

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

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



MEMOIRE DE MAGISTER EN ELECTRONIQUE

OPTION : Télédétection

Présenté par :
Melle ZIKIOU Nadia

THEME :

**Application d'un apprentissage SVM pour le codage d'images
hyperspectrales**

Devant les membres du jury :

<u>Président</u> :	Mr AMEUR Soltane	Professeur, UMMTO
<u>Rapporteur</u> :	Mr LAHDIR Mourad	Maître de Conférences A, UMMTO
<u>Examineurs</u> :	Mr HADDAB Salah	Maître de Conférences A, UMMTO
	Mme AMEUR Zohra	Professeur, UMMTO
	Mme AMIROU Zahia	Maître de Conférences B, UMMTO

Remerciements

Avant tout je tiens à remercier celui qui nous a créé, protégé, aidé et nous a donné la patience et le courage pour pouvoir accomplir entre autre notre mémoire de fin d'étude dans les meilleures conditions en disant « Dieu Merci ».

Ce mémoire n'aurait jamais été entrepris ni achevé sans la patiente assistance, les savants conseils et orientations, les méticuleux contrôles et suivis, que m'a prodigué mon promoteur, Mr. LAHDIR Mourad qui a accepté de m'encadrer. Je lui témoigne ici, de ma gratitude et reconnaissance.

Je tiens également à remercier :

Pr. AMEUR Soltane pour l'honneur qu'il nous fait de présider le jury et d'évaluer ce travail.

Pr. AMEUR Zohra, Mr. HADDAB Salah et Mme AMIROU Zahia pour avoir accepté d'examiner ce travail.

Je remercie particulièrement, Nos enseignants de première année : Mr AMEUR, Mr ADDANE, Mme AMEUR, Mr HADDAB, Mr LEGHROUCHE, Mr LAHDIR et Mr AIDANE pour leur contribution et le temps qu'ils ont bien voulu consacrer pour nous instruire. Qu'ils veuillent apercevoir ici mes termes les plus sincères de remerciements.

Une pensée émue pour mes amis de ma promotion : BERBACHE Kamel, BOUCHERK Kahina, ZERROUKI Fodil et ATMIMOU Omar avec qui les échanges furent toujours chaleureux et constructifs.

Je remercie tous les membres du labo LAMPA pour leur soutien, conseils et encouragements. Qu'ils trouvent ici l'expression de ma profonde affection.

Je remercie aussi, tous mes enseignants et tous ceux et toutes celles qui m'ont aidé ou encouragé, à quelque titre ou degré que ce soit, à entreprendre et achever ce mémoire, qui est ma modeste contribution au domaine de la Recherche Scientifique.

DEDICACES

A ma très chère mère qui s'est tant sacrifiée pour les besoins de nos études,

A mon très cher père pour tous les efforts consentis afin de nous armer du savoir,

A mon frère Abdellah et mes sœurs : Samia, Souad, Yasmine et Roumayssa pour leur affectueux soutien moral,

A toute ma famille,

A tous mes enseignants,

A tous mes amis du groupe PSEP2, mes enseignants et mes collègues de l'INFP de Birkhadem,

A tous mes stagiaires et collègues de l'INSFP de Oued Aissi,

A tous mes stagiaires de l'ENIEM,

A tous ceux à qui je tiens.

ZIKIOU N.

Sommaire

Introduction	1
---------------------------	----------

Chapitre I Compression des Images Hyperspectrales

I.1. Préambule	4
I.2. L'imagerie hyperspectrale.....	4
I.2.1).Application à la télédétection	4
I.2.2). Principe de l'imagerie hyperspectrale.....	4
I.2.3). Représentation des données hyperspectrales	6
I.2.3).1. Espace spatial	7
I.2.3).2. Espace spectral	7
I.2.4). Les caractéristiques des images hyperspectrales	8
I.2.4).1. Résolution spatiale	8
I.2.4).2. Résolution spectrale	9
I.2.4).3. Résolution radiométrique	9
I.2.5).Les capteurs d'imagerie en télédétection.....	10
I.2.5).1. Les capteurs aéroportés	11
I.2.5).2 Les capteurs spatioportés	13
I.2.6).Applications des images hyperspectrales.....	13
I.3. Compression des images hyperspectrales	14

I.3.1).Notions de base	14
I.3.1).1. Compression par quantification vectorielle	15
I.3.1).2. Compression par transformée	15
I.3.1).2.a Transformée.....	16
I.3.1).2.b Quantification.....	18
I.3.1).2.c Codage des coefficients.....	20
I.3.2).Etat de l’art.....	22
I.4. Discussion.....	26

Chapitre II

Les ondelettes et les SVM

II.1. Préambule	27
II.2. Les ondelettes.....	27
II.2.1).L’analyse en ondelette.....	27
II.2.1).a. Transformée en ondelette continue	28
II.2.1).b. Transformée en ondelette discrète	28
II.2.1).c. Analyse multi-résolution.....	29
II.2.2).Transformée en ondelette à deux dimensions	30
II.2.3).Transformée en ondelette à trois dimensions	31
II.2.4).Les différents types des ondelettes	33
II.2.5). Les familles d’ondelettes.....	33

II.2.6).Avantages de la transformée en ondelette et intérêt en traitement d'image	34
II.2.7).Dépendance entre coefficients d'ondelettes	35
II.3. Apprentissage et SVM.....	36
II.3.1). Notion d'apprentissage	36
II.3.2).Machines à vecteurs support	37
II.3.3).Régression par les machines à vecteurs supports	38
II.4. Etat de l'art	43
II.5. Discussion.....	44

Chapitre III

Méthode adoptée basée sur les ondelettes et SVR

III.1. Problématique.....	45
III.2. Algorithme de compression d'images proposé	46
III.2.1) Principe	46
III.2.2)Reconstruction.....	52
III.3. Adaptation de l'algorithme de compression aux images hyperspectrales	53
III.3.1)Problèmes liés aux données hyperspectrales.....	53
III.3.2)Principe de l'algorithme de compression des IHS	55
III.4. Présentation formelle de l'algorithme proposé.....	58
III.5. Discussion	60

Chapitre IV

Résultats et discussions

IV.1. Préambule	61
IV.2. Description des données.....	61
IV.2.1). Images tests	62
IV.2.2). Images AVIRIS.....	63
IV.3. Cadre d'évaluation de la compression et mesure de performances	63
IV.3.1). Taux de compression	64
IV.3.2). Débit.....	64
IV.3.2).a. Mesures objectives.....	65
IV.3.2).b. Mesures subjectives.....	66
IV.4. Tests et validation.....	67
IV.5. Résultats numériques	76
IV.5.1). Influence du nombre de décomposition.....	80
IV.5.2). Influence du contenu de l'image.....	80
IV.5.3). Influence de la taille de l'image.....	82
IV.5.4). Influence de la taille des blocs de décomposition.....	82
IV.6. Comparaison des résultats	83
IV.7. Discussion et problèmes ouverts	84
 Conclusion	 86
 Annexe	
 Bibliographie	

Table des figures

Figure. I.1 De la vision numérique monochrome à l'imagerie hyperspectrale	5
Figure. I.2 Illustration du cube hyperspectral	6
Figure. I.3 Représentation spatiale : collection d'images quasi monochromatiques	7
Figure. I.4 Représentation spectrale : collection de spectres	7
Figure. I.5 Schéma de compression-décompression par transformée. Les pertes sont dues à l'étape de quantification	15
Figure. I.6 Illustration des quantificateurs scalaire uniforme (a) et scalaires uniforme à zone morte (b).....	20
Figure. I.7 Modèle prédictif DPCM.....	20
Figure. I.8 Structure de l'arbre d'orientation asymétrique 3D	23
Figure. I.9 diagramme de codage des images hyperspectrales en utilisant l'algorithme 3D EZBC basé sur la KLT et la TO2D	24
Figure. I.10 Schéma fonctionnel de la compression des images Hyperspectrales basée sur ICA et DWT	25
Figure. II.1 (a) Histogramme des intensités des pixels d'une image - (b) Histogramme des coefficients d'ondelettes d'une sous-image (autre que la sous-image basse-fréquence)	30
Figure. II.2 Illustration des dépendances inter-échelles.....	31
Figure. II.3 Transformée en ondelettes 3D dyadique sur 3 niveaux : illustration de l'aspect volumique des sous-bandes	32
Figure. II.4 Quelques familles d'ondelettes	34
Figure. II.5 Image PELICAN (a) et la transformée en ondelette de cette image (b)	36
Figure. II.6 Exemple de classification binaire linéaire et non-linéaire dans R^2	37
Figure. II.7 Illustration de la fonction perte	39
Figure. II.8 Représentation de la marge souple	40
Figure. II.9 Représentation idéale de la fonction de décision.....	41

Figure. III.1. Schéma de l'algorithme de compression proposé	46
Figure.III.2. L'image 'Lena' après 5 niveaux de décomposition par les ondelettes biorthogonales	47
Figure. III.3. Les résultats de simulation de la régression SVM avec différents noyaux sur un bloc de 8*8 de l'image Lena	52
Figure. III.4. Schéma de l'algorithme de reconstruction	53
Figure. III.5 Schéma de l'algorithme de compression proposé appliqué aux images hyperspectrales.....	55
Figure. III.6 Représentation graphique de la décomposition en ondelette 3D hybride rectangulaire/carré avec trois niveaux de décomposition.....	56
Figure. III.7 Le processus de balayage	57
Figure. IV.1 Description des images hyperspectrales utilisées.....	63
Figure. IV.2 Comparaison des performances des noyaux SVR: Gaussien, Polynomial et Linéaire appliqués sur l'image 'Lena 512x512'	68
Figure. IV.3 Comparaison des images Lena reconstruites.....	69
Figure. IV.3 Image originale 'Lena'	69
Figure. IV.4 Comparaison des images Lena reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial	69
Figure. IV.5 Image originale 'Femme'	71
Figure. IV.6 Comparaison des images 'Femme' reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial	71
Figure. IV.7 Image originale 'Bateau'	72
Figure. IV.8 Comparaison des images 'Bateau' reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial	72
Figure. IV.9 Image originale 'Tigre'	73
Figure. IV.10 Comparaison des images 'Tigre' reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial	73

Figure. IV.11 Image originale ‘Aerien’	74
Figure. IV.12 Comparaison des images ‘Aerien’ reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial	74
Figure. IV.13 Image originale ‘City’	75
Figure. IV.14 Comparaison des images ‘City’ reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial	75
Figure. IV.15 Influence du paramètre ‘C’ sur le Rapport de Compression	76
Figure. IV.16 Les résultats des Rapport de Compression (RC) et PSNR moyens.....	77
Figure. IV.17 Image originale et images compressées pour le canal numéro 31 du cube 3D	78
Figure. IV.18 Image compressée (RC= 48.7 et PSNR= 38.22 dB)	79
Figure IV.19 Les séquences utilisées	81

Liste des tableaux

Tableau. I.1	Caractéristiques du capteur AVIRIS	12
Tableau. I.2	Caractéristiques des données AVIRIS	12
Tableau. IV.1	Les caractéristiques des images tests	62
Tableau. IV.2	Résultats des rapports de compression (CR) et PSNR des différents types de noyaux appliqués sur l'image 'Lena'	67
Tableau. IV.3	Résultats des rapports de compression (CR) et PSNR des différents types de noyaux appliqués sur plusieurs images tests	70
Tableau. IV.4	Résultats des Rapports de Compression (RC) et PSNR issus de l'application de notre algorithme sur les images AVIRIS	77
Tableau. IV.5	Résultats des Rapport de Compression (RC) et PSNR avec différents niveaux de compression	80
Tableau IV.6	Résultats des Rapport de Compression (RC) et PSNR moyens pour deux séquences issues des images AVIRIS	81
Tableau. IV.7	Résultats des Rapport de Compression (RC) et PSNR pour différentes tailles de l'image	82
Tableau. IV.8	Résultats des RC et PSNR pour différents blocs de décomposition	82
Tableau. IV.9	Comparaison des performances de compression pour différents débits.....	83

Introduction

Le domaine du traitement du signal et de l'image connaît une progression importante liée à l'évolution des technologies de l'information et de la communication. Dans de nombreux domaines, il est fait appel aux techniques d'analyse d'images (échographie, reconnaissance de caractères, reconnaissance des visages, compression, etc.).

La compression d'image est un domaine de recherche qui constituait depuis longtemps une préoccupation des chercheurs et les techniques développées, dans ce sens, ne cessent de se poursuivre. Trouvant ses racines théoriques dans la théorie de l'information initiée par Shannon en 1948 [1], elle a depuis fait appel à de nombreux outils mathématiques, de plus en plus sophistiqués. La problématique est cependant toujours d'actualité, sous-jacente des applications de stockage des données, ou de transmission à travers des canaux à bande passante limitée. Malgré les développements technologiques considérables en ces dernières années, l'être humain, insatiable, déclare indispensable ce qu'hier il considérait superflu, et nous sommes sans cesse confrontés à de nouveaux besoins exigeant l'accès à toujours plus d'information.

L'imagerie hyperspectrale (IHS) consiste à acquérir des images dans des centaines de bandes spectrales contiguës et identiquement géo-référencées grâce auxquelles il est possible d'estimer un spectre de réflectance complet pour chaque élément de l'image. C'est une technologie en plein développement qui permet d'accéder à de nombreuses informations sur les propriétés physiques des objets observés comparativement à l'imagerie couleur classique. L'imagerie hyperspectrale est utilisée dans de multiples domaines comme la géologie, l'écologie, l'urbanisme, la foresterie, l'agriculture, dans le domaine militaire ou encore en planétologie.

Cependant, la mise en œuvre de cette technologie et la compression des données qui en sont issues sont des procédures complexes et difficiles. Malgré la quantité d'information fournie par les images hyperspectrales, beaucoup de difficultés subsistent lors de l'analyse de celles-ci; des données volumineuses et des difficultés d'affichage des images. Pour pallier ces difficultés, la compression est l'outil indispensable pour réduire le coût de stockage et les

délais de transmission de toutes ces données. Les méthodes actuelles de compression pour les images hyperspectrales les plus efficaces exploitent la corrélation des images à l'intérieur de la base d'images hyperspectrales appelée pile afin d'améliorer la performance de réduction.

Pendant longtemps, on a utilisé les fonctions sinusoïdales avec la transformée de Fourier ou la DCT (Transformée en Cosinus Discrète) pour la compression d'images. La DCT est utilisée dans les standards de compression JPEG [2] et dans les standards de compression de vidéos MPEG-1 [3]. Dans [4], Robinson et al ont proposé un algorithme de compression d'images basé sur la DCT et les SVM (Machines à Vecteurs Support). Les résultats obtenus par cet algorithme présentent une meilleure qualité comparés à ceux du JPEG. Cependant, les images reconstruites présentent des dégradations remarquables, spécialement pour les taux de compression élevés.

Parallèlement, de nouvelles transformées ont émergés, tendant vers une meilleure prise en compte des caractéristiques de l'image. La Transformée en Ondelettes utilisée par les systèmes de compression des images hyperspectrales afin de pouvoir augmenter ces performances en compression. Cependant, une forte redondance est observée entre les coefficients de celle-ci. Pour exploiter cette redondance plusieurs méthodes de codage ont été mises au point dans la littérature. Dans ce cadre, compte tenu des dépendances entre coefficients d'ondelettes des images hyperspectrales connus par leur haute résolution spatiale, nous présentons une méthode qui est destinée à résoudre des problèmes de discrimination et de régression et qui est particulièrement adaptée pour traiter des données de très hautes dimensions. En effet, les Machines à Vecteurs Support ou les Séparateurs à Vaste Marge (SVM) sont utilisées afin d'exploiter ces redondances, elles sont des techniques inspirées par la théorie statistique de l'apprentissage.

Nous proposons dans ce mémoire, un algorithme de compression des images hyperspectrales en utilisant la régression SVM (Machine à Vecteur de Support ou Séparateur à Vaste Marge) appliquée dans le domaine des Ondelettes 3D. Notre travail est organisé en quatre chapitres.

Le premier chapitre présente les pré-requis pour comprendre le contexte de la compression des images hyperspectrales. Le principe des images hyperspectrales est expliqué, ce qui permet d'en comprendre leur origine. On étudie ensuite les caractéristiques de ces images. En effet, il est important de bien connaître ces propriétés pour en tirer parti lors de la compression. Les domaines d'applications de ce type d'images sont nombreux, nous les classons dans deux grandes catégories principales : premièrement, les applications militaires et deuxièmement les applications civiles. Dans un deuxième temps, les bases des techniques de compression sont exposées. Pour la compression des images hyperspectrales, deux grandes tendances existent : la compression par transformée et la compression par quantification vectorielle. Les différentes parties de la chaîne de compression sont ensuite détaillées. Enfin, un état de l'art de la compression des images hyperspectrales est présenté.

Le deuxième chapitre de ce manuscrit porte sur la Transformée en Ondelettes qui est utilisée pour la compression des images hyperspectrales, en mettant en évidence la dépendance entre ces coefficients, et les SVM qui se situent dans le groupe des algorithmes d'apprentissage supervisés. Un état de l'art, concernant la méthode de compression d'images basée sur les Ondelettes et la régression SVM y est également dressé. Le manque de données concernant l'application de cette approche sur les images hyperspectrales est, par ailleurs, souligné. C'est pourquoi dans le chapitre III, nous présentons une approche permettant la compression des images hyperspectrales en utilisant la régression SVM appliquée dans le domaine des Ondelettes. L'algorithme proposé, sera appliqué en premier lieu sur un ensemble d'images tests visant à choisir les meilleurs paramètres, afin d'être utilisés par la suite pour les images hyperspectrales.

Pour vérifier l'impact de l'algorithme de compression sur la qualité des images, des résultats obtenus sur des exemples réels sont présentés et discutés dans le dernier chapitre. Cette méthode montre des performances satisfaisantes avec une bonne qualité des images reconstruites.

Enfin, une synthèse du travail effectué, suivie d'une discussion sur les perspectives ouvertes par nos études, conclut le corps de ce manuscrit.

Chapitre I

Compression des Images Hyperspectrales

I.1. Préambule

Ce chapitre introduit le principe de l'imagerie hyperspectrale, les contraintes de l'espace et la compression de ce type d'images. Dans un premier temps, nous allons définir ce que sont les images hyperspectrales, la manière dont elles sont acquises et leurs particularités ainsi que les problèmes posés par leur nature. Nous étudierons ensuite les notions de bases nécessaires pour comprendre les principes de la compression d'images, et enfin nous dresserons un état de l'art de la compression des images hyperspectrales.

I.2. L'imagerie hyperspectrale

I.2.1). Application à la télédétection

La télédétection se définit comme l'ensemble des sciences et techniques d'identification, de détection et de classification des objets et des matériaux, à partir de leur rayonnement électromagnétique réfléchi. La physique de la télédétection précise que chaque matériau présente une réflectivité spectrale unique. Cette réflectivité spectrale aussi appelée *signature spectrale*, est considérée comme la source à partir de laquelle les caractéristiques chimiques et physiques d'un matériau peuvent être retrouvées. L'objectif de la télédétection est de tirer parti des informations spectrales pour identifier les objets.

Les capteurs multispectraux fournissent une résolution spatiale suffisamment intéressante. Cependant leur résolution spectrale ne contient pas assez de détails spectraux des objets. Les capteurs hyperspectraux représentent une révolution importante pour identifier les objets dans une scène.

I.2.2). Principe de l'imagerie hyperspectrale

Le principe de l'imagerie hyperspectrale (IHS) est de mesurer la valeur des rayonnements qui parviennent au détecteur, et ceci pour chaque longueur d'onde et pour une

gamme spectrale suffisamment large. Chang [5] précise cette définition en distinguant l'IHS de l'imagerie couleur et multispectrale par trois caractéristiques principales :

- Les systèmes couleurs ou multispectraux enregistrent une image de scène dans 3 ou au plus 10 bandes spectrales alors que les systèmes IHS acquièrent des centaines de bandes contiguës ;
- Les systèmes multispectraux ont une résolution spectrale (longueur d'onde centrale divisée par la largeur de la bande spectrale) de l'ordre de 10, alors qu'elle est de l'ordre de 100 pour les systèmes IHS ;
- Alors que les systèmes multispectraux acquièrent les images dans des bandes de longueur d'onde larges et irrégulièrement espacées, les systèmes IHS ont des bandes spectrales contiguës et régulièrement espacées permettant d'obtenir un spectre quasi-continu pour chaque pixel.




