

**ÉCOLE DOCTORALE MATHÉMATIQUES, INFORMATIQUE,
PHYSIQUE THÉORIQUE ET INGÉNIERIE DES SYSTÈMES**

LABORATOIRE : PRISME

Thèse présentée par :

Kaouthar TABIA

soutenue le : **16 Décembre 2019**

pour obtenir le grade de : **Docteur de l'Université d'Orléans**

Discipline/ Spécialité : **Sciences et Technologies Industrielles**

**Segmentation d'images hyperspectrales par des
méthodes basées graphes**

Thèse encadrée par :

Yves LUCAS

MCF HDR, Université d'Orléans

Xavier DESQUESNES

MCF, Université d'Orléans

Sylvie TREUILLET

MCF HDR, Université d'Orléans

RAPPORTEURS :

Jocelyn CHANUSSOT

Professeur, INP de Grenoble

Abderrahim ELMOATAZ

Professeur, Université de Caen

JURY :

Salah BOURENNANE

Professeur, Université Aix-Marseille

Jocelyn CHANUSSOT

Professeur, INP de Grenoble

Xavier DESQUESNES

MCF, Université d'Orléans

Abderrahim ELMOATAZ

Professeur, Université de Caen

David HELBERT

MCF HDR, Université de Poitiers

Rachid JENNANE

Professeur, Université d'Orléans

Yves LUCAS

MCF HDR, Université d'Orléans

Jean-Yves RAMEL

Professeur, Université de Tours

Remerciements

Mes travaux de thèse ont été réalisés au sein de l'équipe Image et Vision du laboratoire PRISME de l'université d'Orléans et financés par la région Centre-Val de Loire.

Je souhaiterais remercier le Conseil Général de la région Centre pour le soutien financier apporté à ce projet. Je tiens à exprimer ma reconnaissance et mes sincères remerciements envers mon directeur de thèse Yves LUCAS et mes deux encadrants Xavier DESQUESNES et Sylvie TREUILLET pour leur encadrement, leur soutien et leurs conseils prodigieux tout au long de ma thèse.

Je souhaite également remercier les professeurs Jocelyn CHANUSSOT et Abderrahim ELMOATAZ d'avoir accepté d'être les rapporteurs de ce mémoire, ainsi qu'aux professeurs Rachid JENNANE, Salah BOURENNANE, Jean-Yves RAMEL et David HELBERT pour avoir examiné mon travail.

Mes remerciements vont également à toutes les personnes du bureau de recherches géologiques et minières, qui ont contribué de près ou de loin à la réalisation de ce travail dans les meilleures conditions. J'adresse spécialement mes plus vifs remerciements à Audrey HOHMANN, Etienne DUCASSE, Gilles GRANDJEAN et Sebastien GOURDIER pour leur disponibilité, leur implication et leur assistance.

Un grand merci à mes collègues doctorants Fabrice, Asma, Omar, Khadija, Dian, Yassmin et Rania, pour leur sympathie, l'ambiance agréable et les bons moments partagés au laboratoire. Merci à Sylvie PLESSARD et Laure SPINA secrétaires du laboratoire pour leur dynamisme et leur gentillesse.

Ma pensée la plus émue est adressée à mes chers parents qui m'ont toujours soutenue même à l'autre bout de la méditerranée. Tous ces mots ne sauraient exprimer ma gratitude et ma reconnaissance pour leurs sacrifices. Je leur dédie cette thèse comme fruit de leur dévouement et l'expression de mon profond amour.

Je remercie également mes chers frères et sœurs pour leur soutien indéfectible. Je leur témoigne ici ma sincère reconnaissance et ma profonde gratitude. Je suis

chanceuse de vous avoir à mes côtés.

Je remercie aussi mon cher époux pour sa patience et son soutien inconditionnel pendant ces années, et aussi mon fils, Adam, qui nous a rejoint à mi-parcours et a apporté la chaleur et l'amour au sein de notre petite famille. Je le remercie d'avoir été gentil et patient durant mes nuits d'études. Sa présence me tenait compagnie, ses sourires m'apportaient joie et bonheur.

Encore une fois, je les remercie tous, ce mémoire de thèse leur est dédié.

Résumé

Dans le cadre de cette thèse, nous présentons une nouvelle approche pour la segmentation d'images hyperspectrales. Pour cela, nous avons focalisé notre intérêt sur les représentations par graphes et nous avons proposé une approche composée de deux phases principales. Lors de la première phase, un graphe pondéré est construit pour représenter l'image hyperspectrale. La segmentation de l'image est par la suite déduite de la segmentation du graphe construit. Afin de construire un graphe pondéré qui représente efficacement l'image hyperspectrale, nous avons étudié plusieurs topologies telles que graphe complet, 4-voisinage, RAG et la notion de patch. Elles décrivent le nombre ainsi que la structure des sommets du graphe. Nous avons également analysé différentes métriques pour l'estimation de la similarité spectrale entre ces sommets. Les métriques analysées sont indispensables pour pondérer les arrêtes reliant chaque paire de sommets. Notre approche a été évaluée sur deux jeux de données, notamment une base d'images hyperspectrales exclusivement synthétisée pour valider l'approche, ainsi qu'un ensemble d'images hyperspectrales réelles prises sur différents sites avec divers capteurs. Comparé avec les autres méthodes de l'état de l'art, les résultats obtenus sur ces différentes images démontrent l'efficacité et la pertinence de notre approche.

Mots-clés : Image hyperspectrale, segmentation, graphe, méthode des ensembles de niveaux

Abstract

Hyperspectral image analysis has become an important research topic in the remote sensing community. Additionally, image segmentation attracts enormous research attention in the computer vision community. Several segmentation methods have been proposed in both communities. However most of them only consider particular features in the hyperspectral image. Remote sensing based methods generally focus on the spectral information, whereas computer vision based methods find more interest in the gray scale information. In this thesis, we propose to narrow the gap between these communities and propose an hyperspectral image segmentation method which simultaneously exploits spectral and spatial information. To do so, we first model an hyperspectral image using a graph representation which faithfully codes both its spectral and spatial information. Secondly, we propose to segment the constructed graph using a level set based method. The hyperspectral image segmentation is then deduced from the segmentation of the constructed graph. We extensively studied and analyzed different graph construction aspects (i.e., graph topologies and metrics). We also evaluated the segmentation method on two datasets. The first has been exclusively synthesized to validate the proposed approach. The second contains a set of well-known and real hyperspectral images taken on different locations and with various sensors.

The obtained results show the efficiency and the superiority of our proposed approach compared to other state-of-the-art methods.

Keywords : Hyperspectral image, segmentation, graph, level set method

Sommaire

Sommaire	v
Liste des tableaux	ix
Liste des figures	xi
Introduction	1
0.1 Image hyperspectrale	3
0.2 Segmentation d’une image hyperspectrale	5
0.3 Traitement par graphe	7
0.4 Contributions	8
0.5 Organisation de la thèse	9
1 Graphes	11
1.1 Introduction	12
1.2 Définitions et notations	13
1.3 Topologie du graphe	14
1.3.1 Graphe complet	15
1.3.2 Graphe de ϵ -voisinage	15
1.3.3 Graphe d’adjacence de région	17
1.4 Similarité, Métrique et Fonction de poids	17
1.4.1 Fonctions et vecteurs caractéristiques	18

1.4.2	Fonction de poids	21
1.4.3	Métrie	21
1.5	Opérateurs sur graphe	22
1.6	Partitionnement du graphe	24
1.7	Conclusion	27
2	Segmentation par ensembles de niveaux sur graphe	29
2.1	Introduction	30
2.2	Le problème de Mumford et Shah	32
2.3	Méthode des ensembles de niveaux	33
2.4	Modèle deux-phases de Chan et Vese	35
2.5	Modèle multi-phases de Chan et Vese	37
2.6	Transcription de la méthode d'ensembles de niveaux sur graphe . . .	39
2.7	Adaptation des modèles de Chan et Vese sur graphe pour la segmen- tation des images hyperspectrales	41
2.7.1	Modèle deux-phases	41
2.7.2	Modèle multi-phases	42
2.8	Conclusion	43
3	Métriques pour la comparaison de spectres	45
3.1	Introduction	46
3.2	Métriques spectrales	47
3.3	Évaluations et résultats	50
3.3.1	Transformations de spectre	51
3.3.2	Résultats	53
3.4	Conclusion	55
4	Expérimentations sur des images de synthèse	57
4.1	Introduction	58
4.2	Base d'images hyperspectrales synthétiques	59

4.2.1	Génération des images de synthèse	60
4.2.2	Protocole de simulation	63
4.3	Résultats et discussion	64
4.3.1	Graphe complet	66
4.3.2	Graphe 4-voisinage	68
4.3.3	Graphe d'adjacence de région	71
4.4	Conclusion	76
5	Expérimentations sur des images réelles	79
5.1	Introduction	80
5.2	Base d'image hyperspectrales réelles	81
5.2.1	Image de Pavia University	81
5.2.2	Image Indian Pines	81
5.2.3	Image Salinas	83
5.3	Résultats et discussion	83
5.3.1	Graphe complet	84
5.3.2	Graphe 4-voisinage	88
5.3.3	Graphe d'adjacence de régions	90
5.3.4	Graphe ϵ -voisinage étendu basé sur des patches	93
5.4	Application aux images du BRGM	97
5.5	Conclusion	99
	Conclusion générale	101
	Bibliographie	107

Liste des tableaux

4.1	TC moyen de segmentation de 350 images hyperspectrales synthétiques sur un graphe complet avec les différentes métriques spectrales	67
4.2	TC moyen de segmentation de 350 images hyperspectrales synthétiques sur un graphe 4-voisinage avec les différentes métriques spectrales	70
4.3	TC moyen de segmentation de 350 images hyperspectrales synthétiques sur un RAG avec les différentes métriques spectrales	75
5.1	Évaluation des méthodes de segmentation sur graphe complet avec différentes métriques spectrales en calculant OS et JI moyen	88
5.2	Évaluation des méthodes de segmentation sur graphe 4-voisinage avec différentes métriques spectrales en calculant le OS et JI moyen	90
5.3	OS et JI moyen de segmentation d'images hyperspectrales réelles sur un graphe d'adjacence de régions	92
5.4	OS et JI moyen de segmentation sur un graphe de ϵ -voisinage étendu basé sur des patches LBP	98

Liste des figures

1	Exemple d'une image hyperspectrale	4
1.1	Exemple d'un graphe ϵ -voisinage avec $\epsilon \leq 1$	16
1.2	Exemple d'un graphe d'adjacence de régions (RAG)	18
1.3	Exemple de patches	20
1.4	Relation entre la segmentation d'image et le partitionnement du graphe	25
2.1	Courbe représentée par le niveau zéro de la fonction des ensembles de niveaux ϕ	34
2.2	Fonctions de Heaviside et de Dirac	36
2.3	Deux courbes divisant l'image en quatre régions	38
2.4	Représentation discrète d'une courbe évolutive	40
3.1	Les spectres de l'image hyperspectrale Pavia University	51
3.2	Translation spectrale	52
3.3	Changement d'amplitude	53
3.4	Mélange linéaire	54
4.1	Exemple de deux spectres générés aléatoirement	63
4.2	Simulation d'un spectre interne	64
4.3	Exemple d'images hyperspectrales synthétiques	65
4.4	Illustration de la segmentation quatre-phases de trois images synthé- tiques représentées par un graphe complet	66

LISTE DES FIGURES

4.5	TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un graphe complet en fonction des métriques spectrales	68
4.6	TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un graphe complet en fonction de la valeur de β .	69
4.7	Illustration de la segmentation quatre-phases de trois images synthétiques représentées par un graphe 4-voisinage	70
4.8	TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un graphe 4-voisinage en fonction de la valeur de β .	71
4.9	TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un graphe 4-voisinage en fonction des métrique spectrales	72
4.10	Construction d'un graphe à partir d'une image hyperspectrale synthétique	73
4.11	Illustration de la segmentation quatre-phases de trois images synthétiques représentées par un RAG	74
4.12	Exemple de deux masques représentant les deux fonctions des ensembles de niveaux évoluant sur le graphe associé à l'image hyperspectrale	74
4.13	TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un RAG en fonction de la valeur de β .	75
4.14	TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un RAG en fonction des métrique spectrales	76
4.15	Comparaison globale de TC moyen obtenus avec toutes les combinaisons possibles entre les métriques spectrales et les topologies de graphes	77
5.1	Image de Pavia University	82
5.2	Image Indian Pines	82
5.3	Image de Salinas	83

5.4	Les quinze régions d'intérêt extraites (a) de l'image de l'Université de Pavia (b) de l'image Indian Pines et (c) de l'image Salinas	84
5.5	Comparaison de la méthode deux-phases avec les méthodes NC et GC sur graphe complet	86
5.6	Comparaison de la méthode quatre-phases avec les méthodes NGC et GC sur graphe 4-voisinage	89
5.7	Segmentation quatre-phases sur un RAG	91
5.8	Calcul de code LBP	94
5.9	Calcul de distance de Hamming entre deux codes LBP	96
5.10	Segmentation quatre-phases sur un graphe de ϵ -voisinage basé sur des patches LBP	97
5.11	Segmentation quatre-phases des images du BRGM sur un graphe de ϵ -voisinage étendu basé sur des patches LBP	100

Introduction

Les êtres humains peuvent percevoir non seulement l'intensité de la lumière mais aussi la couleur. La vision trichromatique des couleurs résulte de trois types de photorécepteurs couleur sensibles à trois spectres larges et différents dans la lumière visible, centrés respectivement sur le bleu, le vert et le rouge. En effet, à partir du signal généré en un point de la rétine par chacun des trois types de réponse spectrale, le cortex visuel est capable d'élaborer la sensation de couleur. Alors que l'œil humain sépare difficilement plus d'une douzaine de teintes de gris plus ou moins claires, il est capable de différencier plusieurs millions de couleurs. Pourtant, l'œil humain ne dispose que de trois canaux d'acquisition dans le domaine 0.4 à 0.8 μm de longueur d'onde (bande visible) et sa résolution spectrale est limitée car ces trois canaux sont des pics larges et très arrondis qui se chevauchent. Le développement technologique a néanmoins permis de mettre au point différents outils pour capter et caractériser un rayonnement lumineux par des grandeurs photométriques ou énergétiques, en introduisant différents instruments optroniques. Par exemple, un spectromètre est utilisé pour mesurer l'irradiance spectrale en un point unique, et une caméra RGB conventionnelle intègre l'irradiance sur le domaine visible dans une région d'intérêt. Un imageur hyperspectral peut obtenir simultanément ces informations spatiales et spectrales.

Une image hyperspectrale contient généralement des dizaines, voire des centaines, de bandes spectrales étroites indexées en longueur d'onde de lumière continue, offrant une résolution spectrale très supérieure à celle de la vision humaine ou des

caméras RGB classiques. Le spectre qu'il couvre ne se limite pas au domaine visible mais peut s'étendre également aux bandes ultraviolettes ou infrarouges en fonction de la réponse spectrale du capteur. L'apparence d'un objet résulte en fait de son interaction avec les sources lumineuses qui l'entourent : une partie est réfléchie, une autre est absorbée et parfois une partie est transmis à travers le matériau. Ce bilan énergétique doit être effectué pour chaque longueur d'onde émise par les sources lumineuses et dépend de la nature des matériaux recevant le flux lumineux.

Par conséquent, une image hyperspectrale est en relation avec les propriétés physiques ou chimiques des objets. En raison de sa grande capacité à identifier et discriminer différents matériaux, l'imagerie hyperspectrale a été largement utilisée en télédétection pour analyser la surface de la terre pour des applications telles que l'exploitation minière, le domaine militaire, l'agriculture, la surveillance de l'environnement.

L'introduction de l'imagerie hyperspectrale dans les applications de vision par ordinateur pendant la dernière décennie a été favorisée par l'émergence des caméras hyperspectrales de bas coût et de haut débit avec une bonne résolution spatiale et spectrale. En fournissant des informations supplémentaires dans le domaine spectral, l'imagerie hyperspectrale offre un grand potentiel pour améliorer de nombreuses tâches fondamentales et délicates de la vision par ordinateur, telles que l'analyse de scène, le traitement de documents, la classification d'objets et la segmentation d'images.

Pour profiter au mieux de la richesse des images hyperspectrales, il est essentiel d'exploiter efficacement les deux types d'informations qu'elles contiennent : spatiale et spectrale. Néanmoins, la grande dimensionnalité de ces images complique leur traitement et rend difficile l'application des algorithmes classiques de traitement et d'analyse d'images, en particulier les approches de segmentation. En effet, la majorité des approches existantes utilisent ces informations séparément, soit en modélisant les spectres de l'image comme des points dans un espace de grande dimen-

sion [1] ou en ne considérant que l'information spatiale pour appliquer ainsi les approches classiques sur chaque bande individuellement [2]. Étant donné l'importance des informations contenues dans l'image hyperspectrale, une approche judicieuse et performante serait capable d'exploiter ces deux types d'informations conjointement.

Les méthodes basées graphes, qui représentent une image par un graphe pondéré, permettent de s'affranchir de cette limitation en exploitant simultanément les informations spatiales et spectrales. En effet, sous forme de graphe, chaque pixel est représenté par un ou plusieurs nœuds qui peuvent être connectés à leurs voisins, tant sur le plan spatial que spectral.

Dans le cadre de cette thèse, nous avons développé une approche de segmentation d'images hyperspectrales qui exploite les deux types d'informations spectrale et spatiale. Elle débute par la représentation de l'image sous forme d'un graphe construit en associant à chaque sommet du graphe un ou plusieurs pixels voisins et en pondérant les arêtes du graphe par une mesure de similarité spectrale.

0.1 Image hyperspectrale

L'imagerie hyperspectrale [3] est une technique d'imagerie passive qui renvoie, pour une scène considérée, une centaine d'images représentant des mesures de radiance, chacune des images étant dans une longueur d'onde différente comprise en général entre $0.4 \mu\text{m}$ et $3 \mu\text{m}$ (visible et proche infrarouge). Une image hyperspectrale peut donc être assimilée à un cube de données, les données étant des radiances mesurées pour chaque longueur d'onde et pour chaque zone ou pixel de l'image.

Les bandes spectrales sont étroites et en général presque contiguës, souvent avec un pas fixe de 10 nm, pour permettre une exploitation plus facile des données [4]. L'imagerie hyperspectrale se différencie de l'imagerie multispectrale ou super spectrale par le nombre de longueurs d'onde considérées. En télédétection, les images proviennent typiquement de spectromètres hyperspectraux qui mesurent des valeurs de radiance issues de la réflexion de la lumière solaire, et qui sont souvent embarqués

dans des aéronefs survolant la scène étudiée, tels que des avions ou des satellites.

Certaines longueurs d'onde ne peuvent ainsi pas être considérées car elles sont situées dans la bande d'absorption de l'atmosphère [5]. La résolution spatiale est, quant à elle, en général de l'ordre de dizaine de mètre. Cette résolution dépend du champ de vision du spectromètre, lui même dépendant de la taille des détecteurs, de leur résolution spatiale, mais aussi de l'altitude à partir de laquelle l'image est prise.

La figure 1 montre un exemple d'image hyperspectrale, où X et Y représentent les dimensions spatiales, tandis que sur l'axe perpendiculaire au plan spatial se trouvent les différentes longueurs d'ondes considérées.




FIGURE 1 – Exemple d'une image hyperspectrale : (a) cube hyperspectral, (b) spectre de réflectance d'un pixel donné.

Les domaines d'utilisation des images hyperspectrales sont assez variés. Ils peuvent aller des applications militaires (pour la surveillance de zones stratégiques par exemple) aux applications médicales, en passant par l'astronomie (pour la détection et la détermination de la composition de corps célestes) et l'agronomie (par exemple pour l'évaluation de la composition des sols) [5].

Étant donné ce large éventail de domaines de recherche et d'applications, la

segmentation des images hyperspectrales doit extraire des informations spécifiques pour prédire les catégories de cibles dans la scène imagée, par exemple la séparation des objets de la scène, la détection de la saillance et l'étiquetage des images, etc. En vision par ordinateur, les images hyperspectrales n'ont pas été largement utilisées en raison du manque de données à grande échelle. La plupart des tâches de segmentation d'image utilisent encore des images en niveaux de gris ou en couleurs (RGB).

Alors que l'imagerie hyperspectrale donne accès à des données plus précieuses et plus abondantes que dans les images en niveaux de gris et RGB, il est cependant nécessaire d'extraire et d'exploiter ces informations pour diverses tâches.

Un ensemble de méthodes de segmentation ont été développées en télédétection et en vision par ordinateur au cours des dernières décennies. Cependant, la plupart de ces méthodes se concentrent sur des informations spectrales au niveau des pixels en télédétection ou des informations spatiales à niveaux de gris ou en couleur en vision par ordinateur. Il fallait auparavant choisir entre une résolution spectrale élevée et une résolution spatiale faible en télédétection, et l'inverse en vision par ordinateur.

Pour les images hyperspectrales, des informations spectrales détaillées et une résolution spatiale fine permettent d'analyser à la fois la nature des matériaux et la structure des objets dans une scène. Cependant, la plupart des méthodes existantes ne conviennent pas à cette tâche en raison des contraintes mentionnées ci-dessus. Par conséquent, il est nécessaire de développer de nouvelles techniques pour exploiter les informations spatiales et spectrales sous-jacentes dans les images hyperspectrales.

0.2 Segmentation d'une image hyperspectrale

En général, les méthodes de segmentation partitionnent une image en régions homogènes par rapport à un critère d'intérêt ou à un critère d'homogénéité (par exemple, basé sur l'intensité ou sur la texture). Par conséquent, chaque région issue de la segmentation peut être vue comme un voisinage spatial connecté pour tous

les pixels de cette région. Parmi les première méthodes de segmentation spectro-spatiales de la littérature, on peut citer l'approche de Ketting et Landgrebe [6] , qui a été largement utilisé par la communauté de la télédétection. Elle est basée sur la croissance de région où on constitue des groupes homogènes de pixels adjacents, regroupés en des objets uniques par un maximum de vraisemblance.

Depuis ces travaux, différentes méthodes ont été proposées pour la segmentation d'images hyperspectrales, telles que les lignes de partage des eaux [7] et les algorithmes de clustering (ISODATA « et » squared-error clustering method» et EM expectation maximization) [8]. La segmentation automatique d'image hyperspectrale est toutefois une tâche complexe. Deux défis notamment restent à surmonter : le premier est lié à la grande dimensionnalité des bandes spectrales, le second au manque de données de vérité terrain, ce qui freine la mise en œuvre d'algorithmes d'apprentissage. De plus du fait de la structure des images hyperspectrales (informations spectrales et spatiales), la plupart des méthodes de segmentation existantes ne s'appliquent pas correctement. En effet ces méthodes se concentrent sur des informations spectrales au niveau des pixels en télédétection ou sur des informations spatiales à niveaux de gris en vision par ordinateur.

Xu et al. [9] ont exploré la représentation matricielle de rang faible pour intégrer à la fois des informations spatiales et spectrales, puis prédire la classe de chaque pixel de l'image avec un algorithme SVM. Yuan et al. [10] ont proposé une méthode de segmentation, qui utilise à la fois des informations spectrales et des informations de texture. Des filtres linéaires ont été utilisés pour fournir des modèles spatiaux améliorés. Pour chaque emplacement de pixel, des caractéristiques spectrales et de texture combinées sont calculées à l'aide d'histogrammes spectraux, qui concaténent les histogrammes locaux de toutes les bandes en entrée. Gillis et al. [11] ont proposé de représenter une image hyperspectrale sous la forme d'un graphe pondéré dont les sommets sont les pixels de l'image et les arêtes définies comme reliant des voisins spatiaux ; les poids sur les arêtes sont donnés par une combinaison pondérée des

distances spatiales et spectrales entre les sommets. L'un des principaux avantages de l'approche de Gillis et al. est que la structure du graphe incorpore naturellement les informations spatiales et spectrales présentes dans l'image hyperspectrale. L'utilisation de la représentation par graphe en vision par ordinateur n'est pas nouveau. On rencontre dans la littérature plusieurs travaux allant des tâches de traitement d'image de bas niveau, comme par exemple la caractérisation d'images, aux tâches de plus haut niveau, telles que la classification et la reconnaissance d'objet. Dans la section suivante, nous rappelons brièvement quelques travaux en traitement d'images utilisant la théorie des graphes.

0.3 Traitement par graphe

Les graphes sont des outils mathématiques couramment utilisés en traitement et analyse d'images notamment pour la segmentation. La théorie des graphes a été introduite au XVIIème siècle par le mathématicien Leonhard Euler qui apporta ainsi une réponse au célèbre problème des sept ponts de Königsberg [12].

Depuis ces travaux, la théorie des graphes a été appliquée dans de nombreux domaines (par exemple pour représenter divers réseaux routiers, ferrés, de canalisations, électriques, informatiques) et pour la résolution des problèmes inhérents (recherche du débit maximal, du plus court chemin, du goulot d'étranglement d'un réseau, etc). Les graphes sont également très utilisés en traitement et analyse d'images, notamment pour caractériser une image et reconnaître ses objets [13, 14]. La segmentation d'images couleur a également bénéficié de l'utilisation des graphes. Felzenszwalb et al. [15] ont défini un prédicat pour mesurer l'évidence d'une frontière entre deux régions en utilisant une représentation par graphe de l'image RGB. Ils ont ensuite développé un algorithme de segmentation basé sur ce prédicat, et montré que même si cet algorithme prend des décisions grossières, il produit des segmentations satisfaisant les propriétés globales.

