



HAL
open science

Proposition d'une approche de segmentation d'images hyperspectrales

Nathalie J. B. Gorretta

► **To cite this version:**

Nathalie J. B. Gorretta. Proposition d'une approche de segmentation d'images hyperspectrales. Interface homme-machine [cs.HC]. Université Montpellier II - Sciences et Techniques du Languedoc, 2009. Français. NNT: . tel-00368348

HAL Id: tel-00368348

<https://theses.hal.science/tel-00368348>

Submitted on 16 Mar 2009

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

UNIVERSITE MONTPELLIER II
SCIENCES ET TECHNIQUES DU LANGUEDOC

Proposition d'une approche de segmentation d'images hyperspectrales

THÈSE

présentée et soutenue publiquement le 25 Février 2009

pour l'obtention du

Doctorat de l'Université – Montpellier II

Discipline: Informatique

Ecole Doctorale: Informatique, Structures, Systèmes (I2S)

par

Nathalie GORRETTA-MONTEIRO

Composition du jury

Rapporteurs : Bertrand Dominique (Directeur de Recherche, INRA Nantes)
Chanussot Jocelyn (Professeur, INP Grenoble)

Examineurs : Fiorio Christophe (Maître de Conférence, Lirimm Montpellier)
Lennon Marc, (Ingénieur de Recherche, Actimar Brest)
Rabatel Gilles (Directeur de Recherche, Cemagref Montpellier)
Roger Jean-Michel (Ingénieur du GREF, Cemagref Montpellier)
Strauss Olivier (Maître de Conférence, Lirimm Montpellier)

Cemagref, UMR ITAP Information et Technologies pour les Agro-Procédés

Mis en page avec la classe thloria.

Remerciements

Ce travail a été réalisé au sein de l'unité mixte de recherche ITAP (Information et Technologies pour les Agro-Procédés) du Cemagref de Montpellier. Je tiens donc en tout premier lieu à remercier Véronique Bellon-Maurel, directrice de cette unité, pour m'avoir autorisé à me lancer dans une telle aventure. Je remercie dans le même temps, Gilles Rabatel, mon directeur de thèse de m'avoir soutenu dans ce projet.

Merci à Dominique Bertrand et Jocelyn Chanussot d'avoir accepté de rapporter ce travail. Merci à Marc Lennon et Olivier Strauss d'avoir accepté le rôle d'examineurs.

Je tiens à remercier chaleureusement les membres du comité de suivi mensuel : Camille Lelong (UMR TETIS, Cirad), Christophe Fiorio (LIRMM, Montpellier), Véronique Bellon-Maurel et Jean Michel Roger (Cemagref, Montpellier) qui chacun dans leur domaine ont su apporter la pierre à l'édifice. Vos conseils, critiques et les nombreuses discussions que nous avons pu avoir ont permis de faire évoluer ce travail vers une forme particulièrement intéressante et originale.

Un acteur particulièrement incontournable de cette thèse a été Jean-Michel Roger. Je ne le remercierais jamais assez pour s'être investi largement dans le suivi de cette thèse. Ces conseils, encouragements journaliers, leçons de chimométrie et sa grande disponibilité ont contribué très amplement à la qualité du travail accompli.

Je remercie également les relecteurs et relectrices attentifs qui m'ont aidée à rendre ce document plus compréhensible.

Je tiens également à remercier toutes les personnes qui ont contribué de près ou de loin à ce travail. Merci à Ariane, Alexia, Joelle, Ryad, Serge ... pour s'être inquiété quasi-quotidiennement de mon état physique et psychique après de brèves nuits répétées. Merci particulièrement à Michèle, d'avoir entre autre osé braver un blocus étudiant pour récupérer les précieux papiers de soutenance de thèse.

Merci à l'équipe de volley, de m'avoir permis de me défouler hebdomadairement lors de l'entraînement ou des matchs ... désolée pour les excès de zèle, les smaches bourrins (mais cela fait tellement du bien), les ballons piqués ... promis je vais désormais être plus tranquille sur le terrain.