Figure. I.1 De la vision numérique monochrome à l'imagerie hyperspectrale

A partir de cette définition, l'imagerie hyperspectrale peut se voir comme un système de télédétection parfait et idéal qui s'est établi comme une technique avancée capable d'aider à interpréter la terre et ses environnements de manière physique, chimique et biologique [6]. Cette technique d'acquisition simultanée des données d'imagerie en quelques centaines de canaux spectraux contigus, permet de produire des spectres de réflectivité pour chaque pixel de l'image [7].

I.2.3). Représentation des données hyperspectrales

Une image hyperspectrale peut être décrite comme un cube de données à trois dimensions, avec deux dimensions spatiales et une troisième dimension spectrale, de la manière suivante:

- la largeur de ce cube, mesurée en nombre de pixels, est le nombre total de détecteurs utilisés dans le système d'imagerie et est liée à la résolution spatiale.
- la longueur de ce cube mesurée également en pixels, est un nombre défini de lignes enregistrées par le capteur.
- enfin, la profondeur est le nombre de canaux spectraux et représente la résolution spectrale de l'image.




Figure. I.2 Illustration du cube hyperspectral

Le cube hyperspectral ainsi acquis contient une source d'information considérable. Alors que la visualisation d'une image couleur, acquise suivant trois bandes spectrales, est facilement réalisable, il n'en est pas de même pour l'image hyperspectrale. La représentation de telles données nécessite donc de chercher d'autres espaces de représentation qui sauront tirer parti de l'information la plus appropriée en fonction de l'application visée. Les espaces couramment utilisés sont :

I.2.3).1. Espace spatial

L'espace spatial (ou espace image) des données hyperspectrales est valorisé en considérant le cube hyperspectral comme étant une concaténation de I_3 images de dimension $I_1 \times I_2$. Une telle représentation est illustrée à la figure. I.3. On note la matrice :

$$R(:, :, i_3) = \{r_{i_1 i_2} : 1 \leq i_1 \leq I_1, 1 \leq i_2 \leq I_2\} \text{ la } i_3^{\text{ème}} \text{ image spectrale, avec } i_3 = 1, \dots, I_3$$

Chacune des images obtenues est une image quasi-monochromatique qui contient l'information associée à une longueur d'onde donnée.




Figure. I.3 Représentation spatiale : collection d'images quasi monochromatiques

I.3.2).2. Espace spectral

L'espace spectral des données hyperspectrales est valorisé en considérant le cube hyperspectral comme étant une concaténation de $I_1 \cdot I_2$ spectres. Une telle représentation est illustrée à la figure.1.4. Ainsi chaque vecteur pixel est une réalisation d'un vecteur de variable aléatoire : $r = (r_1, r_2, \dots, r_{I_3})^T$ avec I_3 le nombre de bandes spectrales.




Figure. I.4 Représentation spectrale : collection de spectres

I.2.4). Les caractéristiques des images hyperspectrales

La formation d'une image spectrale est indépendante de la technologie d'imagerie, car le concept d'imagerie est valide quelle que soit la taille minimale de la région visualisée. Autrement dit, un système hyperspectral peut utiliser un détecteur simple, une ligne ou une matrice de détecteurs. Les radiances concernant la région sont enregistrées par un détecteur individuel. Pour un système d'imagerie, il existe certaines caractéristiques principales basées sur les différentes capacités du système d'imagerie qui définissent les propriétés de ses images. Il s'agit des caractéristiques spatiales, spectrales et radiométriques des images.

I.2.4).1. Résolution spatiale

La caractéristique spatiale d'une image se décrit par la résolution spatiale. Elle a été définie comme le pouvoir de discrimination de deux objets. En d'autres termes, elle correspond à la taille du plus petit objet identifiable dans l'image. Elle dépend de la taille du détecteur. Cette taille du détecteur, dans le système électro-optique du capteur, détermine un paramètre qui s'appelle le champ de vue instantané ou IFOV. La projection d'un pixel sur la Terre correspond au pas d'échantillonnage spatial minimum qui est connu comme le champ de vue instantané terrestre ou GIFOV. Il peut être appelé, sur le modèle du mot pixel, *groundel*, et est souvent assimilé à la résolution spatiale du capteur. La taille des détecteurs se mesure normalement en microns, alors qu'IFOV est un angle et se mesure en radians. Par contre, GIFOV est sur la Terre et se mesure en mètres et dépend également de l'altitude du véhicule porteur du capteur. Dans le cas où IFOV est suffisamment petit, l'équation ci-dessous permet de définir le rapport entre GIFOV et IFOV pour une prise de vue verticale:

$$GIFOV = \frac{h}{f} \times IFOV \quad (I.1)$$

Où h est l'altitude du capteur ou de son véhicule et f est la distance focale de système optique du capteur. Dans les systèmes d'imagerie numériques actuels, la résolution spatiale est très variable en fonction de l'application de l'imagerie : elle peut aller de quelques dizaines de centimètres à quelques centaines de mètres. Ce paramètre est un paramètre coûteux à améliorer [8].

I.2.4).2. Résolution spectrale

Dans le système optique du capteur, les rayonnements reçus se divisent en différentes longueurs d'ondes. Un grand nombre de divisions (de bandes spectrales) serait idéal, mais plus la bande spectrale est étroite et plus l'énergie des rayonnements reçus par le détecteur est faible et induit une diminution du rapport Signal/Bruit. La technologie du solide est toujours en train d'évoluer, et permet de développer de nouveaux détecteurs, en utilisant des matériels plus sensibles afin d'enregistrer des canaux spectraux plus étroits. De cette façon, la résolution spectrale est définie comme la largeur $\Delta\lambda$ minimum d'un canal spectral. Dans l'IHS, on insiste plutôt sur cette caractéristique de système et d'image, ce qui est légèrement différent de la définition donnée par l'imagerie multispectrales où la résolution spectrale peut être considérée comme le nombre de canaux. Pour l'IHS, la résolution est donc le nombre de canaux spectraux étroits et contigus. Dans ce cas, la largeur de chaque bande est normalement entre 10 et 14 nm. C'est pourquoi, dans le cas où la gamme spectrale couverte par le capteur est continue, le nombre total de canaux spectraux peut s'obtenir par l'équation :

$$N_{bandes} = \frac{[Gamme Spectrale]}{\Delta\lambda} \quad (I.2)$$

D'un point de vue mathématique, si on imagine la restauration d'une fonction après échantillonnage, il est évident que plus le pas d'échantillonnage est petit et plus la restauration sera précise. Nous pouvons restaurer de la même manière la réflectivité spectrale qui est une fonction de longueur d'onde avec le pas d'échantillonnage considéré comme la résolution spectrale.

I.2.4).2. Résolution radiométrique

Le flux de la radiance qui arrive sur chaque détecteur, pour une longueur d'onde spécifique est une valeur analogique. Maintenant une question se pose : comment cette valeur peut-elle être convertie en valeur d'intensité utilisable par les ordinateurs numériques. La question peut être considérée comme un problème de quantification dans laquelle nous convertissons les valeurs de flux de radiance entre le minimum et le maximum sur une gamme de valeurs discrètes. Ces valeurs discrètes déterminent les niveaux gris de chaque pixel. La

résolution radiométrique se mesure normalement en nombre de bits. L'équation (I.3) définit le nombre N de niveaux de gris par rapport au nombre de bits n :

$$N = 2^n \quad (\text{I.3})$$

Par exemple, pour un capteur qui a une résolution radiométrique de 10 bits, nous avons des pixels avec des valeurs de gris compris entre 0 et 1023. Avec cette caractéristique qui est normalement élevée dans le cas de l'IHS, il est probable que deux matériaux très similaires apparaissent avec des valeurs légèrement différentes. Bien que cette probabilité soit petite, elle est importante à prendre en considération [8].

I.2.5). Les capteurs d'imagerie en télédétection

Même si les capteurs de télédétection (panchromatique, multispectral ou hyperspectral) servent un objectif général commun, leurs applications, leurs constructeurs et leurs technologies sont extrêmement variés. Depuis le lancement du premier capteur numérique, MSS porté par Landsat-1, beaucoup de capteurs ont été inventés, fabriqués et mis en opération. Parmi les éléments de choix en matière de télédétection, l'application visée est l'élément le plus important car elle définit les caractéristiques nécessaires au capteur. Un capteur spécifique présentera des propriétés particulières pour acquérir des données d'imagerie pour certaines applications. Ehlers a introduit les critères suivants pour la catégorisation des capteurs de télédétection [9] :

- **Le porteur de capteur**, par lequel, nous reconnaissons différents types de porteurs tels que les porteurs mouvants comme les satellites, les navettes, les avions, les hélicoptères et les ballons, ou les porteurs stationnaires.
- **Le mode de capteur**, par ce critère, les capteurs se groupent comme étant passifs (électro-optique) qui enregistrent toute la gamme spectrale réfléchie de lumière solaire ou actifs tels que les systèmes radar et laser.
- **Le mode d'enregistrement**, par lequel les capteurs se divisent en deux groupes : le groupe analogique comme caméra et vidéo, et le groupe numérique tels que whisk broom, push broom ou matriciel.

- **La couverture spectrale**, il s'agit de l'étendue du spectre électromagnétique qui est couverte par les capteurs, tels qu'ultra violet, visible, infrarouge réfléchissant, infrarouge thermique et les micro-ondes.
- **La résolution spectrale**, par cette mesure, les capteurs sont classés comme panchromatiques avec une seule bande, multispectraux avec un nombre de bandes compris entre 2-20, hyperspectraux pour un nombre de bandes compris entre 20-250 et enfin ultra spectraux avec plus de 250 bandes.
- **La résolution spatiale**, elle permet de classer les capteurs en diverses classes telles que ultra haut (moins d'un mètre), très haut (entre 1 et 4 m), haut (de 4 à 10m), moyen (de 10 à 50 m), bas (de 50 à 250 m) et très bas (plus de 250 m).
- **La résolution radiométriques**, par ce critère, nous pouvons classer les capteurs en très haut (plus de 12 bits), haut (entre 8 et 12 bits), moyen (entre 6 et 8 bits) et bas (moins de 6 bits).

En imagerie hyperspectrale, nous pouvons insister sur les critères les plus importants tels que la gamme spectrale couverte par les capteurs, la résolution spectrale ou le nombre de bandes spectrales qui sont particulièrement déterminantes. De ce point de vu, si un capteur possède plus d'une vingtaine de canaux, avec un maximum de 250 et que ces canaux sont constitués de bandes étroites et contigües, nous pouvons le considérer comme un capteur hyperspectral.

La classification par les véhicules de capteur est aussi importante. Actuellement, deux technologies sont opérationnelles : aéroportée et spatioportée.

I.2.5).1. Les capteurs aéroportés

Les capteurs aéroportés sont historiquement les premiers capteurs grâce auxquels l'IHS a été appliquée et développée. Les capteurs hyperspectraux aéroportés trouveront toujours des applications, notamment lorsque de très hautes résolutions spatiales (de 1 à 4 m) sont nécessaires ou en cas d'événements à court terme et à durée critique pouvant ne pas coïncider avec les paramètres orbitaux des satellites. Le premier système de capteur spectrométrique a été développé en 1983 par JPL (Jet Propulsion Laboratory). Le système s'est appelé AIS (Airborne Imaging Spectrometer). Il faisait des acquisitions de données spectrales en 128 canaux de 1.2 à 2.4 μm . Chaque image acquise avait seulement 32 pixels sur une ligne [10].

A la suite de cette première expérience, JPL a démarré le programme AVIRIS (Airborne Visible-Infrared Imaging Spectrometer) en 1987. Ce capteur était capable d'acquérir des images spectrales en 224 bandes de 0.40 à 2.45 μm avec 512 pixels sur chaque ligne. Différents sites relevant des thèmes géologiques, agricoles, forestiers, etc ont été observés par ce capteur. Le tableau 1.1 donne les principales caractéristiques du capteur AVIRIS et le tableau 1.2 résume les principales caractéristiques des données de ce capteur selon [11].

Tableau. I.1 Caractéristiques du capteur AVIRIS [11]

Imager type	Whiskbroom scanner
Scan rate	12 Hz
Dispersion	Four gratting spectrometers (A, B, C, D)
Detectors	224 detectors (32, 64, 64,64) Si and InSb
Digitization	12 bits
Data rate	20,4 mbits/s
Spectrum rate	7300 spectra/s
Data capacity	>10 GB (> 8000 Km^2)

Tableau. I.2 Caractéristiques des données AVIRIS [11]

<i>Spectral</i>	
Wavelength range	400-2500 nm
Sampling	10 nm
Spectral reponse (fwhm)	10 nm
Calibration	
accuracy	<1 nm
<i>Radiometric</i>	
Radiometric	
range	0 to maximum lambertain radiance
Simpling	~ 1 DN noise RMS
Absolute	
calibration	$\geq 96\%$
Inter flight	
stability	$\geq 98\%$
Signal-to-noise	Exceeding 100:1 requierement
Polarization sensitivity	$\leq 1\%$
<i>Spatial (at 20 Km altitude)</i>	
Feild of view	30 degrees (11 km)
Istantaneous FOV	1,0 mrad (20 m)
Calibration	
accuracy	$\leq 0,1$ mrad
Flight line length	800 Km total

En conséquence, différents domaines de recherches tels que l'étalonnage de capteurs et les études atmosphériques, le géo-référencement et la cartographie, l'analyse d'image et les classifications se sont intéressés à l'imagerie d'AVIRIS. Les résultats de ces travaux ont montré le potentiel et les capacités de l'IHS [9].

Ensuite d'autres systèmes ont été mis en œuvre, dans d'autres pays, pour différentes applications. Le tableau 1 donné dans l'annexe I recense les capteurs hyperspectraux aéroportés qui sont les plus connus.

I.2.5).2 Les capteurs spatioportés

Suite à la réussite des capteurs hyperspectraux aéroportés et grâce à l'expérience de la télédétection spatiale, l'idée de monter un capteur hyperspectral sur satellite a suscité l'attention des agences spatiales. Les capteurs hyperspectraux spatioportés peuvent offrir parfois certains avantages par rapport aux capteurs hyperspectraux aéroportés et par rapport aux satellites multispectraux conventionnels :

1. Ils permettent d'acquérir des données hyperspectrales partout sur la planète, à un coût modique pour l'utilisateur.
2. Un capteur spatioporté aura une orbite héliosynchrone bien définie et assurera ainsi des caractéristiques d'éclairement uniformes.
3. Les capteurs hyperspectraux spatioportés offriront des données temporelles pendant toute l'année.
4. Les données des capteurs hyperspectraux spatioportés offriront des capacités uniques de discerner les propriétés physiques et chimiques des objets à la surface de la Terre, capacités que n'ont pas les satellites multispectraux actuels en bande large. Le capteur Hyperion est le premier capteur hyperspectral spatioporté pour les applications d'observation terrestre [12].

Le tableau 2 donné dans l'annexe I inclut les capteurs hyperspectraux portés par satellites.

I.2.6). Applications des images hyperspectrales

La télédétection hyperspectrale est considérée comme une méthode essentielle pour collecter des données sur l'environnement, grâce à la vue unique qu'elle nous fournit de

la Terre. Les IHS sont appliquées dans deux catégories principales : premièrement, les applications militaires et deuxièmement les applications civiles. Parmi les applications civiles, on peut citer entre autre, les thèmes de recherche suivants :

- L'application urbaine : L'imagerie hyperspectrale dispose d'un potentiel intéressant pour étudier les objets qui composent l'espace urbain et les zones vertes. On note un besoin fort en résolution spatiale (meilleure que 5m) et un intérêt pour l'infrarouge thermique (un canal unique pour la température et un mode hyperspectral pour la qualité de l'air). La complémentarité d'informations multispectrales à haute résolution spatiale et hyperspectrales offre des capacités intéressantes actuellement pour l'étude de ces milieux.
- L'application en végétation : L'imagerie hyperspectrale permet, entre autre, d'accéder au contenu biochimique des plantes :
 - concentration en pigments foliaires ; nombreuses utilisations en agriculture de précision et en écophysiologie,
 - contenu en eau ; forte demande en environnement, en géophysique de surface
 - contenu en matière sèche ; information exploitée dans les modèles SVAT (*Surface Vegetation Atmosphere Transfer*) intégrés aux modèles météorologiques ou pour évaluer et suivre les processus de désertification.
- L'application en Géosciences : géologie, minéralogie, pétrologie, prospection minière et pétrolière, environnements miniers, qualité et dégradation des sols, volcanisme, et en gestion de crises.

L'avenir de ce type d'images apparaît prometteur mais nécessite un investissement de recherche sur des problématiques liées autant à l'acquisition qu'au traitement d'images. Dans la deuxième partie de ce chapitre, nous allons nous intéresser à l'aspect traitement de données plus particulièrement à la compression de ce type d'images.

I.3. Compression des images hyperspectrales

I.3.1). Notions de base

Deux grandes familles d'algorithmes de compression existent : ceux qui peuvent reconstituer l'information exacte (algorithmes sans pertes) et ceux qui tolèrent une perte d'information (algorithmes avec pertes). Les algorithmes sans pertes paraissent

préférables à première vue. En général, les images satellitaires sont complexes. Les rapports de compression obtenus avec des algorithmes sans pertes sur de telles images dépassent rarement 2 ou 3. Cette limitation est due en partie au bruit introduit par les capteurs haute résolution [12].

Pour la compression des images hyperspectrales, deux grandes tendances existent : des systèmes de compression plutôt orientés vers les applications de type classification et des systèmes plus génériques [13]. Les systèmes de compression orientés vers la classification sont basés sur la quantification vectorielle avec création d'un *codebook*. Les systèmes plus génériques sont basés sur un schéma classique de compression par transformée.

I.3.1).1. Compression par quantification vectorielle

La compression par quantification vectorielle des images hyperspectrales est tentante. On peut voir une image hyperspectrale comme une collection de spectres. Si deux pixels de l'image correspondent au même objet au sol, les spectres obtenus pour ces deux pixels seront les mêmes (au bruit près). La notion de *codebook* apparaît naturellement : on identifie les éléments qui sont présents dans l'image, on leur affecte un code. Il suffit ensuite de garder en mémoire le *codebook* et la répartition de ces codes dans l'image.

I.3.1).2. Compression par transformée

Un schéma typique de système de compression par transformée est présenté sur la figure (Figure. I.5).




Figure. I.5 Schéma de compression-décompression par transformée.

Pour traiter et stocker le volume de données issues de capteurs d'images hyperspectrales embarqués, le développement d'algorithmes de compression capables d'exploiter les redondances, spectrale et spatiale, de ces données est nécessaire.

I.3.1).2.a Transformée

Divers travaux ont été réalisés avec différentes transformées notamment au niveau spectral : utilisation d'une transformée de Karhunen-Loeve (aussi appelée Analyse en Composantes Principales), une Transformée Cosinus Discrète (DCT), une analyse en composantes indépendantes (ACI), ondelettes . . .

- **La Transformée Cosinus Discrète :** Très proche de la TFD (Transformée de Fourier Discrète), la DCT décompose le signal en une sommation de cosinus à différentes fréquences discrètes. Les coefficients de la DCT mesurent la contribution de chaque cosinus à différentes fréquences. Pour opérer, elle nécessite un découpage de l'image en blocs $m \times m$. Chaque bloc est traité indépendamment et fournit une matrice de $m \times m$ coefficients de DCT qui sont réels.

La DCT, en elle-même, ne permet pas de compresser l'image. Cependant, une grande partie des coefficients de DCT s'avère être nuls ou proches de zéro. De ce fait, l'application d'un seuil et une quantification permettent de compresser l'image.

- **L'Analyse en Composantes Principales :** Les données d'IHS sont bien adaptées à une représentation dans un espace multidimensionnel. Dans un cube de données hyperspectrales, le vecteur d'observation de chaque pixel $\vec{p} = (X = [x_1 \ x_2 \ ... \ x_n]^t)$ constitue la base de l'analyse. L'ACP considère un ensemble de données vectorielles afin de réduire la dimensionnalité, d'éliminer la corrélation entre les données ou d'extraire les propriétés importantes des données [14]. Les composantes estimées comportent alors les informations essentielles des données. C'est pourquoi, les composantes calculées se nomment les composantes principales. La corrélation entre les vecteurs, exprimée normalement dans une matrice, se nomme matrice de covariance ($\sum x$). C'est un des concepts mathématiques les plus importants dans l'analyse des données de télédétection [15]. Elle contient les valeurs des covariances et les variances des vecteurs d'observation.

L'ACP est également souvent nommé la transformation Karhunen-Loève. Elle projette les données dans un espace non corrélé. Dans ce nouvel espace orthogonal, la variance des données de la première composante est la plus grande. De la même façon, la deuxième composante et les suivantes sont ordonnées par la variance de manière décroissante. Donc, les quelques premières composantes incluent la plupart des informations existante dans les données. Dans le cas de l'IHS, l'ACP est appliquée afin d'estimer le nombre des classes physiques existant dans une scène d'imagerie.