Dans leurs travaux, Boykov et al. [16], ont décrit une technique de segmenta-

tion itérative d'images. Une étape de clustering est appliquée pour marquer certains pixels comme "objet" ou "arrière-plan" afin de fournir des contraintes strictes pour la segmentation. Des contraintes supplémentaires intègrent à la fois des informations de frontière et de région. Les méthodes Graph-cuts permettent de trouver la segmentation optimale globale de l'image. La solution obtenue donne le meilleur équilibre entre les propriétés des frontières et des régions parmi toutes les segmentations satisfaisant les contraintes.

Shi et Malik [17] ont également traité la segmentation d'images comme un problème de partitionnement de graphes et ont proposé un nouveau critère global dit de « coupe normalisée », pour segmenter un graphe. Le critère de sélection normalisé mesure à la fois la dissimilarité totale entre les différents groupes ainsi que la similarité totale au sein des groupes. Shi et Malik ont appliqué cette approche à la segmentation d'images RGB statiques et de séquences d'images.

0.4 Contributions

L'objectif principal de cette thèse est donc de développer une approche de segmentation basée graphes adaptée aux images hyperspectrales. Nous avons focalisé notre intérêt sur les représentations par graphes car la structure de ces représentations facilite l'incorporation des informations spatiales et spectrales présentes dans l'image hyperspectrale. Nous avons donc proposé une approche composée de deux phases principalement :

- (1) La construction d'un graphe pondéré pour représenter l'image hyperspectrale.
- (2) La segmentation de l'image déduite de la segmentation du graphe associé.

Notre approche de segmentation étend le modèle de segmentation proposé par Chan et Vese [18] pour des images couleur aux images hyperspectrales. Elle exploite ainsi la puissance de la représentation par graphe et la rigueur du formalisme des équations aux différences partielles.

Dans ce manuscrit, nous présentons l'ensemble des contributions issues de cette

thèse qui sont :

- La représentation d’une image hyperspectrale par un graphe pondéré par différentes topologies.
- L’adaptation du modèle de segmentation à deux phases de Chan et Vese sur les images hyperspectrales.
- L’introduction d’un modèle de segmentation multi-phase pour les images hyperspectrales en se basant sur l’algorithme de Chan et Vese.
- L’étude et l’évaluation de l’influence de l’utilisation de différentes métriques et différentes topologies de graphe sur les résultats de segmentation.
- La création d’une base d’images hyperspectrales synthétiques.
- La validation des algorithmes de segmentation proposés sur les images synthétiques et des images réelles et leur évaluation par rapport à un ensemble de méthodes de l’état de l’art.

0.5 Organisation de la thèse

Ce manuscrit est divisé en cinq chapitres. Dans le chapitre 1, nous introduisons les différentes notions et définitions nécessaires à la bonne compréhension du manuscrit. Dans ce chapitre, nous rappelons brièvement quelques notions de la théorie de graphes avant de présenter les différentes topologies de graphe utilisées dans nos travaux. Nous rappelons ensuite les différents opérateurs basés sur des équations aux différences partielles, qui sont les constituants principaux de l’approche développée dans cette thèse.

Le chapitre 2 présente notre adaptation discrète sur graphe du modèle de Chan et Vese à deux phases [19] pour la segmentation d’images hyperspectrales avec une seule courbe évolutive, représentée par la fonction des ensembles de niveaux. Nous introduisons par la suite une transcription du modèle de Chan et Vese multi-phases avec plusieurs courbes évoluant simultanément sur un graphe pondéré.

Dans le chapitre 3, nous présentons plusieurs mesures de distance utilisées pour

construire le graphe pondéré et nous étudions leur comportement par rapport à un ensemble de transformations spectrales. L'évaluation est effectuée dans le but de trouver la meilleure métrique pour la segmentation d'une image hyperspectrale.

Le chapitre 4 présente l'ensemble des résultats de segmentation sur une base d'images hyperspectrales synthétiques élaborée dans le cadre de cette thèse pour comparer différentes constructions de graphes.

Le chapitre 5 présente les résultats de segmentation sur une base d'images hyperspectrales réelles.

Enfin les principales contributions et un ensemble de perspectives sont présentés dans la conclusion générale.

Chapitre 1

Graphes

Sommaire

1.1	Introduction	12
1.2	Définitions et notations	13
1.3	Topologie du graphe	14
1.3.1	Graphe complet	15
1.3.2	Graphe de ϵ -voisinage	15
1.3.3	Graphe d'adjacence de région	17
1.4	Similarité, Métrique et Fonction de poids	17
1.4.1	Fonctions et vecteurs caractéristiques	18
1.4.2	Fonction de poids	21
1.4.3	Métrique	21
1.5	Opérateurs sur graphe	22
1.6	Partitionnement du graphe	24
1.7	Conclusion	27

1.1 Introduction

La segmentation d'une image consiste à trouver un ensemble de régions de l'image qui sont sémantiquement cohérentes. La notion de sémantique qui ne fait pas partie des objectifs principaux de cette thèse, pourrait être liée au cadre générique de la perception humaine (segmenter et distinguer les différents objets d'une image) mais aussi elle pourrait être associée à des domaines spécifiques (imagerie médicale, qui demande une expertise pour distinguer les régions pathologiques des régions saines). Le problème de la segmentation peut être également considéré comme un problème de classification de données. Par exemple, étant donné un ensemble de points $X = \{x_1, x_2, \dots, x_n\}$ et une certaine mesure de similarité $S = \{s_{ij} \geq 0\}$ entre les paires de points x_i et x_j , segmenter cet ensemble revient à trouver des partitions de X contenant des points similaires au sens de S .

L'ensemble X peut également être représenté sous forme d'un graphe $G = (V, E)$ avec une pondération selon la mesure de similarité S . Chaque sommet $v_i \in V$ dans ce graphe représente un point de données x_i . Deux sommets sont connectés si la similarité s_{ij} entre les points correspondants x_i et x_j est positive ou supérieure à un certain seuil, et l'arête $(v_i, v_j) \in E$ du graphe est pondérée par un poids calculé à partir de s_{ij} .

Avec cette représentation par graphe, le problème de segmentation peut être décrit comme la partition de ce graphe en un ensemble de composantes connexes. L'objectif est donc de trouver une coupe de graphe telle que les arêtes entre différents groupes aient une très faible pondération et les arêtes au sein d'un même groupe aient des poids élevés.

Avant d'aborder le problème de la segmentation, nous introduisons dans ce chapitre les concepts de base sur les graphes, leur structure et leur construction. Nous présenterons brièvement le type de graphe que nous utilisons par la suite. Nous présenterons, ensuite, les opérateurs sur graphes proposées par [20] [21] et qui sont indispensables pour la compréhension des méthodes proposées. Nous détaillons à

la fin de ce chapitre quelques approches de segmentation d'images basées sur une représentation par graphe.

1.2 Définitions et notations

Les méthodes de traitement d'image qui considèrent une image comme un graphe pondéré, représentent les caractéristiques dans une image par des sommets reliés entre eux par des arêtes pondérées avec la similarité entre ces caractéristiques.

Graphe pondéré :

Mathématiquement, un graphe pondéré, noté $G = (V, E, \omega)$ est composé d'un ensemble fini de sommets (en anglais *Vertices*) $V = \{v_1, \dots, v_n\}$, d'un ensemble non ordonné d'arêtes (en anglais *Edges*) E et d'une fonction de poids ω .

Adjacence :

Deux sommets v_i et v_j dans l'ensemble V sont adjacents si et seulement s'ils sont connectés entre eux par une arête et on note $v_i \sim v_j$.

Le voisinage d'un sommet v_i , noté $\mathcal{N}(v_i)$ représente l'ensemble des sommets adjacents à v_i . Il est défini par

$$\mathcal{N}(v_i) = \{v_j \in V | (v_i, v_j) \in E\} \quad (1.1)$$

Arête :

L'ensemble des arêtes E est un sous-ensemble de $V \times V$ défini comme suit :

$$E = \{(v_i, v_j) \in V \times V \mid v_i \sim v_j \text{ et } v_i \neq v_j\} \quad (1.2)$$

où (v_i, v_j) est une arête appartenant à E et qui relie les sommets v_i et v_j . Cette arête est dite incidente à ces deux sommets et v_i et v_j sont ses extrémités.

Par définition, l'ensemble E contient uniquement les arêtes reliant des sommets distincts, c'est à dire qu'une arête ne peut pas relier un sommet à lui même. Le graphe G est alors considéré sans boucle.

Graphe non-orienté :

Un graphe est dit non-orienté si l'ordre des sommets reliés par une arête est sans importance. Autrement dit, les arêtes sont symétriques : $(v_i, v_j) \in E$ implique $(v_j, v_i) \in E$.

Généralement dans un graphe, une arête reliant deux sommets v_i et v_j a une valeur non négative ω_{ij} . Cette valeur est calculée en fonction de la similarité et la quantité d'interaction entre les sommets v_i et v_j .

Par définition dans un graphe non-orienté, $\omega : E \rightarrow [0, 1]$ est une fonction symétrique : $\omega_{ij} = \omega_{ji}$. Elle est définie comme suit :

$$\omega_{ij} \begin{cases} \in [0, 1] \text{ si } v_j \in \mathcal{N}(v_i) \\ = 0 \text{ si } v_j \notin \mathcal{N}(v_i) \\ = \omega_{ji} \end{cases} \quad (1.3)$$

Matrice d'adjacence :

La matrice d'adjacence d'un graphe pondéré est la matrice W dont les éléments correspondent aux poids des arêtes du graphe :

$$W = (\omega_{ij})_{i,j=1,\dots,n}. \quad (1.4)$$

Degré d'un sommet :

Le degré d'un sommet $v_i \in V$, noté $\delta(v_i)$, désigne la somme des poids des arêtes incidentes à v_i : le degré d'un sommet, $\delta : V \rightarrow \mathbb{N}$ est défini par :

$$\delta_\omega(v_i) = \sum_{v_j \in \mathcal{N}(v_i)} \omega_{ij} \quad (1.5)$$

1.3 Topologie du graphe

La première étape des méthodes de traitement d'images basées graphes est la construction d'un graphe pondéré $G(V, E, \omega)$ pour représenter les données de l'image et coder leurs relations en se basant sur des caractéristiques telles que la couleur des pixels. Ces relations qui correspondent aux poids sur les arêtes du graphe ont généralement une valeur comprise en 0 et 1.

Le problème de la construction du graphe revient ainsi à fixer l'ensemble de ses sommets et identifier l'ensemble de ses arêtes E . Ce problème a été largement étudié ces dernières années mais malgré ces travaux, le problème demeure ouvert jusqu'à aujourd'hui. Ceci est principalement dû au manque de règles générales définissant la structure idéale d'un graphe. En effet, la construction du graphe est le plus souvent influencée par le domaine cible et les données à traiter [22].

Dans cette section, nous présentons les différentes topologies que nous allons utiliser pour représenter une image hyperspectrale dans le but de la segmenter.

1.3.1 Graphe complet

Un graphe complet représentant une image est un graphe pondéré, dont les sommets sont tous reliés entre eux. Il existe donc pour chaque paire de sommets (v_i, v_j) une arête pondérée par un poids ω_{ij} qui représente la similarité entre ces sommets. L'ensemble des arêtes de ce graphe est défini alors par :

$$E = \{V \times V\} \tag{1.6}$$

Le nombre d'arêtes $|E|$ d'un graphe complet est quadratique par rapport au nombre de sommets : $|E| = n \times (n - 1)$ où n est le nombre de sommets dans le graphe.

Ce graphe a le niveau de connectivité le plus élevé, mais le nombre très élevé d'arêtes rend son exploitation difficile. Les algorithmes de traitement appliqués sur ce type de graphe ont généralement un temps de calcul très important.

1.3.2 Graphe de ϵ -voisinage

Le graphe de ϵ -voisinage (appelé aussi graphe de ν -voisinage) est un graphe pondéré tel que chaque sommet $v_i \in V$ est associé à un pixel de l'image et est connecté aux sommets dont la distance est inférieure ou égale au paramètre de seuillage ϵ .

L'ensemble des arêtes de ce graphe est défini comme :

$$E = \{(v_i, v_j) \mid d(C(v_i) - C(v_j)) \leq \epsilon\} \quad (1.7)$$

où $C(v_i)$ et $C(v_j)$ représentent les coordonnées spatiales des sommets v_i et v_j , et $d(C(v_i) - C(v_j))$ désigne la distance entre les coordonnées de ces sommets. L'ensemble de voisinage $\mathcal{N}(v_i)$ pour un sommet v_i est défini alors par :

$$\mathcal{N}(v_i) = \{v_j \in V \setminus \{v_i\} \mid d(C(v_i) - C(v_j)) \leq \epsilon\} \quad (1.8)$$

La distance d entre les sommets du graphe correspond en général à une distance mesurée entre les coordonnées spatiales de leurs pixels associés dans la structure intrinsèque de l'image. Elle peut être obtenue en utilisant par exemple la distance euclidienne ou la distance de Chebyshev.

Prenons l'exemple d'une construction d'un graphe de ϵ -voisinage à partir d'une image donnée avec $\epsilon \leq 1$, en utilisant la distance euclidienne, seuls les 4 sommets adjacents (ceux du bas, du haut, de gauche et de droite) sont ajoutés au voisinage d'un sommet et le graphe est dit graphe de 4-voisinage ou aussi 4-connexité. En utilisant la distance de Chebyshev, on ajoute au voisinage d'un sommet, en plus de ces 4 sommets adjacents, les 4 sommets sur les diagonales et le graphe est dit alors graphe de 8-voisinage. La figure 1.1 illustre les deux modes de construction de ce graphe :




FIGURE 1.1 – Exemple d'un graphe ϵ -voisinage avec $\epsilon \leq 1$: (a) pixels avec les sommets superposés. (b) graphe 4-voisinage avec la distance Euclidienne. (c) graphe 8-voisinage avec la distance de Chebyshev

Il n'existe pas de règle générale pour choisir la valeur adéquate de ϵ . Le choix dépend fortement du problème posé.

1.3.3 Graphe d'adjacence de région

Une autre construction intéressante à partir d'une image, qui permet une représentation simplifiée d'une image donnée sous forme d'un graphe pondéré, est le graphe d'adjacence de région (RAG). Cette topologie de graphe est basée sur une partition de l'image donnée en régions connexes appelées superpixels (par exemple, sous la forme d'un diagramme de Voronoï). Chaque région de cette partition est représentée par un seul sommet du graphe. Les sommets de deux régions adjacentes sont reliés par une arête pondérée dont le poids dépend de la similarité entre les deux régions.

Ce type de graphe permet de réduire la complexité des algorithmes (par rapport à un graphe construit à partir de chaque pixel de l'image) et offre des solutions alternatives intéressantes en termes de temps de calcul.

Figure 1.2 illustre un exemple de RAG correspondant à la partition d'une image donnée. La figure 1.2(a) représente l'image initiale avec les contours de la partition en rouge. La figure 1.2(b) représente le RAG associé à cette partition où les points en bleu correspondent aux sommets du graphe et les arcs en vert à ses arêtes.

1.4 Similarité, Métrique et Fonction de poids

La construction du graphe est une étape cruciale dans les méthodes de traitement d'image basées sur des graphes. Cette étape exige, en plus de la topologie et de la structure du graphe, la définition d'une fonction de poids appropriée qui traduit par le biais d'une métrique la quantité d'interaction et la similarité entre les paires de vecteurs de caractéristiques de sommets du graphe.




FIGURE 1.2 – Exemple d’un graphe d’adjacence de régions (RAG) : (a) partition de l’image initiale, (b) sommets (points bleus) et arêtes (lignes vertes).

1.4.1 Fonctions et vecteurs caractéristiques

Pour chaque sommet du graphe représentant une image, on associe un ou plusieurs attributs le caractérisant, en fonction de l’application considérée ou de la nature de l’image à traiter. Ces attributs sont représentés par une fonction caractéristique (ou fonction d’attributs) noté $f : V \rightarrow \mathbb{R}^m$. Cette fonction associe à chaque sommet du graphe, qui représente les données à traiter, un vecteur caractéristique. Il existe différentes possibilités pour définir la fonction caractéristique, les choix dépendant en général de l’application traitée.

Parmi les fonctions caractéristiques les plus utilisées nous pouvons citer celles qui associent à chaque sommet le vecteur couleur de pixel considéré, l’intensité du niveau de gris [15] [23], ou encore le spectre d’un pixel dans une image hyperspectral [24]. On peut ajouter aussi celle qui utilise les coordonnées de sommets [25], les caractéristiques colorimétriques [17] [26], ou les caractéristiques de texture en utilisant des patches d’images [27].

En général, il y a trois façons de définir une fonction caractéristique pour construire le graphe de similarité :

1. Pixel : dans ce cas, la fonction caractéristique est définie pour chaque pixel

de l'image traité comme un sommet du graphe. La fonction caractéristique f associe à chaque pixel un vecteur caractéristique qui peut être de son côté une information de :

- Couleur : Choisir le bon espace colorimétrique est également un sujet d'actualité en segmentation d'image. Bien que le modèle RVB soit un modèle universel pour l'affichage de vidéos et d'images, il n'est pas bien adapté à la segmentation des scènes couleur en raison de la forte corrélation entre les composantes R, V et B [28].

Shi et Malik [17] ont suggéré de calculer la similarité du graphe avec la valeur HSV pour l'image couleur. Par exemple, dans [29] les auteurs ont proposé d'utiliser plusieurs types d'espaces colorimétriques afin de capturer tous les résultats de segmentation possibles.

- Contour : Les contours ont un pouvoir très discriminant pour mesurer la similarité. Les contours contiennent la majeure partie de l'information d'une image, puisque d'un simple coup d'œil on peut identifier les objets et les sujets d'une image complexe. Plusieurs travaux [30] [31][32] ont utilisé la notion d'"intervening contour" [33] comme caractéristique basée sur le gradient, pour mesurer la similarité entre les données.

2. Patch : Dans ce cas, la fonction caractéristique est basé sur des patches centrés sur les pixels de l'image. Chacun de ces pixels est traité comme un sommet du graphe et est représenté par un patch de vecteurs couleurs ou autre type de caractéristique. Un patch a une forme rectangulaire (généralement un carré) et régulier en terme de forme et de nombre de pixels. La figure 1.3, montre trois exemples de patches de dimensions 20×20 , sur lesquels nous définissons les fonctions caractéristiques des sommets du graphe associés. Le graphe de similarité basé sur les patches incorpore donc plus d'apparence locale en luminosité, couleur et texture, puisque les caractéristiques ont été extraites sur une fenêtre locale. Selon [31], le meilleur moyen de capturer la couleur

est d'utiliser des patches plutôt que des pixels. Wang et al. [34] ont proposé d'utiliser une série de patches centrés sur des points d'intérêt pour représenter une image avec un histogramme de couleur.




FIGURE 1.3 – Exemple de patches : trois patches de dimension 20×20 définis comme vecteur d'attributs caractérisant les sommets du graphe extraits d'une bande hyperspectrale.

3. Superpixels : La fonction caractéristique repose ici sur les superpixels qui regroupent les pixels de l'image en zones homogènes dans certains espaces caractéristiques tout en respectant les contours des objets. Chacun de ces superpixels est considéré comme un sommet du graphe qui peut être représenté par leur vecteur couleur moyen par exemple. Ces dernières années, tant pour les tâches de bas niveau que de haut niveau en vision par ordinateur, la mise en œuvre de superpixels comme échantillons de données, a été une tendance majeure. Par exemple, pour la segmentation [35] [36], la mesure des objets [37] [29], la détection des objets [38] ou la segmentation sémantique [39]. Comme indiqué dans [40], les méthodes basées sur des régions ou des superpixels permet d'étudier et de concevoir des caractéristiques beaucoup plus polyvalentes et puissantes par rapport à celles utilisant les pixels.

1.4.2 Fonction de poids

Le critère de mesure de poids entre les sommets du graphe ou ce qu'on appelle aussi similarité attribue à chaque arête $(v_i, v_j) \in E$ une valeur de similarité entre les deux sommets aux extrémités de cette arête.

D'une manière générale, une mesure de similarité est une fonction $g : E \rightarrow \mathbb{R}^+$ qui associe à chaque paire de sommets adjacents v_i et v_j , décrits par leurs vecteurs de caractéristiques, une valeur de similarité entre $[0, 1]$. Plus cette valeur est proche de 1, plus les sommets sont similaires.

Cette mesure dépend du type de données et de l'application considérée dans laquelle le graphe pondéré intervient. Dans cette thèse, et sans être exhaustifs, nous considérons les mesures de similarité suivantes que nous allons utiliser dans la suite. La fonction μ représente la métrique utilisée pour calculer cette similarité :

$$g_1(v_i, v_j) = 1 - \frac{\mu(v_i, v_j)}{\max \mu(v_i, v_j)} \quad (1.9)$$

$$g_2(v_i, v_j) = \exp\left(-\frac{\mu(v_i, v_j)^2}{\sigma^2}\right) \quad (1.10)$$

où σ^2 représente la variance de toutes les valeurs obtenues par la métrique μ .

La fonction de poids $\omega : V \times V \rightarrow [0, 1]$ est alors définie par :

$$\omega_{ij} \begin{cases} g(v_i, v_j) & \text{si } (v_i, v_j) \in E \\ = 0 & \text{sinon} \end{cases} \quad (1.11)$$

1.4.3 Métrique

La fonction de poids requiert donc la définition d'une métrique μ , qui est une fonction définie par $\mu : V \times V \rightarrow \mathbb{R}^+$, et qui associe à chaque paire de sommets $(v_i, v_j \in V)$ une valeur en comparant leurs vecteurs caractéristiques $f(v_i)$ et $f(v_j)$, où f représente la fonction caractéristique.

La métrique μ doit être choisie avec précaution afin de s'adapter au mieux à l'application considérée et optimiser ses résultats. Elle doit être robuste aux transformations géométriques et prendre en compte les variations des données à traiter

Dans la littérature, il existe plusieurs distances qui peuvent être utilisées comme métrique pour calculer l'affinité entre les sommets du graphe.

Dans ce manuscrit, nous nous sommes appuyés sur l'étude approfondie [41] qui compare et évalue différentes métriques existantes en fonction de leurs propriétés théoriques en utilisant des spectres simulés avec une fonction de distribution gaussienne.

Comme il n'y a pas de règle générale pour définir la métrique appropriée pour pondérer les arêtes d'un graphe donné, nous avons proposé de comparer l'utilisation de plusieurs métriques dans ce contexte. Tout cela sera défini et illustré dans le chapitre 3.

1.5 Opérateurs sur graphe

Nous passons maintenant en revue une série d'opérateurs définis sur des graphes pondérés par Ta et al. dans [20] et [21], nécessaires à la compréhension de la suite de ce manuscrit. Ces opérateurs peuvent être vus comme des extensions de ceux proposés dans [25] et [42].

Pour une fonction caractéristique donnée f qui attribue une valeur réelle $f(v_i)$ à chaque sommet $v_i \in V$, l'opérateur de différence pondéré de f appliqué sur une arête $(v_i, v_j) \in E$ est défini comme suit :

$$(d_\omega f)(v_i, v_j) = \sqrt{\omega_{ij}} (f(v_j) - f(v_i)) \quad (1.12)$$

En se basant sur cette définition, deux opérateurs de différence directionnelle pondérés sont définis. Les opérateurs de différence pondérée externe et interne sont respectivement :

$$(d_{\omega}^+ f)(v_i, v_j) = \sqrt{\omega_{ij}} (f(v_j) - f(v_i))^+ \quad (1.13)$$

et

$$(d_{\omega}^- f)(v_i, v_j) = -\sqrt{\omega_{ij}} (f(v_j) - f(v_i))^- \quad (1.14)$$

avec $(x)^+ = \max(0, x)$ et $(x)^- = \min(0, x)$.

Le gradient pondéré d'une fonction f au sommet v_i , noté ∇_{ω} , est défini comme étant le vecteur des différences pondérées pour l'ensemble des arêtes $(v_i, v_j) \in E$. Cet opérateur est défini localement en un sommet $v_i \in V$ et qui dépend de son voisinage $\mathcal{N}(v_i)$, afin de mesurer la variation locale d'une caractéristique donnée dans $\mathcal{N}(v_i)$. Par exemple dans le cas où le graphe représente une image, l'opérateur de gradient pondéré est utilisé pour déterminer et détecter leurs contours. Cet opérateur est calculé comme suit :

$$(\nabla_{\omega} f)(v_i) = ((d_{\omega} f)(v_i, v_j))_{(v_i, v_j) \in E}^T \quad (1.15)$$

Les opérateurs de gradient externe et interne pondérés de f pour un sommet v_i , notés respectivement ∇_{ω}^+ et ∇_{ω}^- sont :

$$(\nabla_{\omega}^+ f)(v_i) = ((d_{\omega}^+ f)(v_i, v_j))_{(v_i, v_j) \in E}^T \quad (1.16)$$

$$(\nabla_{\omega}^- f)(v_i) = ((d_{\omega}^- f)(v_i, v_j))_{(v_i, v_j) \in E}^T \quad (1.17)$$

En se basant sur la définition de différence (1.13) et de gradient (1.16) externes, nous pouvons exprimer la norme du gradient externe par :

$$\|(\nabla_{\omega}^+ f)(v_i)\| = \sum_{v_j \in V} \sqrt{\omega_{ij}} (|\max(0, f(v_j) - f(v_i))|) \quad (1.18)$$

de même pour la norme du gradient interne qu'est défini par :

$$\|(\nabla_{\omega}^- f)(v_i)\| = \sum_{v_j \in V} \sqrt{\omega_{ij}} (|\min(0, f(v_j) - f(v_i))|) \quad (1.19)$$

Ces opérateurs de gradient constituent les briques élémentaires de notre formulation de la segmentation basée sur des graphes proposées dans le chapitre suivant.

