sheikh, E. P. Simoncelli, "Image quality assessment : from error visibility to structural similarity," IEEE Trans. Image Process., 13(4), pp. 600–612, 2004.
- [121] Z. Wang, D. Zhang, and Y. Yu, "Video Quality Assessment based on Structural Distortion Measurement," Signal Processing : Image Communication, 19(2), pp. 121–132, Feb. 2004.

- [122] A. Villa, J.A. Benediktsson, J. Chanussot, C. Jutten, "Hyperspectral image classification with independent component discriminant analysis," *IEEE Trans. Geosci. Remote Sens.*, 49, pp. 4865–4876, 2011.
- [123] L. Ran, Y. Zhang, W. Wei, Q. Zhang, "A hyperspectral image classification framework with spatial pixel pair features," *Sensors*, 17(10), pp. 2421, 2017.
- [124] W. Fu, S. Li, L. Fang, J. A. Benediktsson, "Adaptive Spectral-Spatial Compression of Hyperspectral Image With Sparse Representation," *IEEE Transactions on Geoscience and Remote Sensing.*, pp. 1–12, 2016.
- [125] A. Karami, S. Beheshti, M. Yazdi, "Hyperspectral image compression using 3D discrete cosine transform and support vector machine learning," *IEEE, Information Science Signal Processing and their Applications (ISSPA)*, pp. 809–812, 2012.
- [126] X. Tang, W. A. Pearlman, "Three-dimensional wavelet-based compression of hyperspectral images," in *Hyperspectral Data Compression*, New York, NY, USA : Springer-Verlag, ch. 10, pp. 273–278, 2006.
- [127] Q. Du, J. E. Fowler, "Hyperspectral image compression using JPEG2000 and principal component analysis," *IEEE Geosci. and Remote Sens. Lett.*, 4, pp. 201–205, Apr. 2007.
- [128] Q. Du, N. Ly, J. E. Fowler, "An operational approach to PCA+JPEG2000 compression of hyperspectral imagery," *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sensing.*, 7(6), pp. 2237–2245, Jun. 2014.
- [129] F. Garcia Vilchez, Muñoz-Marí, J., Zorteza, M., Blanes, I., González-Ruiz, V., Camps Valls, G., ... Serra-Sagristá, J., "On the impact of lossy compression on hyperspectral image classification and unmixing," *IEEE Geosci. Remote Sensing. Lett.*, 8(2), pp. 253–257, Mar. 2011.
- [130] S. Boussakta, H. O. Alshibami, "Fast Algorithm for the 3-D DCT-II," *IEEE TRANS. ON Signal Processing*, 52, pp.992-1001, Apr. 2004.

- [131] A. Karami, M. Yazdi, G. Mercier, "Compression of hyperspectral images using discrete wavelet transform and tucker decomposition," *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sensing.*, 5(2), pp. 444–450, Apr. 2012.
- [132] N. Zikiou, M. Lahdir, S. Ameer, "Color image compression based on wavelet transform and support vector regression," *Image Processing, Applications and Systems Conference (IPAS), 2014 First International IEEE*, pp. 1–6, Nov. 2014.
- [133] W. Hu, Y. Huang, W. Li, F. Zhang, H. Li, "Deep convolutional neural networks for hyperspectral image classification," *J. Sensors*, vol. 2015, Jan. 2015, Art. no. 258619, 2015.
- [134] L. Mou, P. Ghamisi, X.X. Zhu, "Deep recurrent neural networks for hyperspectral image classification," *IEEE Trans. Geosci. Remote Sens.*, 55(7), pp. 3639–3655, 2017.
- [135] W. Li, G. Wu, F. Zhang, Q. Du, "Hyperspectral image classification using deep pixel-pair features," *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), pp. 844–853, 2017.
- [136] Z. Li, J. Zhong, Z. Luo, M. Chapman, "Spectral-Spatial Residual Network for Hyperspectral Image Classification : A 3-D Deep Learning Framework," *IEEE Transactions on Geoscience and Remote Sensing*, 56(2), pp. 847–858, 2018.
- [137] M. Zhang, W. Li, Q. Du, "Diverse Region-Based CNN for Hyperspectral Image Classification," *IEEE Transactions on Image Processing*, 27(6), pp. 2623–2634, 2018.
- [138] H. Lee, H. Kwon, "Going deeper with contextual CNN for hyperspectral image classification," *IEEE Trans, Image Process.*, 26(10), pp.4843–4855, Oct. 2017.
- [139] L. He, Y. Li, X. Li, W. Wu, "Spectral-spatial classification of hyperspectral images via spatial translation-invariant wavelet-based sparse representation," *IEEE Transactions on Geoscience and Remote Sensing*, 53(5), pp. 2696–2712, 2015.
- [140] Y. Chen, N. M. Nasrabadi, T.D. Tran, "Hyperspectral image classification via