Merci à Robin et Julie pour leur lecture approfondie du mémoire de thèse. J'ai ainsi découvert de nouvelles interprétations de figures ... un père Noël (si si page 59), des voitures ... mais étrangement aucun papillon. Merci à ces deux amours de faire chanter notre quotidien. Vos rires, jeux,...,chamaileries sont une source inépuisable d'énergie. Merci enfin à Domingos, pour son soutien sans faille. Un grand merci plein de reconnaissance et d'amour.

...

*Mille choses douces sans nom
Qu'on fait plus qu'on ne les remarque
Mille nuances d'êtres humaines
A demi-songe à demi-joie
Rien moins que rien pourtant la vie*

...

Louis Aragon, Le Voyage de Hollande, 1965

Table des matières

Liste des tableaux	ix
--------------------	----

Table des figures	xi
-------------------	----

Introduction

Chapitre 1

Description du contexte et analyse de la problématique

1.1	Contexte générique	4
1.1.1	De l'imagerie numérique mono-bande et la spectrométrie à l'imagerie hyperspectrale	4
1.2	L'Imagerie HyperSpectrale (IHS)	9
1.2.1	Définition et atouts	9
1.2.2	Développement et applications de l'IHS	11
1.3	Problématiques liées à l'acquisition et au traitement des données hyperspectrales	14
1.3.1	Faire face au phénomène de Hughes [Hughes, 1968]	17
1.3.2	Tenir compte des informations spectrale et spatiale	18
1.4	Conclusion	19

Chapitre 2

État de l'art : Méthodes de traitement des IHS liant informations spectrale et spatiale

2.1	Approches de classification avec contrainte spatiale	24
2.1.1	Fuzzy-C-means contraint spatialement	25
2.1.2	Machines à Support Vecteurs contraint spatialement	27
2.1.2.1	Principe de base des SVM :	27
2.1.2.2	Cas non linéairement séparable	29
2.1.2.3	Travaux en imagerie hyperspectrale basés sur les SVM	30

2.1.3	Champs de Markov	33
2.1.3.1	Quelques définitions [Coquerez, 1995], [Sigelle and Tupin, 1999]	33
2.1.3.2	Quelques travaux concernant le traitement des IHS par champs de Markov	36
2.2	Extension des outils de traitement d'images scalaires aux images IHS	37
2.2.1	Approche par croissance ou division de régions	37
2.2.2	Filtrage par diffusion anisotropique	40
2.2.3	Approches Morphologiques	42
2.2.3.1	Outils morphologiques	42
2.2.3.2	Ligne de partage des eaux (LPE) ou watershed	46
2.3	Conclusion	48

Chapitre 3

Proposition scientifique

3.1	Notations	54
3.2	Segmentation non supervisée d'une IHS : définition et problématique	55
3.3	Proposition	60
3.3.1	Extraction de structures spatiale et spectrale	60
3.3.1.1	Structure spatiale	60
3.3.1.2	Structure spectrale	61
3.3.2	Outils spectraux et spatiaux	62
3.3.2.1	Les outils spatiaux	62
3.3.2.2	Les outils spectraux	63
3.3.3	Coopération entre outils spatiaux et spectraux	65
3.3.4	Schéma définitif du papillon	66
3.4	Implémentation retenue	68
3.4.1	Principes généraux et préconisations	68
3.4.1.1	Dimension des espaces à retenir	68
3.4.1.2	Choix du nombre de divisions à réaliser pour une étape	70
3.4.1.3	Choix du nombre de fusions à réaliser pour une étape	71
3.4.1.4	Paramètres d'arrêt et de choix de meilleure partition	71
3.4.1.5	Choix du scénario de segmentation	71
3.4.2	Algorithmes	71

Chapitre 4

Validation de la méthode et résultats

4.1	Introduction	78
-----	------------------------	----

4.2	Méthodes de segmentation d'images investies (phase de division)	79
4.2.1	Segmentation quad-tree	79
4.2.2	Segmentation par partitionnement et coupes normalisées	80
4.2.3	Segmentation par ligne de partage des eaux	81
4.3	Résultats	84
4.3.1	Description des exemples synthétiques et réels	84
4.3.1.1	Images de synthèse	84
4.3.1.2	Images Réelles	85
4.3.2	Au c œur du papillon	87
4.3.2.1	Fonctionnement de l'algorithme	87
4.3.2.2	Illustration de la prise en compte de l'information spatiale et spectrale	91
4.3.2.3	De l'intérêt d'utiliser une variable latente et une coupe par itération	98
4.3.2.4	De l'intérêt de mixer informations spectrale et spatiale	102
4.3.2.5	Critères d'arrêt	107