1.6 Partitionnement du graphe

Au cours de ces dernières décennies, de nombreuses recherches ont été consacrées au développement d’approches de segmentation. La segmentation d’image produit un ensemble de régions homogènes d’une image. L’intégration de toutes ces régions constitue l’image entière. Chaque région comporte un ensemble de pixels et chaque pixel est caractérisé par sa position et son vecteur de caractéristiques. Tous les pixels d’une région sont similaires par rapport à un ensemble de caractéristiques. Récemment la puissance de manipulation des graphes a été abordé. Cela s’illustre particulièrement par la capacité du graphe à représenter tout type de données, notamment les données de plus grande dimension, telles que des images multispectrales ou hyperspectrales ou encore des séquences vidéo. Il devient donc possible grâce aux graphes d’étendre différents algorithmes de segmentation conçus à l’origine pour les images classiques ou autres [43] [44] [45].

Cette manière de représentation, organise explicitement les éléments d’image en représentation structurelle et rend la formulation du problème plus flexible et le calcul plus efficace.

Le principe de base de la plupart des méthodes de segmentation basées sur des graphes est le partitionnement de graphes. Chaque méthode traite une image comme un graphe G dans lequel les sommets représentent les pixels ou un groupe de pixels de l’image. Chaque arête a un poids généralement déterminé en fonction de ses sommets extrémités. Le concept de segmentation d’image revient donc à la recherche d’un ensemble de sous-graphes $\{SG_1, SG_2, \dots, SG_n\}$ à partir du graphe G tels que pour tout $k \in \{1, 2, \dots, n\}$, $\forall i, j$ et $i \neq j$, $v_i, v_j \in SG_k$ où v_i est connecté à v_j . Le nombre de sommets composant tous les sous-graphes est égal au nombre total de sommets du graphe. Chaque sous-graphe comprend un ensemble de sommets avec

une forte similarité. La figure 1.4 montre une représentation illustrant la relation entre la segmentation d'images et le partitionnement du graphe.




FIGURE 1.4 – Relation entre la segmentation d'image et le partitionnement du graphe : (a) Image initiale (b) Graphe initial (c) Partitionnement du graphe (d) Segmentation d'image

Par conséquent, le meilleur moyen de différencier les méthodes de segmentation basées sur un graphe est de prendre en compte le modèle de graphe et l'algorithme utilisé pour résoudre le problème de la segmentation vu comme la partition d'un graphe.

Depuis la classification effectuée sur les différentes méthodes de segmentation basées graphe, on peut regrouper ces techniques en trois grandes familles :

La première famille correspond aux approches basées sur une minimisation d'énergie. Parmi ces approches, nous trouvons la méthode de Random Walks [23], le p-laplacien [42] [46], le Power Watershed [47] et la méthode de Graph Cuts [16]. Cette dernière a pour but de séparer un objet de l'arrière-plan de l'image. L'image étant représentée par un graphe, la séparation est faite en utilisant l'algorithme Min-Cut/Max-Flow. Cet algorithme a été initialement introduit par Boykov et al. [48]. Il s'agit, dans ce cas, d'une segmentation binaire au cours de laquelle on distingue

deux sommets particuliers appelés aussi "terminaux" (la source S et la cible T). Ces sommets sont généralement fixés par un algorithme de clustering sur les pixels de l'image. Les autres sommets du graphe connectés entre eux par des arêtes "n-links" sont dits intermédiaires. Ces sommets intermédiaires sont aussi connectés aux deux sommets terminaux par des arêtes dites "t-links". Ces arêtes possèdent un poids (ou coût) positif $\omega \geq 0$. Une coupe C dans un graphe est définie comme étant un ensemble d'arêtes qui, une fois ôtées, déconnectent la source de la cible. En d'autres termes, il n'existe plus de chemin entre la source et la cible dans le graphe partiel $G(V, E \setminus C)$. La coupe C possède un coût, appelé aussi capacité, $|C|$ qui est défini comme la somme des coûts des arêtes de la coupe. Une coupe minimale C_{min} d'un graphe est donc définie comme étant la coupe ayant le coût minimal ($\forall C, |C_{min}| \leq |C|$).

La deuxième catégorie quant à elle correspond aux méthodes spectrales où la partition du graphe est illustrée sous forme d'un problème aux valeurs propres généralisées en utilisant les différentes matrices que l'on peut associer à un graphe.

On peut citer parmi ces méthodes, la méthode de Weiss [49] et aussi la méthode de Shi et Malik dénommée Normalized Cuts [17].

La méthode de segmentation Normalized Cuts permet d'intégrer simultanément l'information couleur et texture incluse dans l'image grâce à un processus de regroupement de graphe. La première étape de cette méthode consiste à représenter l'image par un graphe $G = (V, E)$, ensuite à calculer la matrice d'adjacence W (ou matrice d'affinité) qui regroupe le poids des arêtes du graphe (équation 1.4). La segmentation de l'image (graphe) est exécutée par la suite en résolvant le problème de vecteur propre suivant :

$$Ly = \lambda Dy \quad (1.20)$$

où D représente la matrice diagonale des degrés dont les éléments désignent les degrés des sommets (équation 1.5). Elle est définie par : $D_{ij} = \sum_j W_{i,j}$ pour $i = j$

1.7. CONCLUSION

et 0 sinon. L représente la matrice Laplacienne définie comme étant la différence entre la matrice des degrés et la matrice d'adjacence : $L = D - W$. Le vecteur propre y correspond à la deuxième plus petite valeur propre λ obtenue en résolvant l'équation 1.20. L'étude de son signe permet alors de partitionner le graphe en deux régions. Finalement, l'algorithme décide si la partition courante doit être divisée une autre fois et les parties segmentées réparties récursivement.

La troisième catégorie que l'on peut mentionner pour ce type de méthode correspond aux approches basées sur la transcription des équations aux dérivées partielles (EDP) au domaine discret des graphes pondérés en utilisant le formalisme des équations aux différences partielles (EdP). Plusieurs approches ont été développées pour effectuer ces transcriptions, parmi lesquelles nous pouvons citer les travaux de Grady et al. [50] ou Hirani et al. [51].

Par définition, les EdP sont des équations mimant le comportement des EDP sur des graphes, en remplaçant l'opérateur dérivée par un opérateur de différence défini sur graphe. Ces équations ont été introduites initialement dans [52], dont les auteurs ont proposé une résolution numérique des EDP en utilisant la méthode des différences finies. Plus récemment, l'emploi de ces EdP s'est généralisée jusqu'à ce qu'elles deviennent un sujet d'intérêt en elles mêmes. Parmi ces travaux, nous pouvons citer [53], [54], [55], [56] ou [57].

Dans [42], les auteurs ont proposé d'utiliser les formulations des EdP sur des graphes de topologie arbitraire dans le contexte du traitement des images et des données. Suivant la même idée, Desquesnes et al.[19] ont introduit la discrétisation d'EDP du modèle de Chan et Vese [18] sur graphe pour la segmentation d'images.

1.7 Conclusion

Dans ce chapitre, nous avons présenté les notations et les définitions des graphes pondérés nécessaires pour la compréhension de la suite de ce manuscrit. Nous avons

1.7. CONCLUSION

présenté aussi les différentes topologies d'un graphe qui seront utilisées pour représenter une image hyperspectrale. Nous avons également rappelé quelques méthodes existantes de partitionnement du graphe et aussi certains opérateurs sur graphe constitutionnels pour l'élaboration des méthodes proposées.

En se basant sur ce procédé, nous avons proposé une nouvelle méthode de segmentation d'images hyperspectrales que nous la présenterons au chapitre suivant.

Chapitre 2

Segmentation par ensembles de niveaux sur graphe

Sommaire

2.1	Introduction	30
2.2	Le problème de Mumford et Shah	32
2.3	Méthode des ensembles de niveaux	33
2.4	Modèle deux-phases de Chan et Vese	35
2.5	Modèle multi-phases de Chan et Vese	37
2.6	Transcription de la méthode d'ensembles de niveaux sur graphe	39
2.7	Adaptation des modèles de Chan et Vese sur graphe pour la segmentation des images hyperspectrales	41
2.7.1	Modèle deux-phases	41
2.7.2	Modèle multi-phases	42
2.8	Conclusion	43

2.1 Introduction

Au cours de la dernière décennie, un ensemble de méthodes ont été développées pour résoudre les problèmes liés aux caractéristiques particulières des images hyperspectrales. Différents formalismes mathématiques ont été introduits pour des tâches précises, telles que la classification, la reconnaissance d'objets et la segmentation. Cependant, la plupart de ces travaux se focalisent toujours sur le domaine spectral. Avec les images à haute résolution spatiale disponibles, il est impératif nécessaire de développer de nouvelles méthodes spectro-spatiales pour ces images émergentes. Dans le même temps, l'imagerie hyperspectrale reste un sujet relativement nouveau dans le domaine de la vision par ordinateur. Les quelques travaux répertoriés examinent le traitement d'image bas niveau, comment obtenir une image ou une vidéo hyperspectrales avec une résolution spatiale élevée, comment atténuer l'image hyperspectrale, etc. Peu d'efforts ont été consacrés aux méthodes de traitement haut niveau d'images hyperspectrales, en particulier les méthodes de segmentation.

Il est très difficile d'exploiter l'ensemble des informations spectro-spatiales avec les algorithmes de traitement d'images classiques sans introduire trop de complexité dans les données. Les principaux défis proviennent de deux exigences : fusionner des caractéristiques spectrales et spatiales et appliquer des algorithmes de segmentation initialement développés pour des données de faible dimensionnalité.

La représentation par graphe introduite dans le chapitre précédent facilite le processus d'exploitation des informations spectro-spatiales de l'image hyperspectrale et rend possible l'utilisation de nombreux algorithmes de traitement d'images classiques et notamment ceux développés pour la segmentation. En effet, comme présenté dans le chapitre précédent, la modélisation d'une image par un graphe pondéré, permet de s'affranchir des limitations liées à l'application des algorithmes classiques de segmentation sur des données de grande dimension. En établissant les relations entre les sommets correspondant à des pixels voisins dans l'image hyperspectrale, il est possible d'obtenir un graphe dont la topologie reflète l'organisation

initiale des pixels (les relations de voisinage et de similarité) tout en réduisant les informations redondantes (notamment avec la modélisation par patch et superpixel). Par ailleurs, la structure de graphe faisant abstraction des dimensions de l'image, il est envisageable de traiter des données bi- et tridimensionnelles exactement de la même manière ; seule l'étape de construction du graphe nécessite d'être adaptée aux données manipulées. Ces dernières années, plusieurs méthodes de traitement du signal et des images ont été transposées sur graphes. On peut citer parmi celles-ci, les approches basées sur les modèles variationnels et sur la transcription d'Équations aux Dérivées Partielles (EDP) sur graphe. Les méthodes basées sur les EDP, initialement développées par des physiciens, ont fourni des approches originales parmi les méthodes existantes dans le domaine du traitement des images et de la vision par ordinateur. Elles sont utilisées dans de nombreuses applications telles que la restauration, le filtrage, l'interpolation, le suivi d'objets dans des séquences vidéos et aussi la segmentation. Le lecteur intéressé par ces approches pourra se référer par exemple à [58] [59] [60] [61] et aux références associées.

Dans ce manuscrit, nous nous intéressons aux EDP simulées par des fonctions des ensembles de niveaux, introduites initialement par Osher et Sethian [62], pour décrire la propagation d'une courbe évolutive, et leur adaptation sur des graphes pondérés développé par Desquesnes et al [19] afin de proposer une nouvelle approche de segmentation des images hyperspectrales basée sur le formalisme des EDP sur graphe.

Dans ce chapitre, nous rappelons d'abord le problème de Mumford et Shah et nous présentons sa solution par la méthode des ensembles de niveaux utilisée pour simuler la propagation d'une courbe évolutive sur une image. Nous détaillons ensuite l'adaptation discrète de la méthode des ensembles de niveaux au domaine des graphes pondérés. Nous présentons après les deux modèles de Chan et Vese [18] [63] basés sur la fonctionnelle de Mumford et Shah et leurs adaptations sur graphe proposées pour la segmentation des images hyperspectrales.

2.2 Le problème de Mumford et Shah

Dans [64] [65], David Mumford et Jayant Shah ont formulé un problème de minimisation d'énergie afin de résoudre un problème à la fois de reconstruction et de segmentation d'image. Plus précisément, une image u_0 est vue comme une fonction non régulière $u_0 : \Omega \rightarrow \mathbb{R}$, où Ω est un sous-ensemble ouvert borné de $\mathbb{R}^2$ composé de plusieurs composants connexes Ω_i . La fonction u_0 associe à chaque point de l'image $(x, y) \in \Omega$ une valeur $u_0(x, y)$ qui représente par exemple un niveau de gris. Le problème de segmentation de l'image u_0 consiste alors à trouver les contours des composants qu'elle représente. Selon Mumford et Shah, ces contours sont situés aux points (x, y) dans lesquels u_0 est très discontinue, autrement dit où les points présentent une forte discontinuité de caractéristique, qui s'exprime par une forte changement dans les valeurs $u_0(x, y)$.

Pour résoudre le problème de segmentation d'image, qui revient donc à détecter l'ensemble des discontinuités, Mumford et Shah ont proposé une fonctionnelle de minimisation, qui dépend de deux variables C et u . C est un ensemble fermé qui représente les contours à détecter de l'image et u une fonction régulière définie dans $\Omega \setminus C$ qui correspond à la version régularisée de l'image u_0 . La fonctionnelle de Mumford et Shah s'écrit donc comme suit :

$$\min_{u,C} \{E^{MS}(u, C) = \int_{\Omega} (u_0 - u)^2 dx dy + \mu \int_{\Omega \setminus C} |\nabla u|^2 dx dy + \nu |C|\} \quad (2.1)$$

où ∇u représente le gradient de u et $|C|$ désigne la longueur de l'ensemble C avec $\mu, \nu > 0$ deux variables positives à fixer permettant de pondérer les différents termes de l'énergie à minimiser (2.1). Le premier terme de cette fonctionnelle représente un terme d'approximation (ou terme d'attache aux données) qui force u , par minimisation, à ressembler le plus possible à l'image initiale u_0 . Le deuxième et le troisième sont des termes de régularisation (ou pénalité) imposant une régularité à u .

Le modèle *piecewise constant* de Mumford et Shah est un cas réduit du modèle 2.1 obtenu en supposant que l'approximation optimale u de u_0 est constante à l'intérieur

de chaque composant connexe Ω_i (c'est-à-dire $u = c_i$ où c_i est une constante). Ce a conduit à la fonctionnelle suivante :

$$E^{MS}(u, C) = \sum_i \int_{\Omega_i} (u_0 - c_i)^2 dx dy + \nu |C| \quad (2.2)$$

Des résultats théoriques sur l'existence et la régularité de minimisations de (2.2) sont développés dans [65], [66], [67], [67], et [68]. Mais en pratique, il n'est pas toujours facile de minimiser les fonctionnelles (2.2) et (2.1), en raison du caractère inconnu de C , et de l'absence de convexité du problème.

Depuis, plusieurs groupes de recherche ont introduit des implémentations numériques de ce modèle. Le lecteur intéressé par plus de détails sur ces approches peut se référer à [63] et aux références associées pour un aperçu complet des différentes méthodes existantes. Parmi celles-ci, on trouve la méthode "Active Contour without Edges" [18], également connue sous le nom "modèle deux-phases de Chan et Vese". Dans leur papier [18], les auteurs ont introduit une implémentation numérique basée sur l'approche d'ensembles de niveaux pour la fonctionnelle de Mumford et Shah en la convertissant en un problème d'évolution selon la courbure moyenne et qui dépend de la longueur du contour et de la variation d'une fonction d'intensité à l'intérieur et à l'extérieur du contour. Les résultats de segmentation obtenus par ce modèle [18] illustrent la robustesse au bruit et au changement de topologie grâce à la représentation implicite du contour actif par l'approche d'ensembles de niveaux.

Le modèle introduit dans [18] a été étendu par les mêmes auteurs dans [63] pour traiter une évolution multi-phase et segmenter les structures topologiques complexes.

2.3 Méthode des ensembles de niveaux

Cette approche référencée sous le terme level sets en anglais a été introduite en 1988 par Osher et Sethian [62], Elle permet de décrire l'évolution d'une courbe paramétrique fermée notée $C \subset \Omega$ (le contour d'un ensemble $\varpi \in \Omega$, i.e. $C = \partial\varpi$). La méthode des ensembles de niveaux a pour but de trouver pour un ensemble de

2.3. MÉTHODE DES ENSEMBLES DE NIVEAUX

points (x, y) de l'espace une fonction $\phi(x, y, t) : \Omega \rightarrow \mathbb{R}$ telle qu'à chaque instant t la courbe évolutive C puisse être illustrée implicitement par le niveau zéro de ϕ . Cela signifie que $C(t) = \{(x, y) \mid \phi(x, y, t) = 0\}$. La fonction des ensembles de niveaux est définie alors comme suit :

$$\phi(x, y, t) \begin{cases} = 0 & \text{si } (x, y) \in C(t) = \partial\varpi \\ > 0 & \text{si } (x, y) \text{ est à l'intérieur de la courbe } C(t) = \varpi \\ < 0 & \text{si } (x, y) \text{ est à l'extérieur de la courbe } C(t) = \Omega \setminus \varpi \end{cases} \quad (2.3)$$

Nous illustrons en figure 2.1 la définition ci-dessus de la fonction des ensembles de niveaux ϕ , représentant la courbe évolutive C . L'évolution de la courbe $C(t)$ vers les




FIGURE 2.1 – Courbe représentée par le niveau zéro de la fonction des ensembles de niveaux ϕ , correspondant au contour séparant les régions définies par : $\{(x, y) : \phi(x, y) > 0\}$ et $\{(x, y) : \phi(x, y) < 0\}$.

contours des objets à segmenter peut être réalisée alors en résolvant l'équation aux dérivées partielles d'évolution de la fonction ϕ au cours du temps. Cette équation est définie sous la forme suivante :

$$\frac{\partial \phi(x, y, t)}{\partial t} = \mathcal{F}(x, y, t) \|\nabla \phi(x, y, t)\| \quad (2.4)$$

où $\mathcal{F}$ représente la vitesse d'évolution de la courbe C , également appelée vitesse, qui dépend des propriétés locales de la courbe C et $\nabla \phi(x, y, t)$ représente l'opérateur de gradient de ϕ qui permet d'estimer l'amplitude des variations d'intensité le long de la courbe C . Cette approche présente plusieurs avantages tels que sa capacité à gérer automatiquement les changements de topologie de la courbe évolutive $C(t)$, et aussi la possibilité de traiter les auto-intersections et de s'étendre à toute dimension supérieure [62] [69].

2.4 Modèle deux-phases de Chan et Vese

Le modèle de Chan et Vese [18] est une approche de segmentation par contour actif basé région, qui introduit une implémentation numérique pour la fonctionnelle de Mumford et Shah (équation 2.2) en utilisant la méthode d'ensembles de niveaux.

Ce modèle a montré son efficacité dans la segmentation de différents types d'images, [70] [71] [72]. L'objectif de ce modèle est de déterminer une partition optimale d'une image donnée $u_0 : \Omega \rightarrow \mathbb{R}$ en deux régions séparées par une courbe C évoluant dans Ω afin de capturer les contours d'une région ϖ dans Ω . La fonctionnelle de Chan et Vese s'écrit alors comme suit :

$$E(c_1, c_2, C) = \int_{\Omega_1=\varpi} (u_0(x, y) - c_1)^2 + \int_{\Omega_2=\Omega \setminus \varpi} (u_0(x, y) - c_2)^2 + \nu |C| \quad (2.5)$$

Les deux premiers termes de cette fonctionnelle représentent des termes d'attaches aux données permettant de guider la courbe vers les contours de l'objet à segmenter en prenant en compte les descripteurs de régions c_1 et c_2 , correspondant dans ce cas à la moyenne des intensités des niveaux de gris dans la région intérieure et la région extérieure à la courbe C respectivement. Le critère intrinsèque $|C|$ représente la longueur de la courbe C et garantit d'avoir une courbe lisse et régulière, avec $\nu \geq 0$.

Lorsque la courbe C atteint les contours de l'objet à segmenter, les deux premiers termes de 2.5 sont égaux et presque nuls. La minimisation de l'énergie 2.5 revient alors à trouver une partition optimale de l'image en deux régions homogènes séparées par la courbe C et qui correspondent respectivement au domaine délimité par C (ϖ) et son complémentaire ($\Omega \setminus \varpi$). L'objet à segmenter coïncide donc avec une de ces deux régions et la courbe C sera placée sur son contour.

Chan et Vese ont reformulé la fonctionnelle (2.5) en utilisant la méthode d'ensembles de niveaux [62] ce qui donne la fonctionnelle suivante :

$$\begin{aligned}
E(c_1, c_2, \phi) = & \int_{\Omega} (u_0(x, y) - c_1(\phi))^2 H_{\epsilon}(\phi(x, y)) dx dy + \\
& \int_{\Omega} (u_0(x, y) - c_2(\phi))^2 (1 - H_{\epsilon}(\phi(x, y))) dx dy + \\
& \nu \int_{\Omega} \delta_{\epsilon}(\phi) |\nabla \phi(x, y)| dx dy \quad (2.6)
\end{aligned}$$

où $\phi : \mathbb{R}^2 \rightarrow \mathbb{R}$ est la fonction d'ensembles de niveaux définie dans 2.3. $H_{\epsilon}(z)$ et $\delta_{\epsilon}(z)$ représentent respectivement la fonction de Heaviside et la mesure de Dirac définies par Chan et Vese dans [18] comme suit :

$$H_{\epsilon}(z) = \frac{1}{2} \left(1 + \frac{2}{\pi} \arctan\left(\frac{z}{\epsilon}\right) \right) \quad (2.7)$$

$$\delta_{\epsilon}(z) = \frac{dH_{\epsilon}(z)}{dz} = \frac{1}{\pi} \frac{\epsilon}{\epsilon^2 + z^2} \quad (2.8)$$

La figure 2.2 montre une représentation graphique de ces deux fonctions pour une valeur fixe de ϵ .




FIGURE 2.2 – Fonctions de Heaviside et de Dirac : (a) Fonctions de Heaviside classique $H(z)$ et modifiée $H_{\epsilon}(z)$ (b) Fonctions de Dirac classique $\delta_0(z)$ et modifiée $\delta_{\epsilon}(z)$.

$c_1(\phi)$ et $c_2(\phi)$ représentent les moyennes des intensités des niveaux de gris des

pixels en fonction du signe de ϕ définies comme suit :

$$\begin{aligned} c_1(\phi) &= \frac{\int_{\Omega} u_0(x, y) H_{\epsilon}(\phi(t, x, y)) dx dy}{\int_{\Omega} H_{\epsilon}(\phi(t, x, y)) dx dy} \\ c_2(\phi) &= \frac{\int_{\Omega} u_0(x, y) (1 - H_{\epsilon}(\phi(t, x, y))) dx dy}{\int_{\Omega} (1 - H_{\epsilon}(\phi(t, x, y))) dx dy} \end{aligned} \quad (2.9)$$

L'équation d'Euler-Lagrange obtenue en minimisant 2.6 et qui décrit l'évolution de ϕ est définie comme suit :

$$\frac{\partial \phi}{\partial t} = \delta_{\epsilon}(\phi) \left[\mu \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - (u_0 - c_1)^2 + (u_0 - c_2)^2 \right] \quad (2.10)$$

2.5 Modèle multi-phases de Chan et Vese

Le modèle multi-phases de Chan et Vese [63] est une généralisation multi-courbes de leur modèle à deux-phases [18] dédié à la propagation d'une seule courbe.

Étant donné n courbes C_i , ($1 \leq i \leq n$), représentées par n fonctions d'ensembles de niveaux ϕ_i , ce modèle vise à partitionner une image u_0 en $m = 2^n$ régions ou phases. La fonctionnelle de minimisation (2.5) pour ce modèle devient donc :

$$E_n(c, \Phi) = \sum_{1 \leq I \leq m=2^n} \int_{\Omega} (u_0 - c_I)^2 \chi_I dx dy + \sum_{1 \leq i \leq n} \nu \int_{\Omega} |\nabla H(\phi_i)| \quad (2.11)$$

où I désigne le label de chaque région de l'image avec $1 \leq I \leq 2^n$. Le vecteur $c = (c_1, c_2, \dots, c_n)$ est constant de moyenne, où $c_I = \text{moyenne}(u_0)$ dans la région I . Le vecteur $\Phi = (\phi_1, \phi_2, \dots, \phi_n)$ désigne l'ensemble des fonctions des ensembles de niveaux et χ_I est une fonction caractéristique pour chaque région I de l'image. $H(\phi_i)$ représente la fonction Heaviside appliquée sur chaque ϕ_i . Il est clair que, pour $n = 1$ (et donc $m=2$), on obtient le modèle deux-phases (2.5) présenté dans la section précédente. Prenant maintenant le cas de quatre phases obtenu lorsque $n = 2$ ($m=4$), nous considérons donc 2 courbes C_1 et C_2 représentées par l'union de 2 fonctions d'ensembles de niveaux ϕ_1 et ϕ_2 évoluant simultanément pour diviser l'image en quatre régions. Nous montrons dans la figure 2.3 la partition d'un domaine Ω en quatre régions en utilisant deux fonctions des ensembles de niveaux.