- kernel sparse representation," *IEEE Transactions on Geoscience and Remote sensing*, 51(1), pp. 217–231, 2013.
- [141] C. Persello, L. Bruzzone, "Kernel-based domain-invariant feature selection in hyperspectral images for transfer learning," *IEEE transactions on geoscience and remote sensing*, 54(5), pp. 2615–2626, 2016.
- [142] B. Guo, S.R. Gunn, R.I. Damper, J.D.B Nelson, "Customizing kernel functions for SVM-based hyperspectral image classification," *IEEE Trans. Image Process*, 17(4), pp.622–629, 2008.
- [143] L. Bruzzone, C. Persello, "Approaches based on support vector machine to classification of remote sensing data," In *Handbook of Pattern Recognition and Computer Vision* C. Chen, Ed. Singapore : World Scientific, 3(2), pp.329–352, 2009.
- [144] F. Bovolo, L. Bruzzone, L. Carlin, "A novel technique for subpixel image classification based on support vector machine," *IEEE Transactions on Image Processing*, 19(11), pp. 2983–2999, 2010.
- [145] L. Yang, S. Yang, P. Jin, R. Zhang, "Semi-supervised hyperspectral image classification using spatio-spectral Laplacian support vector machine," *IEEE Geoscience and Remote Sensing Letters*, 11(3), pp. 651–655, 2014.
- [146] Y. Tarabalka, J.A. Benediktsson, J. Chanussot, J.C. Tilton, "Multiple spectral-spatial classification approach for hyperspectral data," *IEEE Transactions on Geoscience and Remote Sensing*, 48(11), pp. 4122–4132, 2010.
- [147] L. Liu, P. Fieguth, D. Clausi, G. Kuang, "Sorted random projections for robust rotation-invariant texture classification," *Pattern Recognition*, 45(6), pp.2405–2418, 2012.
- [148] S. Zhou, J. Shi, J. Zhu, Y. Cai, R. Wang, "Shearlet-based texture feature extraction for classification of breast tumor in ultrasound image," *Biomedical Signal Processing and Control*, 8(6), pp. 688–696, 2013.