- **L'Analyse en Composantes Indépendantes :** L'ACI est une méthode de résolution pour les problèmes inverses. Elle a montré son efficacité dans la séparation des sources dans différents domaines [16]. L'idée principale de l'ACI est de résoudre un modèle de mélange linéaire à partir de différentes sources indépendantes. L'ACI utilise les statistiques d'ordre supérieur à deux (e.g. variance et covariance) pour l'ensemble des données afin de trouver les sources originales aussi indépendantes que possible. En cela, l'ACI diffère de l'analyse en composantes principales (ACP), qui cherche les composantes non corrélées. Par ailleurs, les composantes calculées par l'ACI ne sont pas nécessairement géométriquement orthogonales. Du point de vue de son application, l'ACP est généralement employée pour la préservation des informations, la réduction de la dimensionnalité ou l'extraction des caractéristiques d'ensemble des données. En revanche, l'ACI est une méthode pratique pour estimer et séparer les sources indépendantes.

L'application d'ACI pour l'IHS consiste à estimer les spectres les plus purs existants dans la scène ainsi que leur proportion. Il a été appliqué sur l'imagerie de télédétection et a permis d'obtenir des résultats probants. En particulier, la classification des pixels mélangés et la détection sub-pixellique sont des applications largement étudiées à l'aide de l'ACI [17], [18] [19], [20], [21] et [22].

- **La Transformée en Ondelette :** Depuis les travaux de Grossman et Morlet [23], la transformation en ondelettes est apparue comme un outil performant pour résoudre des problèmes relevant de différents domaines d'application [24]. Très tôt, un intérêt soutenu s'est manifesté à l'égard de la transformation en ondelettes en traitement d'images [25], [26].

L'emploi de l'analyse multi-résolutions dans le traitement d'images fournit un certain nombre d'avantages selon l'application envisagée. En compression, le taux de compression de l'image pourra facilement être adapté à la qualité désirée. En effet, en éliminant les détails contenus dans certains niveaux de résolution, jugés peu importants, on pourra fortement augmenter le taux de compression, en conservant uniquement l'information nécessaire. Si l'on désire conserver une bonne qualité d'image, il suffira alors de conserver tous les détails [27], [28], [29], [30] et [31]. Cette partie sera plus détaillée par la suite dans ce manuscrit.

I.3.1).2.b Quantification

La quantification est une étape classique dans ce type de système, cependant, dans le cas de codage par plan de bits cette étape n'apparaît plus aussi clairement. Elle s'apparente plus à un tri des coefficients pour faciliter le travail du codeur entropique ou pour tirer parti des dépendances entre les coefficients. L'information quantifiée doit alors pouvoir être décrite par un nombre de symboles suffisamment petit pour atteindre de bonnes performances en débit mais aussi suffisamment grand pour ne pas trop détériorer l'information originale. On considère une source $X = [X_1, \dots, X_N]^T$, vecteur aléatoire à réalisations dans X^N . Cet ensemble peut être continu et non borné, comme - c'est souvent le cas - l'ensemble des réels. L'opération de quantification est une opération non inversible, définie comme suit :

Une quantification est une opération :

$$q: \begin{cases} X^N \rightarrow \tilde{X}^N, \\ x \rightarrow \tilde{x} = q(x), \end{cases} \quad (\text{I.4})$$

De l'ensemble X^N vers $\tilde{X}^N$.

Dans cette sous-section, nous présentons quelques méthodes de quantification :

- **Quantifications scalaire et vectorielle** : une quantification scalaire approxime chaque coefficient de $\mathbf{x}$ indépendamment les uns des autres de sorte que q est constitué de N opérations séparées. Lorsque les coefficients de $\mathbf{x}$ sont très interdépendants, un

quantificateur vectoriel qui quantifie ensemble les N coefficients de $\mathbf{x}$ peut nettement améliorer la performance d'un quantificateur scalaire. Cependant, un quantificateur vectoriel est d'une plus grande complexité qu'un quantificateur scalaire. Si une étape de structuration de la redondance est utilisée en outre de la quantification, les coefficients qui en résulteront seront par définition moins dépendants les uns des autres, et le gain apporté par le quantificateur vectoriel ne vaudra pas le coût de calcul. Les quantificateurs scalaires sont donc en pratique plus souvent utilisés. Gersho et Gray a présenté une étude approfondie de la quantification vectorielle dans [32].

- **Quantificateur de haute résolution** : Un quantificateur est dit de haute résolution si la distribution de probabilités de la variable X , $p(x)$, peut être vue comme constante sur chaque intervalle de quantification $[a_{k-1}, a_k]$.
C'est le cas si les pas de quantification Δ_k sont suffisamment petits par rapport aux variations de $p(x)$ pour que l'on puisse négliger ces variations sur chaque intervalle de quantification.
- **Quantificateur scalaire uniforme** : un quantificateur scalaire uniforme est un quantificateur scalaire pour lequel tous les pas de quantification sont identiques :

$$\Delta_k = \Delta \quad \forall k \in \{1, \dots, K\} \quad (I.5)$$

- **Quantificateur uniforme à zone morte** : un quantificateur scalaire à zone morte - dead-zone en anglais - est un quantificateur scalaire où l'intervalle autour de zéro est plus large. La zone morte - ou dead-zone -, notée T , qualifie cet intervalle, qui permet à l'ensemble des valeurs considérées comme petites, d'être quantifiées à une seule et même valeur zéro. Ce type de quantificateur est non-uniforme ($T \neq \Delta$). Toutefois, si tous les autres pas de quantification sont égaux, on qualifie le quantificateur de 'uniforme à zone morte'. Ce type de quantificateur est très répandu en compression d'image.

La figure I.6 présente une illustration du quantificateur scalaire uniforme et du quantificateur scalaire uniforme à zone morte. Sur la figure 1.6.(a) est représenté graphiquement un quantificateur scalaire uniforme de pas de quantification Δ tandis que la figure 1.6.(b) montre un quantificateur scalaire uniforme à zone morte $T = 2\Delta$.




Figure. I.6 Illustration des quantificateurs scalaire uniforme (a) et scalaires uniforme à zone morte (b)

I.3.1).2.c Codage des coefficients

De nombreux travaux ont été développés sur le codage des coefficients issus de la transformée. On peut avoir une simple quantification, de la quantification vectorielle ou des systèmes par DPCM (Differential Pulse Code Modulation). Pour la transformée en ondelettes, des algorithmes de codage par plans de bits basés sur des structures d'arbres de zéros donnent de bons résultats. Il s'agit de EZW [33] et SPIHT [34] principalement. La quantité et l'ordre des données dépendent des valeurs codées.

➤ Le codage DPCM

Certains codeurs (comme standard JPEG) sont appliqués en une seule passe sur l'image, ligne après ligne et pixel par pixel. Cette approche est souvent généralisée sous le nom de codage DPCM (Differential Pulse Code Modulation). Le schéma de fonctionnement peut se décrire à un niveau pixelique et être appliqué séquentiellement (Figure I.7).




Figure. I.7 Modèle prédictif DPCM

L'approche DPCM s'effectue en une seule passe. Pour chaque pixel, ses voisins précédemment encodés sont tout d'abord utilisés pour effectuer une détection rudimentaire de contours. Une prédiction non linéaire s'appuyant sur cette détection est ensuite appliquée.

➤ Codage entropique

Le principe du codage entropique est de coder les symboles les plus fréquents avec un code plus court. Il existe plusieurs exemples de codages : Fano-Shannon, FLC (Codage à Longueur Fixe), Huffman, arithmétique...

- **Codage de Huffman** : les probabilités d'apparition des symboles sont placées dans un tableau trié par ordre décroissant de probabilités. L'algorithme de Huffman est implémenté suivant une structure d'arbre.

Le principe de cet algorithme consiste à regrouper les deux symboles de probabilité la plus faible pour en faire un nouveau symbole dont la probabilité est la somme des probabilités de ces deux symboles. On itère cette opération et à chaque étape le nombre de symboles diminue. On construit de cette manière un arbre dont les feuilles sont les symboles à coder et les embranchements les codages intermédiaires.

- **Codage arithmétique** : le code est associé à la séquence et non chaque symbole pris individuellement. On associe à chaque symbole à coder un intervalle $[a_k, b_k[$ de $[0,1[$.

On itère ce processus jusqu'à ce que toute la séquence soit traitée, la séquence est alors codée par un réel de l'intervalle $[0,1[$.

Cet algorithme comporte 5 étapes successives :

- 1) On initialise l'intervalle de codage $[a_c, b_c[$ avec les valeurs $a_c = 0$ et $b_c = 1$, cet intervalle a une largeur $L = b_c - a_c = 1$
- 2) Cet intervalle est partitionné en N sous-intervalles (N nombre de symboles de l'alphabet de la source) proportionnellement aux probabilités $p(S_k)$ de chaque symbole S_k . cette partition est constituée de sous-intervalles $[a_k, b_k[$ tels que :

$$a_k - b_k = p(S_k) \text{ avec } a_k = a_c + \text{largeur} \times \sum_{i=1}^{k-1} p(S_i) \text{ et } b_k = a_c + \text{largeur} \times \sum_{i=1}^k p(S_i)$$

- 3) On choisit le sous-intervalle correspondant au prochain S_k à coder dans la séquence et on met à jour les valeurs : a_c et b_c de la manière suivante : $a_c = a_c + largeur \times a_k$ et $b_c = a_c + largeur \times b_k$
- 4) Avec le nouvel intervalle $[a_c, b_c [$ on recommence le processus de l'étape 2.
- 5) Les étapes 2,3 et 4 sont répétées jusqu'à épuisement des symboles de la séquence et obtention du dernier intervalle $[a_c, b_c [$

La représentation binaire de tout réel x_c de l'intervalle $[a_c, b_c [$ est un code de la séquence.

- **Codage par plages de zéros** : le codage par plages de zéros - Run-Length Encoding (RLE) en anglais- est utilisé pour des blocs constitués de symboles binaires uniquement. Ici, ce ne sont pas les probabilités d'apparition des symboles qui servent de base à l'encodage mais les probabilités d'apparition des suites de symboles identiques (par exemple 000, 11, etc...).

Une fois ces probabilités d'apparition établies, l'algorithme procède comme un codeur entropique "classique", par exemple, comme l'algorithme de Huffman en construisant un arbre binaire de façon bottom-up. Il suffit alors d'indiquer au décodeur le premier symbole du bloc (par exemple 0 ou 1) - ou de fixer une règle du premier symbole, par exemple 1, et ajouter 0 comme "longueur" possible de suite lors de l'apprentissage de la table - avant de transmettre le code binaire proprement dit.

Ce type de codage est très populaire. On le trouve dans le standard de compression JPEG par exemple, utilisé pour coder les indices des coefficients de transformée non nuls (on a alors des blocs de 0 et 1 qui se prêtent très bien au codage par plages).

I.3.2). Etat de l'art sur la compression d'images hyperspectrales

Plusieurs recherches étaient menées dernièrement en compression des images hyperspectrales par transformation, nous donnons ci-après quelques une de ces méthodes ;

- ✓ **ASCP et JPEG2000** : Wei Zhu et *al* dans [35] ont montré que l'analyse de composantes principales (ACP) +JPEG2000 peut fournir plus de performances pour le taux de distorsion. L'ACP est utilisé pour le codage spectral et le JPEG2000 pour le codage spatial des images de composantes principales (PC) (désigné sous le nom d'ACP+JPEG2000). La décorrelation spectrale est la clef pour la compression des

images hyperspectrales et l'ACP peut faire un meilleur travail que la TOD dans ce concept. Cependant, les bits supplémentaires impliqués consommés par la grande matrice de transformation peuvent affecter les performances à faible débit, en particulier quand la taille spatiale d'image est relativement petite comparée à la dimension spectrale, on a proposé donc dans ce travail d'appliquer l'analyse segmentée de composantes principales (ASCP) pour atténuer cet effet. Le ASCP+JPEG2000 résultant peut améliorer les performances de compression même lorsque l'ACP+JPEG2000 est applicable.

- ✓ **La KLT et l'arbre de signification asymétrique 3D [36] :** La KLT est employée pour exploiter entièrement la redondance spectrale, alors que la TO est appliquée sur la dimension spatiale. Pour la KLT, le processus de calcul de la matrice de covariance est suivi sur un sous-ensemble de vecteurs qui est aléatoirement choisi parmi l'ensemble complet de vecteurs spectraux. La matrice de transformation est factorisée en matrices triangulaires réversibles élémentaires (TERM).

Chaque coefficient est codé par l'information de signification fournie par son nœud asymétrique correspondant à chaque *bitplane* de l'arbre de la signification.




Figure. I.8 Structure de l'arbre d'orientation asymétrique 3D

- ✓ **L'algorithme 3D EZBC basé sur la KLT et la TO [37]:** Un codeur des images hyperspectrales employant l'algorithme (3D EZBC) basé sur la transformée de Karhunen-Loève (KLT) et la TO est proposé. Ce code adopte la KLT 1D en tant que décorrelateur spectral et la TO2D en tant que décorrelateur spatial. En outre, la complexité informatique et les performances de codage de la KLT sont comparées et évaluées. En comparaison entre plusieurs algorithmes de codage les résultats indiquent

que ce codeur est performant en compression des images hyperspectrales. La structure de base de cet algorithme est illustrée sur la figure suivante :




Figure. I.9 diagramme de codage des images hyperspectrales en utilisant l'algorithme 3D EZBC basé sur la KLT et la TO2D

- ✓ **L'ACP et la VD [38]:** On a déjà vu l'utilisation de l'ACP pour la décorrélation spectrale des images hyperspectrales, la nouveauté dans ce travail est l'emploi du concept de la VD (dimension virtuelle) pour déterminer des PCs (composantes principales) choisis comme un cube en image 3D (3D p – PC cube). On applique ensuite, une technique de compression d'image 3D-cube telle que : JPEG2000 multi-composantes 3D ou 3D-SPITH. La VD est considérée comme étant meilleure en terme critères de réduction de dimension [39].
- ✓ **Compression d'images hyperspectrales en utilisant l'ACI et la TOD [40] :** Un algorithme de compression d'images hyperspectrales basé sur la transformée en ondelette (TOD) et l'analyse segmentée des composantes indépendantes est proposé, il consiste en :
 - Premièrement, diviser des bandes en différents groupes basés sur le coefficient de corrélation
 - Deuxièmement, la méthode du maximum de fraction de bruit (MNF) et l'évaluation de maximum de vraisemblance sont employées pour estimer la dimensionnalité des données dans chaque groupe
 - Basé sur le résultat de l'évaluation de dimension, l'ICA et la TOD sont déployés dans les directions spectrales et spatiales respectivement.
 - Finalement, le SPIHT et le codage arithmétique sont appliqués respectivement aux coefficients de transformation, réalisant la quantification et le codage d'entropie.




Figure. I.10 Schéma fonctionnel de la compression des images Hyperspectrales basée sur ICA et DWT

Les résultats expérimentaux sur 220 données hyperspectrales de la bande AVIRIS prouvent que la méthode proposée réalise un rapport plus élevé de compression et de meilleures possibilités d'analyse par rapport aux algorithmes de PCA et de SPIHT.

- ✓ **Compression ICA/3D-cube** [38]: l'ACP ne peut pas être efficace pour préserver l'information subtile qui pourrait être seulement caractérisée par des statistiques d'ordre élevé. Afin d'aborder cette question, on a employé dans [38] l'ICA. Les techniques résultantes sont désignées sous le nom des techniques de compression d'ICA/3D-cube. Seulement, les composantes générées par l'ICA sont statistiquement indépendantes. Pour palier ce problème, un intérêt particulier est porté à un algorithme non supervisé, appelé le processus de génération de cible automatique (ATGP) [39] et [40], qui a pour rôle de générer un ensemble approprié de vecteurs initiaux de projection pour le FastICA, de sorte que les ICs-FastICA générés peuvent être rangées dans le même ordre que celui des vecteurs initiaux de projection générés par l'ATGP. L'algorithme ATGP-FastICA s'est avéré prometteur [36] et a été employé dans des techniques de compression 3D-cube.
- ✓ **Compression d'images hyperspectrales en utilisant la TOD et la TWH** : la méthode proposée dans [41] est basée sur la Transformée en Ondelette Discrète et la Transformée Walsh Hadamard, ces deux transformées sont utilisées pour exploiter les informations spatiales et spectrales de l'image hyperspectrale et réduire le temps d'exécution. Les résultats de cet algorithme ont montré qu'il est prometteur sur points

de vue des résolutions spatiale et spectrale, mémoire de stockage des données d'images compressées et le temps pour le traitement.

- ✓ **Compression d'images hyperspectrales en utilisant la TOD et NDT [42]** : Dans ce travail, on a proposé un schéma hybride basé sur la Transformée en Ondelette Discrète et la Non négative Décomposition Tucker. L'idée de base de cet algorithme est d'appliquer une DT sur les coefficients issus des bandes spectrales de l'IHS. En premier lieu, on a appliqué la TOD pour séparer les images hyperspectrales en sous-images, ensuite la DT pour compacter leur énergie. La DT permet la sélection de toutes les valeurs pour chaque dimension du tenseur de base. Un tenseur est un tableau multidimensionnel et la décomposition Tucker décompose un tenseur en un ensemble de matrices et un petit tenseur de base. Pour cet algorithme on calcule la DT sur quatre tenseurs et on applique un codage pour le tenseur de base. Les résultats obtenus par cet algorithme ont montrés des performances satisfaisantes en termes de PSNR.

I.4. Discussion

Dans ce chapitre, nous avons présenté le principe d'acquisition des données hyperspectrales. Du fait de l'importance du nombre de bandes acquises (en général plus de 200) et du caractère contigu des bandes spectrales (résolution spectrale de 10 nm), plusieurs méthodes de compression étaient proposées; nous avons essayé de citer quelques unes.

La transformée en ondelettes possède des propriétés intéressantes du point de vue de la compression. En particulier, elle est utilisée dans les récents codeurs pour la compression d'images à bord des satellites comme JPEG2000 [43] et le CCSDS [44]. Cependant, on a constaté des dépendances statistiques entre les coefficients d'ondelettes. De ce fait, différentes stratégies sont développées pour les exploiter. L'approche que nous allons proposer est l'apprentissage par SVM. Le principe et les caractéristiques des SVM ainsi que ceux de la transformée en ondelette seront détaillés dans le prochain chapitre.

Chapitre II

Les Ondelettes et les SVM

II.1. Préambule

Dans ce chapitre, nous nous proposons de rappeler les fondements essentiels des méthodes d'ondelettes et des SVM (Les machines à vecteurs support) en insistant sur leurs utilisations en compression d'images. Le chapitre commence par la présentation du domaine des ondelettes, ses outils, ses types et ses applications. Dans la deuxième partie de ce chapitre, les résultats principaux de la théorie de l'apprentissage de Vapnik sont rappelés. En particulier ceux relatifs à la notion de la régression SVM qui sera utilisée (dans les prochains chapitres) pour la compression d'images. Ce chapitre termine par un état de l'art sur les méthodes de compression d'images basées sur les ondelettes et les SVMs.

II.2. Les ondelettes

La transformation en ondelettes est un outil incontournable dans de nombreuses applications. Elle est bien-sûr omniprésente en compression puisqu'elle permet de disposer l'information dans une représentation duale temps-fréquence propice au développement de stratégies de sélection de l'information utile. En outre, son pouvoir de décorrélation et de concentration de l'information a détrôné dès les années 90 la transformée en Cosinus (DCT).

II.2.1). L'analyse en ondelette

La transformée en ondelettes décompose le signal d'entrée en une série de fonctions d'ondelettes $\psi_{a,b}(t)$ qui dérivent d'une fonction mère $\psi(t)$ donnée par des opérations de dilatation et de translation :

$$C_{a,b} = \int_{-\infty}^{+\infty} x(t) \psi_{a,b}(t) dt \quad (\text{II.1})$$

Grossman et Morlet ont montré que les coefficients d'ondelette $C_{a,b}$ résultants de cette transformation contiennent des informations concernant le signal $x(t)$ étudié à différentes échelles.

$$\psi_{s,\tau} = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad \text{avec } s \neq 0 \quad (\text{II.2})$$

' τ ' étant le paramètre de translation et ' s ' le paramètre d'échelle.