FIGURE 2.3 – Deux courbes divisant l'image en quatre régions suivant le signe de ϕ_1 et ϕ_2 en un point (x,y) de l'image.

La fonctionnelle de minimisation dans ce cas devient alors :

$$\begin{aligned}
 E_4(c, \Phi) = & \int_{\Omega} (u_0 - c_{11})^2 H(\phi_1) H(\phi_2) \, dx dy + \int_{\Omega} (u_0 - c_{10})^2 H(\phi_1) (1 - H(\phi_2)) \, dx dy + \\
 & \int_{\Omega} (u_0 - c_{01})^2 (1 - H(\phi_1)) H(\phi_2) \, dx dy + \int_{\Omega} (u_0 - c_{00})^2 (1 - H(\phi_1)) (1 - H(\phi_2)) \, dx dy + \\
 & \nu \int_{\Omega} |\nabla H(\phi_1)| + \nu \int_{\Omega} |\nabla H(\phi_2)| \quad (2.12)
 \end{aligned}$$

où $\Phi = (\phi_1, \phi_2)$ et $c = (c_{11}, c_{10}, c_{01}, c_{00})$ est un vecteur constant tel que :

$$c_{11} = \text{moyenne}(u_0) \text{ dans } \{(x, y) : \phi_1(t, x, y) > 0, \phi_2(t, x, y) > 0\}$$

$$c_{10} = \text{moyenne}(u_0) \text{ dans } \{(x, y) : \phi_1(t, x, y) > 0, \phi_2(t, x, y) < 0\}$$

$$c_{01} = \text{moyenne}(u_0) \text{ dans } \{(x, y) : \phi_1(t, x, y) < 0, \phi_2(t, x, y) > 0\}$$

$$c_{00} = \text{moyenne}(u_0) \text{ dans } \{(x, y) : \phi_1(t, x, y) < 0, \phi_2(t, x, y) < 0\}$$

Les équations d'Euler-Lagrange obtenues par minimisation de (2.12) pour décrire

2.6. TRANSCRIPTION DE LA MÉTHODE D'ENSEMBLES DE NIVEAUX SUR GRAPHE

l'évolution de ϕ_1 et ϕ_2 est alors définie comme suit :

$$\begin{aligned}\frac{\partial \phi_1}{\partial t} &= \delta_\epsilon(\phi_1) \left\{ \nu \operatorname{div} \left(\frac{\nabla \phi_1}{|\nabla \phi_1|} \right) - \left[((u_0 - c_{11})^2 - (u_0 - c_{01}^2))H(\phi_2) \right. \right. \\ &\quad \left. \left. + ((u_0 - c_{10})^2 - (u_0 - c_{00}^2))(1 - H(\phi_2)) \right] \right\} \\ \frac{\partial \phi_2}{\partial t} &= \delta_\epsilon(\phi_2) \left\{ \nu \operatorname{div} \left(\frac{\nabla \phi_2}{|\nabla \phi_2|} \right) - \left[((u_0 - c_{11})^2 - (u_0 - c_{01}^2))H(\phi_1) \right. \right. \\ &\quad \left. \left. + ((u_0 - c_{10})^2 - (u_0 - c_{00}^2))(1 - H(\phi_1)) \right] \right\} \quad (2.13)\end{aligned}$$

avec $\operatorname{div} \left(\frac{\nabla \phi_1}{|\nabla \phi_1|} \right)$ et $\operatorname{div} \left(\frac{\nabla \phi_2}{|\nabla \phi_2|} \right)$ représentant les courbures des courbes évolutives C_1 et C_2 décrites par ϕ_1 et ϕ_2 .

2.6 Transcription de la méthode d'ensembles de niveaux sur graphe

La transcription de l'approche des ensembles de niveaux et de son équation du mouvement du domaine continu vers le domaine discret sur un graphe pondéré a été introduite par Desquesnes [19]. Par analogie avec le cas continu, nous représentons implicitement une courbe évolutive C évoluant sur un graphe pondéré $G(V, E, \omega)$, en tant qu'ensemble fermé Ω_t , comme le niveau zéro d'une fonction d'ensembles de niveaux ϕ définie dans $V \rightarrow \mathbb{R} \times \mathbb{R}$ et vérifiant les propriétés suivantes :

$$\phi(v_i, t) \begin{cases} < 0 & \text{si } v_i \notin \Omega_t \\ \geq 0 & \text{si } v_i \in \Omega_t \end{cases} \quad (2.14)$$

La courbe C est définie comme l'hyperplan ou l'interface séparant le graphe en deux sous-ensembles $\Omega_t \subset V$ et $\overline{\Omega_t} \subset V$, qui représentent respectivement les sommets à l'intérieur de la courbe ou les sommets déjà atteints par la courbe et les sommets à l'extérieur de la courbe et qui ne sont pas encore atteints à l'instant t . On peut définir la relation entre ces deux sous-ensembles comme suit :

$$\Omega_t \cup \overline{\Omega_t} = V \quad \Omega_t \cap \overline{\Omega_t} = \emptyset \quad (2.15)$$

2.6. TRANSCRIPTION DE LA MÉTHODE D'ENSEMBLES DE NIVEAUX SUR GRAPHE

L'évolution de la courbe C dans le domaine discret est contrôlée par une fonction de vitesse $\mathcal{F} : V \times \mathbb{R} \rightarrow \mathbb{R}$. La courbe s'étend lorsque $\mathcal{F}$ est positif (on ajoute les sommets atteints par la courbe) et se rétracte lorsque $\mathcal{F}$ est négatif (on retire les sommets quittés par la courbe). Cette représentation discrète d'un front est illustrée à la figure 2.4. L'équation de propagation de la courbe décrite par une fonction des




FIGURE 2.4 – Représentation discrète d'une courbe évolutive : Les sommets du graphe à l'intérieur de la courbe sont représentés en vert. Les sommets susceptibles d'être atteints par la courbe lorsque $\mathcal{F} > 0$ sont représentés en bleu. Les sommets susceptibles d'être quittés par la courbe lorsque $\mathcal{F} < 0$ sont cerclés de rouge.

ensembles de niveaux évoluant sur un graphe pondéré (équation 2.4) peut être alors exprimée comme suit :

$$\frac{\partial \phi(v_i, t)}{\partial t} = \begin{cases} \mathcal{F}(v_i, t) \| (\nabla_{\omega}^+ \phi(v_i, t)) \| & \text{si } \mathcal{F}(v_i, t) > 0 \\ \mathcal{F}(v_i, t) \| (\nabla_{\omega}^- \phi(v_i, t)) \| & \text{si } \mathcal{F}(v_i, t) < 0 \\ 0 & \text{sinon} \end{cases} \quad (2.16)$$

où $(\nabla_{\omega}^+ \phi(v_i, t))$ et $(\nabla_{\omega}^- \phi(v_i, t))$ sont les opérateurs de gradient externe et interne pondérés définis en 1.16 et 1.17. L'équation 2.16 de l'évolution de la courbe C peut être exprimée comme une combinaison de traitements morphologiques. En effet, lorsque $\mathcal{F} > 0$ les sommets adjacents à la courbe sont ajoutés à Ω_t , ce qui coïncide avec une dilatation de l'ensemble Ω_t et lorsque $\mathcal{F} < 0$ des sommets sont retirés de la courbe, ce qui correspond à une érosion.

2.7 Adaptation des modèles de Chan et Vese sur graphe pour la segmentation des images hyperspectrales

2.7.1 Modèle deux-phases

En se basant sur la transcription de la fonction des ensembles de niveaux sur graphe, il est possible également de transcrire les modèles deux-phases et multi-phases de Chan et Vese sur graphe.

Intéressons nous tout d'abord au cas d'une seule courbe C évoluant sur un graphe $G(V, E, \omega)$. La courbe C est définie comme étant un sous-ensemble $\Omega \subset V$, et est implicitement représentée initialement par le niveau zéro d'une fonction d'ensembles de niveaux ϕ_0 . La transposition de l'équation du modèle deux-phases de Chan et Vese (2.10) sur un graphe pondéré, initialement introduite dans [19], se base sur l'équation discrète du mouvement d'une fonction d'ensembles de niveaux (2.16) dont la fonction de vélocité dépend de la moyenne à l'intérieur et à l'extérieur de la courbe. Cette fonction de vélocité est définie comme suit :

$$\mathcal{F}(v_i, t) = \alpha \mathcal{K}_\omega(v_i) + \beta \left((f(v_i) - \mu_{out}(t))^2 - (f(v_i) - \mu_{in}(t))^2 \right) \quad (2.17)$$

où $\mathcal{K}_\omega$ désigne la courbure moyenne définie par :

$$(\mathcal{K}_\omega f)(v_i) = \sum_{v_j \in V} \omega_{ij} \left(\frac{1}{\|(\nabla_\omega f)(v_j)\|_2} + \frac{1}{\|(\nabla_\omega f)(v_i)\|_2} \right) (f(v_i) - f(v_j)) \quad (2.18)$$

et f la fonction caractéristique associée à chaque sommet v_i du graphe. Cette expression de la courbure représente la version discrète de la courbure définie par Chan et Vese désignée par $div \left(\frac{\nabla \phi}{|\nabla \phi|} \right)$ qui représente le premier terme de l'équation du mouvement de la courbe évolutive (2.10). Les fonctions μ_{out} et μ_{in} sont respectivement les vecteurs caractéristiques moyens des sommets à l'extérieur et à l'intérieur de la courbe C et α et β deux constantes dépendant de l'application. À chaque instant t , la nouvelle valeur de la fonction d'ensembles de niveaux au sommet v_i dépend seulement de sa valeur à l'instant $t - 1$ et des valeurs de ses voisins. L'équation

2.7. ADAPTATION DES MODÈLES DE CHAN ET VESE SUR GRAPHE POUR LA SEGMENTATION DES IMAGES HYPERSPECTRALES

générale pour calculer la valeur de la fonction d'ensembles de niveaux pour chaque sommet v_i à chaque instant t est définie par :

$$\phi^t(v_i) = \begin{cases} \phi^{t-1}(v_i) + \Delta_t \mathcal{F}(v_i) \| (\nabla_{\omega}^+ \phi^{t-1}(v_i)) \| & \text{si } \mathcal{F}(v_i) > 0 \\ \phi^{t-1}(v_i) + \Delta_t \mathcal{F}(v_i) \| (\nabla_{\omega}^- \phi^{t-1}(v_i)) \| & \text{si } \mathcal{F}(v_i) < 0 \end{cases} \quad (2.19)$$

avec Δ_t un constant permettant de pondérer la fonction de vélocité et qui dépend de l'application considérée.

2.7.2 Modèle multi-phases

S'appuyant sur les travaux existants sur l'adaptation du modèle deux-phases de Chan et Vese sur des graphes [19], nous proposons de généraliser cette formulation au modèle multi-phases pour évaluer son potentiel dans la segmentation des images hyperspectrales. Dans ce cas, chaque courbe illustrée par une fonction d'ensembles de niveaux ϕ_i est décrite par une équation de propagation d'une fonction d'ensembles de niveaux sur un graphe pondéré (2.16) avec une fonction de vitesse spécifique. L'évolution générale d'une courbe dans le cas multi-phases est définie donc comme suit 2.20 :

$$\frac{\partial \phi_n^t(v_i)}{\partial t} = \begin{cases} \Delta_t \mathcal{F}_n(v_i) \| (\nabla_{\omega}^+ \phi_n^t(v_i)) \| & \text{si } \mathcal{F}_n(v_i) > 0 \\ \Delta_t \mathcal{F}_n(v_i) \| (\nabla_{\omega}^- \phi_n^t(v_i)) \| & \text{si } \mathcal{F}_n(v_i) < 0 \end{cases} \quad (2.20)$$

Pour illustrer ce fait, nous prenons l'exemple de $n = 2$ fonctions d'ensembles de niveaux représentées par deux courbes évolutives sur graphe. L'équation de mouvement (2.20) devient donc :

$$\begin{aligned} \frac{\partial \phi_1(v_i, t)}{\partial t} &= \begin{cases} \Delta_t \mathcal{F}_1(v_i, t) \| (\nabla_{\omega}^+ \phi_1(v_i, t)) \| & \text{si } \mathcal{F}_1(v_i, t) > 0 \\ \Delta_t \mathcal{F}_1(v_i, t) \| (\nabla_{\omega}^- \phi_1(v_i, t)) \| & \text{si } \mathcal{F}_1(v_i, t) < 0 \\ 0 & \text{sinon} \end{cases} \\ \frac{\partial \phi_2(v_i, t)}{\partial t} &= \begin{cases} \Delta_t \mathcal{F}_2(v_i, t) \| (\nabla_{\omega}^+ \phi_2(v_i, t)) \| & \text{si } \mathcal{F}_2(v_i, t) > 0 \\ \Delta_t \mathcal{F}_2(v_i, t) \| (\nabla_{\omega}^- \phi_2(v_i, t)) \| & \text{si } \mathcal{F}_2(v_i, t) < 0 \\ 0 & \text{sinon} \end{cases} \end{aligned} \quad (2.21)$$

Les vélocités $\mathcal{F}_1$ et $\mathcal{F}_2$ (respectivement pour ϕ_1 et ϕ_2) sont définies par :

$$\begin{aligned} \mathcal{F}_1(v_i, t) &= \alpha \mathcal{K}_{1\omega}(v_i) - ((f(v_i) - c_{11})^2 - (f(v_i) - c_{01})^2) H(\phi_2) \\ &\quad + ((f(v_i) - c_{10})^2 - (f(v_i) - c_{00})^2) (1 - H(\phi_2)) \end{aligned} \quad (2.22)$$

et

$$\begin{aligned}\mathcal{F}_2(v_i, t) = & \alpha \mathcal{K}_{2\omega}(v_i) - ((f(v_i) - c_{11})^2 - (f(v_i) - c_{10})^2) H(\phi_1) \\ & + ((f(v_i) - c_{01})^2 - (f(v_i) - c_{00})^2) (1 - H(\phi_1))\end{aligned}\quad (2.23)$$

où c_{11} représente la moyenne à l'intérieur de $SG_{11} = \{v_i \mid \phi_1^t(v_i) > 0 \text{ et } \phi_2^t(v_i) > 0\}$, c_{10} la moyenne à l'intérieur de $SG_{10} = \{v_i \mid \phi_1^t(v_i) > 0 \text{ et } \phi_2^t(v_i) < 0\}$, c_{01} la moyenne à l'intérieur de $SG_{01} = \{v_i \mid \phi_1^t(v_i) < 0 \text{ et } \phi_2^t(v_i) > 0\}$, c_{00} la moyenne à l'intérieur de $SG_{00} = \{v_i \mid \phi_1^t(v_i) < 0 \text{ et } \phi_2^t(v_i) < 0\}$.

2.8 Conclusion

Dans ce chapitre, nous avons proposé une adaptation du modèle à deux-phases de Chan et Vese pour la segmentation des images hyperspectrales. Nous avons introduit également un modèle discret de segmentation multi-phases de ce type d'images en se basant sur l'algorithme de Chan et Vese. Grâce à cette méthode multi-phases transposée sur graphe, on va pouvoir segmenter une image de structure complexe en la manipulant avec la puissance disponible sur les graphes mais il reste à construire le graphe optimal associé à l'image. Dans le prochain chapitre, nous présentons diverses métriques utilisées pour la mesure de similarité entre les sommets et la pondération des arêtes. Nous étudions également leur sensibilité par rapport à différentes transformations spectrales. L'évaluation est effectuée dans le but de trouver la meilleure métrique pour la segmentation des images hyperspectrales. Dans les deux derniers chapitres, nous présentons des applications de deux modèles discrets définis sur des graphes et mis en œuvre pour la segmentation d'images hyperspectrales synthétiques et réelles. Les expérimentations associées montrent les potentialités de notre méthodologie, sur les deux types d'images.

Chapitre 3

Métriques pour la comparaison de spectres

Sommaire

3.1	Introduction	46
3.2	Métriques spectrales	47
3.3	Évaluations et résultats	50
	3.3.1 Transformations de spectre	51
	3.3.2 Résultats	53
3.4	Conclusion	55

3.1 Introduction

La construction d'un graphe décrivant au mieux les relations entre des points de données initiales a été largement étudiée ces dernières années mais reste toujours un problème ouvert. La pertinence d'un graphe est très sensible à plusieurs paramètres notamment : (1) sa structure topologique qui décrit la relation entre les points de données. Dans ce cas, il est essentiel que le graphe puisse coder avec précision le voisinage local de chaque point de données pour en déduire une structure globale (segments significatifs) à partir des informations locales. La topologie est définie en identifiant chaque arête et en l'associant aux sommets correspondants (voir la section 1.3 pour plus de détails sur les différentes topologies de graphe utilisées) et (2) la fonction de similarité ou la similarité entre les sommets du graphe.

En effet, un problème clé que nous pouvons rencontrer lors de la construction de graphe pour le traitement d'images hyperspectrales repose sur la mesure des similarités entre ses sommets. Les principales mesures utilisées, telles que l'angle spectral et la distance Euclidienne, trouvent leur origine dans le traitement vectoriel et se sont révélées relativement fiables. Elles sont utilisées dans la détection et la classification des objets. De plus, de nouvelles mesures telles que la divergence spectrale de l'information et le gradient spectral ont été proposées pour mieux refléter la nature des données hyperspectrales. Dans notre recherche, nous avons étudié l'efficacité de diverses mesures de distance notamment la robustesse vis à vis de trois types de transformations spectrales (la translation spectrale, le changement d'amplitude et le mélange linéaire entre deux spectres). Les métriques étudiées sont également évaluées en relation avec notre objectif final qui est la segmentation des images dans les deux chapitres qui suivent. Contrairement à une approche traditionnelle où les distances spectrales sont utilisées uniquement comme distances dans le processus de classification, nous sommes intéressés par leur rôle dans la pondération des arrêtes du graphe avant traitement.

3.2 Métriques spectrales

Cette section fournit un aperçu sur différentes métriques spectrales étudiées. Notre objectif est de trouver la meilleure métrique permettant de mieux s'adapter à l'objectif de la segmentation. Une étude exhaustive dans laquelle les auteurs ont proposé de comparer différentes métriques existantes en fonction de leurs propriétés théoriques dans le contexte du traitement d'images hyperspectrales a été réalisée par Deborah et al. [41]. Dans leur article, les auteurs ont comparé et évalué différentes distances en utilisant des spectres simulés avec une fonction de distribution gaussienne. Dans notre cas, nous avons étudié la robustesse de ces métriques par rapport à trois types de transformations spectrales et en utilisant des spectres réels.

Étant donnés deux spectres S_1 et S_2 à comparer notés $S_1 = \{s_{1,\lambda}\}$ et $S_2 = \{s_{2,\lambda}\}$, où λ représente la longueur d'onde ou le numéro de la bande spectrale définie dans $\lambda \in [0, nb - 1]$, avec nb le nombre de longueurs d'onde, les différentes métriques spectrales trouvées dans la littérature peuvent être regroupées en quatre grandes familles :

- **Vecteur dans l'espace Euclidien** : dans cette première famille, un spectre est représenté sous la forme d'un n-uplet dans l'espace Euclidien avec des bandes spectrales orthogonales et non corrélées. Avec cette hypothèse, les bandes spectrales n'auraient aucun ordre particulier, ce qui signifie que la distance entre deux spectres resterait inchangée quel que soit l'ordre des bandes utilisé. Plusieurs distances dans cette catégorie sont dérivées de la distance de Minkowski (équation 3.1).

$$\mu_p(S_1, S_2) = \left(\sum_{\lambda} |s_{1,\lambda} - s_{2,\lambda}|^p \right)^{\frac{1}{p}} \quad (3.1)$$

En faisant varier l'ordre p de cette équation, on obtient la distance de Manhattan ($p = 1$), la distance Euclidienne ($p = 2$) et la distance de Chebyshev ($p = \infty$). La distance de Chebyshev peut également être écrite sous cette

3.2. MÉTRIQUES SPECTRALES

forme (équation 3.2).

$$\mu_{Che}(S_1, S_2) = \max_{\lambda} (|s_{1,\lambda} - s_{2,\lambda}|) \quad (3.2)$$

Une variante de cette formule de Minkowski est appelée fractional Minkowski [73] obtenue lorsque $p < 1$. Selon Aggarwal et al [73], cette variante améliore significativement l'efficacité des algorithmes de clustering pour les données de grande dimension.

En plus de ces variations, plusieurs autres métriques peuvent être généralisées par une fonction angulaire, telles que la distance cosinus et l'angle spectral [74] qui déterminent la similarité spectrale entre deux spectres en calculant l'angle géométrique entre leurs deux vecteurs.

$$\mu_{Cos}(S_1, S_2) = 1 - \frac{\sum_{\lambda} s_{1,\lambda} \cdot s_{2,\lambda}}{\sqrt{\sum_{\lambda} s_{1,\lambda}^2} \sqrt{\sum_{\lambda} s_{2,\lambda}^2}} \quad (3.3)$$

$$\mu_{SAM}(S_1, S_2) = \cos^{-1} \left(\frac{\sum_{\lambda} s_{1,\lambda} \cdot s_{2,\lambda}}{\sqrt{\sum_{\lambda} s_{1,\lambda}^2} \sqrt{\sum_{\lambda} s_{2,\lambda}^2}} \right) \quad (3.4)$$

Ces deux métriques sont basées sur la similarité dérivée du cosinus. Bornées par la valeur 1, les valeurs de la distance cosinus varient entre 0 pour des spectres identiques et 1 pour des spectres complètement différents. Dans le cas de l'angle spectral, la valeur est exprimée en radians.

- **Données de dimension n dans une variété** : dans cette classe, un spectre peut être considéré comme une donnée à n dimensions, l'ensemble des spectres considérés formant une variété. Parmi ces métriques, citons le coefficient Goodness-of-fit (GFC), utilisé à l'origine pour vérifier l'exactitude des spectres lumineux reconstruits [75].

$$\mu_{GFC}(S_1, S_2) = 1 - \frac{|\sum_{\lambda} s_{1,\lambda} \cdot s_{2,\lambda}|}{\sqrt{|\sum_{\lambda} s_{1,\lambda}^2|} \sqrt{|\sum_{\lambda} s_{2,\lambda}^2|}} \quad (3.5)$$

La distance Isomap entre deux spectres peut être exprimée sous la forme d'une somme de distances locales entre ces deux spectres et leurs voisins immédiats dans la variété. Les distances locales sont généralement calculées avec la distance Euclidienne. Plusieurs applications de la distance Isomap dans le cadre des images hyperspectrales peuvent être citées [76] [77].

- **Distribution** : dans cette famille, un spectre est considéré comme une distribution dont les bandes spectrales sont ordonnées. Les bandes voisines sont considérées comme plus corrélées, comparées aux bandes plus éloignées. L'hypothèse latente derrière la mise en place de cette famille concorde bien avec celle admise communément sur les données spectrales, et qui concerne la forte corrélation entre des bandes voisines [78]. En tant que distribution, un spectre pourrait alors être représenté sous forme d'une fonction de densité de probabilité (PDF) ou d'une fonction de distribution cumulative (CDF). Plusieurs métriques sont définies dans ce scenario, la corrélation spectrale, initialement développée pour le Spectral Correlation Mapper (SCM) [79] comme une mesure de similarité utilisée dans le domaine de la télédétection. D'autres métriques utilisées pour comparer des distributions sont celles qui mesurent la quantité d'intersection entre deux PDF ou CDF, par exemple la divergence de Jeffery [80] et le Pearson χ^2 [81] .

$$\mu_{SCM}(S_1, S_2) = 1 - \frac{1 + R(S_1, S_2)}{2} \quad (3.6)$$

avec

$$R(S_1, S_2) = \frac{\sum_{\lambda} (s_{1,\lambda} - \hat{s}_{1,\lambda}) \cdot (s_{2,\lambda} - \hat{s}_{2,\lambda})}{\sqrt{\sum_{\lambda} (\hat{s}_{1,\lambda})^2} \cdot \sqrt{\sum_{\lambda} (\hat{s}_{2,\lambda})^2}}$$

et où $\hat{s}$ représente le spectre normalisé, calculé par :

$$\hat{S} = \{\hat{s}_{\lambda} = s_{\lambda} - m, \forall \lambda \in [\lambda_{min}, \lambda_{max}]\} \text{ avec } m = \frac{k}{\lambda_{max} - \lambda_{min}} \text{ et } k = \sum_{\lambda} s_{\lambda}$$

La divergence de Jeffrey a été introduite initialement pour obtenir une diver-

gence symétrique, elle est définie comme suit :

$$\mu_{JEF}(S_1, S_2) = \sum_{\lambda} (s_{1,\lambda} \ln \frac{2 \cdot s_{1,\lambda}}{s_{1,\lambda} + s_{2,\lambda}} + s_{2,\lambda} \ln \frac{2 \cdot s_{2,\lambda}}{s_{1,\lambda} + s_{2,\lambda}}) \quad (3.7)$$

Le Pearson χ^2 (3.8), qui mesure la probabilité d'une distribution (spectre) déduite d'un ensemble de distributions (l'ensemble des spectres) représentée par la moyenne $s_{m,\lambda}$, est défini comme suit :

$$\mu_{Pea}(S_1, S_2) = \sum_{\lambda} \frac{(s_{1,\lambda} - s_{m,\lambda})^2}{s_{m,\lambda}} \text{ avec } s_{m,\lambda} = \frac{s_{1,\lambda} + s_{2,\lambda}}{2} \quad (3.8)$$

- **Spectre séquence** : Cette catégorie a été inspirée des fonctions de distance utilisées en biologie pour la comparaison d'ADN. L'hypothèse faite ici est de considérer un spectre comme une séquence, et de supposer que les bandes spectrales sont ordonnées en fonction de leur position dans la séquence. Les métriques qui font partie de cette catégorie sont principalement utilisées pour la comparaison des chaînes de caractères. Nous trouvons la distance de Hamming [82] qui mesure la différence entre deux séquences de même longueur en calculant le nombre d'éléments différents entre elles. Cette métrique s'applique seulement entre deux séquences de même longueur. Quant à la distance de Levenshtein [83], elle est égale au nombre minimal de caractères qu'il faut supprimer, insérer ou remplacer pour passer d'une séquence à l'autre. À l'inverse de la distance de Hamming, la distance de Levenshtein convient à des séquences de longueurs différentes.