- [149] Y. Chen, Z. Lin, X. Zhao, G. Wang, Y. Gu, "Deep learning-based classification of hyperspectral data," *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, 7(6), pp.2094–2107, 2014.
- [150] X. Ma, J. Geng, H. Wang, "Hyperspectral image classification via contextual deep learning," *EURASIP J. Image Video Process*, 20(1), pp.1–12, 2015.
- [151] Q. Zou, L. Ni, T. Zhang, Q. Wang, "Deep learning based feature selection for remote sensing scene classification," *IEEE Geosci. Remote Sens. Lett.*, 12(11), pp.2321–2325, 2015.
- [152] L. Zhang, L. Zhang, B. Du, "Deep learning for remote sensing data : A technical tutorial on the state of the art," *IEEE Geosci. Remote Sens. Mag.*, 4(2), pp. 22–40, 2016.
- [153] Y. Li, W. Xie, H. Li, "Hyperspectral image reconstruction by deep convolutional neural network for classification," *Pattern Recognit.*, 63, pp. 371–383, 2017.
- [154] M. Masoumi, A. B. Hamza, "Shape classification using spectral graph wavelets," *Applied Intelligence*, 47(4), pp.1256–1269, 2017.
- [155] M. Malek, D. Helbert, P. Carre, "Color graph based wavelet transform with perceptual information," *Journal of Electronic Imaging*, 24(5), pp. 053004, 2015.
- [156] N. Pham, D. Helbert, P. Bourdon, P. Carre, "Spectral Graph Wavelet based Non-rigid Image Registration," In 2018 25th IEEE International Conference on Image Processing (ICIP), IEEE, pp. 3348–3352, 2018.
- [157] N. Keshava, "Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries," *IEEE Transactions in Geosciences and Remote Sensing*, 42, pp. 1552–1565, 2004.
- [158] S.A. Robila, "Using spectral distances for speedup in hyperspectral image processing," *International Journal of Remote Sensing*, 26(24), pp. 5629–5650, 2005.

- [159] T. Achalakul, S. Taylor, "Real-time multi-spectral image fusion," *Concurrency and Computing : Practice and Experience*, 13, pp. 1063–1081, 2001.
- [160] J. Qin T. F. Burks, M.A. Ritenour, W.G. Bonn, "Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence," *Journal of food engineering*, 93(2), pp. 183–191, 2009.
- [161] G. Franchi, J. Angulo, "Quantization of hyperspectral image manifold using probabilistic distances," In *International Conference on Networked Geometric Science of Information*, Springer, Cham, pp. 406–414, 2015.
- [162] A. Nakhmani, A. Tannenbaum, "A new distance measure based on generalized image normalized cross-correlation for robust video tracking and image recognition," *Pattern recognition letters*, 34(3), pp. 315–321, 2013.
- [163] J. Ham, Y. Chen, M. M. Crawford, J. Ghosh, "Investigation of the random forest framework for classification of hyperspectral data," *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), pp. 492–501, 2005.
- [164] Y. Tarabalka, J. A. Benediktsson, J. Chanussot, "Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques," *IEEE Transactions on Geoscience and Remote Sensing*, 47(8), pp. 2973–2987, 2009.
- [165] S. Mei, J. Ji, J. Hou, X. Li, Q. Du, "Learning sensor-specific spatial-spectral features of hyperspectral images via convolutional neural networks," *IEEE Trans. Geosci. Remote Sens.*, 55(8), pp. 4520–4533, 2017.
- [166] K. Makantasis, K. Karantzalos, A. Doulamis, N. Doulamis, "Deep supervised learning for hyperspectral data classification through convolutional neural networks," *Proc. IGARSS, Milan, Italy*, pp. 4959–4962, 2015.
- [167] Q. Zhang, J. Sun, G. Zhong, J. Dong, "Random multi-graphs : a semi-supervised learning framework for classification of high dimensional data," *Image Vis. Comput.*, 60, pp.30–37, 2017.