Chapitre 5

Conclusions et perspectives

5.1	Conclusions	115
5.2	Perspectives	117

Annexe A

Algorithme LPE modifié

Annexes

Annexe B

Optimisation pour le calcul de l'inertie à chaque itération

Annexe C

Contributions de l'auteur

C.1	Contributions de l'auteur	127
-----	---------------------------	-----

Bibliographie

129

Liste des tableaux

1.1	Du multispectral à l'ultraspectral : définition numérique	10
1.2	Possibilités étendues de l'imagerie hyperspectrale en comparaison avec des techniques vision couleur (imagerie RGB), spectrométrie proche infrarouge (NIRS) et imagerie multispectrale (IMS), (d'après [Gowen et al., 2007])	12
3.1	Comparaison de la complexité de la mesure pour des images binaires, couleur (dynamique 8 bits) et hyperspectrale (dynamique 16 bits) (d'après [Lennon, 2002])	58
4.1	Bilan des approches investies	85
4.2	Contenu des colonnes figures 4.9 et 4.10	90
4.3	Les diverses configurations testées pour la phase de division et la phase de fusion : nombre de variables latentes et nombre de coupes	102

Table des figures

1.1	Effet de la sénescence sur la réflectance d'une feuille de blé	8
1.2	De la vision numérique monochrome à l'imagerie hyperspectrale	10
1.3	Imagerie hyperspectrale : accès à une information spectrale spatialisée	11
1.4	Possibilités étendues offertes par l'IHS pour des applications liées à l'agriculture ([Lennon, 2002]	12
1.5	IHS : Identification de verrous scientifiques par HYDRESSA	15
2.1	Principe des SVM : (a) Recherche de l'hyperplan optimal ; (b) Hyperplan optimal, marge et vecteurs supports	30
2.2	Représentation de l'astuce du noyau (Trick Kernel)	31
2.3	Représentation des cliques suivant le système de voisinage : (gauche) - connexité 4, (droite) - connexité 8	35
2.4	Principales caractéristiques des techniques spectro-spatiales évoquées dans ce cha- pitre	51
3.1	Éparpillement des données	57
3.2	Exemple de corrélation inter-bandes pour des spectres obtenus sur des pommes .	59
3.3	Notre approche : ébauche du processus	61
3.4	Basculement sémantique : de l'espace spatial à l'espace spectral	65
3.5	Le schéma du papillon amélioré	66
3.6	Schéma complet de l'approche <i>papillon</i> : découpage des étapes d'analyse spatiale et spectrale sous la forme d'opérations unitaires simples et processus de coopération	67

3.7	Schéma du papillon lors d'une segmentation par division (haut) et par fusion (bas)	69
3.8	Processus de segmentation d'IHS utilisant l'approche papillon : scénarios possibles suivant l'approche de segmentation utilisée	72
4.1	Principe de l'opération de division standard dans l'algorithme Split and Merge (d'après [Baillie, 2005])	80
4.2	(a) : notions de graphe, sommet, arêtes; (b) : Représentation des connexions du sommet i avec ses n voisins et exemple de définition d'une similarité inter-pixel (poids des liaisons inter-pixels) liant intensité et adjacence; (c)- Définition du critère des coupes normalisées. (D'après [Enberg and Boonaert, 2008])	82
4.3	Illustration mono-dimensionnelle du principe de segmentation par Ligne de Partage des Eaux : (a) Signal initial. (b) Gradient correspondant au signal initial. Les minima locaux sont indiqués par les points verts (c) Processus ascendant d'inondation à partir de chaque minima local. Lorsque deux bassins se rencontrent, un barrage est construit pour éviter le mélange. Ces barrages sont les contours finaux de la segmentation (d) Résultats de la segmentation du signal initial (4 régions déterminées). (d'après [Roudier, 2008])	84
4.4	Spectres utilisés comme base des images de synthèse, par combinaison linéaire avec les composante RGB des images couleurs.	86
4.5	Images hyperspectrales réelles : (a) image IR1, couleur, (b) image IR2, bande spectrale 50	87
4.6	Image RVB utilisée comme base de la première image de synthèse.	88
4.7	Principe du papillon utilisé sur l'image de synthèse $IS1$ (haut : processus de division, bas : processus de fusion)	89
4.8	Déroulement approche papillon sur image de synthèse $IS1$: Haut : phase de division, itérations D1 à D4; Bas : phase de fusion, itérations F1 à F2.	90
4.9	Déroulement détaillé de la phase de division sur l'image de synthèse $IS1$	92
4.10	Déroulement détaillé de la phase de fusion sur l'image de synthèse $IS1$	93