3.3 Évaluations et résultats

Dans le but d'avoir une idée sur le comportement de ces métriques face à un ensemble de transformations qu'un spectre peut subir et pour distinguer la meilleure métrique à utiliser dans notre contexte de segmentation, nous avons appliqué quelques transformations à des spectres réels. Nous avons par la suite mesuré la robustesse des métriques en analysant la distance entre les spectres d'origine et les spectres transformés.

3.3. ÉVALUATIONS ET RÉSULTATS

L'ensemble des spectres réels que nous avons utilisé dans nos tests a été extrait de l'image Pavia University. Cette image de 610×340 pixels contient 10 types de spectres différents en 103 bandes spectrales.¹ La figure 3.1(a) contient les régions formées par ces spectres dans l'image. À chaque région, une couleur différente est attribuée en fonction du type de spectre. La figure 3.1(b) présente les profils spectraux de ces 10 spectres en utilisant les mêmes couleurs que les régions correspondantes.




FIGURE 3.1 – Les spectres de l'image hyperspectrale Pavia University : (a) Les différentes régions présentes dans l'image, (b) Les profils spectraux des 10 spectres de référence de l'image

3.3.1 Transformations de spectre

Dans le cadre de l'évaluation des métriques spectrales, nous avons considéré trois types de transformations. Notre idée est motivée par le fait que les spectres d'un segment de l'image hyperspectrale peuvent subir des transformations sans affecter la sémantique du segment. Dans ce cas il est très important que la métrique choisie pour construire le graphe de l'image soit robuste à ces transformations. Dans cette études, nous considérons :

1. http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes

3.3. ÉVALUATIONS ET RÉSULTATS

- la première transformation appliquée est la translation spectrale. Nous avons fait subir cette transformation au spectre *metal sheet* choisi pour sa forme très différente de celle des autres spectres figurés dans l'image Pavia University. La translation d'un spectre revient à le déplacer sur l'axe de la longueur d'onde (axe des abscisses sur la figure 3.2(a)). Cette modification du spectre peut être vue comme un changement de plage de couleurs.




FIGURE 3.2 – Translation spectrale : (a) simulation des nouveaux spectres par translation du spectre metal sheet , (b) comportement des métriques utilisées envers la translation appliquée.

- la deuxième transformation que nous avons appliquée est le changement d'amplitude. Nous avons également utilisé le spectre metal sheet de l'image Pavia University. La transformation appliquée revient à augmenter l'amplitude de ce spectre par rapport à sa forme initiale, de sorte qu'elle peut être considérée comme une simulation de changement de réflectance. La figure 3.3(a) présente un ensemble de spectres générés en augmentant l'amplitude du spectre original (le spectre le plus clair est avec l'intensité la plus faible).
- La troisième transformation réalisée est le mélange linéaire entre deux spectres S_1 et S_2 , qui simule un nouveau spectre S_{new} en appliquant l'équation de mélange linéaire suivante : $S_{new} = \alpha \times S_1 + (1 - \alpha) \times S_2$, où α est une variable

3.3. ÉVALUATIONS ET RÉSULTATS




FIGURE 3.3 – Changement d’amplitude : (a) Simulation des nouveaux spectres par changement d’amplitude du spectre metal sheet, (b) Comportement des métriques utilisées envers le changement d’amplitude appliquée.

réelle dans l’intervalle $[0, 1]$. Cette transformation permet de combiner deux spectres afin de créer un spectre dépendant de deux spectres de référence comme c’est le cas avec une couverture mixte d’un sol par exemple. Dans le but d’avoir une série de nouveaux spectres, la valeur de α peut être modifiée de façon incrémentale. Pour appliquer cette transformation, nous avons utilisé le spectre metal sheet et le spectre shadow. Nous avons choisi spécialement ces deux types de spectres car ils ont des caractéristiques différentes telles que leur nature, leur amplitude maximale et leur valeur de réflectance à chaque longueur d’onde.

3.3.2 Résultats

Les résultats de mesures de distance sont présentés dans les figures 3.2(b), 3.3(b) et 3.4(b). Nous décrivons par chaque point de l’axe des abscisses de ces courbes le nouveau spectre obtenu par les différentes transformations, tandis que l’axe des ordonnées représente les valeurs obtenues des distances entre le nouveau spectre et celui de référence. Dans le but de visualiser l’allure de la réponse des métriques

3.3. ÉVALUATIONS ET RÉSULTATS




FIGURE 3.4 – Mélange linéaire : (a) Simulation des nouveaux spectres par un mélange linéaire entre le spectre metal sheet et le spectre shadow, (b) Comportement des métriques utilisées envers le mélange linéaire appliqués.

mentionnées sur une même échelle $[0,1]$, chaque mesure de distance a été divisée par le maximum théorique obtenu par sa fonction mathématique.

Dans l'ensemble, nous constatons qu'une forte modification appliquée sur le spectre de référence engendre naturellement une grande valeur de distance entre le spectre original et sa version modifiée. Ce comportement est partagé par toutes les métriques étudiées. Évidemment plus le spectre simulé est éloigné du spectre de référence et plus la valeur de distance est grande pour les différents modes de transformation et pour les différentes métriques.

La figure 3.2(b) montre que la divergence de Jeffery est la plus robuste aux transformations spectrales. Une bonne robustesse est également observée avec les métriques Pea et SCM. Ceci confirme la robustesse des métriques de la famille « distribution » qui considèrent un spectre comme une distribution dont les bandes spectrales sont ordonnées. À l'inverse la distance Euclidienne est beaucoup plus sensible à ce type de transformation puisqu'elle considère les bandes spectrales comme orthogonales et non corrélées.

La figure 3.3(b) quant à elle montre que la majorité des métriques étudiées sont

robustes aux changement d’amplitude spectrale.

Dans le cas du mélange linéaire, les métriques se comportent dans l’ensemble d’une manière similaire. La distance croît en fonction de la modification successive du spectre original. Néanmoins, certaines métriques telle que le Jef, Pea et GFC croissent plus lentement que d’autres telle que la distance Euclidienne et Chebyshev.

3.4 Conclusion

Dans ce chapitre, nous avons présenté un ensemble de métriques spectrales qui pourront être utilisées pour pondérer les arrêtes d’un graphe construit à partir d’une image hyperspectrale. De plus, nous avons testé leur comportement en évaluant leur robustesse face à différentes transformations spectrales, notamment la translation, l’amplification et le mélange linéaire de spectre. Dans l’ensemble, toutes les métriques se comportent de manière similaire. Néanmoins, certaines montrent plus de robustesse par rapport à d’autres. Ce comportement reste à valider dans le cadre de la segmentation des images hyperspectrales. Dans le chapitre suivant, nous présentons les résultats expérimentaux des méthodes de segmentation proposées ainsi que l’évaluation de l’utilisation de chaque métrique dans ces méthodes.

Chapitre 4

Expérimentations sur des images de synthèse

Sommaire

4.1	Introduction	58
4.2	Base d'images hyperspectrales synthétiques	59
4.2.1	Génération des images de synthèse	60
4.2.2	Protocole de simulation	63
4.3	Résultats et discussion	64
4.3.1	Graphe complet	66
4.3.2	Graphe 4-voisinage	68
4.3.3	Graphe d'adjacence de région	71
4.4	Conclusion	76

4.1 Introduction

Dans ce chapitre nous évaluons sur des images hyperspectrales synthétiques l'approche de segmentation développée et nous montrons également l'influence de la construction du graphe (le choix de la métrique et de la topologie) sur les performances de la segmentation.

Les données hyperspectrales sur lesquelles nous avons effectué les différents tests sont issues de deux bases de données hyperspectrales (l'une synthétique et l'autre réelle). Pour générer la première base comportant 350 images obtenues par tirage aléatoire, nous avons développé un outil de simulation, permettant de créer des images hyperspectrales paramétrées constituées de régions polygonales homogènes avec mélange spectral à proximité des frontières.

Nous avons recouru à la création d'une base de données hyperspectrales, du fait du nombre limité de données hyperspectrales réelles disponibles (vu le coût élevé des systèmes d'acquisition), mais aussi dans le but de valider plus facilement l'implémentation des méthodes développées et d'évaluer leurs performances sur des images de synthèse avant de les tester sur des images réelles.

La création d'images hyperspectrales à partir de données synthétiques, offre plusieurs avantages. D'abord, on dispose d'une connaissance complète de l'ensemble de l'image (images simples sans défaut et sans dégradation comparé aux images réelles), on peut aussi faire varier ses caractéristiques et voir leur influence sur les résultats de segmentation, et bien sûr on dispose de la vérité terrain sur l'ensemble des pixels.

Dans la littérature, plusieurs travaux s'appuient sur la création d'images hyperspectrales synthétiques, toujours à cause du manque d'images réelles et aussi pour résoudre des problèmes bien spécifiques. Il s'agit souvent de fournir des données pour la phase d'apprentissage d'algorithmes de classification supervisée ou faciliter la mise au point de méthodes de détection sur des images simples et complètement connues. Dans [84], Lu et al. ont généré 80 bandes hyperspectrales synthétiques à partir de 8 bandes multispectrales réelles collectées par le satellite WorldView-2, en

utilisant la méthode de Extended Multi-Attribute Profile (EMAPs) [85] afin d'entraîner un réseau de neurones convolutifs profond à 4 couches pour la détection et la classification de sols.

Fadiran et al. [86] ont présenté une méthode permettant de générer automatiquement des images hyperspectrales synthétiques pour l'évaluation et le développement d'un algorithme de reconnaissance automatique de cible.

Dans [87], les auteurs ont développé une méthode de classification de régions dans des images hyperspectrales basée sur la méthode SVM. Dans leur travail, ils ont aussi proposé une méthode permettant de fournir automatiquement des données synthétiques pour l'étape d'entraînement de SVM.

Pour avoir un panorama complet sur ces méthodes, le lecteur intéressé peut se référer à [88], où les auteurs ont présenté une étude sur les différentes approches de simulation des images multispectrales et hyperspectrales dans le domaine de la télédétection en les classifiant en quatre grandes familles : approche empirique, statistique, avec modélisation physique et enfin avec modification d'image.

4.2 Base d'images hyperspectrales synthétiques

Les images réelles étant en général issues du domaine de la télédétection, nous avons cherché à produire des images s'apparentant à un paysage agricole, composé de champs cultivés polygonaux.

Il faut d'une part définir l'étendue spatiale des régions, d'autre part le contenu spectral au sein de chaque région. La modélisation choisie doit être suffisamment simple pour permettre le paramétrage des images et une interprétation facile des résultats, mais assez élaborée pour pouvoir évaluer finement les performances de segmentation sur la base d'images synthétiques. On peut ainsi transposer les conclusions des simulations sur des images réelles.

4.2.1 Génération des images de synthèse

Pour créer facilement des images hyperspectrales synthétiques avec un nombre varié de régions et adaptées à nos approches de segmentation en régions, nous nous sommes appuyés sur le formalisme élégant des diagrammes de Voronoï pour définir ces régions et leurs frontières. Le diagramme de Voronoï [89] qui réalise un pavage de l'espace en régions polygonales, peut être défini comme suit : étant donné un ensemble fini P de n points $\{p_1, \dots, p_n\}$ dans le plan euclidien $\mathbb{R}^2$, chaque point $p_k \in P$ est appelé centroïde. Le principe de base d'un diagramme de Voronoï consiste à diviser l'espace en n régions ou cellules correspondant aux centroïdes de P . Chaque région R_k représente l'ensemble des points qui sont plus proches de p_k que de tout autre centroïde de P . Les frontières entre deux régions correspondent à tous les points du plan équidistants de leurs centroïdes.

Les diagrammes de Voronoï interviennent souvent lorsque l'on cherche à partitionner l'espace en zones d'influence. Ils sont utilisés dans de nombreux domaines tels que l'astronomie pour la partition des structures spatiales des populations d'étoiles, la médecine pour la diagnostic de cellules cancéreuses, ou encore dans l'industrie pour les calculs de trajectoire en robotique mobile.

Plusieurs algorithmes [90] [89] [91] permettent de créer automatiquement un diagramme de Voronoï associé à un ensemble P de centroïdes. Ici, il n'est pas nécessaire de calculer les équations des frontières des régions. Il suffit d'affecter chaque pixel à la région définie par le centroïde le plus proche.

Pour définir spatialement le diagramme de Voronoï, nous fixons le nombre de centroïdes ou régions que nous souhaitons obtenir. Pour contrôler la taille des régions, nous avons généré aléatoirement les positions de centroïdes sous la contrainte suivante : on n'accepte un nouveau centroïde que s'il est distant au moins de d_{min} des centroïdes existants et au plus de d_{max} d'au moins un centroïde existant (d_{min} et d_{max} sont deux distances euclidiennes fixées en fonction de la taille de l'image).

Pour définir spectralement le diagramme de Voronoï, nous définissons pour chaque

4.2. BASE D'IMAGES HYPERSPECTRALES SYNTHÉTIQUES

région, un spectre de référence généré automatiquement par la somme de trois distributions gaussiennes paramétrées aléatoirement.

Leurs positions centrales et leurs largeurs sont données respectivement par la moyenne μ et l'écart type σ de leurs fonctions gaussiennes correspondantes selon l'équation 4.1.

$$f(\lambda) = \frac{1}{\sigma\sqrt{2\pi}} \exp^{-\frac{(\lambda-\mu)^2}{2\sigma^2}} \quad (4.1)$$

où λ désigne la longueur d'onde. Le choix de cette modélisation s'explique par la facilité de représentation de pics spectraux par des fonctions gaussiennes avec la maîtrise du paramétrage (largeur, hauteur et position).

Ce spectre de référence permettra de calculer le spectre total en chaque pixel de l'image hyperspectrale simulée en le décomposant en spectre interne (spectre de référence d'une région altéré par un bruit) et spectre externe (spectres des régions bordant la région de référence considérée).

Pour ne pas avoir de spectre strictement uniforme dans les régions, nous avons altéré les spectres de référence de chacune des régions en ajoutant un bruit gaussien à son spectre de référence (le bruit ajouté permet de modéliser la dispersion du spectre propre aux images naturelles et aussi le bruit de mesure lié à la chaîne d'acquisition), ce qui donne pour le spectre interne de la région R_1 :

$$Spectre_{interne_1} = C_{11} \times spectre_{ref_1} + bruit_{Gaussien} \quad (4.2)$$

L'amplitude du bruit gaussien est normalisée d'après l'amplitude moyenne du spectre de référence. En outre et afin de calculer le spectre externe pour un pixel donné dans une région R_1 , il faut d'abord déterminer les régions voisines, c'est-à-dire celles ayant une frontière commune avec la région R_1 .

Si par exemple les régions 2,3 et 4 ont toutes une frontière commune avec la région R_1 , le calcul du spectre externe est établi par l'équation suivante :

$$Spectre_{externe_1} = c_2 \times spectre_{ref_2} + c_3 \times spectre_{ref_3} + c_4 \times spectre_{ref_4} \quad (4.3)$$

4.2. BASE D'IMAGES HYPERSPECTRALES SYNTHÉTIQUES

avec c_1, c_2, c_3 et c_4 représentant les coefficients de mélange spectral linéaire vérifiant $c_1 + c_2 + c_3 + c_4 = 1$ et qui sont calculés comme suit :

$$c_1 = \frac{C_{11}}{C}, \quad c_2 = \frac{C_{12}}{C}, \quad c_3 = \frac{C_{13}}{C}, \quad c_4 = \frac{C_{14}}{C} \quad (4.4)$$

où

$$\begin{aligned} C_{11} &= 1 \\ C_{12} &= \alpha_2 \exp^{-\beta_2 \left[\frac{(d_2 - d_1)}{d_{12}} \right]} \\ C_{13} &= \alpha_3 \exp^{-\beta_3 \left[\frac{(d_3 - d_1)}{d_{13}} \right]} \\ C_{14} &= \alpha_4 \exp^{-\beta_4 \left[\frac{(d_4 - d_1)}{d_{14}} \right]} \\ C &= C_{11} + C_{12} + C_{13} + C_{14} \end{aligned} \quad (4.5)$$

où $\alpha_2, \alpha_3, \alpha_4, \beta_2, \beta_3$ et β_4 sont des constantes réelles à fixer. d_1, d_2, d_3 et d_4 désignent respectivement les distances d'un pixel au centre de R_1, R_2, R_3 et R_4 et d_{12}, d_{13} et d_{14} indiquent respectivement les distances entre le centroïde de la région R_1 et les centroïdes des régions R_2, R_3 et R_4 .

Cette formulation assure une atténuation du mélange lorsqu'on s'éloigne de la frontière de la région. Sur la frontière, le mélange est équilibré entre les 2 spectres correspondants. On garantit aussi que le spectre de référence d'une région est majoritaire en tout point de cette région. Si une région n'a pas de frontière commune avec la région de référence, son spectre n'intervient pas dans le mélange spectral.

Le spectre final en chaque pixel dans une région R_1 de l'image est calculé alors par l'équation de mélange linéaire suivante :

$$Spectre_1 = Spectre_{interne_1} + Spectre_{externe_1} \quad (4.6)$$

On lisse enfin le spectre spatialement sur toute l'image en appliquant un filtre médian, pour éviter des transitions trop fortes entre pixels proches, dues au bruit gaussien ajouté, avant de normaliser sur l'amplitude max du spectre obtenu pour former l'amplitude spectrale dans l'intervalle $[0, 255]$.

4.2. BASE D'IMAGES HYPERSPECTRALES SYNTHÉTIQUES

On procède de façon similaire pour générer le spectre sur l'ensemble des régions de Voronoï en considérant successivement les spectres définis comme spectre de référence de la région considérée. La figure 4.1 illustre la création de spectres simulés aléatoirement avec 3 pics spectraux gaussiens.




FIGURE 4.1 – Exemple de deux spectres générés aléatoirement sur 150 bandes spectrales avec des amplitudes entre 0 et 255 et synthétisés par combinaison de 3 gaussiennes de centre, largeur et position aléatoires.

4.2.2 Protocole de simulation

Nous avons créé 350 images de taille 50×50 pixels comportant chacune 4 régions de Voronoï. Le spectre de référence des centroïdes de chacune de ces régions est un vecteur de 150 valeurs, représentant les longueurs d'ondes, comprises entre 0 et 255. Ce spectre est généré automatiquement par la combinaison de 3 distributions gaussiennes dont les moyennes et écart-types sont choisis aléatoirement dans l'intervalle $[0, 150]$ (figure 4.2).

Le spectre final de chaque pixel d'une région donnée est calculé en additionnant son spectre interne et son spectre externe en utilisant respectivement les équations 4.2 et 4.3.

4.3. RÉSULTATS ET DISCUSSION




FIGURE 4.2 – Simulation d’un spectre interne : (a) 3 spectres générés aléatoirement (b) combinaison de ces 3 spectres en normalisant leur maximum (c) ajout d’un bruit gaussien sur le spectre simulé

Pour calculer le spectre externe de chaque pixel de l’image, nous avons fixé α à 1 afin de respecter l’égalité du mélange spectral à la frontière, et nous avons fait varier la valeur de β entre 0 et 3 avec un pas de 0.5 (50 images pour chaque valeur de β) dans le but d’analyser son influence sur les résultats de segmentation. Plus la valeur de β est grande, plus le spectre de référence devient rapidement dominant lorsqu’on s’éloigne du bord de la région. La figure 4.3 présente trois images contenant chacune quatre régions à segmenter. Les trois images sont obtenues pour une même partition par diagramme de Voronoï avec différentes valeurs de β ($\beta=0$: pas de mélange entre les spectres des régions, $\beta=1.5$: mélange moyen, $\beta=3$: mélange élevé).

4.3 Résultats et discussion

Dans cette section, nous analysons le comportement de notre adaptation discrète de l’équation multi-phases des ensembles de niveaux appliquée sur différentes constructions de graphes et commentons ses performances pour la segmentation sur les images hyperspectrales synthétiques définies plus haut. Tout d’abord, nous détaillons les différents constructions de graphes pondérés appliquées à ces images hyperspectrales synthétiques en appliquant les différentes topologies et métriques




FIGURE 4.3 – Images hyperspectrales synthétiques pour un même diagramme de Voronoï : (a) $\beta = 0$ (b) $\beta = 1.5$ (c) $\beta = 3$

spectrales mentionnées. Puis nous comparons les résultats de segmentation sur ces différentes constructions et nous évaluons les performances qualitativement sur les images segmentées et quantitativement en utilisant le taux de bonne classification TC (équation 4.7) comme mesure de précision de la segmentation. Le critère TC considère les valeurs les plus élevées proches de 1 comme la meilleure segmentation.

$$TC = \frac{\text{Nombre de pixels correctement identifiés}}{\text{Nombre de pixels total}} \quad (4.7)$$

Remarque: Nous avons utilisé comme critère le taux de bonne classification pour mesurer la précision de segmentation car nous disposons de la vérité terrain dédiée à la segmentation sur chaque pixel de l'image fournie par définition grâce à la simulation. Par exemple dans le cas où la segmentation fournit 4 régions, le centroïde sera considéré comme bien classé et les pixels de la région segmentée qui le contient auront le même label. Néanmoins, dans le cas où des régions sont regroupées lors de la segmentation, par exemple si 2 régions de référence se retrouvent fusionnées, on considérera que le label donné sera celui de la plus grande région. Les pixels de la plus petite région auront donc un label incorrect.

Notre intention ici est à la fois de montrer l'efficacité de notre méthode de segmentation et de la valider sur une base d'image hyperspectrales synthétiques et de comparer la précision de la segmentation obtenue pour différentes métriques spec-

trales et différentes topologies de graphe. Pour chaque topologie de graphe testée, nous allons comparer les résultats de segmentation obtenus avec différentes métriques pour différents degrés de mélange aux frontières des régions.

4.3.1 Graphe complet

Dans ce paragraphe, nous présentons les résultats de segmentation sur un graphe complet (cf. section 1.3.1 pour la définition d'un graphe complet). Ces résultats ont été obtenus avec notre méthode multi-phases sur graphe avec deux fonctions d'ensembles de niveaux conduisant à une segmentation à quatre phases (équation 2.21). Nous avons réalisé ces expérimentations sur 350 images (50 images pour chaque valeur de β) comportant chacune 4 régions constituant notre base d'images synthétiques. La figure 4.4 illustre un exemple de segmentation des images de la figure 4.3.




FIGURE 4.4 – Illustration de la segmentation quatre-phases de trois images synthétiques, de même digramme de Voronoï mais avec différents degrés de mélange spectral (paramètre β), représentées par un graphe complet en utilisant différentes métriques spectrales.

4.3. RÉSULTATS ET DISCUSSION

Nous avons représenté chacune de ces images par un graphe complet en utilisant la mesure de similarité g_2 (équation 1.10) associée pour pondérer ses arêtes en fonction des spectres caractérisant ses sommets et en se servant des différentes métriques spectrales citées dans la section 3.2. L'évaluation de ces résultats permet de mettre en évidence l'influence de la métrique spectrale utilisée pour calculer la distance entre les spectres de sommets voisins et de la valeur de β utilisée pour la simulation des images.

L'examen qualitatif des images segmentées correspond de toute évidence à une segmentation très précise dans tous les cas étudiés. En effet, les segmentations de l'image pour $\beta = 3$ et $\beta = 1.5$ semblent très robustes à la dégradation liée au bruit et au mélange appliqué sur l'image. On peut aussi remarquer, que les performances des segmentations basées sur les différentes métriques ne présentent pas de différence très notoire entre les différentes images.

L'évaluation quantitative de ces résultats est fournie dans le tableau 4.1, où nous donnons le TC moyen calculé sur les différentes images hyperspectrales.