II.2.1).a. Transformée en ondelette continue

On définit la transformée en ondelettes continue Wf de la fonction f par la formule suivante [45], [46]:

$$Wf(t,s) = \int_{\mathbb{R}} f(\tau) \frac{1}{\sqrt{s}} \overline{\psi\left(\frac{\tau-t}{s}\right)} d\tau \quad (\text{II.3})$$

La transformée inverse s'écrit :

$$f(t) = \frac{1}{c_\psi} \iint_{\mathbb{R}^2} W(\tau,s) \psi\left(\frac{t-\tau}{s}\right) d\tau \frac{ds}{s^2} \quad (\text{II.4})$$

II.2.1).b. Transformée en ondelette discrète

Morlet a proposé de construire des bases ou des frames de fonctions construits sur le modèle suivant:

$$g_{t_0,\Delta t}(t) = \frac{1}{\sqrt{\Delta t}} g\left(\frac{t-t_0}{\Delta t}\right) \quad (\text{II.5})$$

où les valeurs possibles de Δt sont pris sur une échelle géométrique et les paramètres de translation sont proportionnels à Δt :

$$\begin{aligned} \Delta t &= b^j \\ t_0 &= k\Delta t \end{aligned} \quad (\text{II.6})$$

Une gamme d'échelles Δt couramment utilisée est la gamme des échelles dyadiques 2^j , et on obtient des familles constituées de fonctions de la forme $g_0(2^j(t-2^{-j}k)) = g(2^j t - k)$ où j et k sont des entiers relatifs. La normalisation la plus couramment utilisée étant une normalisation en norme L_2 , on obtient des familles de fonctions $(\psi_{jk})_{j,k \in \mathbb{Z}}$ où :

$$\psi_{jk}(t) = 2^{j/2} \psi_{jk}(2^j t - k) \quad (\text{II.7})$$

II.2.1).c. Analyse multi-résolution

Le cadre d'analyse de ces ondelettes qui s'expriment à l'aide de filtres discrets s'est considérablement développé [47], [48], [49], Une analyse multi-résolutions est une famille de sous-espaces de $L_2(\mathbb{R})$ notée $(V_j)_{j \in \mathbb{Z}}$, qui ont les propriétés suivantes [50]:

$$V_j = \left\{ \sum_{k \in \mathbb{Z}} a_k \phi_{jk} : a_k \in \mathbb{R} \right\} \quad \text{Espace de RIESZ} \quad (\text{II.8a})$$

$$V_j \subset V_{j+1} \quad (\text{II.8b})$$

$$\bigcap_{j \in \mathbb{Z}} V_j = \{0\} \quad (\text{II.8c})$$

$$\overline{\bigcup_{j \in \mathbb{Z}} V_j} = L_2(\mathbb{R}) \quad (\text{II.8d})$$

- L'hypothèse (II.8a) signifie que V_j est un espace de Riesz engendré par la famille $(\phi_{jk})_{k \in \mathbb{Z}}$. Sa définition dépend de la topologie choisie pour l'espace fonctionnel.
- Intuitivement, nous pouvons considérer que l'ensemble des fonctions de V_{j+1} constitue un ensemble plus « riche » ou plus « dense » que V_j , ce qui ne signifie nullement de relation d'inclusion. L'hypothèse (II.8b) l'impose.
- L'hypothèse (II.8c) est formulée plus pour des raisons de principe, car elle est toujours vérifiée. L'hypothèse (II.8d) l'est pourvu que la fonction $\hat{\phi}$ ne soit pas nulle en $\omega=0$. Les ondelettes apparaissent naturellement comme un moyen d'écrire la différence entre deux espaces V_j et V_{j+1} consécutifs. On construit pour cela un espace de Riesz W_0 tel que :

$$V_0 \oplus W_0 = V_1 \quad (\text{II.9})$$

L'espace W_0 est engendré par une fonction :

$$W_0 = \left\{ t \mapsto \sum_{k \in \mathbb{R}} d_k \psi(t - k) : d_k \in \mathbb{R} \right\} \quad (\text{II.10})$$

II.2.2). Transformée en ondelette à deux dimensions

L'extension à deux dimensions de la TOD (TOD 2D) est essentielle pour la transformation des signaux à deux dimensions (2D), comme le cas d'une image numérique. L'approche simple pour la mise en œuvre de la TOD2D est d'effectuer la TOD unidimensionnelle (TOD1D) ligne par ligne pour produire un résultat intermédiaire et ensuite effectuer la même TOD1D en colonne sur ce résultat intermédiaire pour obtenir le résultat final [51]. Par conséquent, une transformée en ondelettes sur une image produit quatre sous images à la résolution inférieure :

- Une sous-bande basse-fréquence qui représente l'approximation de l'image à la résolution inférieure.
- Trois sous-bandes V, H et D correspondant au résultat du filtrage, respectivement, horizontal, vertical et diagonal (application des filtres verticaux et horizontaux). Ces sous-bandes contiennent les détails orthogonaux à la direction du filtrage. Par exemple un contour vertical correspondra à de forts coefficients dans la sous-bande V.

Le succès des ondelettes en traitement d'images et particulièrement en compression est essentiellement basé sur deux points :

1. Les ondelettes permettent de représenter, à une échelle donnée, les variations brutales d'une image sur un faible nombre de coefficients. Cette propriété permet de délivrer une représentation creuse du signal comme le montre la figure II.1.




Figure. II.1 (a) Histogramme des intensités des pixels d'une image - (b) Histogramme des coefficients d'ondelettes d'une sous-image (autre que la sous-image basse-fréquence).

2. Les images peuvent présenter des propriétés d'autosimilarités à différents niveaux d'échelles qui sont préservées par la transformée en ondelettes. C'est ce qu'on appelle le zoom multiéchelle [52]. Il existe donc des dépendances entre les représentations de

l'image à différentes échelles. La figure II.2 permet de se rendre compte de ces dépendances inter-échelles : les motifs présents dans l'image (b) se retrouvent bien sur les différentes échelles représentées sur la figure (b). Cette propriété est à la base des méthodes de compression de type arbres de zéro comme l'algorithme SPIHT [34] que nous décrirons un peu plus loin.

Soulignons enfin qu'il existe une troisième propriété liée à la localisation spatiale de la transformée en ondelettes et à l'utilisation de filtres orientés verticalement et horizontalement : le phénomène d'agglutinement. La figure II.2 montre bien que les coefficients de forte amplitude ont tendance à se regrouper.




Figure. II.2 Illustration des dépendances inter-échelles

II.2.3). Transformée en ondelette à trois dimensions

La transformée en ondelettes 3D sur une image volumique (pile d'images 2D) peut être vue comme un produit séparable d'ondelettes 1D en les appliquant dans les trois directions spatiales [53], [54]. Après avoir été appliqués sur les lignes (x) et les colonnes (y), les filtres d'analyse/synthèse suivis d'une décimation 2 pour 1 sont appliqués le long de la troisième dimension (z). A la fin de la décomposition, 8 sous-bandes volumiques de résolution inférieure sont obtenus : l'image 3D basse-fréquence LLL et les 7 sous-bandes volumiques 3D de détails perdus.

Les ondelettes 3D séparables fourniront une décorrélation égale des voxels (un pixel en 3D) dans les trois directions. De façon identique au cas 1D, cette opération peut être appliquée autant de fois que le nombre de décompositions souhaité. Dans la transformée dyadique, chaque nouvelle décomposition est obtenue à partir d'une nouvelle transformée en

ondelettes 3D sur la sous-bande basse-fréquence LLL. La figure II.3 illustre la récursivité de la transformation en ondelettes 3D pour une transformée dyadique sur 3 niveaux.

Comme dans le cas 1D ou 2D, l'image volumique basse fréquence LLL_3^8 dans la figure II.3 et les sous-volumes de détails perdus produits (coefficients d'ondelettes) par les différents niveaux de décomposition vont permettre de reconstruire l'image. Cette opération de synthèse consiste à remonter les résolutions en sens inverse de celui appliqué pendant l'analyse en appliquant à chaque fois les filtres de synthèse pour obtenir l'image 3D reconstruite. Notons également qu'il est plus intéressant de réaliser une transformée en ondelettes 3D qu'une transformée en ondelettes 2D pour chaque image de la pile pour bien prendre en compte la corrélation entre les coupes. Il est donc acquis que l'utilisation d'une transformée en ondelettes 3D est toujours préférable à une succession de TO2D sauf dans le cas des images pour lesquelles la résolution sur le troisième axe est très faible. En effet, comme la résolution spatiale et par conséquent la dépendance entre les coupes est réduite, le bénéfice d'utiliser une transformation 3D décorrélant et implicitement un système de codage 3D décroît [55].

On peut également appliquer un nombre de niveaux de décomposition différent dans chaque direction spatiale. Cela permet d'adapter la taille de la pyramide d'ondelettes dans chaque direction spatiale dans le cas où la résolution spatiale est limitée. Par exemple, moins de niveaux sont requis le long de l'axe de coupe si le nombre de coupes ou la résolution le long de l'axe est limitée. Notons aussi que des filtres différents peuvent être utilisés pour la transformation spatiale et temporelle.




Figure. II.3 Transformée en ondelettes 3D dyadique sur 3 niveaux : illustration de l'aspect volumique des sous-bandes.

II.2.4). Les différents types des ondelettes

Il existe de nombreuses méthodes permettant d'effectuer la transformée en ondelettes, chacune se différenciant des autres soit par le type de la fonction de base employée, soit par la méthode d'implantation de la transformée. En fonction du type de traitement que l'on voudra effectuer par la suite, on pourra employer l'une des méthodes suivantes :

- **Translations et dilatations dyadiques d'une fonction** : ce sont les ondelettes classiques. Elles sont naturellement reliées à l'analyse multi-résolution et au codage en sous-bandes ;
- **Les paquets d'ondelettes** : extension des ondelettes classiques, ils reposent sur des fonctions de base ayant une meilleure localisation fréquentielle au prix d'une transformée légèrement plus lourde [56], [57] ;
- **Les bases trigonométriques locales** : l'idée principale est de travailler avec des sinus et des cosinus définis sur des intervalles finis combinés avec une méthode simple mais très puissante permettant de joindre les fonctions de base à leurs extrémités ;
- **Les ondelettes multiples** : l'idée n'est plus d'utiliser une fonction fixe que l'on va traduire et dilater mais plutôt un nombre fini de fonctions. Cette méthode permet d'obtenir des combinaisons de propriétés utiles qui seraient impossibles avec les ondelettes classiques ;
- **Le *lifting scheme*** : on abandonne ici complètement l'idée de translation et de dilatation. Cela fournit une grande flexibilité dans la construction d'ondelettes adaptées à des échantillons irréguliers ou variés [58].

II.2.5). Les familles d'ondelettes

Il existe une infinité de fonctions d'ondelettes parce que toute fonction oscillante localisée est une ondelette mère possible. Toutefois, elles ne possèdent pas toutes des propriétés intéressantes. Aussi, de nombreux spécialistes des ondelettes ont construit des familles d'ondelettes possédant certaines propriétés remarquables. Parmi ces familles, les ondelettes de Haar sont les plus simples, mais elles ne sont pas bien localisées. Ingrid

Daubechies [59] a construit des ondelettes à support compact qui permettent d'utiliser des filtres de taille finie.

Une autre famille d'ondelettes est la famille des splines dont la réponse fréquentielle est bien localisée. Les différentes familles d'ondelettes sont utilisées selon leurs propriétés en fonction du problème à résoudre.

La figure suivante présente quelques familles d'ondelettes




Figure. II.4 Quelques familles d'ondelettes

II.2.6). Avantages de la transformée en ondelette et intérêt en traitement d'image

L'emploi de l'analyse multi-résolutions dans le traitement d'images fournit un certain nombre d'avantages selon l'application envisagée :

- **Compression** : le taux de compression de l'image pourra facilement être adapté à la qualité désirée. En effet, en éliminant les détails contenus dans certains niveaux de résolution, jugés peu importants, on pourra fortement augmenter le taux de compression, en conservant uniquement l'information nécessaire. Si l'on désire conserver une bonne qualité d'image, il suffira alors de conserver tous les détails ;

- **Détection de contours** : la détection de contours est une tâche ardue lorsque les images traitées présentent des variations brusques dans des zones inintéressantes : en pratique, on voudrait pouvoir ignorer certains contours et ne conserver que les plus représentatifs. L'analyse d'un arbre par exemple présente des contours principaux, ceux de l'arbre lui même, ainsi que des contours plus précis (ceux du feuillage). En fonction de l'application, on voudrait pouvoir conserver uniquement les contours principaux (l'arbre), ou bien conserver l'aspect de texture (le feuillage). Ce type d'analyse est permis par la multi-résolution. En analysant l'image à une résolution grossière, après avoir éliminé les détails, les informations sur le feuillage auront disparu. *A contrario*, l'analyse à une résolution plus précise nous donnera tous les contours présents dans l'image.
- **Détection/reconnaissance de texture** : l'analyse multi-résolution apporte un avantage considérable dans le domaine de la reconnaissance de texture, puisque l'échelle est prise en compte en plus des paramètres habituels de détection comme les motifs.

Bien évidemment, la transformée en ondelettes ne se limite pas aux applications mentionnées ci-dessus. On peut également citer la reconnaissance de visage, la détection de mouvements, et d'une manière générale la plupart des applications reposant sur l'analyse d'images.

D'autre part, un avantage non négligeable de la transformée en ondelettes est qu'elle n'est pas liée à une fonction prédéfinie comme l'est la transformée de Fourier qui utilise les fonctions sinus et cosinus exclusivement. Ainsi, le choix de l'ondelette utilisée pour l'analyse pourra dépendre de l'application envisagée, voire même du type de donnée traitée.

II.2.7). Dépendance entre coefficients d'ondelettes

Bien que la transformée en ondelettes soit utilisée pour décorréler les images, il est encore possible d'observer des structures dans les images transformées. La figure II.1(b), représente la transformée en ondelettes de l'image de la figure II.1(a).




Figure. II.5 a) Image PELICAN, b) la transformée en ondelette de cette image

Des dépendances statistiques ont aussi été observées entre coefficients d'ondelettes dans un voisinage très local. Liu et Moulin [60] ont étudié les dépendances inter et intra échelles en mesurant l'information mutuelle entre deux ou plusieurs coefficients d'ondelettes. Simoncelli a modélisé les probabilités d'apparition conjointes entre coefficients d'ondelettes voisins [61] et développé un codeur basé sur cette modélisation avec Buccigrossi [62]. On a donc mis en évidence l'existence de dépendances entre coefficients d'ondelettes voisins. Afin d'exploiter les dépendances entre coefficients d'ondelettes, plusieurs méthodes de codage ont été mises au point dans la littérature. Dans ce cadre, compte tenu des dépendances entre coefficients d'ondelettes des IHS connus par leur haute résolution spatiale, nous présentons dans la section suivante la méthode SVM (Machine Vecteur Support) qui est destinée à résoudre des problèmes de discrimination et de régression et particulièrement adaptée pour traiter les données de très hautes dimensions.

II.3. Apprentissage et SVM

II.3.1). Notion d'apprentissage

L'apprentissage c'est l'acquisition de connaissances et compétences permettant la synthèse d'information [63]. Un algorithme d'apprentissage va permettre de passer d'un espace des exemples X à un espace dit des hypothèses H . L'algorithme SVM va explorer l'espace H pour obtenir le meilleur hyperplan séparateur. L'apprentissage permet, à partir d'un ensemble de paramètres en entrée, d'obtenir un ensemble de résultats en sortie. On va donc préparer un jeu de données à apprendre constitué de couples paramètre/résultat. Le but

recherché est d'apprendre une fonction permettant de prédire de nouveaux résultats pour de nouvelles entrées. L'apprentissage est dit supervisé ou non supervisé. Les SVM se situent dans le groupe des algorithmes d'apprentissage supervisés puisque que l'on utilise une base d'exemples pour obtenir la règle de classification.

II.3.2). Machines à vecteurs support

Les machines à vecteurs support (ou SVM) sont des techniques inspirées par la théorie statistique de l'apprentissage. Le principe consiste à déterminer une séparation linéaire entre deux classes en maximisant la marge définie comme la distance minimale entre la surface de séparation (un hyperplan) et le point le plus proche de l'ensemble d'apprentissage (vecteur de support). On parlera de *méthode des séparateurs à vaste marge* [64], [65], [66], [67], [68].

Lorsque les données ne sont pas linéairement séparables, ou contiennent du bruit (outliers : données mal étiquetées ou étranges), on projette les points de l'ensemble d'apprentissage dans un espace de dimension supérieure où une séparation linéaire peut être trouvée. On parle alors de SVM à noyau.




Figure. II.6 Exemple de classification binaire linéaire et non-linéaire dans R^2

L'intérêt des SVM par rapport aux autres approches est dû, principalement, à quatre raisons [66]:

1. Méthode non-linéaire
2. Le problème d'apprentissage se réduit à la résolution d'un problème d'optimisation quadratique convexe
3. Robustesse à la dimension des données
4. Utilisation d'un ensemble d'entraînement de petite taille.

Les SVM sont utilisées dans de nombreux problèmes d'apprentissage : reconnaissance de forme, la classification des images [69], catégorisation de texte [70], [71] ou encore diagnostic médical [72].

Dans leur origine, les SVMs ont été développés pour des problèmes de classification. Cependant, leur nature leur permet de résoudre également des problèmes de régression [73]. La régression est un cas particulier de classification où les classes des exemples ne sont pas dénombrables, c'est-à-dire continues, dans la section suivante nous détaillerons ce cas.

II.3.3). Régression par les machines à vecteurs supports

La régression par les machines à vecteurs supports (SVR pour Support Vector Regression) est une extension des machines à vecteurs supports développées par l'équipe de VAPNIK [74]. Le but de cette approche est de déterminer l'hyperplan optimal représentant le jeu de données. Cet hyperplan doit interpoler les observations avec une certaine marge ε , marge définie par la fonction perte d'insensibilité ε . Les principaux avantages de cette approche sont : sa robustesse contre le bruit et les erreurs, ainsi que la possibilité de son utilisation dans les cas non-linéaires grâce aux fonctions noyaux.

II.3.3).a Cas linéaire

Soit un ensemble de données $\{(x_1, y_1), \dots, (x_n, y_n)\} \subset \chi$, où χ représente l'espace des données. Dans la régression par vecteurs supports, notre objectif est de trouver la fonction $f(x)$ qui possède, au plus, une déviation de ε par rapport aux cibles y_i de toutes les données de l'ensemble, et dans le même temps, qui soit aussi "plate" que possible. En d'autres termes, nous ne ferons pas attention aux erreurs tant que celles-ci seront inférieures à ε , mais nous n'accepterons aucune déviation qui lui soit supérieure.

Nous commencerons par décrire le cas des fonctions linéaires f , prises sous la forme :

$$f(x) = \langle w, x \rangle + b \quad \text{avec } w \in \chi, b \in \mathbb{R} \quad (\text{II.11})$$

Où $\langle \cdot, \cdot \rangle$ représente le produit scalaire dans χ . La *platitude* dans le cas linéaire signifie que l'on cherche le plus petit w . La façon la plus simple de s'en assurer est d'utiliser la norme

Euclidienne au carré, c'est-à-dire $\|w\|^2$. Formellement, nous pouvons écrire ce problème comme un problème d'optimisation convexe présenté ci-dessous dans sa forme primale :

$$\begin{array}{ll} \text{minimiser} & \frac{1}{2} \|w\|^2 \\ \text{sous contraintes} & \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon \\ y_i - \langle w, x_i \rangle - b \geq -\varepsilon \end{cases} \end{array} \quad (\text{II.12})$$

Cependant, une hypothèse tacitement admise dans cette équation est qu'il existe une fonction f qui approxime tous les couples de données (x_i, y_i) avec une précision ε , ou en d'autres termes, que le problème d'optimisation convexe possède une solution. Mais, bien souvent, ceci n'est pas le cas et nous devons donc nous résoudre à autoriser quelques erreurs. On peut utiliser la fonction perte linéaire d'insensibilité ε et ainsi introduire les variables ressorts (ou variables de relâchement) ξ_i, ξ_i^* pour gérer les contraintes irréalisables du problème d'optimisation convexe, ce qui est appelé la marge douce (soft margin). La fonction perte linéaire d'insensibilité ε est représentée sur la figure II.7 et s'écrit sous la forme :

$$l(\xi)_\varepsilon = \begin{cases} 0 & \text{si } |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & \text{sinon} \end{cases} \quad (\text{II.13})$$




Figure. II.7 Illustration de la fonction perte

Nous devons résoudre un problème d'optimisation convexe sous contraintes dont voici la formulation primale :

$$\min L(w, \xi_i, \xi_i^*) = \frac{1}{2} \|w\|^2 + C \cdot \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (\text{II.14})$$

Sous les contraintes :

$$\begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle - b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i * \xi_i^* \geq 0 \end{cases} \quad \forall i \in \{1, \dots, n\} \quad (\text{II.15})$$

La constante C détermine le compromis entre la "platitude" de f et l'attache aux données, c'est à dire qu'elle donne plus ou moins d'importance (de poids) aux erreurs ξ_i ξ_i^* par rapport à la solution régulière $\frac{1}{2} \|w\|^2$. Pour faire un parallèle avec les notions de risque, minimiser II.14 revient à minimiser le risque empirique régularisé.