4.11	Variable latente utilisée pour la première étape de division, en superposition au spectre de différence entre spectre pur bleu et spectres purs vert et rouge pondérés ($1.3 \cdot R - V - 0.2 \cdot R$) pour l'image de synthèse $IS1$	93
4.12	Variable latente utilisée pour la deuxième étape de division en superposition au spectre de différence entre spectre pur vert et spectre pur rouge pour l'image de synthèse $IS1$	94
4.13	Images RVB utilisées comme base des images de synthèse $IS2_A$ (gauche) et $IS2_B$ (droite)	94
4.14	Déroulement de l'algorithme (phase de division) sur l'image de synthèse $S2_A : D_1$ à D_2 phases de division.	95
4.15	Déroulement détaillé de la phase de division sur l'image de synthèse $S2_A$	96
4.16	Variable latente utilisée pour la première étape de division, en superposition au spectre de différence entre spectre pur rouge et spectres purs vert et bleu pondérés ($V + 2B - 3R$) pour l'image de synthèse $S2_A$	96
4.17	Variable latente utilisée pour la deuxième étape de division (trait bleu), en superposition au spectre de différence entre le spectre pur rouge et le spectre pur vert ($R - V$) (trait pointillé noir) pour l'image de synthèse $S2_A$	97
4.18	Déroulement de l'algorithme (phase de division) sur l'image de synthèse $IS2_B$: itération D_1 à D_{27}	98
4.19	Déroulement détaillé de la phase de division sur l'image de synthèse $IS2_B$	99
4.20	Variable latente utilisée pour la première étape de division, (trait bleu) en superposition au spectre de différence pondéré entre spectres purs bleu et vert et spectre pur rouge ($V + 2B - 3R$) (trait pointillé rouge) pour l'image $S2_B$	100
4.21	Algorithme du papillon, étape de division, variation du nombre de variables latentes : Résultats obtenus sur image réelle $IR1$ avec un nombre de variable latente et un nombre de coupe égal respectivement à 1 et 2 (haut) puis avec ces paramètres fixés respectivement à 2 et 1 (bas).	101

4.22	Algorithme du papillon, étape de division : images scores obtenues sur la première (gauche) et la deuxième (droite) variable latente extraite lors de la première itération.	103
4.23	Algorithme du papillon, étape de division : nombre de variable latente égal à 1 et nombre de coupe égal à 2	104
4.24	Algorithme du papillon, étape de fusion : Résultats obtenus sur image réelle <i>IR1</i> avec un nombre de variables latentes variable	105
4.25	Segmentation de l'image Hypsax obtenues avec diverses approches et un nombre variable de régions finales.	108
4.26	Segmentation de l'image DAIS obtenue avec diverses approches et un nombre variable de régions finales.	109
4.27	Évolution du Λ de Wilks au cours de la phase de division et de fusion : en gras sur l'espace des variables latentes, en fin sur l'espace support (espace complet initial)	110
4.28	Évolution des 4 premiers vecteurs propres extraits au cours de la phase de fusion (13 pas)	111
4.29	Évolution des 4, 5, 6 et 8ème vecteurs propres extraits au cours de la phase de fusion (13 pas)	112
4.30	Évolution de la segmentation de l'image <i>IR1</i> au cours du processus de fusion . .	113
5.1	Une implémentation du papillon permettant de gérer des contraintes liées à la forme des objets	119
A.1	Illustration du principe de l'algorithme LPE modifié utilisé pour obtenir une bi-partition de l'image ou d'une région	123