- [168] F. Gao, Q. Wang, J. Dong, Q. Xu, "Spectral and Spatial Classification of Hyperspectral Images Based on Random Multi-Graphs," *Remote Sensing*, 10(8), pp. 1271, 2018.
- [169] M. Lahdir, H. Hamiche, S. Kassim, M. Tahanout, K. Kemih, S.A. Addouche, "A novel robust compression-encryption of images based on SPIHT coding and fractional-order discrete-time chaotic system," *Optics and Laser Technology*, 109, pp. 534–546, 2019.
- [170] H. Hamiche, M.Lahdir, M. Tahanout, S. Djennoune, "Masking digital image using a novel technique based on a transmission chaotic system and SPIHT coding algorithm," *International Journal of Advanced Computer Science and Applications*, 3(12), pp. 228–234, December 2012.
- [171] H. Hamiche, O. Megherbi, R. Kara, R. Saddaoui, M. Laghrouche, S. Djennoune, "A new implementation of an impulsive synchronization of two discrete-time hyperchaotic systems using Arduino-Uno boards," *International Journal of Modeling, Identification and Control*, 28(2), pp.177–186, 2017.
- [172] F. Zouad, K. Kemih, Hamid Hamiche, "A new secure communication scheme using fractional order delayed chaotic system : Design and electronics circuit simulation," *Analog Integrated Circuits and Signal Processing*, 99(3), pp. 619–632, 2019.
- [173] O. Meguerbi, S. Guermah, H. Hamiche, S. Djennoune, M. Ghanes, "A Novel transmission scheme based on impulsive synchronization of two Colpitts chaotic systems," *3rd International Conference on Systems and Control, ICSC'13*, October 29-31, Algiers, Algeria, 2013.

Résumé

L'imagerie hyperspectrale enregistre des centaines de bandes spectrales étroites et contiguës reçues dans chaque position spatiale de l'image. Comme chaque matériau manifeste une signature spectrale différente, l'imagerie hyperspectrale permet la classification précise des images, ce qui est une tâche importante dans beaucoup de domaines. Cependant, la grande dimension de ces images complique l'analyse des données. Dans ce travail, nous proposons et développons des nouvelles méthodes pour la compression et la classification des données hyperspectrales. Une représentation parcimonieuse de la texture hyperspectrale basée sur la transformée en ondelettes discrète 3D et une méthode de régression est utilisée pour la compression des images hyperspectrales. Les ondelettes et la régression SVM sont deux outils efficaces pour la compression des données de grande dimension et pour l'analyse contextuelle d'images. En effet, les résultats de compression obtenus sont d'un apport considérable. D'un autre côté la méthode aboutie à de bonnes performances de classification des images hyperspectrales compressées. Cependant, une meilleure sélection des pixels représentatifs peut améliorer davantage les résultats de classification des images hyperspectrales. La transformée en ondelettes spectrales sur graphes (SGWT) permet d'extraire les caractéristiques de texture d'un graphe pondéré d'une image hyperspectrale. Nous avons proposé une méthode de classification basée sur cette transformée pour extraire les pixels représentatifs de l'image. En outre, une classification SVM est appliquée aux coefficients SGWT obtenus. Les résultats ont montré l'efficacité de la méthode en termes de robustesse et de précision.

Mot clés : Télédétection, Images hyperspectrales, Compression, Classification de textures hyperspectrales, Représentation parcimonieuse, Traitement de signal sur graphes.

Abstract

Hyperspectral imagery records hundreds of narrow and contiguous spectral bands received in each spatial position of the image. As each material exhibits a different spectral signature, hyperspectral imaging allows for the precise classification of images, which is an important task in many areas. However, the large size of these images complicates data analysis. In this work, we propose and develop new methods for the compression and classification of hyperspectral data. A sparse representation of the hyperspectral texture based on the 3D discrete wavelet transform and a regression method is used for the compression of the hyperspectral images. Wavelets and SVM regression are two effective tools for compressing large data and for contextual image analysis. Indeed, the obtained compression results are of significant contribution. On the other hand, the method results in good classification performance for compressed hyperspectral images. However, better selection of representative pixels can further improve the classification results of hyperspectral images. The spectral graph wavelets transform (SGWT) extract the texture characteristics of a weighted graph from an hyperspectral image. We have proposed a classification method based on this transform to extract representative pixels from the image. In addition, an SVM classification is applied to the obtained SGWT coefficients. The results showed the effectiveness of the method in terms of robustness and precision.

Key-words: Remote sensing, Hyperspectral images, Compression, Hyperspectral texture classification, Sparse representation, Graph signal processing.