Figure. II.8 Représentation de la marge souple

Afin de résoudre ce problème d'optimisation, on utilise sa formulation duale car il est plus facile à résoudre. De plus, la formulation duale apporte la clef d'une extension des machines à vecteurs supports aux fonctions non-linéaires. Pour obtenir cette formulation duale, on utilise une méthode standard de dualisation basée sur les coefficients du Lagrangien.

Forme duale

D'après la théorie de l'optimisation, un problème d'optimisation possède une forme duale dans le cas où la fonction objectif et les contraintes sont strictement convexes. Dans ce cas, la résolution de l'expression duale du problème est équivalente à la solution du problème original. Ces critères de convexité sont réalisés dans le problème défini ci-dessus.

Après transformation, le problème devient celui de la recherche de paramètres vérifiant le système d'équations :

$$\begin{cases} \text{Max} \left\{ \sum_{i=1}^m a_i - \frac{1}{2} \sum_{i,j=1}^m a_i a_j u_i u_j (X_i \cdot X_j) \right\} \\ a_i \geq 0, \quad i = 1, \dots, m \\ \sum_{i,j=1}^m a_i u_i = 0 \end{cases} \quad (\text{II.16})$$

L'hyperplan solution correspondant peut alors s'écrire :

$$h(x) = (w^* \cdot x) + w_0^* = \sum_{i=1}^m a_i^* u_i \cdot (X_i X_j) + w_0^* \quad (\text{II.17})$$

où les a_i^* sont solution de l'équation (II.16) et w_0^* est obtenue en utilisant n'importe quel exemple critique (x_c, u_c) dans l'équation :

A ce point, on remarque deux choses. D'abord, que l'hyperplan solution ne requiert que le calcul des produits scalaires $\langle X_i, X \rangle$ entre des vecteurs de l'espace d'entrée X . Ensuite, la solution ne dépend plus de la dimension d de l'espace d'entrée, mais de la taille m de l'échantillon de données et même du nombre m_c d'exemples critiques qui est généralement bien inférieur à m .

II.3.3.b Cas non linéaire

Certains noyaux, appelés noyaux de *MERCER* [75], ont la propriété suivante : il existe une transformation Φ telle que $k(x, z) = \langle \Phi(x), \Phi(z) \rangle$

Plus précisément, il existe un espace de Hilbert $\mathcal{F}$ muni d'un produit scalaire $\langle \cdot, \cdot \rangle$ tel que :

$$\begin{aligned} \Phi: \chi &\mapsto \mathcal{F} \\ x &\rightarrow x = \Phi(x) \end{aligned} \quad (\text{II.18})$$

Et

$$k(x, z) = \langle \Phi(x), \Phi(z) \rangle \quad \forall (x, z) \in \chi^2 \quad (\text{II.19})$$




Figure. II.9 Représentation idéale de la fonction de décision

Le problème traité est donc transformé dans un espace $\mathcal{F}$ de dimension supérieure à la dimension de χ où il existe une solution linéaire.

Voici quelques exemples de fonctions noyaux utilisées :

- Les noyaux linéaires

$$k(x, x') = x \cdot x' \quad (\text{II.20})$$

- Les noyaux polynomiaux

$$k_{poly1}(x, z) = (x^T z)^m \quad (\text{II.21})$$

$$k_{poly2}(x, z) = (x^T z + c)^m \quad (\text{II.22})$$

- Les noyaux Gaussiens (RBF)

$$k_G(x, z) = \exp\left(-\frac{\|x-z\|^2}{2\sigma^2}\right) \quad (\text{II.23})$$

L'astuce du noyau consiste donc à remplacer un produit scalaire par un noyau. Dans le cas de notre problème, nous obtenons les équations suivantes :

- la formulation primale

$$\min L(w, \xi_i, \xi_i^*) = \frac{1}{2} \|w\|^2 + C \cdot \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (\text{II.24})$$

Sous les contraintes :

$$\begin{cases} y_i - \langle w, \Phi(x_i) \rangle \geq \varepsilon - \xi_i \\ \langle w, \Phi(x_i) \rangle - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (\text{II.25})$$

- la formulation duale

$$\left\{ \begin{array}{l} \max L(a_i, a_i^*) = -\frac{1}{2} \sum_{i,j=1}^n (a_i - a_i^*)(a_j - a_j^*) \langle \Phi(x_i), \Phi(x_j) \rangle \dots \\ \quad - \varepsilon \sum_{i=1}^n (a_i - a_i^*) + \sum_{i=1}^n y_i (a_i - a_i^*) \\ \text{sous les contraintes} \quad \begin{cases} \sum_{i=1}^n (a_i - a_i^*) = 0 \\ a_i, a_i^* \in [0, C] \end{cases} \end{array} \right. \quad (\text{II.26})$$

La reconstruction de w

$$\vec{w} = \sum_{i=1}^n (a_i - a_i^*) \Phi(x_i) \quad (\text{II. 27})$$

La reconstruction de $f(x)$

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) \langle \Phi(x_i), \Phi(x) \rangle + b \quad (\text{II.28})$$

Ou aussi

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) k(x_i, x) + b \quad (\text{II. 29})$$

II.4. Etat de l'art de la compression d'images basée sur les ondelettes et les SVM

Les bases d'ondelettes sont en pratique un outil très efficace, le débruitage par seuillage dans une base d'ondelettes, introduit par Donoho et Johnstone [76], [77], utilise la capacité des ondelettes à représenter de façon compacte une image, et ainsi à bien séparer le signal du bruit. Les ondelettes sont également employées en compression d'images avec succès [78], [79], [80], [81] et [82]. Elles sont en effet à la base du nouveau standard de compression d'images JPEG2000 [83].

Les SVMs ont été utilisées dans de nombreux domaines (reconnaissance de forme, imagerie médicale, le traitement des images hyperspectrales où elles ont donné des résultats encourageants [84], [85], [86], [87] ...), mais également dans la compression d'images qui consiste à réduire la taille physique des blocs d'informations. Plusieurs techniques sont utilisées afin d'atteindre cet objectif, la combinaison entre la Transformée en Ondelettes et la Régression SVM dans ce domaine est l'une de ces techniques qui a fait l'objet de plusieurs recherches. Dans [88], [89], [90] et [91], un algorithme de compression basé sur l'application de la régression SVM aux coefficients d'ondelettes est développé. L'idée est d'appliquer la transformée en ondelettes discrète 2D à l'image originale. Cependant, il existe une grande redondance entre les coefficients issus de cette transformation, on a donc fait appel aux SVM afin d'exploiter ces redondances. Dans [92], JIA-MING CHEN et al ont utilisé un noyau hybride SVM avec cet algorithme en combinant deux types de noyaux : RBF et polynomial. Saeid Fazli et al ont proposé dans [93] d'utiliser la "Daubechies 9.7" comme base d'ondelettes et ont comparé les résultats de cet algorithme avec le "JPEG standard" et le "JPEG 2000". L'approche qui utilise les Curvelets pour coder les coefficients est une façon astucieuse de prendre en compte la redondance géométrique et

permet ainsi de représenter de façon parcimonieuse les contours. Dans [94], on a proposé un algorithme de compression d'images en utilisant la transformée en Curvelets et la Régression SVM. L'application de toutes ces méthodes pourrait aussi être envisagée pour les images hyperspectrales bien que leurs implémentations soient plus difficiles.

II.5 Discussion

Dans ce chapitre, nous avons introduit les ondelettes et les machines à vecteur support, leur fondement théorique et leurs utilisations sans être très exhaustifs. Nous nous sommes concentrés sur les principaux principes qu'on doit utiliser dans la compression d'images tout en introduisant un algorithme qui combine ces deux méthodes sans beaucoup approfondir les détails théoriques. Nous allons revenir sur ces détails dans le chapitre suivant pour mettre l'accent sur l'utilisation de cet algorithme et ces spécificités dans le cas de la compression d'images.

Chapitre III

Méthode adoptée basée sur les ondelettes et SVR

III.1. Problématique

Les avancées technologiques en matière de capteurs satellitaires ont permis l'essor de l'imagerie hyperspectrale. Celle-ci consiste en l'acquisition simultanée d'images dans de nombreuses bandes spectrales étroites et contigües. Ainsi, les données hyperspectrales offrent une information plus riche d'une scène que les autres types de données de télédétection acquises en bandes spectrales larges et non contigües. Cependant, leur apparition liée à l'amélioration des capteurs et à la volonté de voir toujours plus depuis l'espace, crée de nouvelles problématiques. La quantité importante d'information générée par ces capteurs, la forte redondance entre ces informations et l'importance des détails requiert un système de compression adapté. La compression est l'outil indispensable pour réduire le coût de stockage et les délais de transmission de toutes ces données.

La compression d'images met en jeu différentes techniques. Parmi ces techniques, les standards JPEG constituent les formats de compression avec perte d'image fixe les plus populaires et sont basés sur un schéma de codage par transformation. Ces dernières années, un ensemble de techniques d'apprentissage supervisé destiné à résoudre des problèmes de discrimination et de régression et sont particulièrement adaptées pour traiter les données de très hautes dimensions ; les machines à vecteurs support.

Aussi, nous allons mettre à profit les avantages des Ondelettes Biorthogonales et la Régression SVM pour élaborer un algorithme de compression d'images qu'on va appliquer dans un premier temps sur plusieurs images tests afin de tirer les meilleurs paramètres que nous utiliserons par la suite pour la compression des images hyperspectrales. Cet algorithme sera présenté dans les prochaines sections de ce chapitre.

III.2. Algorithme de compression d'images proposé

III.2.1) Principe

La méthode proposée est basée sur l'utilisation de la Régression SVM pour la compression des coefficients d'ondelette 2D. Dans toute cette démarche, nous serons amenés à définir de nombreux éléments de la méthodologie : les paramètres de la quantification, la normalisation des coefficients et le modèle SVM utilisé (le choix du modèle, ses caractéristiques et les types de noyaux utilisés). L'algorithme de compression proposé suit un processus de plusieurs étapes, la figure III.1 donne un aperçu du schéma de compression.




Figure. III.1. Schéma de l'algorithme de compression proposé

Les étapes de la technique de compression adoptée sont résumées comme suit :

1. Charger l'image : cette étape inclut le choix de : l'image, sa taille et son affichage en guise de comparaison avec l'image reconstruite.

2. Appliquer la TOD 2D à l'image avec 5 niveaux de décomposition : l'image originale est décomposée par la transformée en ondelettes discrètes 2D en approximations et détails (horizontaux, verticaux et diagonaux). Nous utilisons les bases d'ondelettes biorthogonales (bior 4.4) [95], [96] en fixant le niveau de résolution à 5.




Figure. III.2. L'image 'Lena' après 5 niveaux de décomposition par les ondelettes biorthogonales

3. Quantifier les coefficients d'ondelettes : Ce type de quantifieur est très utilisé en compression d'image, où suite à une transformation de l'image par ondelette ou DCT, il existe de très nombreuses valeurs autour de zéro, non-significatives, qui pénaliseraient la suite du processus de codage. Typiquement, les valeurs comprises dans la zone morte sont quantifiées à zéro, et ne sont donc pas considérées par le codage entropique. Il existe alors de très nombreux coefficients quantifiés à zéro, ce qui permet d'utiliser des méthodes comme le RLE. En utilisant la quantification 'Dead-zone', on quantifie les coefficients issus de la

décomposition en ondelettes. A partir des expériences, la valeur optimale pour la quantification ‘Dead-zone’ est prise entre 0.6 et 0.75. Le code de la fonction ‘Dead-zone’ est donné comme suit :

```
function Y = dead_zone_q(X,qstep)

    if (~isfloat(X))

        X = double(X);
    end;
    Xs = sign(X);
    Y = abs(X);
    Y(Y < qstep) = 0;
    Y = floor(Y/qstep);
    Y(Y~=0) = Y(Y~=0)+0.5;
    Y = Xs.*Y*qstep;
```

4. Coder la sous-bande BF_5 : les approximations contiennent la majeure partie de l’information. La compression est réalisée en utilisant un codage différentiel DPCM (Differential Pulse Code Modulation) sur les approximations de la dernière sous-bande des coefficients d’ondelettes (BF_5) afin de préserver l’information pertinente de l’image originale. Le codage DPCM permet de compresser de manière intelligente un plan comportant des valeurs homogènes. On considère ici que dans le plan BF (l’information homogène de l’image), la valeur d’un pixel est fortement corrélée à celles de ses voisins passés au travers d’un prédicteur. Le prédicteur est une simple matrice de coefficients permettant de pondérer les pixels voisins du pixel à coder. L’erreur obtenue entre le plan d’origine et le plan prédit est alors transmise, et le gain de cette solution repose sur le fait que l’on peut de manière générale coder cette erreur sur un nombre bien inférieur de bits par pixel.

5. Pour chaque sous-bande des détails :

- *Normaliser les coefficients d’ondelettes* : la normalisation est une étape importante pour la compression d’images. Les coefficients des ondelettes varient de manière remarquable d’une sous-bande à une autre, il est donc préférable de normaliser les coefficients de

chaque sous-bande des niveaux ‘Détails’. Nous avons utilisé l’équation (III.1) pour la normalisation :

$$c' = \frac{c - c_{min}}{c_{max} - c_{min}} \quad (III.1)$$

c_{max} et c_{min} sont les valeurs maximale et minimale des coefficients d’ondelettes respectivement, c est le coefficient à normaliser et c' est la valeur après normalisation.

- *Partitionner les coefficients d’ondelettes* : on décompose les coefficients normalisés en blocs de (8*8).
- *Apprentissage des coefficients d’ondelettes par les SVM* :

Il existe deux versions de régression SVM couramment utilisées : ‘epsilon-SVR’ et ‘nu-SVR’. La formulation originale de la SVR a utilisé les paramètres : $C = [0, inf]$ et $epsilon = [0, inf]$ comme paramètres de pénalité pour l’optimisation des points qui ne sont pas correctement prédits. Une autre version de SVR a été développée plus tard, où le paramètre de pénalité epsilon a été remplacé par un autre paramètre : $nu = [0, 1]$, qui applique une pénalité légèrement différente. Epsilon ou nu sont seulement des versions différentes du paramètre de pénalité. Le même problème d’optimisation est résolu dans les deux cas [97]. Nous avons choisi d’utiliser ‘epsilon-SVR’ car c’était la formulation originale et c’est la forme la plus couramment utilisée. Un exemple de code de fonction ‘epsilon-SVR’ implémenté par [98] est donné juste après.

```
function [y, alpha_out, b_out] = svr(xdata,ydata,x,alpha, b, c, epsilon)

    ntrain = size(xdata,2);
    M = zeros(ntrain);
    y = inf;

    if size(alpha,1) == 0
        svr_train()
    end
    if size(x,1) ~= 0
        y = svr_eval(x);
```

```

        end

        alpha_out = alpha;
        b_out = b;

function svr_train()

    Aeq = sparse([ones(1,ntrain); zeros(ntrain-1,ntrain)]);
    beq = sparse(zeros(ntrain,1));
    lb = -c*ones(ntrain,1);
    ub = c*ones(ntrain,1);

    alpha0 = zeros(ntrain,1);
    M = zeros(ntrain);
    for l=1:ntrain
        for m=1:ntrain
            M(l,m) = K(xdata(:,l),xdata(:,m));
        end
    end
    M = M + 1/c*eye(ntrain);
    image(M)
    options = optimoptions('fmincon','Algorithm','interior-
point','MaxFunEvals',100000,'TolX',1e-3,'Display','iter');

    %options = gaoptimset('TolFun',1e-10);
    alpha = fmincon(@W, alpha0, [],[],Aeq, beq, lb, ub,[],options);

    for m=1:ntrain
        bmat(m) = ydata(m);
        for n = 1:ntrain
            bmat(m) = bmat(m) - alpha(n)*M(m,n);
        end
        bmat(m) = bmat(m) - epsilon - alpha(m)/c;
    end
    b = mean(bmat);
end

function f = svr_eval(x)
    f = 0;

    for i=1:ntrain
        f = f + alpha(i)*K(x,xdata(:,i));
    end
    f = f + b;
end

function cost = W(alpha)
    cost = 0;

    for i=1:ntrain
        cost = cost + alpha(i)*ydata(i) - epsilon*abs(alpha(i));
        for j = 1:ntrain

```

```
        cost = cost - 0.5*alpha(i)*alpha(j)*M(i,j);
    end
end
cost = -cost;
end

function uv = K(u,v)
a = 4;
n = size(u);
uv = 1;
    for k=1:n
        uv = uv*cos(1.75*(u(k)-v(k))/a)*exp(-(u(k)-v(k))^2/(2*a^2));
    end
end

end.
```

Pour l'apprentissage par SVM, il existe deux paramètres qui affectent l'efficacité de la compression : les paramètres de noyau et le type du noyau. En général, les types de noyaux sollicités pour les SVM sont les noyaux : linéaire, polynomial et gaussien. La figure III.5 montre un exemple des résultats de simulation SVR avec les trois types de noyaux sur un bloc de 8*8 pixels pris sur l'image Lena.




Figure. III.3. Les résultats de simulation de la régression SVM sur un bloc de 8*8 de l'image Lena. (a) avec un noyau Linéaire, (b) avec un noyau Polynomial, (c) avec un noyau Gaussien

- *Codage des coefficients* : l'idée est de combiner les vecteurs de support (SVs) avec leurs valeurs (poids), puis de quantifier le vecteur de poids et appliquer les codages RLE et Arithmétique sur ce vecteur.

III.2.2) Reconstruction

L'étape de la décompression consiste à effectuer les opérations inverses qui ont été accomplies lors de la compression. Pour ce faire, les approximations sont décodées par DPCM inverse. Et pour les détails, on doit reconstruire les vecteurs des poids en appliquant un décodage sur la séquence codée. En plaçant chaque bloc des poids dans la matrice initiale

de reconstruction (comme les pièces d'un puzzle), on reconstruit la matrice de détails du niveau correspondant. On applique ensuite la transformée en ondelettes 2D inverse pour reconstruire l'image. La figure III.4 résume les étapes de la reconstruction.




Figure. III.4. Schéma de l'algorithme de reconstruction

III.3. Adaptation de l'algorithme de compression aux images hyperspectrales

III.3.1) Problèmes liés aux données hyperspectrales

Malgré la quantité d'information fournie par ces données, certains problèmes subsistent lors de l'analyse des données issues des images hyperspectrales [99]. Dans les paragraphes suivants, nous décrirons brièvement ces difficultés.

1. Des données volumineuses ; Le volume de données produites par un capteur hyperspectral est extrêmement élevé. En raison de l'amélioration des résolutions spatiales et spectrales par rapport aux données multispectrales, il faut traiter un cube de données très volumineux. Par exemple, pour un site couvrant une surface au sol de 10 km par 10 km, on obtiendra 500 par 500 pixels dans les images acquises par AVIRIS. Avec une résolution radiométrique de 16 bits (deux octets) pour niveau de gris d'un pixel dans chaque bande, le volume pour l'ensemble des 224 canaux est de 112 Mo.

2. Les difficultés d'affichage des images ; Avec l'affichage simple en noir et blanc, la capacité de l'opérateur humain pour distinguer les niveaux gris est très limitée. D'ailleurs, il est impossible d'intégrer l'information de plusieurs centaines de canaux d'images binaires pour l'inspection visuelle. Une image colorée formée d'une composition de trois canaux spectraux sélectionnés et associés aux trois couleurs primaires additives : rouge, vert et bleu (R, V, B) permet de visualiser une plus grande quantité d'information. Cependant, l'affichage d'une telle image ne peut montrer que trois bandes de données hyperspectrales. Donc, il faudrait utiliser les techniques de sélection des bandes pour choisir les trois meilleures bandes dans ce but. En résumé, l'interprétation de données hyperspectrale par un analyste humain peut être réaliste pour sept voire une douzaine de bandes, mais est certainement impossible dans le cas de l'imagerie hyperspectrale où plusieurs centaines de canaux sont disponibles.