Tableau 4.1 – TC moyen de segmentation de 350 images hyperspectrales synthétiques sur un graphe complet avec les différentes métriques spectrales (segmentation quatre-phases)

Métrique \ β	0	0.5	1	1.5	2	2.5	3
Jef	0.9882	0.9565	0.9387	0.9214	0.9182	0.9168	0.9132
Pea	0.9878	0.9561	0.9382	0.9208	0.9178	0.9164	0.9128
SCM	0.9874	0.9555	0.9378	0.9202	0.9173	0.9159	0.9123
GFC	0.9869	0.9550	0.9374	0.9198	0.9168	0.9156	0.9118
Cos	0.9866	0.9542	0.9371	0.9195	0.9164	0.9151	0.9113
SAM	0.9861	0.9538	0.9368	0.9190	0.9160	0.9147	0.9111
Manhattan	0.9856	0.9531	0.9365	0.9185	0.9156	0.9144	0.9106
Euclidean	0.9850	0.9527	0.9362	0.9180	0.9152	0.9141	0.9104
Chebyshev	0.9844	0.9519	0.9358	0.9176	0.9148	0.9137	0.9100

Nous pouvons constater à partir de ces résultats que les métriques spectrales influent très légèrement sur la segmentation finale. Les écarts semblent même très

4.3. RÉSULTATS ET DISCUSSION

faibles au premier abord mais il faut se rappeler que le TC est calculé sur l'ensemble d'une région et que les pixels mals classés vont se trouver près des frontières. Nous observons aussi que la meilleure précision de segmentation est obtenue par la métrique *Jef* et celle la plus faible par Chebyshev dans toutes les valeurs de β . La figure 4.5 présente le TC moyen obtenu avec chaque métrique utilisée.




FIGURE 4.5 – TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un graphe complet en fonction de la métrique spectrale utilisée pour la pondération des arêtes du graphe

Nous remarquons également que le TC moyen et la valeur de β sont inversement proportionnels autrement dit, si la valeur de β augmente, la segmentation devient moins pertinente, ce que nous pouvons traduire par la perte d'homogénéité aux frontières et le fort mélange spectral entre les régions induit par une grande valeur de β . Ce constat est illustré en figure 4.6.

4.3.2 Graphe 4-voisinage

Nous exposons dans ce paragraphe, les résultats de segmentation de notre méthode quatre-phases, obtenus sur un graphe de topologie 4-voisinage (la définition

4.3. RÉSULTATS ET DISCUSSION




FIGURE 4.6 – TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un graphe complet en fonction de la valeur de β .

détaillée de cette topologie est décrite dans la section 1.3.2) pondéré par la fonction de poids ω calculé par la mesure de similarité g_2 (1.10). Chaque sommet est connecté à ses quatre voisins spatialement connexes. Les interactions dans ce type de graphe sont donc limitées au voisinage immédiat. Le calcul des distances entre les sommets permettant de pondérer le graphe est basé sur les vecteurs spectraux de l'image. Les résultats de segmentation sur les trois différentes images et en utilisant les différentes métriques sont présentés dans la figure 4.7.

Ces résultats montrent un comportement similaire à ceux obtenus avec le graphe complet, mais avec cette configuration, la complexité des algorithmes de traitement est diminuée grâce à la réduction du nombre de voisins de chaque sommet du graphe et les taux de classification sont presque aussi haut que pour le graphe complet. La figure 4.8 montre de même que la valeur de β influe inversement sur la pertinence de segmentation. Néanmoins, avec les différents valeurs de β , nous constatons le même classement des métriques spectrales sur la segmentation comme illustré en figure 4.9.

4.3. RÉSULTATS ET DISCUSSION




FIGURE 4.7 – Illustration de la segmentation quatre-phases de trois images synthétiques, de même digramme de Voronoï mais avec différentes valeurs de β , représentées par un graphe 4-voisinage en utilisant différentes métriques spectrales.

Le tableau 4.2 généralise ce constat en terme de taux de classification moyen sur les 350 images.

Tableau 4.2 – TC moyen de segmentation de 350 images hyperspectrales synthétiques sur un graphe 4-voisinage avec les différentes métriques spectrales (segmentation quatre-phases)

β Métrique	0	0.5	1	1.5	2	2.5	3
Jef	0.9780	0.9538	0.9363	0.9093	0.9062	0.9053	0.8999
Pea	0.9776	0.9534	0.9360	0.9089	0.9059	0.9050	0.8996
SCM	0.9773	0.9530	0.9358	0.9086	0.9056	0.9047	0.8993
GFC	0.9769	0.9527	0.9355	0.9082	0.9052	0.9044	0.8990
Cos	0.9758	0.9520	0.9345	0.9073	0.9044	0.9038	0.8982
SAM	0.9750	0.9512	0.9337	0.9080	0.9035	0.9031	0.8976
Manhattan	0.9741	0.9508	0.9328	0.9075	0.9026	0.9023	0.8969
Euclidean	0.9734	0.9503	0.9319	0.9068	0.9020	0.9015	0.8960
Chebyshev	0.9722	0.9491	0.9310	0.9060	0.9012	0.9009	0.8952




FIGURE 4.8 – TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un graphe 4-voisinage en fonction de la valeur de β .

4.3.3 Graphe d'adjacence de région

Un point fort de notre approche basée graphes est que nous pouvons utiliser notre algorithme de segmentation sur n'importe quelle représentation d'une image, pour peu que cette représentation soit assimilable à un graphe pondéré.

Dans ce paragraphe, nous illustrons l'adaptivité de notre méthode de segmentation sur un RAG (voir la définition d'un RAG section 1.3.3).

Pour cela, nous utilisons une version simplifiée de l'image sous forme de partitions, sur lesquelles nous construisons le RAG. Ces partitions représentent les sommets du graphe connectés entre eux par des arêtes pondérées en fonction de leurs vecteurs spectraux moyens. Différentes méthodes efficaces permettant d'obtenir une partition sont disponibles dans la littérature telles que dans [92] [93] [94] [95] [96] [97] [98]. Le lecteur intéressé pourra se référer à [99] pour une comparaison quantitative de différentes méthodes de superpixels.

Dans notre approche, nous avons choisi d'utiliser la méthode de Turbo Pixel [93]

4.3. RÉSULTATS ET DISCUSSION




FIGURE 4.9 – TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un graphe 4-voisinage en fonction de la métrique spectrale utilisée pour la pondération des arêtes du graphe

en raison de sa simplicité et de son efficacité.

La méthode Turbo Pixels initialement développée par Levinshtein et al. [93] réalise une implémentation des superpixels dans laquelle la partition de l'image en régions est obtenue par la dilatation simultanée et contrôlée d'une grille régulière de marqueurs jusqu'à recouvrir l'intégralité de l'image. La dilatation est basée sur une approche par ensembles de niveaux et dépend de la structure de l'image. Ainsi, les contours des régions coïncident avec les contours de l'image.

La figure 4.10 illustre la construction d'un RAG à partir de l'image hyperspectrale synthétique présentée dans 4.3 (a). La première image de la figure 4.10 présente l'image initiale et les contours des 58 partitions en superposition (en rouge) en utilisant la méthode Turbo Pixels. Ces contours coïncident avec les contours internes de l'image originale.

Quant à la seconde image de cette figure 4.10, elle présente le graphe d'adjacence des régions (en vert) construit à partir de cette partition (en rouge).




FIGURE 4.10 – Construction d'un graphe à partir d'une image hyperspectrale synthétique : (a) L'image initiale avec les contours de la partition en rouge (b) le RAG correspondant (Les points bleus correspondent aux sommets et les arcs verts aux arêtes)

La figure 4.11 montre les résultats de segmentation de la même image hyperspectrale obtenus en la représentant par un RAG et la fonction de poids ω calculée à partir de la mesure de similarité g_2 associée (1.10) qui utilise les moyennes spectrales des régions.

Comme précédemment, nous faisons varier le degré de mélange β entre 0 et 3 pour les 6 métriques spectrales testées.

Les résultats de segmentation sont obtenus par la propagation de deux courbes associées aux masque initial 4.12 appliqué sur ce RAG.

Le tableau 4.3 résume la performance de notre méthode de segmentation sur RAG en terme de taux de bonne classification. De manière identique aux résultats obtenus sur graphe complet et graphe 4-voisinage, nous pouvons constater que la métrique Jef donne toujours la meilleure segmentation comparée aux autres métriques.

En revanche, nous remarquons une diminution de la précision de segmentation spécialement pour les images avec $\beta = 3$, ce qui peut s'interpréter par la forte réduction en terme de sommets du graphe de régions par rapport au nombre de sommets d'un graphe qui aurait été construit à partir de tous les pixels de l'image.

Les figures 4.13 et 4.14 présentent respectivement la précision de segmentation




FIGURE 4.11 – Illustration de la segmentation quatre-phases de trois images synthétiques, de même digramme de Voronoï mais avec différentes valeurs de β , représentées par un RAG en utilisant différentes métriques spectrales.




FIGURE 4.12 – Exemple de deux masques représentant les deux fonctions des ensembles de niveaux évoluant sur le graphe associé à l'image hyperspectrale

en fonction de valeur de β et en fonction des métriques utilisées pour la mesure de similarité entre les sommets d'un RAG.

Enfin la figure 4.15 rassemble toutes les combinaisons de métriques spectrales et

4.3. RÉSULTATS ET DISCUSSION

Tableau 4.3 – TC moyen de segmentation de 350 images hyperspectrales synthétiques sur un RAG avec les différentes métriques spectrales (segmentation quatre-phases)

Métrique \ β	0	0.5	1	1.5	2	2.5	3
Jef	0.8663	0.8659	0.8602	0.8548	0.8399	0.8388	0.8267
Pea	0.8658	0.8656	0.8598	0.8543	0.8396	0.8385	0.8264
SCM	0.8654	0.8650	0.8595	0.8540	0.8393	0.8382	0.8260
GFC	0.8651	0.8647	0.8592	0.8537	0.8390	0.8378	0.8256
Cos	0.8613	0.8574	0.8550	0.8536	0.8387	0.8374	0.8254
SAM	0.8613	0.8575	0.8545	0.8489	0.8377	0.8366	0.8238
Manhattan	0.8565	0.8518	0.8520	0.8365	0.8344	0.8227	0.8132
Euclidean	0.8560	0.8515	0.8517	0.8361	0.8338	0.8220	0.8130
Chebyshev	0.8558	0.8512	0.8511	0.8357	0.8330	0.8215	0.81326




FIGURE 4.13 – TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un RAG en fonction de la valeur de β .

de topologies de graphes présentées dans ce chapitre en utilisant le TC obtenu par notre méthode de segmentation sur 350 images hyperspectrales synthétiques. Nous pouvons constater que le classement des métriques spectrales est le même quelle que soit la topologie utilisée. Nous constatons également que l'impact de la topologie est

4.4. CONCLUSION




FIGURE 4.14 – TC moyen de segmentation quatre-phases de 350 images synthétiques représentées par un RAG en fonction de la métrique spectrales utilisée pour la pondération des arêtes du graphe

beaucoup plus fort sur les performances que celui de la métrique.

4.4 Conclusion

Dans ce chapitre, nous avons testé notre adaptation du modèle multi-phases de Chan et Vese sur graphes pondérés pour la segmentation d’images hyperspectrales synthétiques. Les résultats expérimentaux ont montré le potentiel de la méthode et son efficacité avec différentes approches de construction du graphe.

Dans notre protocole expérimental, nous avons testé différentes combinaisons de métriques spectrales et de topologies du graphe afin de construire un graphe représentant au mieux une image hyperspectrale avant de procéder à la segmentation. Nous comparons les trois topologies susmentionnées (graphe complet, graphe de 4-voisinage et graphe d’adjacence de régions) présentées dans la section 1.3 ainsi que les neuf métriques spectrales (L’angle spectral mapper, SCM, GFC, Chebyshev, Jef,




FIGURE 4.15 – Comparaison globale de TC moyen obtenus avec toutes les combinaisons possibles entre les métriques spectrales et les topologies de graphes

Cos, Pea, Euclidean et Manhattan) présentées dans la section 3.2.

Pour évaluer ces résultats de segmentation des images hyperspectrales obtenus, nous avons calculé le taux de bonne classification. Au terme de l'analyse, nous pouvons affirmer que les résultats de segmentation dépendent fortement de la topologie du graphe et faiblement de la métrique spectrale utilisé pour pondérer les arêtes du graphe.

Les résultats expérimentaux montrent que la segmentation d'une image hyperspectrale est sensible à la construction du graphe qui représente l'image. L'étude indique que le graphe complet produit une structure plus robuste reflétant correctement l'image hyperspectrale, du fait que, cette topologie permet d'intégrer toutes les informations de l'image. Cette topologie offre ainsi une segmentation nettement

4.4. CONCLUSION

meilleure par rapport aux autres topologies de graphe. De plus, Jef, Pea et SCM sont les métriques spectrales qui donnent les meilleurs résultats de segmentation avec les différentes structures de graphe.

Au chapitre suivant nous allons étudier et évaluer les performances de notre méthode de segmentation multi-phases sur des images hyperspectrale réelles représentées par différentes constructions du graphe.

Chapitre 5

Expérimentations sur des images réelles

Sommaire

5.1	Introduction	80
5.2	Base d'image hyperspectrales réelles	81
5.2.1	Image de Pavia University	81
5.2.2	Image Indian Pines	81
5.2.3	Image Salinas	83
5.3	Résultats et discussion	83
5.3.1	Graphe complet	84
5.3.2	Graphe 4-voisinage	88
5.3.3	Graphe d'adjacence de régions	90
5.3.4	Graphe ϵ -voisinage étendu basé sur des patches	93
5.4	Application aux images du BRGM	97
5.5	Conclusion	99

5.1 Introduction

Ce chapitre complète le chapitre précédent en évaluant notre approche de segmentation sur des images hyperspectrales réelles. Une partie de ces images circulent dans la communauté scientifique et sont très fréquemment utilisées car la vérité terrain associée est disponible et la comparaison des performances avec d'autres travaux est immédiate. L'autre partie de ces images provient d'une collaboration avec le BRGM (site d'Orléans), autour d'images hyperspectrales collectées par capteur aéroporté pour la détection de terrains argileux présentant des risques pour le bâti. Nous mettons également l'accent sur les avantages de la représentation par graphe qui facilite l'exploitation des informations spectro-spatiales des images.

Nous évaluons notre approche de segmentation par comparaison avec deux méthodes de l'état de l'art qui exploitent également la représentation par graphe. Ces méthodes sont (1) Graph Cuts (GC) [100] et (2) Normalized Cuts (NC) [17]. Étant donné que ces méthodes ont été d'abord développées dans le cadre de la segmentation des images en niveaux de gris ou couleur, nous les avons implémentées et étendues aux images hyperspectrales.

Nous aborderons également, dans ce chapitre, l'impact de différentes constructions de graphe sur les résultats de la segmentation, en considérant de manière systématique toutes les combinaisons de métriques spectrales et de topologies de graphes étudiées dans ce manuscrit.

Notre méthode de segmentation est évaluée quantitativement en utilisant deux critères différents qui sont (1) le score de recouvrement (Overlapping Score = OS) [101] et (2) l'indice de Jaccard (Jaccard index = JI) [102]. Ayant le résultat de la segmentation S et la vérité terrain G correspondante, ces critères sont définis par :

$$OS = \frac{|S \cap G|}{\min(|S|, |G|)}. \quad (5.1)$$

$$JI = \frac{|S \cap G|}{|S \cup G|} \quad (5.2)$$

Ces deux critères indiquent une bonne classification lorsqu'ils sont proches de 1.

5.2 Base d'image hyperspectrales réelles

Nous avons évalué notre approche de segmentation sur une base contenant quinze images hyperspectrales réelles de taille 50×50 extraites de trois images hyperspectrales :

5.2.1 Image de Pavia University

L'image hyperspectrale Pavia University (figure 5.1) a été acquise par le spectromètre optique embarqué "Reflective Optics System Imaging Spectrometer" (ROSIS) au-dessus du campus universitaire de Pavia, au Nord de l'Italie. Cette image a été capturée, en juillet 2002, par le centre de recherche allemand de l'aéronautique et astronautique "Deutsches Zentrum für Luft-und Raumfahrt" (DLR) dans le cadre du projet européen HySens. Cette image contient 610×340 pixels, avec une résolution spatiale de 1.3 m/pixel. Le nombre de bandes spectrales présentées dans cette image est de 103 bandes avec une plage spectrale allant de 0.43 à 0.86 μm dans la partie visible et proche infrarouge.

5.2.2 Image Indian Pines

L'image hyperspectrale Indian Pines (figure 5.2) a été acquise par le spectromètre optique "Airborne Visible/Infrared Imaging Spectrometer" (AVIRIS) dans la région Indian Pines dans le nord-ouest de l'Indiana aux États-Unis en juin 1992. Cette image est constituée de 145×145 pixels et de 200 bandes de réflectance spectrale dans une plage spectrale allant de 0.4 à 2.5 μm avec une résolution spatiale de 20 m/pixel.




FIGURE 5.1 – Image de Pavia University : (a) Image en RGB (b) la bande numéro 30 de cette image affichée en niveaux de gris (c) la bande numéro 100 de cette image affichée en niveaux de gris




FIGURE 5.2 – Image de Indian Pines : (a) Image en RGB (b) la bande numéro 30 de cette image affichée en niveaux de gris (c) la bande numéro 100 de cette image affichée en niveaux de gris

5.2.3 Image Salinas

L'image hyperspectrale Salinas (figure 5.3) a été également capturée par le capteur AVIRIS en octobre 1998. Cette image a été prise à basse altitude dans la vallée de la Salinas sur le littoral de la Californie. La taille de cette image est de 512×217 pixels, avec une résolution spatiale de 3.7 m/pixel. Cette image est composée de 224 bandes spectrales avec une couverture spectrale de 0.4 à $2.5 \mu\text{m}$.




FIGURE 5.3 – Image de Salinas : (a) Image en RGB (b) la bande numéro 30 de cette image affichée en niveaux de gris (c) la bande numéro 100 de cette image affichée en niveaux de gris

5.3 Résultats et discussion

Les expériences ont été réalisées sur une base d'images hyperspectrales réelles constituée de quinze petites images (figure 5.4) de taille 50×50 correspondant aux régions les plus saillantes dans les trois images présentées ci-dessus.




FIGURE 5.4 – Les quinze régions d'intérêt extraites (a) de l'image de l'Université de Pavia (b) de l'image Indian Pines et (c) de l'image Salinas

Pour chacune des constructions de graphe, nous comparons les méthodes de segmentation sur notre base d'images. Les résultats sont présentés de façon qualitative à travers quelques images segmentées et de façon quantitative avec le calcul des scores moyens de recouvrement pour chaque configuration.

5.3.1 Graphe complet

Nous présentons dans cette partie les résultats de segmentation en deux régions obtenus par notre méthode de généralisation du modèle de Chan et Vese deux-phases sur graphe décrite dans la section 2.7 ($n=1$ fonction des ensembles de niveaux c'est-à-dire une seule courbe évoluant sur le graphe avec l'équation 2.19) et les deux méthodes de l'état de l'art mentionnées dans la section 1.6, appliquées sur la base

5.3. RÉSULTATS ET DISCUSSION

d'images réelles hyperspectrales. Pour une image donnée, nous avons appliqué les différentes méthodes de segmentation sur le même graphe construit avec la même topologie de graphe complet.

La fonction de poids ω de ce graphe est calculée par la mesure de similarité g_2 (équation 1.10) où chacun des sommets est caractérisé par une fonction caractéristique correspondant aux spectres des pixels de l'image associée. La mesure de distance entre ces sommets a été effectuée en utilisant les différentes métriques citées dans la section 3.2 dans le but d'étudier leur efficacité et leur influence sur les résultats finaux de segmentation.

La figure 5.5 illustre quelques résultats qualitatifs obtenus pendant ces tests. La première colonne de cette figure présente la bande spectrale $\lambda = 50$ de quelques images sélectionnées dans notre base de test et la deuxième colonne présente les vérités terrains correspondantes. Les trois dernières colonnes de cette figure présentent respectivement les résultats de segmentation obtenus à partir de notre méthode à deux-phases, la méthode NC et la méthode GC.

Concernant les lignes de cette figure, elles correspondent respectivement de haut en bas aux résultats obtenus en utilisant les métriques spectrales Manhattan, SAM, Euclidean, GFC et Pea pour mesurer la distance entre les sommets.

En examinant cette figure, nous pouvons constater que ces résultats sont visuellement très proches et relativement similaires aux vérités terrains correspondantes.

Le tableau 5.1 affiche la précision moyenne des résultats de segmentation obtenus avec notre méthode à deux-phases et les méthodes NC et GC sur l'ensemble des images hyperspectrales réelles. Nous donnons dans ce tableau les valeurs moyennes de OS (5.1) et JI (5.2) calculées sur l'ensemble de la base de test.

Nous pouvons observer dans ce tableau que les deux critères d'évaluation donnent des valeurs relativement proches avec notre méthode à deux-phases et la méthode GC. Nous constatons également que la précision de segmentation obtenue avec notre

5.3. RÉSULTATS ET DISCUSSION




FIGURE 5.5 – Comparaison de la méthode deux-phases avec les méthodes NC et GC sur graphe complet

méthode est sensiblement plus forte que celle obtenue par NC et GC.

Ceci peut être expliqué par le fait d'utiliser la méthode des ensembles des niveaux pour simuler la propagation de courbe sur graphe. En effet, la méthode GC et NC cherchent à trouver une coupe optimale du graphe, ce qui conduit souvent à une fragmentation des régions ou à des contours irréguliers. Contrairement à la méthode des ensembles des niveaux, où la courbe favorise les régions compactes et connexes à l'aide de la fonction $\mathcal{F}$ qui s'appuie sur les moyenne de ces régions. En

plus, la représentation de courbe par cette méthode, sous la forme d'un ensemble de sommets, permet de manipuler tout type de courbe, sans contrainte sur leur topologie (lorsque elle se démultiplie ou fusionne), ni sur la topologie du graphe sur lequel elle se propage.

Ensuite nous pouvons remarquer aussi que les métriques spectrales influent notablement sur la qualité de résultats finaux de segmentation et quelle que soit la méthode appliquée, nous obtenons toujours des scores de même ordre, dont la meilleure précision de segmentation obtenue par la métrique Jef et celle la plus faible par Chebyshev. Nous constatons également que, pour toutes les méthodes de segmentation, le classement des métriques suivant les valeurs moyennes des critères de recouvrement, est identique. Ceci confirme bien les résultats d'évaluation des métriques obtenus dans le chapitre 3. En effet les métriques qui ont montré une grande sensibilité face à différentes transformations spectrales sont celles qui ont donné la meilleure précision de segmentation. Dans l'ensemble, nous constatons que les métriques appartenant à la famille "distribution" donnent toujours des scores très élevés par rapport aux autres métriques. Cela peut s'expliquer par l'hypothèse formulée pour cette famille, selon laquelle un spectre est considéré comme une distribution dont les bandes spectrales sont ordonnées et où les bandes voisines sont considérées plus corrélées comparées aux bandes plus éloignées, ce qui concorde bien avec la connaissance commune sur les données spectrales [78]. A l'inverse, les métriques de la première famille telles que Chebyshev, Euclidean et Manhattan, considèrent un spectre comme étant un vecteur dans l'espace Euclidien et supposent que les bandes spectrales d'un spectre donné sont orthogonales et non corrélées. Cette hypothèse mal étayée pourrait expliquer les faibles score de segmentation obtenus par les métriques de cette famille.

De surcroît, les résultats de segmentation obtenus sur des images réelles pour un graphe complet confirment bien les résultats obtenus sur la base d'images hyperspectrales synthétiques.

5.3. RÉSULTATS ET DISCUSSION

Tableau 5.1 – Évaluation des méthodes de segmentation sur graphe complet avec différentes métriques spectrales en calculant OS et JI moyen des résultats obtenus

Evaluation Distance	Méthode de segmentation sur un graphe complet					
	2-phases		NC		GC	
	OS	JI	OS	JI	OS	JI
Jef	0.9157	0.8439	0.8310	0.7793	0.8898	0.8182
Pea	0.9151	0.8432	0.8299	0.7785	0.8889	0.8179
SCM	0.9142	0.8426	0.8291	0.7753	0.8881	0.8171
GFC	0.9125	0.8413	0.8284	0.7725	0.8873	0.8163
Cos	0.9085	0.8302	0.8226	0.7714	0.8812	0.8115
SAM	0.8974	0.8284	0.8182	0.7614	0.8786	0.8052
Manhattan	0.8484	0.8025	0.7131	0.7141	0.8422	0.7892
Euclidean	0.8484	0.8013	0.7063	0.7132	0.8413	0.7885
Chebyshev	0.8483	0.8004	0.7019	0.7027	0.8405	0.7879

5.3.2 Graphe 4-voisinage

Nous présentons dans cette partie les résultats de segmentation en quatre régions des images hyperspectrales réelles représentées par un graphe 4-voisinage. Ces résultats sont obtenus par notre méthode de généralisation du modèle Chan et Vese à quatre-phases ($n = 2$ fonctions d'ensembles de niveaux) c'est-à-dire pour deux courbes évoluant sur le graphe et les méthodes NC et GC. Chaque sommet du graphe construit à partir d'une image donnée est connecté à ses quatre voisins spatialement connexe par une arête pondérée par la fonction de poids ω calculée par g_2 (équation 1.10) qui mesure la similarité entre les spectres correspondants. Les distances entre ces spectres intervenant dans la pondération du graphe ont été calculées en utilisant les neuf métriques spectrales décrites à la section 3.2.