Introduction

Le travail présenté dans ce mémoire vise à proposer une approche originale de segmentation d'images hyperspectrales. L'imagerie hyperspectrale consiste à acquérir des images dans des centaines de bandes spectrales contiguës et identiquement géoréférencées grâce auxquelles il est possible d'estimer un spectre de réflectance complet pour chaque élément de l'image. Dans le cadre de nos applications, i.e. la caractérisation des agros et écosystèmes, cette technologie, par sa capacité à mettre à disposition une information spectrale spatialisée, permet d'envisager un élargissement des possibilités de détection. En effet, si la dimension spatiale des données nous permet d'accéder à des informations pertinentes pour certains besoins de caractérisation des cultures (stade de développement, présence d'adventices...), leur dimension spectrale permet de s'intéresser à des informations essentielles pour la conduite des cultures telles que leur état physiologique, pathologique...

Cependant, la mise en oeuvre de cette technologie et le traitement des données qui en sont issues sont des procédures complexes et difficiles. Dans le cadre de ces travaux de thèse, nous nous sommes intéressés successivement à ces deux aspects. Concernant la mise en oeuvre d'un système d'imagerie hyperspectrale et son utilisation dans des milieux largement contraints (champ), la nécessité de réaliser une étape d'étalonnage soignée préalable permettant de s'affranchir de diverses perturbations s'est vite fait sentir. Ainsi, une première période a consisté en l'élaboration et la mise en oeuvre de diverses approches de standardisation permettant d'obtenir des images hyperspectrales de qualité convenable. Ces travaux ne sont pas décrits dans ce mémoire mais ont fait l'objet de publications qui sont données en annexe C. Dans un deuxième temps, nous nous sommes intéressés à la définition d'une approche de traitement des images hyperspectrales per-

mettant de prendre en compte les dimensions spectrale et spatiale des données. Dans le contexte de nos applications et à nos échelles de mesure ('proxi-détection' et donc forte résolution spatiale) la prise en compte de ces deux dimensions a en effet tout son sens.

Ce mémoire est organisé en 5 chapitres. Le premier s'intéresse au contexte dans lequel s'inscrit ce travail. On y trouvera des informations sur l'acquisition et le traitement des données hyperspectrales et les points durs qui ont orienté nos recherches. Dans le chapitre 2, nous présentons un état de l'art des méthodes disponibles pour le traitement des données hyperspectrales. Nous nous intéresserons succinctement aux méthodes n'utilisant que l'information spectrale puis plus en détails aux méthodes disponibles tentant d'inclure une contrainte spatiale. Ce chapitre nous permet de statuer sur les lacunes des méthodes présentées et de justifier l'originalité et la pertinence de la stratégie proposée dans le cadre de ce mémoire. Le troisième chapitre constitue notre proposition scientifique. À la vue des méthodes existantes liant informations spectrale et spatiale, nous proposons dans un premier temps un schéma générique permettant de lier ces deux espaces de façon symétrique et équilibrée. Nous proposons par la suite des implémentations de ce schéma à l'aide d'outils de segmentation d'images et d'outils de la chimiométrie. Le chapitre 4 est dédié à la présentation de notre approche et de ses principales caractéristiques à travers des exemples synthétiques et réels. Enfin, pour clore ce mémoire, un dernier chapitre de conclusion synthétise les points importants de l'approche développée et propose également des perspectives et des pistes de recherche pour continuer les travaux entrepris.

Chapitre 1

Description du contexte et analyse de la problématique

Dans ce chapitre, nous évoquons en premier lieu le contexte générique de nos travaux (caractérisation des produits végétaux) et les outils à notre disposition pour ce faire. Nous nous intéressons plus particulièrement à une technologie pleine de promesses : l'imagerie hyperspectrale. Après avoir évoqué les particularités et les atouts de ce nouvel outil dans le cadre de nos applications nous dressons un bilan des problématiques liées à son utilisation. Ensuite, nous évoquons et justifions les voies de recherche que nous avons investies.