3. L'augmentation du temps de calcul ; La quantité de calculs exigés par les différents algorithmes d'analyse est relativement élevée. Naturellement, plus le nombre de bandes employées dans l'analyse est élevé, plus le temps est important. Une réduction de volume ou une sélection de l'information pertinente donc s'avérer nécessaire. Cependant, la réduction de taille elle-même est également une étape coûteuse pour des données hyperspectrales. Trouver le meilleur sous-ensemble de bandes par l'intermédiaire d'une recherche approfondie de toutes les combinaisons de sous-ensembles des canaux s'avère délicat, car la combinaison des bandes à examiner augmente exponentiellement le temps du calcul. En outre, le nombre d'opérations nécessaires pour l'extraction d'information par des transformations linéaires des données augmente naturellement avec le nombre de bandes utilisées.

C'est pourquoi pour notre application, nous allons utiliser une stratégie qui permettra de pallier ces difficultés. Nous allons proposer donc de généraliser notre algorithme de compression proposé précédemment sur les données hyperspectrales.

III.3.2) Principe de l'algorithme de compression des images hyperspectrales

La méthode proposée basée sur l'utilisation de SVR et la transformée en ondelettes pour la compression d'images est appliquée aux images hyperspectrales. Pour ces images, nous avons opté pour les ondelettes bior4.4 (CDF 9/7) et le nombre de décomposition n_{scale} est toujours fixé à 5. Le schéma de la figure III.5 résume la procédure de l'algorithme proposé appliqué sur les images hyperspectrales:




Figure. III.5 Schéma de l'algorithme de compression proposé appliqué aux images hyperspectrales

➤ Les étapes de compression

1. Stratégie Multi-2D (M2D)

Cette stratégie consiste à appliquer une transformée en ondelettes 3D hybride rectangle/carré sur l'ensemble des IHS. Cela consiste à appliquer sur chaque image propre de l'hypercube la même décomposition en ondelette puis un codage 2D. La décomposition en ondelettes est composée par des filtres CDF 9/7 suivant les directions spatiales. On peut par la

suite appliquer un apprentissage SVM et un codage 2D sur chaque sous-bande résultante pour achever la compression.




Figure. III.6 Représentation graphique de la décomposition en ondelette 3D hybride rectangulaire/carré avec trois niveaux de décomposition.

2. Balayage et quantification

Après l'exécution de la transformée en ondelettes 3D, on doit faire un balayage des valeurs des coefficients obtenus. Deux méthodes sont employées dans le procédé de balayage. La première méthode va utiliser un *balayage zigzag*, semblable au JPEG, sur les coefficients des sous-bandes de chaque niveau d'ondelettes et appliquer ensuite la quantification 'Dead-zone'. Après normalisation et décomposition en blocs de 8x8x1, un autre balayage des coefficients est utilisé sur la matrice résultante pour obtenir un vecteur 1D. Le schéma de la figure III.7 illustre le processus de balayage.




Figure. III.7 Le processus de balayage

3. Apprentissage par Régression SVM

3.a) La régression SVM pour les images hyperspectrales

Le fait qu'une image hyperspectrale soit constituée d'une série de bandes spectrales étroites et contiguës de la même scène, produit une séquence d'images fortement corrélée. Ainsi, les méthodes de compression conventionnelles ne sont pas optimales pour la compression d'images hyperspectrales. C'est pour cela que les algorithmes de compressions ont besoin d'être adaptés pour ce type d'images et, souvent, requièrent une étape de décorrélation spectrale. Dans notre cas, avec l'utilisation de la stratégie M2D, nous allons plutôt nous concentrer sur l'utilisation de la régression SVM sur les coefficients de chaque niveau d'ondelettes, cela permet d'approximer ces coefficients en utilisant quelques vecteurs supports (SVs) avec leurs valeurs (poids). L'application des SVR a pour objectif d'éliminer les redondances existantes entre les coefficients issus des ondelettes. Toute cette démarche sera répétée en passant d'un canal à un autre jusqu'au balayage de tout l'hypercube.

3.b) Modèle de sélection

En utilisant l'ordre approprié de balayage, chaque bloc de coefficient est tracé dans un vecteur de dimension 1×64 , appelé Y . Les positions des éléments dans Y forment le vecteur X , qui est également un vecteur de dimension 1×64 . Dans le modèle de régression SVM, X et Y sont respectivement les données d'entrée et les données de sortie désirées. Dans le processus d'apprentissage, sans compter ϵ , il y a toujours deux paramètres dans le modèle qui affectent l'efficacité de la compression : le type de noyau et les paramètres du noyau. Il y a habituellement trois types de noyaux, comme nous l'avons déjà cité auparavant, qui peuvent être choisis pour le modèle SVR : linéaire, polynômial et gaussien. En se référant à [100], la distribution des coefficients dans un bloc est approximativement considérée en tant que distribution gaussienne, ainsi nous choisissons la fonction gaussienne comme noyau de régression et les résultats expérimentaux, que nous allons exposer au prochain chapitre, vérifient son efficacité. Généralement, il n'existe aucune directive pour placer les valeurs des paramètres de noyaux, et la valeur optimale est obtenue à partir des expériences.

4. Codage entropique

Le codage comporte deux parties, la première partie consiste à appliquer aux vecteurs des SVs et leurs poids un codage RLE. Ce codage est préférable, vu que plusieurs valeurs du vecteur de poids sont nulles. Afin d'augmenter l'efficacité de la compression, une combinaison des codages RLE et Arithmétique est employée pour coder les poids. Ces derniers sont d'abord traités par le codage RLE, et chacun des groupes de zéros forme une séquence (codeword). En dernière partie, toutes ces séquences et les poids différents de zéro (nonzero) sont codés ensuite par le codeur arithmétique.

III.4. Présentation formelle de l'algorithme proposé

L'algorithme suivant décrit formellement la démarche adoptée :

Entrées : H , images hyperspectrales

Sorties : S_f , séquence finale de l'image codée

Initialisation

$Nb_niveaux = 5$, nombre de niveaux de décomposition d'ondelettes

$a_f \leftarrow$ bior 4.4, choisir le filtre d'ondelettes

pour $i_H = 1 : 32$

pour $Nb_niveaux = 1 : 5$

Décomposition en ondelettes : $Image\ dwt \rightarrow \{ap, dh, dv, dd\}$

Quantification avec Dead-Zone : $Image\ dwtQ \rightarrow \{apq, dhq, dvq, ddq\}$

Normalisation des détails (Z) :

$$Z_{norm} = (Z - \min_2(Z)) / (\max_2(Z) - \min_2(Z))$$

Division en blocs de 8x8 :

$N_i=8 ; M_i = 8 ;$

pour $i = 1 : N_i : (size(Z), 2)$

pour $j = 1 : M_i : (size(Z), 1)$

$Bloc \leftarrow Z_{norm}(i,j)$

Translater Bloc en vecteur 1D : $V \leftarrow Bloc(1D)$

Appliquer un apprentissage SVM sur V : $SVM(V) \rightarrow \{SV, w\}$

Quantifier les poids : $w_q \leftarrow quantification(w)$

Coder les w_q par codages RLE et Arithmétique :

$$DC\ codés \leftarrow codage(w_q)$$

fin

fin

$$S_f = \sum DC\ codés$$

Codage des approximations niveau LL_5 : $AC\ codés \leftarrow DPCM(apq)$

fin

fin.

III.5 Discussion

Dans ce chapitre, nous avons abordé l'algorithme de compression d'images en adoptant comme technique l'application de la régression SVM dans le domaine des ondelettes. Cette technique est appliquée sur un ensemble d'images tests puis sur les images hyperspectrales. En effet, les images hyperspectrales se satisfont généralement mal des techniques classiques de compression d'image, telles qu'on les applique aux images monochromes ou multispectrales. Disposer d'un signal spectral détaillé pour chaque pixel, ou encore considérer l'image hyperspectrale comme un bloc tridimensionnel au demeurant fortement corrélé d'un canal au suivant, constituent des caractéristiques qui nécessitent d'adapter des techniques de compression qui permettront leurs exploration avec efficacité.

Nous avons proposé dans ce chapitre un algorithme de compression en essayant de nous baser sur tous ces éléments, les tests et résultats de l'application de cet algorithme, sur des exemples réels, feront l'objet d'une mise en œuvre concrète au chapitre suivant.

Chapitre IV

Résultats et discussions

IV.1. Préambule

Dans ce chapitre, nous appliquons l'algorithme de compression d'images basé sur la transformée en ondelettes et la régression SVM décrit au chapitre III. Cependant, pour mieux prendre en compte les caractéristiques des images hyperspectrales, nous allons d'abord exposer les test et résultats de cet algorithme sur un ensemble d'images tests.

Nous donnons donc, dans un premier temps, une description des données que nous allons utiliser. Une étape de test et validation sera présentée afin de choisir les paramètres du modèle de sélection. Nous allons ensuite présenter, à l'aide d'exemples réels, les résultats obtenus par l'application de notre algorithme dans le domaine de la compression d'images.

Plusieurs résultats nous permettront de décrire précisément le fonctionnement de notre approche et mettront en lumière sa capacité dans le domaine de la compression d'images et plus précisément la compression des images hyperspectrales.

IV.2. Description des données

L'algorithme est implémenté avec MATLAB (R2012a) et nous avons utilisé LIBSVM pour la régression SVM. C'est une des bibliothèques les plus usitées, elle a été développée par Chang et Lin [101]. Elle contient de nombreux modules de classification et régression et elle est développée en C++ et Java. Des interfaces sont disponibles pour Python, MATLAB, Perl et Ruby. Elle permet l'usage de différents noyaux : linéaire, polynomial ...

Les nouvelles méthodes de compression de données qui sont développées et implémentées doivent être testées. En testant ces différentes méthodes sur les mêmes données, il devient possible de comparer leurs performances en efficacité de compression et en rapidité. C'est pourquoi il existe des collections de données standards de test. En effet, nous nous proposons d'utiliser notre algorithme de compression sur un ensemble d'images tests afin de tirer les meilleurs paramètres qu'on utilisera par la suite pour les images hyperspectrales.

IV.2.1). Images tests

Nous appliquons notre algorithme de compression sur plusieurs images tests qui sont codées sur 8 bits en format ‘bitmap’. Les caractéristiques des 6 images utilisées sont récapitulées dans le tableau suivant :

Tableau. IV.1 Les caractéristiques des images tests

Images	Taille totale	Taille utilisée	Aperçu
Femme	256 x 256	256 x 256	
Bateau	256 x 256	256 x 256	
Tigre	256 x 256 x3	256 x 256	
CITY	257 x 257 x 3	256 x 256	
Lena	512 x 512 x1	512 x 512	
Aerien	256 x 256 x 3	256 x 256	

IV.2.2). Images AVIRIS

Nous utilisons des images AVIRIS de la scène Yellowstone, acquise en 2006, la taille de ces images est de $512 \times 614 \times 224$ codées sur 16 bits. Ces images 3D sont produites en combinant plusieurs canaux. Il est possible de les coder de manière indépendante canal par canal, elles seront donc de taille $512 \times 614 \times 1$ codée sur 16 bits (après corrections radiométriques) chacune. Nous avons utilisé pour nos tests un cube hyperspectral de 32 canaux pris arbitrairement du canal 1 jusqu'au canal 32 de taille spatiale 512×512 pour chaque canal. La taille de l'ensemble de la séquence qu'on utilise est donc de $512 \times 512 \times 32$ afin de réduire le temps de calcul nécessaire à l'exécution de l'algorithme de compression.




Figure. IV.1. Description des images hyperspectrales utilisées. (a) Les données AVIRIS, (b) La séquence utilisée, (c) Image correspondante au canal 29.

IV.3. Cadre d'évaluation de la compression et mesure de performances

Les principaux paramètres qui permettent d'évaluer une méthode de compression sont : le taux de compression, le débit, le temps d'exécution et les mesures de distorsions. En pratique, il s'agit de réaliser le meilleur compromis possible entre le taux de compression et la qualité de l'image décompressée tout en minimisant le temps d'exécution [102].

Quand la compression avec perte est utilisée, il est nécessaire d'évaluer et de décrire la nature et l'importance des dégradations dans l'image reconstruite (décompressée) [103]. Habituellement, dans le cadre d'images 2D classiques, les performances des méthodes sont évaluées à l'aide d'un critère qui privilégie un seul aspect (reflétant habituellement la perception de la vision humaine). Ce n'est pas le cas pour les images multi/hyperspectrales,

qui sont utilisées dans des algorithmes de classification et de détection. À cet effet les métriques doivent correspondre aux applications. C'est pour cela qu'au lieu d'évaluer les performances de compression suivant une seule métrique ou un seul type de métrique, nous proposons l'utilisation de plusieurs métriques. Nous les utilisons comme cadre d'évaluation de la compression. Les métriques que nous proposons peuvent être divisées en quatre différentes familles : critères issues d'une extension isotrope de critères de traitement du signal (PSNR, MSE, MAE et MAD). Dans [104], Christophe et al démontrent que l'utilisation d'un jeu de plusieurs métriques est plus pertinente que d'en utiliser un seul. Ainsi nous avons choisi d'utiliser quelques métriques en plus du PSNR. L'utilisation de ce dernier résulte du fait qu'elle est la métrique la plus employée, ce qui facilite la comparaison avec les résultats d'autres méthodes.

IV.3.1). Taux de compression

Le taux de compression est une mesure de la performance d'un algorithme de compression de données. Il est donné par l'équation (IV.1).

$$C = (1 - 1/R_c) \times 100 \quad (IV.1)$$

où R_c est rapport de compression, défini par l'équation (IV.2).

$$R_c = \frac{\text{Taille de l'image originale en bits}}{\text{Taille de l'image comprimée en bits}} \quad (IV.2)$$

IV.3.2). Débit

Le débit ou facteur de compression est une mesure alternative très utilisée. Il représente le nombre moyen de bits nécessaire pour coder un pixel de l'image. Il est défini par l'équation (IV.3).

$$B_{pp} = \frac{\text{Nombre de bits par pixels dans l'image originale}}{R_c} \quad (IV.3)$$

IV.3.3). Le temps de compression / décompression

Le temps de compression/décompression nécessaire pour coder/décoder une image est fonction de la complexité de l'algorithme, de l'efficacité de son implémentation et de la puissance du processeur.

IV.3.2). Les mesures de distorsions

Les techniques de compression avec pertes modifient l'image en y introduisant des distorsions. Pour évaluer la qualité de l'image décompressée, il faut donc estimer le niveau de ces distorsions. Dans la pratique, on utilise des mesures objectives et subjectives qui permettent d'évaluer ces distorsions [105].

IV.3.2).a. Mesures objectives

Les images hyperspectrales sont représentées sous la forme d'une matrice tridimensionnelle : $I(x, y, \lambda)$, x est la position du pixel dans la ligne, y est le numéro de la ligne et λ la bande spectrale considérée. n_x , n_y et n_λ sont respectivement le nombre de pixels par ligne, le nombre de lignes et le nombre de bandes spectrales. On notera également $\sum_x^{n_x} \sum_y^{n_y} \sum_\lambda^{n_\lambda} I(x, y, \lambda)$ par $\sum_{x,y,\lambda} I(x, y, \lambda)$. Ces notations seront conservées par la suite.

A l'origine, ces traitements sont adaptés à des données à une seule dimension. Ils ont été ensuite étendus avec succès aux images classiques à deux dimensions. Pour les images hyperspectrales, des extensions à une troisième dimension ont été réalisées. Dans ce cas, on considère les critères traitant les 3 dimensions (2 spatiales et une spectrale) de la même manière. La spécificité des images hyperspectrales n'est donc pas prise en compte. Parmi les mesures utilisées, on peut citer :

- **Mean Absolute Error (MAE)** : C'est la moyenne de la différence en valeurs absolues entre les pixels de l'image originale et compressée.

$$MAE = \frac{1}{n_x n_y n_\lambda} \sum_{x,y,\lambda} (I(x, y, \lambda) - \tilde{I}(x, y, \lambda)) \quad (IV.4)$$

Où $I(i, j)$: Un pixel de l'image originale ;

$\tilde{I}(i, j)$: Un pixel de l'image reconstruite.

- **Erreur quadratique moyenne (Mean Square Error, MSE)** : reste la mesure objective la plus utilisée. Elle représente l'erreur quadratique moyenne entre l'image compressée et l'image originale. Cette mesure va permettre d'évaluer l'influence des dégradations de la compression sur l'image compressée. Elle est définie comme suit :

$$MSE = \frac{1}{n_x n_y n_\lambda} \sum_{x,y,\lambda} (I(x, y, \lambda) - \tilde{I}(x, y, \lambda))^2 \quad (IV.5)$$

Pour une meilleure interprétation, cette mesure peut être reliée à des notions de moyenne et variance. En notant μ la moyenne et σ^2 sa variance.

$$MSE = \sigma_{I-\tilde{I}}^2 + \mu_{I-\tilde{I}}^2 \quad (IV.6)$$

- **Rapport Signal sur Bruit Crête (Peak Signal to Noise Ratio, PSNR)** : c'est la mesure de la distorsion entre l'image originale et compressée. Il s'agit de quantifier la performance des codeurs en mesurant la qualité de reconstruction de l'image compressée par rapport à l'image originale. Ce rapport est donné par l'équation (IV.7).

$$PSNR = 10 \log_{10} \frac{(2^R - 1)^2}{MSE} \quad (IV.7)$$

Où R représente le nombre de bits par pixel

- **Maximum Absolute Distortion (MAD)** : ou L_∞ ou Maximum Absolute Error, elle est donnée par l'équation (4.8).

$$MAD = L_\infty (I - \tilde{I}) = \max \{|I(x, y, \lambda) - \tilde{I}(x, y, \lambda)|\} \quad (IV.8)$$

IV.3.2).b. Mesures subjectives

Ces mesures permettent d'évaluer la qualité de l'image de façon visuelle par un opérateur humain. Parmi les dégradations qu'on peut détecter, on peut citer : des contours mal définis, des textures mal reproduites, la présence d'un effet de bloc, le lissage de l'image et le masquage des détails, etc.. [106] et [107]. Bien que ce jugement

subjectif soit important, puisqu'il fournit des informations que les mesures objectives ne peuvent pas mettre en évidence, il n'est pas suffisant pour mesurer fidèlement la qualité des images compressées. En effet, le résultat dépend de l'expérience de l'opérateur et de la qualité de son système visuel.

IV.4. Tests et validation

La phase d'apprentissage est la plus importante, mais la détermination des bons paramètres n'est pas toujours facile. Dans cette étude, nous nous intéressons aux paramètres du SVR afin d'aboutir au meilleur compromis entre qualité de l'image et taux de compression. Pour fixer le modèle SVM approprié à la compression d'images, nous étudions les performances de trois types de modèles SVM selon le noyau utilisé : linéaire, gaussien et polynomial. Ainsi que le choix des paramètres utilisés pour ces noyaux.

a. Type de noyau

Chaque modèle est appliqué sur les coefficients issus de la décomposition en ondelettes, plus précisément, sur les détails. La comparaison des rapports de compression de l'algorithme proposé avec différents noyaux 'epsilon-SVR' est donnée sur le tableau 1, qui présente l'ondelette utilisés, les PSNR et les rapports de compression pour l'image 'Lena'.

Tableau. IV.2 Résultats des rapports de compression (CR) et PSNR des différents types de noyaux appliqués sur l'image 'Lena'

Image	Ondelettes	Noyau	CR	PSNR (dB)
Lena 512x512	bior 4.4	Polynomial	36.92	13.65
			24.87	17.04
			8.80	25.52
		Gaussien	35.06	15.66
			23.73	20.01
			19.12	26.63
		Linéaire	59	9.41
			43	9.89
			28	9.85

La figure suivante montre la comparaison entre des rapports de compression et PSNR des trois types de noyaux appliqués sur l'image 'Lena'.




Figure. IV.2 Comparaison des performances des noyaux SVR: Gaussien, Polynomial et Linéaire appliqués sur l'image 'Lena 512x512'

La figure suivante montre la qualité des images reconstruite à partir des noyaux SVR : gaussien et polynomial. A signaler que les images obtenues par le noyau linéaire sont très dégradées.



Figure. IV.3 Image originale ‘Lena’



a)



b)

Figure. IV.4 Comparaison des images Lena reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial

Le tableau suivant, Tableau IV.3, donne les rapports de compression (CR) et les PSNR obtenus de l’application de notre algorithme avec les différents types de noyaux sur plusieurs images tests.

Tableau. IV.3 Résultats des rapports de compression (CR) et PSNRs des différents types de noyaux appliqués sur plusieurs images tests.