La figure 5.6 présente qualitativement les résultats obtenus par notre méthode de segmentation à quatre-phase et les méthodes de l'état de l'art en reproduisant une segmentation en quatre régions. La composition de cette figure est identique à celle adaptée précédemment en figure 5.5.

Visuellement, les résultats de segmentation montrent un comportement similaire à ceux obtenus avec le graphe complet mais avec cette configuration, la complexité des algorithmes de traitement est diminuée grâce à la réduction du nombre de voisins

5.3. RÉSULTATS ET DISCUSSION

de chaque sommet du graphe. Par contre, comme nous pouvons le voir, la méthode NC produit des résultats inférieurs comparés aux autres méthodes utilisées. Notre méthode à quatre-phases et la méthode GC produisent des segmentations relativement similaires entre elles et aussi proches des vérités terrain associées.




FIGURE 5.6 – Comparaison de la méthode quatre-phases avec les méthodes NGC et GC sur graphe 4-voisinage

Le tableau 5.2 présente les résultats quantitatifs en termes de OS et JI moyen calculés sur les différentes images de la base de test. Au vu des résultats fournis dans le tableau 5.2, nous constatons que la segmentation réalisée par notre approche est la plus performante selon les deux critères d'évaluation utilisés. Les métriques Jef, Pea, SCM GFC, Cos, SAM produisent une segmentation plus fine, favorisant une classification ultérieure de la nature de spectre. En revanche, les métriques Manhat-

5.3. RÉSULTATS ET DISCUSSION

tan, Euclidean et Chebyshev fournissent une segmentation plus grossière par rapport à la segmentation obtenue avec les autres métriques. Les résultats expérimentaux obtenus sont bien en accord avec ceux obtenus sur la base d’images hyperspectrales synthétiques.

Tableau 5.2 – Évaluation des méthodes de segmentation sur graphe 4-voisinage avec différentes métriques spectrales en calculant le OS et JI moyen des résultats obtenus

Evaluation Distance	Méthode de segmentation sur un graphe 4-voisinage					
	4-phases		NC		GC	
	OS	JI	OS	JI	OS	JI
Jef	0.8997	0.8034	0.8159	0.6788	0.8751	0.7671
Pea	0.8989	0.8021	0.8151	0.6779	0.8745	0.7666
SCM	0.8981	0.8012	0.8142	0.6771	0.8734	0.7656
GFC	0.8974	0.7996	0.8133	0.6761	0.8722	0.7648
Cos	0.8913	0.7787	0.8072	0.6708	0.8661	0.7596
SAM	0.8387	0.7768	0.7546	0.6598	0.8135	0.7586
Manhattan	0.7632	0.6995	0.6791	0.5907	0.7380	0.6927
Euclidean	0.7547	0.6896	0.6706	0.5686	0.7295	0.6874
Chebyshev	0.7104	0.6890	0.5263	0.5127	0.7089	0.6815

5.3.3 Graphe d’adjacence de régions

Dans ce paragraphe, nous présentons les résultats expérimentaux de notre méthode de segmentation à quatre-phases sur un graphe d’adjacence des régions (RAG) (voir la section 1.3.3 pour plus de détails sur ce type de graphes).

La construction d’un RAG implique d’abord une partition de l’image en petites régions sur lesquelles nous construisons le RAG. Pour implémenter cette étape, nous avons utilisé la méthode Turbo Pixels [93] définie dans la section 4.3.3.

Cette topologie permet alors d’avoir un graphe plus petit comparé aux autres topologies existantes, car le nombre de sommets est réduit au nombre des régions résultant de la partition de l’image. Dans ce cas, la fonction de poids ω est calculée à partir de la mesure de similarité g_2 (équation 1.10) basée sur le spectre moyen des pixels de chaque région et la distance entre ces spectres est calculée en utilisant les différentes métriques étudiées dans la section 3.2. Quelques exemples de segmen-

5.3. RÉSULTATS ET DISCUSSION

tation à quatre-phases sur un RAG avec les métriques GFC, Pea et Chebyshev, utilisées pour mesurer la distance entre les sommets, sont présentées à la figure 5.11.




FIGURE 5.7 – Segmentation quatre-phases sur un RAG : la première colonne représente des bandes spectrales affichées en niveau de gris, la deuxième colonne représente la vérité terrain, troisième, quatrième et cinquième colonne représentent respectivement le résultat de segmentation de ces images en utilisant la métrique GFC, Pea, Chebyshev

Le tableau 5.3 détaille ces résultats en mesurant OS et JI moyen des résultats obtenus. Les performances de notre méthode sur un RAG sont autour de 0.9 pour OS lorsque le nombre de superpixels est égal à 500. Cette performance diminue avec la réduction du nombre de superpixels sélectionnés. Ceci était prévisible car tous les pixels regroupés au sein d'un même superpixels seront de fait affectés à la même région dans les résultats finaux de segmentation.

5.3. RÉSULTATS ET DISCUSSION

Tableau 5.3 – OS et JI moyen de segmentation d’images hyperspectrales réelles sur un graphe d’adjacence de régions (RAG) avec différentes métriques spectrales pour mesurer la distance entre les sommets du graphe

4-phases Segmentation sur un RAG		
Métrique \ Critère d’évaluation	OS	JI
Jef	0.9009	0.8349
Pea	0.9003	0.8343
SCM	0.8995	0.8338
GFC	0.8989	0.8330
Cos	0.8920	0.8205
SAM	0.8752	0.8098
Manhattan	0.8498	0.7673
Euclidean	0.8315	0.7714
Chebyshev	0.8235	0.7604

L’évaluation qualitative et quantitative de la méthode de segmentation à quatre-phases sur un RAG montre que le meilleur résultat de segmentation est obtenu avec la distance spectrale Jef. Les métriques Pea et SCM fournissent également de bons résultats par rapport aux autres métriques. Quant aux métriques spectrales de la première famille telles que Chebyshev, Euclidean ou Manhattan, même avec la topologie RAG, elles produisent une segmentation inférieure aux autres métriques mais toujours meilleure qu’avec une topologie de graphe à 4-voisinage. La représentation d’une image par un RAG permet en plus de réduire le temps de calcul de segmentation, ce qui s’explique par la réduction du nombre de sommets composant le graphe comparé à la topologie 4-voisinage. Pour donner un ordre de grandeur des temps de calcul, la segmentation quatre-phases sur un RAG de 500 superpixels obtenus par la méthode Turbo Pixels [93] permet un gain d’un facteur 9 comparé à une segmentation sur un graphe 4-voisinage.

5.3.4 Graphe ϵ -voisinage étendu basé sur des patches

Nous illustrons ici le comportement du processus de segmentation reposant sur la généralisation du modèle Chan et Vese multi-phases sur une construction particulière d'un graphe ϵ -voisinage. En effet, nous avons proposé de représenter chaque sommet du graphe par une fonction caractéristique spécifique reposant sur des patches et d'associer un voisinage plus étendu à chaque sommet du graphe.

L'idée derrière cette construction est motivée principalement par la volonté d'étudier et d'exploiter l'information de texture incluse dans les images hyperspectrales afin d'améliorer les résultats finaux de segmentation. Pour cette raison, inspirés par son efficacité à caractériser la texture et les détails fins de l'image, nous avons choisi d'utiliser le descripteur Local Binary Pattern (LBP) [103] comme fonction caractéristique pour chaque pixel de l'image. Cette méthode offre de bonnes performances en fournissant des informations structurelles et statistiques qui décrivent la texture des images. De plus, c'est une méthode de faible complexité qui rend possible l'analyse d'images 2D en temps réel. Cette méthode permet de représenter la texture de l'image en assignant un code binaire à chaque pixel en fonction de son voisinage afin d'obtenir le code LBP. Cette méthode génère le code LBP par seuillage du voisinage 3×3 de chaque pixel avec la valeur centrale en considérant les résultats sous forme de nombre binaire converti en nombre décimal pour avoir le code LBP du pixel central. La figure 5.8 résume les différentes étapes de calcul de LBP.

Dans le cadre de la classification des textures avec LBP, les occurrences des codes (valeurs décimales des codes LBP) dans une image sont collectées dans un histogramme. La classification est ensuite effectuée par un simple calcul de distance entre histogrammes. Il faut noter que plusieurs descripteurs, qui sont dérivés de LBP, ont été proposés dans la littérature. Nous pouvons noter la version LBP invariante à la rotation [104] ou aussi la version invariante aux facteurs d'échelle [105].

L'utilisation de LBP pour la caractérisation et la classification d'images hyperspectrales a connu récemment un gain d'intérêt considérable. Nous pouvons citer




FIGURE 5.8 – Calcul de code LBP

les travaux de Musci et al. [106] qui ont présenté une nouvelle approche de représentation de texture hyperspectrale basée sur le LBP et le LPQ (Local Phase Quantization [107]), ou encore Li et al. [108] dont le travail repose sur le filtre de Gabor et le LBP pour analyser l'information de texture afin de classifier des images hyperspectrales. Gan et al. [109] ont aussi proposé une méthode de classification des images hyperspectrales en utilisant le descripteur LBP pour extraire les caractéristiques locales de texture présentées dans des images de télédétection.

Suivant la même idée d'utiliser la performance de ce descripteur pour caractériser la texture hyperspectrale, nous avons introduit une nouvelle approche de représentation d'images hyperspectrales par graphe en utilisant LBP.

La première étape de notre approche de construction du graphe consiste à représenter une image hyperspectrale donnée par un ensemble des patches superposés $\{P_i, i = 1 \dots N\}$ de dimension 5×5 , chaque patch P_i étant extrait autour d'un pixel $p_i = (x_i, y_i, S_{p_i})^t$ où x_i et y_i représentent les coordonnées spatiales du pixel p_i et S_{p_i} le spectre correspondant.

5.3. RÉSULTATS ET DISCUSSION

Chaque pixel dans l'image hyperspectrale est représenté par un sommet du graphe connecté à ses 15×15 voisins plus proches avec une arête pondérée. Pour chaque pixel p_i , nous calculons le code LBP sur chacune des bandes hyperspectrales λ comme suit :

$$LBP_\lambda(p_i) = \sum_{n=0}^{N-1} \text{sign}(s_{n,\lambda} - s_{c,\lambda}) \times 2^n \quad (5.3)$$

où $S_c = \{s_{c,\lambda}\}$ représente le spectre du pixel central et $S_n = \{s_{n,\lambda}\}$ représente le spectre d'un pixel voisin. L'entier N représente le nombre total de pixels ($N = X \times Y$) dans un patch P_i , et $\text{sign}(x)$ une fonction définie par $\text{sign}(x) = 1$ si $x \geq 0$ et 0 sinon. Le code binaire LBP, associé au code décimal obtenu par l'équation (5.3), est donc de taille 24 bits ($5 \times 5 - 1$). Le code LBP final d'un pixel p_i est calculé ensuite comme la concaténation des codes LBP standards de chacune de ses bandes hyperspectrales. Ce qui donne un vecteur binaire de taille $24 \times \Lambda$ bit où Λ désigne le nombre total de bandes spectrales dans l'image. Le code LBP final est défini alors comme suit :

$$LBP(p_i) = \sum_{\lambda=0}^{\Lambda} LBP_\lambda(p_i) \times 2^{\lambda \times N} \quad (5.4)$$

Une fois les codes LBP calculés pour chaque pixel p_i (sommet v_i dans le graphe), la métrique de Hamming est utilisée pour associer une distance entre chaque paire de sommets (v_i, v_j) . Ceci est effectué en appliquant l'opérateur XOR ($\oplus$) entre les codes binaires de vecteurs LBP des sommets correspondants, ce qui donne comme résultat le nombre de positions pour lesquelles les codes binaires sont différents. La figure 5.9 et l'équation 5.5 détaillent le calcul de la distance de Hamming entre deux codes binaires LBP de deux sommets v_i et v_j .

$$\mu_{Hamming}(v_i, v_j) = LBP(v_i) \oplus LBP(v_j) \quad (5.5)$$

Une étape de mesure de similarité est finalement appliquée pour définir toutes les valeurs de poids des arêtes dans l'intervalle $[0,1]$ en appliquant l'équation de mesure de similarité (1.10) g_2 , qui peut être exprimée comme suit :




FIGURE 5.9 – Calcul de distance de Hamming entre deux codes LBP

$$\omega_{ij} \begin{cases} \exp(-\frac{\mu_{Hamming}(v_i, v_j)^2}{\sigma^2}) & \text{si } (v_i, v_j) \in E \\ = 0 & \text{si } (v_i, v_j) \notin E \end{cases} \quad (5.6)$$

où σ^2 représente la variance de toutes les valeurs obtenues par la distance de Hamming.

La figure 5.10 montre les résultats de segmentation quatre-phases sur le graphe décrit ci-dessus. Le tableau 5.4 montre les résultats quantitatifs de cette segmentation évalués par les critères OS et JI. Dans ce tableau, nous pouvons remarquer la nette différence entre la segmentation fournie par le graphe local donné par la topologie 4-voisinage et le graphe non-local donné par la topologie ϵ -voisinage étendu. En effet, l'utilisation des patches permet de mieux capturer les similarités entre les éléments comportant certains détails tels que les textures fines, ce qui explique la production de résultats plus pertinents.




FIGURE 5.10 – Segmentation quatre-phases sur un graphe de ϵ -voisinage étendu en utilisant comme fonction caractéristique en chaque sommet un patch LBP de taille 5×5 : Lignes (1 et 3) Bandes hyperspectrales affichées en niveau de gris, lignes (2 et 4) Résultats de segmentation par le modèle quatre-phases de Chan et Vese sur un graphe ϵ -voisinage en utilisant des patches LBP

5.4 Application aux images du BRGM

L'étude des sols argileux fait l'objet de nombreux travaux de recherche géologique. Ces travaux sont essentiellement motivés par leur rôle dans les processus

5.4. APPLICATION AUX IMAGES DU BRGM

Tableau 5.4 – OS et JI moyen de segmentation des trois images hyperspectrales mentionnées (Pavia University, Indian Pines et Salinas) sur un graphe de ϵ -voisinage étendu en utilisant comme fonction caractéristique en chaque sommet un patch LBP de taille 5×5

Segmentation 4-phases sur un graphe de ϵ -voisinage étendu en utilisant des patches LBP		
Critère d'évaluation	OS	JI
Image hyperspectrale		
Pavia University	0.9102	0.8403
Indian Pines	0.9275	0.8930
Salinas	0.9134	0.8897

d'érosion et les catastrophes naturelles.

En particulier dans le cadre de la planification urbaine, il est important d'avoir une cartographie précise d'aléas des argiles gonflantes responsables de la fissuration des bâtiments. La quantification des argiles gonflantes est alors nécessaire pour évaluer le risque de retrait-gonflement des sols responsable des ces dégâts.

Les techniques traditionnelles pour réaliser la cartographie des minéraux argileux des sols sont en général coûteuses et fastidieuses et sont basées sur des campagnes de mesures sur le terrain. La télédétection hyperspectrale est une technique intéressante pour obtenir des cartes d'argile plus précises, à moindre coût et sur une zone plus importante.

Dans ce cadre, le Bureau de Recherche Géologique Minière (BRGM) d'Orléans a réalisé une campagne d'acquisition aéroportée d'images hyperspectrales pour la détection de ces argiles. Le but de cette campagne est de pouvoir automatiser la cartographie, en limitant les prélèvements sur le terrain.

Néanmoins, cette technique est limitée par le fait que : (1) les minéraux sont mélangés de manière intime dans les sols avec d'autres composants ; et aussi (2) à l'échelle aéroportée, le signal réfléchi du sol nu est mélangé à celui de la végétation au sein d'un pixel et il faut prendre en compte l'absorption d'une partie du rayonnement par la couche atmosphérique. Ces phénomènes de mélange, aux échelles microscopique et macroscopique, rendent difficile l'estimation du contenu en argiles

minéralogiques.

Dans cette partie, nous proposons une application concrète de la méthode de segmentation présentée dans ce manuscrit pour segmenter les images fournies par le BRGM afin de faciliter le repérage des zones argileuses.

Le BRGM nous a fourni, après une étape de correction atmosphérique, un ensemble de 15 images hyperspectrales de taille 672×320 sur 256 bandes spectrales dans le but de les segmenter en petites régions pour pouvoir identifier plus facilement les zones en question. Ces images ne disposant pas de vérité terrain, seuls des relevés ponctuels sur le terrain pourraient permettre de conclure sur la présence d'argiles à risque.

Nous avons choisi de représenter ces images avec l'une de constructions de graphes les plus performante, le graphe ϵ -voisinage étendu basé sur des patches, en utilisant un voisinage de dimension 11×11 où chaque pixel est caractérisé par un patch spectral de dimension 3×3 . Notre méthode produit automatiquement une partition des images en quatre classes regroupant les spectres homogènes. Nous pouvons remarquer que les contours détectés de ces régions correspondent bien aux contours des images originales et sont cohérents par rapport aux formes des objets. Cette étape permet de séparer les terrains nus, de ceux couverts par la végétation ou par des constructions. L'étape suivante de classification sera ensuite appliquée par le BRGM pour labelliser les régions segmentées en comparant leurs caractéristiques et les caractéristiques de référence des argiles afin d'identifier les régions argileuses dans les images, à l'aide de prélèvements ponctuels sur site pour disposer d'une vérité terrain.

5.5 Conclusion

Dans ce chapitre, nous avons testé notre adaptation du modèle multi-phases de Chan et Vese sur graphes pondérés pour la segmentation d'images hyperspectrales réelles. Les résultats expérimentaux ont montré le potentiel de la méthode et son efficacité avec différentes approches de construction de graphe, comparé à deux mé-




FIGURE 5.11 – Segmentation quatre-phases des images du BRGM sur un graphe de ϵ -voisinage étendu basé sur des patches LBP : la première ligne représente les bandes spectrales affichées en niveaux de gris, la deuxième ligne représente les résultats de segmentation de ces images.

thodes basées graphes très connues dans la littérature. L'évaluation de ces résultats montre aussi que la topologie du graphe et la métrique utilisée dans l'étape de pondération influent considérablement sur les résultats finaux de segmentation.

L'étude expérimentale indique d'une part que la topologie de graphe complet produit un graphe exhaustif plus robuste, où les informations spatiales et spectrales complètes de l'image sont préservées, ce qui lui permet de donner une segmentation plus précise par rapport aux autres topologies, mais il est prohibitif en pratique par ses temps de calcul.

D'autre part, les métriques de la famille distribution sont celles qui ont donné les meilleurs résultats de segmentation quelle que soit la topologie adoptée.

Nous pouvons donc en conclure que l'impact des topologies et des métriques sur la précision de la segmentation est indépendant. La meilleure segmentation d'une image hyperspectrale est finalement obtenue avec la meilleure topologie combinée avec la meilleure métrique.

Conclusion générale

Avec l'émergence de capteurs et d'instruments d'imagerie avancés de faible coût, l'imagerie hyperspectrale se diversifie pour analyser et résoudre les problèmes traditionnels en télédétection et en vision par ordinateur. Pour exploiter les informations spectrales et spatiales abondantes dans les images hyperspectrales, il est nécessaire de concevoir et développer de nouvelles méthodes permettant de faciliter les tâches génériques de la reconnaissance de formes, telles que la détection et la reconnaissance d'objets et la segmentation d'images.

Les méthodes existantes issues respectivement de l'analyse d'images et de l'analyse spectrale se concentrent soit sur des caractéristiques spatiales pour segmenter une image en niveau de gris, soit sur une caractéristique spectrale pour classifier des pixels individuellement. Bien que des recherches aient été menées sur la gestion conjointe des informations spatiales et spectrales, le développement de nouvelles méthodes, exploitant les caractéristiques spatiales et spectrales reste très ouvert notamment pour la segmentation des images hyperspectrales.

Dans cette thèse, nous avons exploré une approche du problème de la segmentation d'images hyperspectrales. Cette approche exploite les caractéristiques spectro-spatiales simultanément en représentant une image hyperspectrale sous forme d'un graphe pondéré. Comparés aux structures d'images sous forme de grilles ou de cubes traditionnellement utilisées, la représentation par graphe offre une plus grande flexibilité, permettant ainsi d'utiliser un plus haut niveau d'abstraction que celui des pixels (par exemple des superpixels ou des patches pour représenter les sommets du

5.5. CONCLUSION

graphe). Dans le premier chapitre de ce manuscrit, nous avons présenté les notions et les définitions des graphes pondérés. Nous avons également présenté les différentes topologies de graphe utilisées pour représenter une image hyperspectrale. Nous avons par la suite rappelé les principes de certaines méthodes de l'état de l'art utilisées pour la comparaison avec notre méthode.

Dans le deuxième chapitre, nous avons présenté notre méthode de segmentation d'images hyperspectrales. La méthode proposée est une extension sur des graphes du modèle variationnel à deux-phases de Chan et Vese. Nous avons également présenté notre adaptation de leur algorithme multi-phases et proposé un modèle discret de segmentation multi-phases en exploitant le formalisme des équations aux différences partielles définies sur des graphes et la transcription de l'approche des ensembles de niveaux sur graphe.

Dans le troisième chapitre, nous avons présenté un ensemble de métriques spectrales que nous avons utilisées pour pondérer les arrêtes des graphes construits à partir des images hyperspectrales. Nous avons également analysé leurs comportements en évaluant leur robustesse face à différentes transformations spectrales.

Dans le but d'évaluer les approches de segmentations proposées, dans le quatrième chapitre, nous avons introduit une nouvelle base d'images hyperspectrales synthétiques. Ceci nous a permis de bien étudier les différentes constructions de graphe et leur impact sur la segmentation.

Dans le dernier chapitre, nous avons évalué la performance de nos segmentations basées graphes sur des images hyperspectrales réelles partagées par la communauté scientifique. Les résultats obtenus démontrent la supériorité de nos approches notamment en comparaison avec deux méthodes de l'état de l'art (le Graph Cut et le Normalized Cut).

Étant donné que notre méthode de segmentation d'images hyperspectrales s'appuie sur le modèle variationnel de Chan et Vese, deux améliorations pourraient être

5.5. CONCLUSION

abordées, à court terme. En premier lieu, l'amélioration du temps de calcul. En effet, le modèle variationnel est relativement coûteux en temps de calcul, ce qui ralentit le temps d'exécution de notre méthode de segmentation, surtout quand l'image est représentée par un graphe de grande dimension. Pour résoudre ce problème, nous proposons de paramétrer la construction de graphe afin de trouver le seuil optimal qui permet de déterminer la dimension optimale du graphe offrant un temps de calcul réduit et une performance de segmentation élevée. En second lieu, la minimisation de la fonction d'énergie dans le modèle de Chan et Vese principalement dépend de la méthode de descente de gradient. Cette méthode est connue par une convergence potentielle vers des optimums locaux ce qui pourrait dans certain cas fausser la segmentation. Cette problématique est également connue dans le modèle variationnel. Une solution envisageable est de bien étudier l'initialisation des courbes de niveaux, notamment utiliser des grilles et exécuter l'algorithme avec différentes initialisations.

En plus de ces deux axes d'amélioration de notre méthode de segmentation d'autres perspectives pointent à l'horizon. Notamment dans le cadre de la construction du graphe, nous envisageons l'utilisation d'autres types de descripteurs connus dans la communauté de la vision par ordinateur par leur pouvoir discriminatoire tel que le descripteur d'histogramme de gradient ou le descripteur de covariance. Nous sommes également très attentifs à l'augmentation de la masse de données hyperspectrales annotées. L'objectif est de pouvoir étudier et tester les techniques d'apprentissage profond pour la segmentation des images hyperspectrales.

Liste des publications

Conférences internationales

K. Tabia, X.Desquesnes, Y. Lucas and S. Treuillet, Local Binary Pattern based Graph Construction for Hyperspectral Image Segmentation, 12th IAPR intern. Workshop on Graph based Representations, École Polytechnique de l'Université de Tours, June 19th-21th 2019.

K. Tabia, X.Desquesnes, Y.Lucas, S.Treuillet, Influence of spectral metrics on the graph-based segmentation of hyperspectral images, 9th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing, WHISPERS 2018, 23-26 sept 2018, Amsterdam, The Netherlands.

K. Tabia, X. Desquesnes, Y. Lucas, S. Treuillet, A multiphase level set method on graphs for hyperspectral image segmentation, 17th int. Conference on Advanced Concepts for Intelligent Vision Systems (ACIVS 2016), Lecce, Italy, Oct 24-27 2016 Lecture Notes in Computer Science LNCS 10016, Springer, p.559-569.

Conférences nationales

K. Tabia, X. Desquesnes, Y. Lucas, S. Treuillet, Représentation par graphe pour la segmentation d'images hyperspectrales, ID201, Colloque GRETSI 2017, Juan-les-Pins 5-8 Sept. 2017.

K. Tabia, X. Desquesnes, Y. Lucas, S. Treuillet Contours actifs sur graphe pour la segmentation d'images hyperspectrales 4ème Colloque du groupe hyperspectral de la société française de photogrammétrie et de télédétection SFPT-GH Grenoble 11-13 mai 2016.

Colloques - Séminaires

K. Tabia, X.Desquesnes, Y.Lucas, S.Treuillet Différentes constructions de graphe pour la segmentation d'images hyperspectrales, GDR ISIS SFO, Journées Imagerie Optique Non Conventionnelle , JIONC 2018, Paris, 26-27 mars 2018.