Sommaire

1.1	Contexte générique	4
1.1.1	De l'imagerie numérique mono-bande et la spectrométrie à l'imagerie hyperspectrale	4
1.2	L'Imagerie HyperSpectrale (IHS)	9
1.2.1	Définition et atouts	9
1.2.2	Développement et applications de l'IHS	11
1.3	Problématiques liées à l'acquisition et au traitement des données hyperspectrales	14
1.3.1	Faire face au phénomène de Hughes [Hughes, 1968]	17
1.3.2	Tenir compte des informations spectrale et spatiale	18

1.1 Contexte générique

Nos sujets d'étude concernent la caractérisation des productions végétales au sens large allant de la maturation au champ à la transformation. L'objectif au champ est alors, de caractériser les agro-systèmes à partir d'indicateurs pertinents sur le plan agronomique pour en permettre une gestion raisonnée et durable : détection précoce des maladies pour un traitement optimal, localisation et/ou identification des adventices au sein d'une culture pour un désherbage optimisé, gestion des déplacements d'engins pour un impact réduit sur les parcelles... Lors de la transformation de produits agricoles, il s'agit de caractériser des produits agro-alimentaires pour en déterminer, soit des caractéristiques importantes pour le consommateur (taux de sucre, acidité...), soit pour détecter des défauts les rendant impropres à la consommation (sécurité alimentaire). Pour être efficace, cette caractérisation des agro-produits et agro-systèmes voire des éco-systèmes doit s'appuyer sur des outils pertinents permettant de réaliser des mesures objectives. Leur développement est primordial et dans le cadre de nos études nous nous sommes intéressés à l'utilisation d'outils optiques tels que la vision numérique et la spectrométrie.

1.1.1 De l'imagerie numérique mono-bande et la spectrométrie à l'imagerie hyperspectrale

La vision numérique, parce qu'elle permet d'accéder directement à des informations de distributions spatiales, apparaît bien adaptée à certains besoins de caractérisation des productions végétales. De nombreuses applications ont été ainsi développées dans le secteur agricole à diverses échelles de prise de vue (échelle rapprochée ou plus éloignée par des prises de vue aéroportées ou satellitaires) pour, entre autres, la gestion des ressources naturelles, l'agriculture de précision, l'évaluation de la qualité avant et après récolte ou encore l'automatisation de certaines tâches. Les capteurs monochromes puis couleur ont été largement utilisés et avec succès dans ce secteur. La détection des défauts sur ligne de tri, avant récolte ou au champ s'effectue alors par des algo-

rithmes de détection de forme et/ou de texture et/ou utilisant des différences colorimétriques. Par exemple, dans le domaine de l'évaluation de la qualité des produits carnés, Marty-Mahé et ses co-auteurs [Marty-Mahe et al., 2002] se sont intéressés à l'évaluation numérique des défauts sur carcasses de dindes. L'objectif est de détecter deux types de défauts : défauts de conformation et défauts d'aspect. Les premiers sont traités par un algorithme de reconnaissance de forme (combinaison de trois approches complémentaires). Les seconds se repèrent à la couleur de la lésion (chair rouge pour une plaie, couleurs diverses pour les hématomes) et sont traités par l'analyse d'un histogramme couleur multidimensionnel. Pour une revue complète des applications de la vision numérique classique dans ce domaine, le lecteur intéressé pourra se référer à l'article de Du et Sun [Du and Sun, 2004].