Image	Noyau	CR	PSNR (dB)
Femme 256x256	Polynomial	17.5	30.54
	Gaussien	17.5	30.74
	Linéaire	42.4	6.94
Bateau 256x256	Polynomial	17.8	29.16
	Gaussien	17.8	30.54
	Linéaire	44.8	5.90
Tigre 256x256	Polynomial	17	29.20
	Gaussien	17	29.50
	Linéaire	43	6.21
CITY 256x256	Polynomial	16.5	31.36
	Gaussien	16.5	31.98
	Linéaire	41.86	8.69
Aerien 256x256	Polynomial	16.6	30.86
	Gaussien	16.6	31.70
	Linéaire	41.29	9.00

Les résultats montrent qu'on peut atteindre des taux de compression élevés avec des bons PSNR. Effectivement, nous avons atteint avec notre algorithme un rapport de compression allant jusqu'à 18.37 pour un PSNR de 31.32 dB pour l'image "Lena" de taille 512x512 avec un noyau Gaussien. Les résultats obtenus avec le noyau Gaussien sont les meilleurs des trois types de noyaux, et cela est dû à la distribution des coefficients des blocs qui est approximativement considérée comme une distribution gaussienne. Le meilleur résultat de PSNRs qu'on a pu atteindre avec le noyau Polynomial est de 31.07 dB avec un rapport de compression de 18.49, ce qui signifie que même avec ce type de noyaux on peut avoir une bonne qualité de l'image. Malgré que les rapports de compression atteints par le noyau Linéaire sont élevés mais la qualité de l'image obtenue est dégradée. Les figures suivantes (Figure IV.6, Figure IV.8, Figure IV.10, Figure IV.12 et Figure IV.14) montrent la qualité des images tests reconstruites.



Figure. IV.5 Image originale 'Femme'



a)



b)

Figure. IV.6 Comparaison des images 'Femme' reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial



Figure. IV.7 Image originale ‘Bateau’



Figure. IV.8 Comparaison des images ‘Bateau’ reconstruites. (a) Avec noyau Gaussien,
(b) Avec noyau polynomial



Figure. IV.9 Image originale ‘Tigre’



a)



b)

Figure. IV.10 Comparaison des images ‘Tigre’ reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial



Figure. IV.11 Image originale ‘Aerien’



a)



b)

Figure. IV.12 Comparaison des images ‘Aerien’ reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial



Figure. IV.13 Image originale 'City'



a)



b)

Figure. IV.14 Comparaison des images 'City' reconstruites. (a) Avec noyau Gaussien, (b) Avec noyau polynomial

Les résultats expérimentaux montrent que les noyaux "Gaussien" et "Polynomial" sont préférables pour ce type d'applications que le noyau "Linéaire", celui-ci permet d'atteindre des taux de compression excellents mais avec des dégradations remarquables sur les images

reconstruites. Nous allons donc utiliser pour notre application le noyau SVM qui a permis d'atteindre les meilleurs résultats ; le noyau Gaussien.

b. Les hyper-paramètres

Les différents paramètres qui peuvent influencer durant la phase d'apprentissage représentent : les paramètres de la fonction noyau et le paramètre de pénalisation « C ». Plusieurs essais ont été effectués afin de pouvoir fixer ce paramètre de régularisation. En effet ce paramètre a une grande influence sur les résultats de la compression. La figure suivante, Figure IV.15, illustre l'influence du changement de ce paramètre sur le rapport de compression :




Figure. IV.15 Influence du paramètre 'C' sur le Rapport de Compression

IV.5. Résultats numériques

Le tableau IV.4 présente les résultats des expériences de notre algorithme sur les images AVIRIS suivant quatre paramètres. En fait, ces résultats présentent les valeurs moyennes de ces paramètres qui sont calculées pour l'hypercube de 32 canaux.

Tableau. IV.4 Résultats des Rapports de Compression (RC) et PSNR issus de l'application de notre algorithme sur les images AVIRIS

Image	Ondelettes	Noyau	RC	PSNR	MSE	NAE	MAD
AVIRIS 512*512*32	CDF 9/7	Gaussien	2148.5	8.07	1.02e+08	4.22	-3.4e-12
			158.9	7.88	7.62e+07	0.05	-3.8e-12
			110	15	1.69e+07	1.56	-3.6e-12
			53.17	34.5	1.94e+05	0.15	-3.7e-12
			52.60	37.76	1.41e+05	0.13	-3.8e-12
			48.7	38.22	6.53e+04	0.10	-3.7e-12

La figure IV.16 donne les résultats des Rapport de Compression (RC) et PSNR moyens.




Figure. IV.16 Les résultats des Rapport de Compression (RC) et PSNR moyens

Les résultats obtenus de l'application de notre algorithme de compression sur les images AVIRIS sont illustrés dans les figures IV.17 et IV.18.



Image originale

Image compressée (RC=48.7 et
PSNR=38.22 dB)Image compressée (RC= 20.73 et
PSNR=37.43 dB)Image compressée (RC= 56.68 et
PSNR= 35.78 dB)

Figure. IV.17 Image originale et images compressées pour le canal numéro 31 du cube 3D




Figure. IV.18 Image compressée pour toute la séquence
(RC= 48.7 et PSNR= 38.22 dB)

IV.5.1). Influence du nombre de décomposition

Nous donnons dans le tableau IV.5, les résultats de différents niveaux de décomposition des Ondelettes utilisées (bior4.4).

Tableau. IV.5 Résultats des Rapport de Compression (RC) et PSNR avec différents niveaux de compression.

Niveaux de compression	J=2	J=3	J=4	J=5
RC	50.23	47.27	46.5	46.3
PSNR (dB)	39.88	38.86	38.67	38.58

Nous avons varié le nombre de niveaux de décompositions en commençant par le niveau 2. Les résultats des PSNRs et rapports de compression sont donnés dans le tableau IV.6, l'augmentation du niveau de décompositions a entraîné plus de sous bandes de détails à traiter. Un apprentissage régressif SVM a été appliqué aux détails afin d'obtenir les vecteurs de support (les SVs), d'où l'élimination de plusieurs points de l'image. Cela a pour effet de minimiser des détails de l'image et donc diminuer la qualité de celle-ci et augmenter la taille de l'image compressée (plus de vecteurs de support).

IV.5.2). Influence du contenu de l'image

Nous utilisons deux séquences des images AVIRIS, à savoir séquence A (1 :256, 1 :256) et séquence B (128 :383, 179 :434). Elles sont illustrées dans la figure IV.19.




Figure. IV.19 Les séquences utilisées

Le tableau IV.6 présente les résultats de deux séquences, de différents contenus, issues des images AVIRIS.

Tableau IV.6 Résultats des Rapport de Compression (RC) et PSNR moyens pour deux séquences issues des images AVIRIS

Les séquences	Séquence A	Séquence B
CR	36.81	57.5
PSNR	34.55	37.1

Le deuxième paramètre qui peut influencer sur les résultats est le contenu de l'image. En effet, il ya une différence remarquable entre les résultats des PSNRs et rapports de

compression de deux séquences de tailles 256x256x32 chacune, prises de l'image originale. La séquence que nous avons nommé A est de (1 :256, 1 :256, 1 :32) de l'image originale et la séquence B est de (128 :383, 179 :434, 1 :32) de la même image. Nous avons atteint un PSNR de 34.55 dB pour un rapport de compression de 36.81 pour la séquence A. Quant à la séquence B, le PSNR atteint une valeur allant jusqu'à 37.1 pour un rapport de compression de 57.7.

IV.5.3). Influence de la taille de l'image

L'algorithme peut être mis en œuvre pour toute taille d'image, mais quand la taille de l'image augmente le temps nécessaire à la compression et la reconstruction de l'image augmente aussi. Le tableau IV.7 montre l'effet de la taille de l'image sur le temps de calcul et sur qualité de compression.

Tableau. IV.7 Résultats des Rapport de Compression (RC) et PSNR pour différentes tailles de l'image

Tailles	128*128*32	128*128*64	256*256*32	256*256*64	512*512*32
RC	23.65	23.34	36.81	35.95	46.3
PSNR	38.06	36.97	34.55	33.67	38.58

IV.5.4). Influence de la taille des blocs de décomposition

Les tailles des blocs utilisées sont choisies par l'utilisateur, le tableau IV.8 donne les résultats des Rapport de Compression (RC) et PSNR de décomposition en blocs de 4*4 puis de 8*8.

Tableau. IV.8 Résultats des RC et PSNR pour différents blocs de décomposition

Performances	RC	PSNR (dB)
Bloc de 4*4	32.24	38.58
Bloc de 8*8	46.3	38.58

Nous avons constaté, que la taille des blocs issus de la partition de l'image peut influencer sur les résultats des rapports de compression. Effectivement pour un même PSNR de 38.58 nous avons des rapports de compression de 32.24 pour le bloc de 4*4 et 46.3 pour le

bloc de 8*8. Cette différence est due en fait à la longueur maximale choisie pour le codage par plage de zéros (RLE).

IV.6. Comparaison des résultats

La comparaison entre l'adaptation de notre algorithme (présenté dans les chapitres III et IV) et l'adaptation d'autres algorithmes (présentés au chapitre I) sur des images AVIRIS en terme de PSNR (dB) est résumée dans le tableau donné juste après.

Tableau. IV.9 Comparaison des performances de compression pour différents débits

	0.25 bpp	0.5 bpp	1 bpp
ICA / SPITH [108]	25.27	26.89	29.47
PCA / SPITH [108]	22.78	24.31	27.04
3D DWT (j=4) 3D SPIHT [18]	38.77	43.79	48.34
3D DWT (j=4) 3D SPECK [18]	37.75	42.78	47.56
1D KLT+ 2D DWT 3D SPITH [18]	42.49	47.59	50.25
1D KLT+ 2D DWT 3D SPECK [18]	41.41	46.5	49.49
3D DWT (j=5) SVM	35.3	38.42	39.7

Remarque : Dans le tableau IV.9, le PSNR de notre algorithme est de 35.3 dB pour un niveau de décomposition de 5 contre 42.49 dB qui est le meilleur PSNR atteint par les autres algorithmes pour 0.25 bpp et un niveau de décomposition de 4. Pour comparer les performances en terme de PSNR, il faudrait utiliser le même nombre de niveaux de décomposition en ondelettes. Dans ce cas le PSNR augmente à 38.18 dB.

La comparaison entre les performances obtenues de l'adaptation de notre approche et l'adaptation d'autres approches de compression des images hyperspectrales, montre qu'aux mêmes débits, notre approche donne de meilleurs PSNR que les deux approches ICA / SPITH et PCA / SPITH. D'un autre côté, notre approche produit des performances similaires à ceux des approches 3D DWT/3D SPIHT et 3D DWT/3D SPECK et même meilleures à certains

débits. Afin d'optimiser la compression des images hyperspectrales, une étape de décorrélation est utilisée par les approches 1D KLT+ 2D DWT+3D SPITH et 1D KLT+ 2D+DWT 3D SPECK. Il a été montré (comme nous l'avons vu dans le chapitre I) que l'utilisation de l'ACP (KLT) est l'un des moyens les plus efficaces pour la décorrélation spectrale. Cela peut expliquer le fait que ces deux méthodes donnent de meilleurs résultats.

IV.7. Discussions et problèmes ouverts

Notre algorithme de compression/décompression basé sur les ondelettes biorthogonales et la régression SVM a été appliqué sur des images hyperspectrales. Pour la première séquence traitée (images AVIRIS de la scène Yellowstone) qui est de taille $512 \times 512 \times 32$ (taille spatiale de : (1 :512, 1 :512) et taille spectrale de 32 allant du canal : (1 : 32)), nous avons fixé le nombre de décompositions des ondelettes à 5. Pour la régression SVM nous avons utilisé un noyau gaussien et choisis les hyper-paramètres obtenus de l'expérimentation de cet algorithme sur un ensemble d'images tests.

Le tableau IV.4 résume les critères de performances obtenus avec cette approche, il apparait que les résultats de celle-ci sont prometteurs. En effet, on a pu atteindre un PSNR moyen de 38.22 dB pour un rapport de compression moyen de 48.7. Nous rappelons que pour des images de bonne qualité, le PSNR varie entre 30 et 40 dB. Les résultats sont reportés à la figure IV.16 sous la forme de courbe de Rapport de Compression/Distorsion, mesurée à l'aide du PSNR. Pour ce dernier, on peut atteindre 39.43 dB pour un rapport de compression de 20.73. Les figures IV.17 et IV.18 donnent un aperçu sur la qualité des images obtenues en variant les hyper-paramètres du noyau. La phase de test a permis de constater que l'approche développée aboutit à des résultats de compression intéressants avec une bonne qualité de l'image. Cependant, il existe une présence remarquable de l'effet de blocs. Cet effet est dû au fait de partitionner nos images en blocs lors de l'application de l'apprentissage SVM.

Les expériences réalisées montrent bien que le temps d'exécution est un inconvénient majeur pour cette méthode. Une question naturelle est donc de savoir s'il est possible d'améliorer ce paramètre. D'un autre côté, l'effet de bloc est un autre inconvénient qu'on doit prendre en considération pour améliorer la qualité de ces images.

Les résultats présentés ici semblent prometteurs, tant du point de vue des performances de l'algorithme de compression défini que de la fiabilité des critères qualité.

Cependant, ces résultats restent à confirmer pour une base de test plus grande : plus d'images et plus d'applications.

On a vu que cette méthode donne des résultats positifs. Il serait intéressant de raffiner cette méthode par le choix de meilleurs paramètres pour le noyau SVM et envisager une amélioration en termes de temps d'exécution.

Conclusion

Au cours de ce mémoire, nous avons abordé le problème de la compression des images hyperspectrales. Nous avons notamment étudié le système d'acquisition (des instruments), les données (propriétés statistiques), le cadre d'évaluation et le codage (transformées, codage entropique) de ces images. Après une étude bibliographique, rapportée dans le premier chapitre, nous avons constaté que la problématique de stockage, de traitement et de transmission de ces images, ne peut être résolue convenablement sans recourir aux techniques de compression.

Le chapitre 2 rentre dans le vif du sujet en présentant les constructions des bases d'Ondelettes et en développant la partie théorique de la méthode de régression que nous avons décidé d'utiliser : la régression par les machines à vecteurs supports. Cette méthode possède certains avantages :

- la forme de la fonction de perte linéaire d'insensibilité ε utilisée par les machines à vecteurs supports lui assure une certaine robustesse,
- les deux paramètres ε et C règlent respectivement la largeur de la marge (l'insensibilité de la fonction de perte) et le compromis entre la simplicité de la solution et l'attache aux données,
- les vecteurs supports dépendent directement des variables duales, permettant ainsi d'identifier les outliers (les données étranges) dans l'ensemble de données.

Dans un deuxième temps, nous nous sommes attachés au cœur de ce travail, c'est-à-dire au développement d'une méthode de compression d'images hyperspectrales. Nous sommes partis du constat des dépendances qui subsistent entre coefficients après transformée en ondelettes pour obtenir une approche de compression qui devait donner le meilleur compromis possible entre le taux de compression et la qualité de restitution des images. Donc l'approche développée devait satisfaire impérativement les critères suivants :

- Réaliser une réduction de dimension,
- Une image reproduite fidèlement.

Nous avons proposé une méthode permettant de combiner les SVM et les ondelettes pour répondre à cette problématique. Cette méthode consiste à appliquer un apprentissage régressif SVM sur les coefficients issus de la transformée en ondelettes biorthogonales appliquée sur les images hyperspectrales. Différentes expérimentations ont été menées pour aboutir au bon choix des différents paramètres des ondelettes et des SVM afin d'apprécier qualitativement le bon fonctionnement de l'approche [109].

Dans un dernier chapitre, nous avons présenté et discuté les résultats de l'application de cet algorithme. Nous avons alors montré expérimentalement que notre approche permet d'atteindre des rapports de compression élevés avec une bonne qualité des images. En effet, on a pu atteindre un PSNR moyen de 38.22 dB pour un rapport de compression moyen de 48.7. En variant les hyper-paramètres du noyau utilisé par les SVM, on peut obtenir un PSNR allant jusqu'à 39.43 dB pour un rapport de compression de 20.73. La comparaison de cette approche avec d'autres approches montre des résultats compétitifs en terme de performances.

Les apports de cette thèse concernent la comparaison des résultats obtenus des trois noyaux SVM et l'application de l'algorithme développé sur un ensemble d'images tests. La principale contribution concerne l'application de cet algorithme sur les images hyperspectrales.

Enfin, l'application temps réel de la régression par les machines à vecteurs supports soulève quelques difficultés de par la complexité calculatoire et le nombre de données. Cela nécessite une optimisation de l'algorithme, aussi bien au niveau du code que de l'approche elle-même (échantillonnage par exemple), on trouve déjà dans la littérature quelques développements dans cette optique [110], [111]. Une implémentation dans un langage offrant une meilleure portabilité et rapidité que Matlab est également une solution à envisager (langage JAVA, plateforme CUDA, ...). D'un point de vue matériel, l'utilisation de processeurs multi-cœurs ou de multiprocesseurs permettrait de paralléliser les calculs.

Annexe I

Le tableau 1 recense les capteurs hyperspectraux aéroportés qui sont les plus connus

Tableau.1. Les capteurs hyperspectraux aéroportés

Capteur	Nom Complet	Opérateur/Pays	Bandes	Gamme Spectrale (μm)
AVIRIS	Airborne Visible Infrared Imaging Spectrometer	NASA/JPL USA	224	0.4 - 2.5
HYDICE	Hyperspectral Digital Imagery Collection Experiment	Naval Research Laboratory USA	210	0.4 - 2.5
HYMAP	Hyperspectral Mapper	Integrated Spectronics Co. Australia	100/200	VIS-TIR
CASI	Compact Airborne Spectrographic Imager	Itres Research Canada	228 (max.)	0.1 - 1.0
PROBE-1	-	Earth Search Sciences Inc. USA	128	0.4 - 2.5
EPS-H	Envirenmental Protection System	GER Co.	182	VIS/NIR SWIR,TIR
DAIS 7915	Digital Airborne Imaging Spectrometer	GER Co.,DLR Germany	79	VIS/NIR SWIR,MIR,TIR
DAIS 21115	Digital Airborne Imaging Spectrometer	GER Co.,DLR Germany	211	VIS/NIR SWIR,MIR,TIR
AISA	Airborne Imaging Spectrometer	Specim Ltd. Finland	228	0.43 - 1.0
MODIS	Moderate Resolution Imaging Spectrometer	NASA USA	36	0.41 - 14.24
MIVIS	Multispectral Infrared and Visible Imaging Spectrometer	Daedalus Enterprise Inc. Italy	102	VIS/NIR MIR,TIR

Le tableau 2 inclut les capteurs hyperspectraux portés par satellites. Ils sont moins nombreux par rapport aux capteurs aéroportés mais il existe beaucoup de programmes d'IHS pour étudier et développer prochainement de nouveaux capteurs.

Tableau. 2. Les capteurs hyperspectraux spatiaux

Capteur	Nom	Opérateur/ Pays	Bandes	Gam. Spect. (μm)	Résolution Spatiale (m)
HYPERION	EO-1	NASA Goddard USA	220	0.4 - 2.5	30
FTHSI	MightySatII	Air Force Research Lab USA	256	0.475 - 1.05	30
Orbview-4	Airforce Warfighter-1	Air Force Research Lab USA	200	0.4 - 2.5	8
SSTI HSI	Small Satellite Technology Initiative Hyperspectral Imager	TRW Inc. NASA USA	384	0.4 - 2.5	30
NEMO	Naval Earth Map Observer	Office of Naval Research USA	220	0.4 - 2.5	30/60

Bibliographie

- [1] Shannon, C. E., (July and October 1948) A mathematical theory of communication. Bell System Technical Journal, 27: 379–423 and 623–656.
- [2] ISO AND CCIT, Digital and coding of continuous-tone still images. ISO/IEC 10918-1,2,3 Information Technologie.
- [3] ISO/IEC JTC1/SC2/WG11. Coding of moving pictures and associated audio for digital storage media at up about 1.5 Mbps. ISO/IEC 11172.
- [4] Robinson, J., Kecman, V. (2003) Combining support vector machine learning with the discrete cosine transform in image compression. IEEE Trans, Neural Networks, 14 (4) 950–958.
- [5] Chang, C., (2007) Hyperspectral Data Exploitation. Wiley Edition.
- [6] Rast, M. (1991) Imaging spectroscopy and its applications in spaceborne systems. European Space Agency Publications ESA SP-114, Noordwijk, Netherland, page 114.
- [7] Goetz, A.F.H., Vane, G., Solomon, J. E., Rock, B. N. (1985) Spectrometry for earth remote sensing. Science, 228:1147–1153.
- [8] Landgrebe, D. (1999) Some fundamentals and methods for hyperspectral image data analysis. In SPIE Int. Symp. on Biomedical Optics (Photonics West), San Jose CA, p.104–113.
- [9] Ehlers, M. (2003) Remote sensing for gis applications: New sensors and analysis methods. Remote Sensing for Environmental Monitoring, GIS Applications, and Geology III, SPIE.
- [10] JPL/NASA : *AVIRIS documaentations and application*. JPL/NASA.
- [11] Robert O. Green and *al.* (1998) Imaging Spectroscopy and the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS), Elsevier Science Inc.
- [12] EO1/NAS: *EO1 documantations (new technology demonstrator satellite)*. NASA Earth Observer - 1, (<http://eo1.gsfc.nasa.gov/>).
- [13] Aiazzi, B., Alparone, L., Baronti, S. (November 2001) Near-lossless compression of 3-D optical data. IEEE Transactions on Geoscience and Remote Sensing, vol. 39, no 11, p. 2547–2557.