K. Tabia, X. Desquesnes, S. Gourdier, A. Hohmann, Y. Lucas, S. Treuillet. Analyse d'images hyperspectrales aéroportées pour la cartographie de sols à risques, Journée Réseau Thématique Recherche Images, CESR Tours 3 juillet 2015.

Bibliographie

- [1] A. Paoli, F. Melgani, and E. Pasolli, “Clustering of hyperspectral images based on multiobjective particle swarm optimization,” *IEEE transactions on geoscience and remote sensing*, vol. 47, no. 12, pp. 4175–4188, 2009.
- [2] K. Masood and N. Rajpoot, “Texture based classification of hyperspectral colon biopsy samples using clbp,” in *2009 IEEE International Symposium on Biomedical Imaging : From Nano to Macro*, pp. 1011–1014, IEEE, 2009.
- [3] A. F. Goetz, G. Vane, J. E. Solomon, and B. N. Rock, “Imaging spectrometry for earth remote sensing,” *science*, vol. 228, no. 4704, pp. 1147–1153, 1985.
- [4] R. O. Green, M. L. Eastwood, C. M. Sarture, T. G. Chrien, M. Aronsson, B. J. Chippendale, J. A. Faust, B. E. Pavri, C. J. Chovit, M. Solis, *et al.*, “Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (aviris),” *Remote sensing of environment*, vol. 65, no. 3, pp. 227–248, 1998.
- [5] D. Manolakis, E. Truslow, M. Pieper, T. Cooley, and M. Brueggeman, “Detection algorithms in hyperspectral imaging systems : An overview of practical algorithms,” *IEEE Signal Processing Magazine*, vol. 31, no. 1, pp. 24–33, 2014.
- [6] R. L. Kettig and D. Landgrebe, “Classification of multispectral image data by extraction and classification of homogeneous objects,” *IEEE Transactions on geoscience Electronics*, vol. 14, no. 1, pp. 19–26, 1976.
- [7] Y. Tarabalka, J. Chanussot, and J. A. Benediktsson, “Segmentation and classification of hyperspectral images using watershed transformation,” *Pattern*

- Recognition*, vol. 43, no. 7, pp. 2367–2379, 2010.
- [8] Y. Tarabalka, J. A. Benediktsson, and J. Chanussot, “Spectral–spatial classification of hyperspectral imagery based on partitional clustering techniques,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 8, pp. 2973–2987, 2009.
- [9] L. Xu, H. Zhang, M. Zhao, D. Chu, and Y. Li, “Integrating spectral and spatial features for hyperspectral image classification using low-rank representation,” in *2017 IEEE International Conference on Industrial Technology (ICIT)*, pp. 1024–1029, IEEE, 2017.
- [10] J. Yuan, D. Wang, and R. Li, “Remote sensing image segmentation by combining spectral and texture features,” *IEEE Transactions on geoscience and remote sensing*, vol. 52, no. 1, pp. 16–24, 2013.
- [11] D. B. Gillis and J. H. Bowles, “Hyperspectral image segmentation using spatial-spectral graphs,” in *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVIII*, vol. 8390, p. 83901Q, International Society for Optics and Photonics, 2012.
- [12] L. Euler, “Solutio problematis ad geometriam situs pertinentis,” *Commentarii academiae scientiarum Petropolitanae*, pp. 128–140, 1741.
- [13] Y. Liu, D. Zhang, G. Lu, and W.-Y. Ma, “A survey of content-based image retrieval with high-level semantics,” *Pattern recognition*, vol. 40, no. 1, pp. 262–282, 2007.
- [14] B. Xu, J. Bu, C. Chen, C. Wang, D. Cai, and X. He, “Emr : A scalable graph-based ranking model for content-based image retrieval,” *IEEE Transactions on knowledge and data engineering*, vol. 27, no. 1, pp. 102–114, 2013.
- [15] P. F. Felzenszwalb and D. P. Huttenlocher, “Efficient graph-based image segmentation,” *International journal of computer vision*, vol. 59, no. 2, pp. 167–181, 2004.

- [16] Y. Boykov, O. Veksler, and R. Zabih, “Fast approximate energy minimization via graph cuts,” in *Proceedings of the Seventh IEEE International Conference on Computer Vision*, vol. 1, pp. 377–384, IEEE, 1999.
- [17] J. Shi and J. Malik, “Normalized cuts and image segmentation,” *Departmental Papers (CIS)*, p. 107, 2000.
- [18] T. F. Chan and L. A. Vese, “Active contours without edges,” *IEEE Transactions on image processing*, vol. 10, no. 2, pp. 266–277, 2001.
- [19] X. Desquesnes, A. Elmoataz, and O. Lezoray, “Pdes level sets on weighted graphs,” in *2011 18th IEEE International Conference on Image Processing*, pp. 3377–3380, IEEE, 2011.
- [20] V.-T. Ta, A. Elmoataz, and O. L  zoray, “Partial difference equations over graphs : Morphological processing of arbitrary discrete data,” in *European Conference on Computer Vision*, pp. 668–680, Springer, 2008.
- [21] V.-T. Ta, A. Elmoataz, and O. L  zoray, “Partial difference equations on graphs for mathematical morphology operators over images and manifolds,” in *2008 15th IEEE International Conference on Image Processing*, pp. 801–804, IEEE, 2008.
- [22] M. Maier, U. V. Luxburg, and M. Hein, “Influence of graph construction on graph-based clustering measures,” in *Advances in neural information processing systems*, pp. 1025–1032, 2009.
- [23] L. Grady, “Random walks for image segmentation,” *IEEE Transactions on Pattern Analysis & Machine Intelligence*, no. 11, pp. 1768–1783, 2006.
- [24] K. Tabia, X. Desquesnes, Y. Lucas, and S. Treuillet, “A multiphase level set method on graphs for hyperspectral image segmentation,” in *International Conference on Advanced Concepts for Intelligent Vision Systems*, pp. 559–569, Springer, 2016.

- [25] S. Bougleux, A. Elmoataz, and M. Melkemi, “Discrete regularization on weighted graphs for image and mesh filtering,” in *International Conference on Scale Space and Variational Methods in Computer Vision*, pp. 128–139, Springer, 2007.
- [26] O. Lezoray, A. Elmoataz, and S. Bougleux, “Graph regularization for color image processing,” *Computer Vision and Image Understanding*, vol. 107, no. 1-2, pp. 38–55, 2007.
- [27] O. Lezoray, V. T. Ta, and A. Elmoataz, “Nonlocal graph regularization for image colorization,” in *2008 19th International Conference on Pattern Recognition*, pp. 1–4, IEEE, 2008.
- [28] H.-D. Cheng, X. H. Jiang, Y. Sun, and J. Wang, “Color image segmentation : advances and prospects,” *Pattern recognition*, vol. 34, no. 12, pp. 2259–2281, 2001.
- [29] J. R. Uijlings, K. E. Van De Sande, T. Gevers, and A. W. Smeulders, “Selective search for object recognition,” *International journal of computer vision*, vol. 104, no. 2, pp. 154–171, 2013.
- [30] J. Malik, S. Belongie, T. Leung, and J. Shi, “Contour and texture analysis for image segmentation,” *International journal of computer vision*, vol. 43, no. 1, pp. 7–27, 2001.
- [31] C. Fowlkes, D. Martin, and J. Malik, “Learning affinity functions for image segmentation : Combining patch-based and gradient-based approaches,” in *2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2003. Proceedings.*, vol. 2, pp. II–54, IEEE, 2003.
- [32] X. Y. Stella and J. Shi, “Multiclass spectral clustering,” in *null*, p. 313, IEEE, 2003.
- [33] T. Leung and J. Malik, “Contour continuity in region based image segmentation,” in *European Conference on Computer Vision*, pp. 544–559, Springer, 1998.

- [34] X. Wang, H. Li, S. Masnou, and L. Chen, "Sparse coding and mid-level superpixel-feature for 0-graph based unsupervised image segmentation," in *International Conference on Computer Analysis of Images and Patterns*, pp. 160–168, Springer, 2013.
- [35] J. Wang, Y. Jia, X.-S. Hua, C. Zhang, and L. Quan, "Normalized tree partitioning for image segmentation," in *2008 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1–8, IEEE, 2008.
- [36] A. Y. Yang, J. Wright, Y. Ma, and S. S. Sastry, "Unsupervised segmentation of natural images via lossy data compression," *Computer Vision and Image Understanding*, vol. 110, no. 2, pp. 212–225, 2008.
- [37] B. Alexe, T. Deselaers, and V. Ferrari, "Measuring the objectness of image windows," *IEEE transactions on pattern analysis and machine intelligence*, vol. 34, no. 11, pp. 2189–2202, 2012.
- [38] G. Shu, A. Dehghan, and M. Shah, "Improving an object detector and extracting regions using superpixels," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 3721–3727, 2013.
- [39] J. Carreira, R. Caseiro, J. Batista, and C. Sminchisescu, "Semantic segmentation with second-order pooling," in *European Conference on Computer Vision*, pp. 430–443, Springer, 2012.
- [40] Z. Yu, A. Li, O. C. Au, and C. Xu, "Bag of textons for image segmentation via soft clustering and convex shift," in *2012 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 781–788, IEEE, 2012.
- [41] H. Deborah, N. Richard, and J. Y. Hardeberg, "A comprehensive evaluation of spectral distance functions and metrics for hyperspectral image processing," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 6, pp. 3224–3234, 2015.

- [42] A. Elmoataz, O. Lezoray, and S. Boughleux, “Nonlocal discrete regularization on weighted graphs : a framework for image and manifold processing,” *IEEE transactions on Image Processing*, vol. 17, no. 7, pp. 1047–1060, 2008.
- [43] Y. Boykov, V. Kolmogorov, D. Cremers, and A. Delong, “An integral solution to surface evolution pdes via geo-cuts,” in *European Conference on Computer Vision*, pp. 409–422, Springer, 2006.
- [44] N. El Zehiry, S. Xu, P. Sahoo, and A. Elmaghraby, “Graph cut optimization for the mumford-shah model,” in *The Seventh IASTED International Conference on Visualization, Imaging and Image Processing*, pp. 182–187, ACTA Press, 2007.
- [45] L. Grady and C. V. Alvino, “The piecewise smooth mumford–shah functional on an arbitrary graph,” *IEEE Transactions on Image Processing*, vol. 18, no. 11, pp. 2547–2561, 2009.
- [46] S. Boughleux, A. Elmoataz, and M. Melkemi, “Local and nonlocal discrete regularization on weighted graphs for image and mesh processing,” *International journal of computer vision*, vol. 84, no. 2, pp. 220–236, 2009.
- [47] C. Couprie, L. Grady, L. Najman, and H. Talbot, “Power watershed : A unifying graph-based optimization framework,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 33, no. 7, pp. 1384–1399, 2011.
- [48] Y. Boykov and V. Kolmogorov, “An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision,” *IEEE Transactions on Pattern Analysis & Machine Intelligence*, no. 9, pp. 1124–1137, 2004.
- [49] Y. Weiss, “Segmentation using eigenvectors : a unifying view,” in *Proceedings of the seventh IEEE international conference on computer vision*, vol. 2, pp. 975–982, IEEE, 1999.
- [50] L. J. Grady and J. R. Polimeni, *Discrete calculus : Applied analysis on graphs for computational science*. Springer Science & Business Media, 2010.

- [51] A. N. Hirani, *Discrete exterior calculus*. PhD thesis, California Institute of Technology, 2003.
- [52] R. Courant, K. Friedrichs, and H. Lewy, “On the partial difference equations of mathematical physics,” *IBM journal of Research and Development*, vol. 11, no. 2, pp. 215–234, 1967.
- [53] A. Bensoussan and J.-L. Menaldi, “Difference equations on weighted graphs,” *Journal of Convex Analysis*, vol. 12, no. 1, pp. 13–44, 2005.
- [54] J. M. Neuberger, “Nonlinear elliptic partial difference equations on graphs,” *Experimental Mathematics*, vol. 15, no. 1, pp. 91–107, 2006.
- [55] J.-H. Park and S.-Y. Chung, “Positive solutions for discrete boundary value problems involving the p-laplacian with potential terms,” *Computers & Mathematics with Applications*, vol. 61, no. 1, pp. 17–29, 2011.
- [56] T. F. Chan, S. Osher, and J. Shen, “The digital tv filter and nonlinear denoising,” *IEEE Transactions on Image processing*, vol. 10, no. 2, pp. 231–241, 2001.
- [57] D. Zhou and B. Schölkopf, “Regularization on discrete spaces,” in *Joint Pattern Recognition Symposium*, pp. 361–368, Springer, 2005.
- [58] L. Alvarez, F. Guichard, P.-L. Lions, and J.-M. Morel, “Axioms and fundamental equations of image processing,” *Archive for rational mechanics and analysis*, vol. 123, no. 3, pp. 199–257, 1993.
- [59] T. F. Chan and J. J. Shen, *Image processing and analysis : variational, PDE, wavelet, and stochastic methods*, vol. 94. Siam, 2005.
- [60] Y.-H. R. Tsai and S. Osher, “Total variation and level set methods in image science,” *Acta Numerica*, vol. 14, pp. 509–573, 2005.
- [61] G. Aubert and P. Kornprobst, *Mathematical problems in image processing : partial differential equations and the calculus of variations*, vol. 147. Springer Science & Business Media, 2006.

- [62] S. Osher and J. A. Sethian, "Fronts propagating with curvature-dependent speed : algorithms based on hamilton-jacobi formulations," *Journal of computational physics*, vol. 79, no. 1, pp. 12–49, 1988.
- [63] L. A. Vese and T. F. Chan, "A multiphase level set framework for image segmentation using the mumford and shah model," *International journal of computer vision*, vol. 50, no. 3, pp. 271–293, 2002.
- [64] D. Mumford and J. Shah, "Boundary detection by minimizing functionals," in *IEEE Conference on Computer Vision and Pattern Recognition*, vol. 17, pp. 137–154, San Francisco, 1985.
- [65] D. Mumford and J. Shah, "Optimal approximations by piecewise smooth functions and associated variational problems," *Communications on pure and applied mathematics*, vol. 42, no. 5, pp. 577–685, 1989.
- [66] U. Massari and I. Tamanini, "On the finiteness of optimal partitions," *Annali dell'Università di Ferrara*, vol. 39, no. 1, pp. 167–185, 1993.
- [67] I. Tamanini, "Optimal approximation by piecewise constant functions," in *Variational Methods for Discontinuous Structures*, pp. 73–85, Springer, 1996.
- [68] G. P. Leonardi and I. Tamanini, "On minimizing partitions with infinitely many components," *Annali dell'Università di Ferrara*, vol. 44, no. 1, pp. 41–57, 1998.
- [69] R. Malladi, J. A. Sethian, and B. C. Vemuri, "Shape modeling with front propagation : A level set approach," 1994.
- [70] J. E. Solem, N. C. Overgaard, and A. Heyden, "Initialization techniques for segmentation with the chan-vese model," in *18th International Conference on Pattern Recognition (ICPR'06)*, vol. 2, pp. 171–174, IEEE, 2006.
- [71] G. Cao, Z. Mao, X. Yang, and D. Xia, "Optical aerial image partitioning using level sets based on modified chan-vese model," *Pattern Recognition Letters*, vol. 29, no. 4, pp. 457–464, 2008.

- [72] Y. Peng, L. Pi, and C. Shen, “A semi-automatic method for burn scar delineation using a modified chan–vese model,” *Computers & Geosciences*, vol. 35, no. 2, pp. 183–190, 2009.
- [73] C. C. Aggarwal, A. Hinneburg, and D. A. Keim, “On the surprising behavior of distance metrics in high dimensional space,” in *International conference on database theory*, pp. 420–434, Springer, 2001.
- [74] F. A. Kruse, A. Lefkoff, J. Boardman, K. Heidebrecht, A. Shapiro, P. Barloon, and A. Goetz, “The spectral image processing system (sips)-interactive visualization and analysis of imaging spectrometer data,” in *AIP Conference Proceedings*, vol. 283, pp. 192–201, AIP, 1993.
- [75] J. Hernández-Andrés, J. Romero, A. García-Beltrán, and J. L. Nieves, “Testing linear models on spectral daylight measurements,” *Applied Optics*, vol. 37, no. 6, pp. 971–977, 1998.
- [76] M. Brand, “Charting a manifold,” in *Advances in neural information processing systems*, pp. 985–992, 2003.
- [77] M. M. Crawford, L. Ma, and W. Kim, “Exploring nonlinear manifold learning for classification of hyperspectral data,” in *Optical Remote Sensing*, pp. 207–234, Springer, 2011.
- [78] C. Rodarmel and J. Shan, “Principal component analysis for hyperspectral image classification,” *Surveying and Land Information Science*, vol. 62, no. 2, pp. 115–122, 2002.
- [79] O. de Carvalho Jr, R. Guimaraes, R. Gomes, A. de Carvalho, N. da Silva, and E. Martins, “Spectral multiple correlation mapper,” in *2006 IEEE International Symposium on Geoscience and Remote Sensing*, pp. 2773–2776, IEEE, 2006.
- [80] H. Jeffreys, “An invariant form for the prior probability in estimation problems,” *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences*, vol. 186, no. 1007, pp. 453–461, 1946.

- [81] Y. Rubner and C. Tomasi, *Perceptual metrics for image database navigation*, vol. 594. Springer Science & Business Media, 2013.
- [82] R. W. Hamming, “Error detecting and error correcting codes,” *The Bell system technical journal*, vol. 29, no. 2, pp. 147–160, 1950.
- [83] V. I. Levenshtein, “Binary codes capable of correcting deletions, insertions, and reversals,” in *Soviet physics doklady*, vol. 10, pp. 707–710, 1966.
- [84] Y. Lu, D. Perez, M. Dao, C. Kwan, and J. Li, “Deep learning with synthetic hyperspectral images for improved soil detection in multispectral imagery,” in *Proceedings of the IEEE Ubiquitous Computing, Electronics & Mobile Communication Conference, New York, NY, USA*, pp. 8–10, 2018.
- [85] S. Bernabé, P. R. Marpu, A. Plaza, and J. A. Benediktsson, “Spectral unmixing of multispectral satellite images with dimensionality expansion using morphological profiles,” in *Satellite Data Compression, Communications, and Processing VIII*, vol. 8514, p. 85140Z, International Society for Optics and Photonics, 2012.
- [86] O. O. Fadiran, P. Molnár, and L. M. Kaplan, “Automated synthetic hyperspectral image generation for clutter complexity metric development,” tech. rep., CLARK ATLANTA UNIV GA, 2006.
- [87] B. Abbasi, H. Arefi, B. Bigdeli, and S. Roessner, “Automatic generation of training data for hyperspectral image classification using support vector machine,” *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 2015.
- [88] S. Han and J. P. Kerekes, “Overview of passive optical multispectral and hyperspectral image simulation techniques,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 11, pp. 4794–4804, 2017.

- [89] M. I. Shamos and D. Hoey, “Closest-point problems,” in *16th Annual Symposium on Foundations of Computer Science (sfcs 1975)*, pp. 151–162, IEEE, 1975.
- [90] P. J. Green and R. Sibson, “Computing dirichlet tessellations in the plane,” *The computer journal*, vol. 21, no. 2, pp. 168–173, 1978.
- [91] S. Fortune, “A sweepline algorithm for voronoi diagrams,” *Algorithmica*, vol. 2, no. 1-4, p. 153, 1987.
- [92] M. Meila and J. Shi, “Learning segmentation by random walks,” in *Advances in neural information processing systems*, pp. 873–879, 2001.
- [93] A. Levinstein, A. Stere, K. N. Kutulakos, D. J. Fleet, S. J. Dickinson, and K. Siddiqi, “Turbopixels : Fast superpixels using geometric flows,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 31, no. 12, pp. 2290–2297, 2009.
- [94] P. A. Arbeláez and L. D. Cohen, “Energy partitions and image segmentation,” *Journal of Mathematical Imaging and Vision*, vol. 20, no. 1-2, pp. 43–57, 2004.
- [95] X. Ren and J. Malik, “Learning a classification model for segmentation,” in *null*, p. 10, IEEE, 2003.
- [96] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Süsstrunk, “Slic superpixels compared to state-of-the-art superpixel methods,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 34, no. 11, pp. 2274–2282, 2012.
- [97] M.-Y. Liu, O. Tuzel, S. Ramalingam, and R. Chellappa, “Entropy rate superpixel segmentation,” in *CVPR 2011*, pp. 2097–2104, IEEE, 2011.
- [98] A. Vedaldi and S. Soatto, “Quick shift and kernel methods for mode seeking,” in *European conference on computer vision*, pp. 705–718, Springer, 2008.
- [99] P. Neubert and P. Protzel, “Superpixel benchmark and comparison,” in *Proc. Forum Bildverarbeitung*, vol. 6, 2012.

- [100] Y. Y. Boykov and M.-P. Jolly, “Interactive graph cuts for optimal boundary & region segmentation of objects in nd images,” in *Proceedings eighth IEEE international conference on computer vision. ICCV 2001*, vol. 1, pp. 105–112, IEEE, 2001.
- [101] M. Vijaymeena and K. Kavitha, “A survey on similarity measures in text mining,” *Machine Learning and Applications : An International Journal*, vol. 3, no. 2, pp. 19–28, 2016.
- [102] M. Levandowsky and D. Winter, “Distance between sets,” *Nature*, vol. 234, no. 5323, p. 34, 1971.
- [103] T. Ojala, M. Pietikäinen, and D. Harwood, “A comparative study of texture measures with classification based on featured distributions,” *Pattern recognition*, vol. 29, no. 1, pp. 51–59, 1996.
- [104] M. Pietikäinen, A. Hadid, G. Zhao, and T. Ahonen, “Local binary patterns for still images,” in *Computer vision using local binary patterns*, pp. 13–47, Springer, 2011.
- [105] Z. Li, G. Liu, Y. Yang, and J. You, “Scale-and rotation-invariant local binary pattern using scale-adaptive texton and subuniform-based circular shift,” *IEEE Transactions on Image Processing*, vol. 21, no. 4, pp. 2130–2140, 2011.
- [106] M. Musci, R. Q. Feitosa, G. A. Costa, and M. L. F. Velloso, “Assessment of binary coding techniques for texture characterization in remote sensing imagery,” *IEEE Geoscience and Remote Sensing Letters*, vol. 10, no. 6, pp. 1607–1611, 2013.
- [107] T. Ahonen, E. Rahtu, V. Ojansivu, and J. Heikkilä, “Recognition of blurred faces using local phase quantization,” in *2008 19th international conference on pattern recognition*, pp. 1–4, IEEE, 2008.
- [108] W. Li, C. Chen, H. Su, and Q. Du, “Local binary patterns and extreme learning machine for hyperspectral imagery classification,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 7, pp. 3681–3693, 2015.

- [109] L. Gan, J. Xia, P. Du, and J. Chanussot, “Class-oriented weighted kernel sparse representation with region-level kernel for hyperspectral imagery classification,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 11, no. 4, pp. 1118–1130, 2017.

Segmentation d'images hyperspectrales par des méthodes basées graphes

Dans le cadre de cette thèse, nous présentons une nouvelle approche pour la segmentation d'images hyperspectrales. Pour cela, nous avons focalisé notre intérêt sur les représentations par graphes et nous avons proposé une approche composée de deux phases principales. Lors de la première phase, un graphe pondéré est construit pour représenter l'image hyperspectrale. La segmentation de l'image est par la suite déduite de la segmentation du graphe construit. Afin de construire un graphe pondéré qui représente efficacement l'image hyperspectrale, nous avons étudié plusieurs topologies telles que graphe complet, 4-voisinage, RAG et la notion de patch. Elles décrivent le nombre ainsi que la structure des sommets du graphe. Nous avons également analysé différentes métriques pour l'estimation de la similarité spectrale entre ces sommets. Les métriques analysées sont indispensables pour pondérer les arrêtes reliant chaque paire de sommets. Notre approche a été évaluée sur deux jeux de données, notamment une base d'images hyperspectrales exclusivement synthétisée pour valider l'approche, ainsi qu'un ensemble d'images hyperspectrales réelles prises sur différents sites avec divers capteurs. Comparé avec les autres méthodes de l'état de l'art, les résultats obtenus sur ces différentes images démontrent l'efficacité et la pertinence de notre approche.

Mots clés : Image hyperspectrale, segmentation, graphe, méthode des ensembles de niveaux

Segmentation of hyperspectral images by graph-based methods

Hyperspectral image analysis has become an important research topic in the remote sensing community. Additionally, image segmentation attracts enormous research attention in the computer vision community. Several segmentation methods have been proposed in both communities. However most of them only consider particular features in the hyperspectral image. Remote sensing based methods generally focus on the spectral information, whereas computer vision based methods find more interest in the gray scale information. In this thesis, we propose to narrow the gap between these communities and propose an hyperspectral image segmentation method which simultaneously exploits spectral and spatial information. To do so, we first model an hyperspectral image using a graph representation which faithfully codes both its spectral and spatial information. Secondly, we propose to segment the constructed graph using a level set based method. The hyperspectral image segmentation is then deduced from the segmentation of the constructed graph. We extensively studied and analyzed different graph construction aspects (i.e., graph topologies and metrics). We also evaluated the segmentation method on two datasets. The first has been exclusively synthesized to validate the proposed approach. The second contains a set of well-known and real hyperspectral images taken on different locations and with various sensors.

The obtained results show the efficiency and the superiority of our proposed approach compared to other state-of-the-art methods.

Keywords : Hyperspectral image, segmentation, graph, level set method