- [14] Chang, C.I. (2003) *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. Kluwer Academic/Plenum Publishers, New York.
- [15] Richards, J.A., Jia, X. (1986) *Remote Sensing Digital Image Analysis*. Springer, 3rd edition, Verlag, Berlin.
- [16] Hyvarinen, A., Oja, E. (2000) Independent component analysis : algorithms and applications. *Neural Networks*, 13:411–430.
- [17] Zhu, Wei., Du, Qian., Fowler, James E. (2009) Segmented PCA and JPEG2000 for Hyperspectral Image Compression. *Proc of SPIE*, vol. 7455, 74550I.
- [18] Huang, Jing., Zhu, Rihong., (2009) Hyperspectral image compression using low complexity integer KLT and three-dimensional asymmetric significance tree. *Proc of SPIE*, vol 7444, 74440I.
- [19] Hou, Ying., (2009) Embedded zeroblock coding algorithm based on KLT and wavelet transform for hyperspectral image compression. *Proc of SPIE*, vol 7498, 74984Y.
- [20] Chang, Chein-I., Ramakrishna, Bharath., Wang, Jing., Plaza, Antonio. (3 December 2010) Low-bit rate exploitation-based lossy hyperspectral image compression. *Journal of Applied Remote Sensing*, vol 4, 041760.
- [21] Hyvarinen, A., Karhunen, E., Oja, J. (2001) *Independent Component Analysis*. John Wiley and Sons.
- [22] Hyvarinen, A. (1999) Survey on independent component analysis. *Neural Computing Surveys*, 2:94–128.
- [23] Grossman, A., Morlet, J. (July 1984) Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape, *SIAM J. of Math Anal*, vol 15, no. 4, p. 723-736.
- [24] Meyer, Y., (1990) *Ondelettes et Opérateurs* , Hermann, Paris.
- [25] Mallat, S. (1998) *Wavelet Tour of Signal Processing* – Academic Press, London.
- [26] Barlaud, M., (1995) *Wavelets in Image communications*. Elsevier, 1995.
- [27] CCSDS. (novembre 2005) *Image Data Compression Recommended Standard - CCSDS 122. 0-B-1 Blue Book*.

- [28] CCSDS. (Juin 2007) Image Data Compression Informational Report CCSDS 120. 1-G-1 Green Book.
- [29] Villasenor, J., Belzer, B., Liao, J. (1995) Wavelet filter evaluation for image compression. *IEEE Transactions on Image Processing*, 4(8), p. 1053–1060.
- [30] ISO/IEC JTC 1/SC 29/WG 1. (Mars 2000) JPEG 2000 Part I Final Committee Draft Version 1.0. JPEG 2000 Editor Martin Boliek.
- [31] Taubman, D. S., Marcellin, M. W. (2002) *JPEG2000 Image Compression Fundamentals, Standards and Practice*. Kluwer Academic Publishers, Boston, MA.
- [32] Gersho, A., Gray, R.M. (1992) *Vector Quantization and Signal Compression*. Kluwer Academic Publishers.
- [33] Shapiro, J. M., (December 1993) Embedded image coding using zerotrees of wavelet coefficients. *IEEE Transactions on Signal Processing*, vol 41, no 12, p. 3445–3462.
- [34] Said, A., Pearlman, W. A. (Juin 1996) A new, fast, and efficient image codec based on set partitioning in hierarchical trees. *IEEE Transactions on Circuits and Systems for Video Technology*, vol 6, no 3, p. 243–250.
- [35] Robila, S. A. (2002) *Independent Component Analysis Feature Extraction for Hyperspectral Images*. Thèse de doctorat, Syracuse University, Syracuse, NY.
- [36] Lennon, M. (Décembre 2002) *Méthodes d'analyse d'images hyperspectrales. Exploitation du capteur aéroporté CASI pour des applications de cartographie agro-environnementale en Bretagne*. Thèse de doctorat, ENST-Bretagne, Brest.
- [37] Bijaoui, A., Nuzillard, D., Deb Barma, T. (December 2003) Séparation aveugle de sources, démixage de pixel et la classification, application en télédétection. Action spécifique de GDR-ISIS, ENST-Paris.
- [38] Nascimento, J. M. P., Dias, J. M. B. (2003) Does independent component analysis play a role in unmixing hyperspectral data. F.J. Perales, A. Campilho et N.P.B.A. Sanfeliu, éditeurs : *Pattern Recognition and Image Analysis (Lecture Notes in Computer Science, Springer-Verlag Heidelberg,)*, chapitre 616 - 625.

- [39] Wang, J., Chang, C.-I. (2006) Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis. *IEEE Trans, Geosci and Rem Sens*, 44(6), p. 1586-1600.
- [40] He, Mingyi., Bai, Lin., Syeda Narjis, Fatima. (2010) Hyperspectral Image Compression Algorithm Using Wavelet Transform and Independent Component Analysis, *Proc. of SPIE*, vol 7810, 781005.
- [41] Sujithra, D.S., Manickam, T., Sudheer, D.S. (March 2013) Compression Of Hyperspectral Image Using Discrete Wavelet Transform And Walsh Hadamard Transform. *International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE)*, vol 2, Issue 3.
- [42] Poonam, Chauhan, R.S. (2013) Compression and Classification of Hyperspectral Images using an Algorithm based on DWT and NTD. *Advance in Electronic and Electric Engineering*, ISSN 2231-1297, Volume 3, Number 4, p. 447-456.
- [43] ISO/IEC JTC 1/SC 29/WG 1. (Mars 2000) JPEG 2000 Part I Final Committee Draft Version 1.0. JPEG 2000 Editor Martin Boliek.
- [44] Image data compression green book June2007 <http://www.ccsds.org>
- [45] Burke Hubbard, B. (1998) Ondes et ondelettes- La saga d'un outil mathématique. Pour la Science, Paris, 1995. 2nd edn (1998) *The World According to Wavelets*. A.K. Peters, Wellesly, MA.
- [46] Rioul, O., Vetterli, M. (October 1991) Wavelets and signal processing, *IEEE SP Magazine*, p. 14-38.
- [47] Mallat, S. (September 1989) Multiresolution approximations and wavelet orthonormal bases of $L^2(R)$. *Trans Am Math Soc*, vol 315, N°1, p. 69-87.
- [48] Mallat, S. (December 1989) Multifrequency channel decomposition of images and wavelet models, *IEEE Trans, on Accoustic Speech and Signal Proc*, vol 37, N°12, p. 2091-2110.
- [49] Mallat, S. (July 1989) A theory for multiresolution signal decomposition: the wavelet representation. *IEEE PAMI*, vol 11, N°7, p. 674-693.
- [50] STEPHANE G. MALLAT, *MULTIRESOLUTION APPROXIMATIONS AND WAVELET ORTHONORMAL BASES OF $L^2(R)$* , pp,3.

- [51] Antonini, M., Barlaud, M., Mathieu, P. et Daubechies, I. (Avril 1992) Image coding using wavelet transform. *IEEE Trans. Image Proc.*, 1(2) p. 205-220.
- [52] Mallat, S. (2000) Une exploration des signaux en ondelettes. Les éditions de l'école polytechniques, 2000.
- [53] Baskurt, A., Khamadja, M., Baudin, O., Dupont, F., Prost, R., Revel, D. and Goutte, R. (December 1997) Adaptive image compression scheme. Application to medical images and diagnostic quality assessment *Journal Européen des Systèmes Automatisés JESA*, vol. 31, n° 7, p. 1155-1171.
- [54] Munteanu, P. A. and Cornelis, J. (Mars 2002) Wavelet Coding of volumetric Medical Data. *Proc. 3rd IEEE Benelux Signal Processing Symposium*, Louvain, Belgique.
- [55] Schelkens, P., Munteanu, A., Barbarien, J., Galca, M., Giro-Nieto, X., et Cornelis, J. (Mars 2003) Wavelet Coding of volumetric Medical Datasets, *IEEE Transactions on Medical Imaging*, vol 22.
- [56] Coifman, R.R., Mayer, Y., Quake, S. and Wickerhauser, M.V. (1991) Signal processing and compression with wavelets packets, in *Springer Berlin, and Masson, Paris*, p. 77-93.
- [57] Wickerhauser, M.V. (1994) *Adapted wavelets analysis: From Theory of Software*. A.K. Peters, Wellesly, Mass.
- [58] Sweldens, W. (1996) The lifting scheme: a costum design construction of biorthogonal wavelets. *Applied Comput, Harm, Anal.*, 3:1186-1200.
- [59] Daubechies, I. (November 1998) Orthonormal bases of compactly supported wavelets. *Com on Pure Appl, Math.*, vol. 41, p. 909-996.
- [60] Liu, J. et Moulin, P. (Novembre 2001) Information-theoretic analysis of interscale and intrascale dependencies between image wavelet coefficients. *IEEE Transactions on Image Processing*, 10(11), p. 1647–1658.
- [61] Simoncelli, E. P. (Juillet 1999) Modeling the joint statistics of images in the wavelet domain. Dans *Proc SPIE, 44th Annual Meeting*, tome 3813, p. 188–195. Denver, CO.
- [62] Buccigrossi, R. W. et Simoncelli, E. P. (December 1999) Image compression via joint statistical characterization in the wavelet domain. *IEEE Transactions on Image Processing*, 8(12), p. 1688–1701.

- [63] BISSON G., (2009). Intelligence artificielle
- [64] Vapnik, V. (1998) Statistical Learning Theory. Wiley, New York.
- [65] Cristianni, N. and Shawe-taylor, J. (2000) An introduction to support vector machines. Cambridge, University press.
- [66] Vapnik, V. The Nature of Statistical Learning Theory, *Second Edition*. Springer, New York, 1999.
- [67] Schölkopf, B. and Smola, A. J. (2000) Learning with Kernels: Support vector machines, regularization, optimization, and beyond, MIT Press.
- [68] Herbrich, R. (2002) Learning kernel classifiers: Theory and algorithms, MIT Press.
- [69] Chapelle, O. Haffner, P. and Vapnik, V. N. (September 1999) Support vector machines of histogram-based image classification. *IEEE Transactions on Neural Networks*, 10(5):1055–1064.
- [70] Cancedda, N., Gaussier, E., Goutte, C. and Michel Renders, J. (February 2003) Word sequence kernels. *Journal of Machine Learning Research*, 3:1059–1082.
- [71] Joachims, T. (1998) Text categorization with support vector machines. In *Proceeding of European conference on machine learning*.
- [72] Schölkopf, B., Tsuda, K. and Vert, J.-P. (2004) *Kernel methods in computational biology*. MIT press.
- [73] Kecman, V. (2001) Learning and Soft Computing: Support Vector Machines, Neural Networks, and Fuzzy Logic Models, The MIT Press.
- [74] Vapnik, V.N. (1995) The Nature Of Statistical Learning Theory.
- [75] Mercer, J. (1909) Functions of positive and negative type and their connection with the theory of integral equations. *Philos. Trans. Roy. Soc.*
- [76] Donoho, D. and Johnstone, I. (December 1994) Ideal spatial adaptation via wavelet shrinkage. *Biometrika*, 81 : 425–455.

- [77] Donoho, D.L. and Johnstone, I.M. (1994) Ideal denoising in an orthonormal basis chosen from a library of bases. *Comptes Rendus de l'Académie des Sciences, Serie 1*(319) :1317–1322.
- [78] Antonini, M., Barland, M., Mathien, P. and Daubechies, I. (April 1992) Image coding using wavelet transform. *IEEE Trans. Image Processing*, vol. 1, pp. 205-220.
- [79] Shapiro, J. M. (1993) Embedded image coding using zerotrees of wavelet coefficients, *IEEE Trans. Signal Processing*, vol. 41, p. 3445-3462.
- [80] Mandal, M. K., Panchanathan, S. and Aboulnasu, T. Choice of Wavelets for Image Compression, *Lecture Notes in Computer Science*, vol. 1133, p.239 -249
- [81] Hilton, M. L. (1994) Compressing Still and Moving Images with Wavelets. *Multimedia Systems*, vol 2, no 3.
- [82] Lu, J., Algazi, V. R. and Estes, R. R. (1996) Comparative study of wavelet image coders, *Optical Engineering*, vol. 35, no. 9, p. 2605 -2619.
- [83] JPEG2000 Committee. (July 2002) Jpeg 2000 image coding system, part1. *ISO/IEC JTC 1/SC 29/WG 1 N2678*, 19.
- [84] Karimi, Y., Prasher, S. O., Patel, R. M., and Kim, S. H. (2006). Application of support vector machine technology for weed and nitrogen stress detection in corn. *Computers and Electronics in Agriculture*, 51(1-2): 99–109.
- [85] Melgani, F. and Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machine. *IEEE Transactions on geoscience and remote sensing*, 42(8) :1778–1790.
- [86] Roli, F. and Fumera, G. (2001). Support vector machine for remote-sensing image classification. In *SPIE, editor, Image and Signal Processing for Remote Sensing VI*, volume 4170, pages 160–166.
- [87] Gualtieri, J. and Chettri, S. (2000). Support vector machines for classification of hyperspectral data. In *Geoscience and Remote Sensing Symposium (IGARSS)*, volume 2, pages 813–815, Honolulu, HI.
- [88] Ahmed Clerk, R. (Aug. 15- 17, 2005) Wavelet-Based Image Compression Using Support Vector Machine Learning And Encoding Techniques. *Proceeding of the eighth IASTED International Conference*, Honolulu, Hawaii, USA, p.162 -166.

- [89] Abirami, J., Siva sankari, S., Narashiman, K. (Apr-May 2013) Image compression based on Wavelet Support Vector Machine Kernels. International Journal of Engineering and Technology (IJET), Vol 5, N°2.
- [90] Jiao, R.H., Li, Y.C., Wang, Q.Y., Li, B. (2005) SVM Regression and its Application to Image Compression. Lecture Notes in Computer Science, v 3644, n PART I, Advances in Intelligent Computing. International Conference on Intelligent Computing, ICIC 2005, Proceedings, p.747-756.
- [91] Li, Y. and Hu, H. (2007) Image Compression Using Wavelet Support Vector Machines, ICIC 2007, LNCS 4681, p. 922-929.
- [92] Chen, J., Li, L. and Nei, N.Y. (2008) Wavelet Image Compression by Using Hybrid Kernel SVM. IEEE, p. 3056-3060.
- [93] Fazli, S., Toofan, S., Mehrara, Z. (April 2012) JPEG2000 Image Compression Using SVM and DWT. In International Journal of Science and Engineering Investigations, Volume 1, Issue 3.
- [94] Li, Y., Yang, Q., Jiao, R (2010) Image compression scheme based on curvelet transform and support vector machine. In: Expert Systems with Applications 37, 3063–3069.
- [95] Ouahioune, M., Akrou, L., Lahdir, M. and Ameer, S. (November 21-24, 2011) Compression d'images hyperspectrales par transformée en ondelettes 3D et SPIHT3D. International Conference on Signal, Image, Vision and their Applications SIVA'11, Guelma, Algeria.
- [96] Ouahioune, M. (2001) Mohand Compression d'images hyperspetrales par la transformée en ondelettes 3D. LAMPA- UMMTO, Algeria.
- [97] Chang, C.-C. and Lin, C.-J. (2002) Training support vector regression: Theory and algorithms. Neural Computation, 14(8):1959-1977.
- [98] Clark, R., Cristianini N. and Shawe-Taylor J. (2003) An introduction to Support Vector Machines and other kernel - based learning methods, Cambridge, University Press.
- [99] Jia, X. (1996) Classification techniques for Hyperspectral Remote sensing Image Data. Phd. thesis, Electrical engineering Department, University of Canberra, Australia.

- [100] Wang, XL., Han, H. and Peng SL (2004) Image Restoration Based on Wavelet-domain Local Guassian Model. *Jorunal of Software*, Vol. 15, No 3, p.433–450.
- [101] CHANG, C.-C. et LIN, C.-J. (2010). Library for support vector machines. National Taiwan University. URL <http://www.csie.ntu.edu.tw/~cjlin/libsvm/LIBSVM>.
- [102] Lahdir, M., Ameur, S. et Akrou, L. (2006) Compression d'images par un codage fractal non itératif Implémenté dans le domaine DCT. 4ème Conférence Internationale JTEA 2006, 12-14 Mai 2006, Tunisie.
- [103] Eskicioglu, A.M. et Fisher, P.S. (1995) Image quality measures and their performance. *IEEE Transactions on Communications*, 43(12) :2959–2965.
- [104] Christophe, E., Léger, D. et Mailhes, C. Quality criteria benchmark for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 43(9) :2103.
- [105] Cziho, A. (1999) Quantification vectorielle et compression d'image, application à l'imagerie médicale. Thèse de doctorat, école doctorale en informatique, traitement du signal et télécommunications, université de Rennes 1, France, p. 160.
- [106] Bertrand, F. et Gouyet, J. (1998) Systèmes de compression d'images fixes, outils pour la téléconsultation et la distribution sur réseaux de documents audiovisuels et multimédia. Institut national de l'audiovisuel, France, p. 9–73.
- [107] Delgorge, C. (2005) Proposition et Evaluation de techniques de compression d'images ultrasonores dans le cadre d'une télé échographie robotisée. Thèse de doctorat, Sciences et technologies industrielles université d'Orléans, France.
- [108] HE, M., BAI, L., SYEDA NARJIS, F. (2010) Hyperspectral Image Compression Algorithm Using Wavelet Transform and Independent Component Analysis. *Proc. of SPIE* Vol. 7810.
- [109] Zikiou, N., Lahdir, M., (2014) SVM Kernels for Image Compression. The International Conference on Computing Technology and Information Management ICCTIM 2014, Dubai, UAE.
- [110] Balcazar, J., Dai, Y. et Watanabe, O. (2002) Provably fast support vector regression using random sampling. Dans *SIAM Workshop in Discrete Mathematics and Data Mining*, p. 19–29.
- [111] Platt, J. (1998) Fast Training of Support Vector Machines using Sequential Minimal Optimization.

Résumé

Le travail présenté dans ce mémoire vise à proposer une approche de compression d'images hyperspectrales. Pour se faire, nous proposons un nouveau algorithme de compression d'images en utilisant la régression SVM (Machine à Vecteur de Support ou Séparateur à Vaste Marge) appliquée dans le domaine des ondelettes biorthogonales. L'image originale est décomposée par la transformée en ondelettes discrètes biorthogonales en approximations et détails (horizontaux, verticaux et diagonaux). La compression est réalisée en utilisant un codage différentiel DPCM sur les approximations des coefficients d'ondelettes afin de préserver l'information pertinente de l'image originale et les détails sont compressés en utilisant la régression SVM avec le modèle 'epsilon-SVR'. Les codages 'Run Length' et arithmétique sont appliqués pour le codage des vecteurs de support (SVs) et leurs poids (weights) correspondants. L'application de notre algorithme de compression sur un ensemble d'images tests a permis d'atteindre un rapport de compression de 18.37 pour un PSNR de 31.32 dB sur l'image "Lena". La comparaison entre les PSNR et les rapports de compression de quelques types de noyaux 'epsilon-SVR' appliqués sur plusieurs images tests, montre que cette méthode permet d'atteindre des rapports de compression élevés avec une très bonne qualité des images. Aussi, nous avons mis à profit les meilleurs paramètres obtenus par l'application de cet algorithme sur ces images tests pour les appliquer sur des images hyperspectrales ; nous avons utilisé une séquence de 32 canaux de la scène Yellowstone, acquise en 2006. Les résultats de cette application ont atteint un PSNR moyen de 38.22 dB pour un rapport de compression moyen de 48.7.

Mots-clés : Compression d'images hyperspectrales, Transformée en Ondelette Discrète Biorthogonales, Machine à Vecteur de Support (SVM), Régression, Noyaux, Codages RLE et Arithmétique.