Concernant les applications au champ et dans l'objectif de proposer à l'agriculteur des fonctions d'assistance au pilotage lui permettant de se consacrer pleinement au contrôle et à la surveillance de sa machine et de son outil associé, de nombreux auteurs ont proposé un système de guidage d'engins agricoles. Derras et ses co-auteurs [Derras et al., 1994] puis Gerrish et ses co-auteurs [Gerrish et al., 1997] utilisent une caméra monochrome avec des approches de segmentation diverses pour respectivement guider un engin de tonte, ou un engin de récolte. De nombreux travaux ([Tian et al., 1997, Burks et al., 2000, Rabatel et al., 2001, Terawaki et al., 2003, Bossu, 2007]...) peuvent également être cités concernant le problème de la détection de mauvaises herbes (ou « adventices ») au sein des cultures. L'objectif est, d'une façon générale, d'évaluer la répartition spatiale des diverses variétés de mauvaises herbes au sein d'une parcelle, de façon à utiliser une stratégie de désherbage non uniforme et prenant en compte la quantité et les espèces en présence (limitation et sélection chimique des intrants). Ainsi, Tian et ses co-auteurs [Tian et al., 1997] réalisent une acquisition d'image en niveau de gris puis utilisent des opérations morphologiques simples, dans le cas spécifique d'un robot de désherbage de tomates. Bossu [Bossu, 2007] a développé un système de vision pour une pulvérisation spécifique en temps réel qui, à partir d'une caméra monochrome placée à l'avant du tracteur, réalise une discrimination entre culture et adventices en utilisant un filtre de Gabor 2D. Pour finir, on peut citer les travaux

de Manh [Manh, 2001] qui, dans le cadre de la reconnaissance d'espèces d'aventices et pour faire face aux écueils des méthodes classiques de segmentation d'images noir et blanc ou couleur, a proposé une approche plus complexe reposant sur l'introduction d'une description *a priori* des formes en présence lors du processus de segmentation.

Cependant, de nombreuses difficultés liées à la complexité des scènes naturelles et aux conditions d'éclairage en milieu extérieur ont conduit la communauté scientifique à s'intéresser aux propriétés spectrales des objets. L'environnement agricole bénéficie en effet, d'un atout essentiel, lié à l'origine biologique de ces derniers. Les objets biologiques sont composés d'un ensemble limité de composés actifs spectralement, qui leur confère des propriétés de réflectance uniques pouvant être utilisées pour leur discrimination ou leur identification.

La différenciation spectrale est déjà largement exploitée, à des degrés divers, dans nombre d'études ou de développements dans le domaine agricole. Ainsi, une simple acquisition d'image monochrome dans le proche infra-rouge permet déjà une différenciation entre sol nu et végétation, cette dernière ayant une très forte réflectance dans ce domaine spectral. De la même manière, l'identification d'une longueur d'onde ou d'une bande spectrale permettant d'accroître le contraste entre l'objet et les caractéristiques à extraire, a été utilisée, par exemple, pour la détection de graines de blés infestées par des insectes [Ridgway and Chambers, 1998] la détection de défauts sur les pêches ou encore sur les abricots [Miller and Delwiche, 1991, Zwiggelaar et al., 1996, Gorretta and Bellon-Maurel, 2001].

D'autres outils plus élaborés, combinant plusieurs longueurs d'onde, ont été également proposés. Ainsi, de nombreux indices de végétation tels que l'indice bi-canal NDVI (Normalised Difference Vegetation Index) [Rouse et al., 1973] ou encore l'indice EVI (Enhanced Vegetation Index) [Huete et al., 1997] utilisent des combinaisons à deux ou plusieurs longueurs d'onde permettant de mettre en évidence une propriété particulière de la végétation. Taylor et McCure [Taylor and McCure, 1989] ont montré que l'utilisation de trois longueurs d'onde (670, 800 et 990 nm) permettait de discriminer les tissus sains des tissus malades dans des feuilles. Chao et ses co-auteurs [Chao et al., 2001] rapportent l'utilisation de 9 longueurs d'onde pour

la caractérisation du cœur de poulets et la détection de maladies. Martin-Chefson et ses co-auteurs [Martin-Chefson et al., 1999] utilisent une combinaison linéaire de 4 bandes spectrales obtenue par analyse en composantes principales (ACP) pour parvenir à une discrimination plantes/adventices au sein d'une culture de maïs. Plus généralement, un nombre quelconque de bandes spectrales peut être utilisé, dont le choix dépendra de l'application et des objets à différencier. On parle d'imagerie "multispectrale" ¹.

Certaines données essentielles pour la conduite des cultures sont peu accessibles à la vision numérique (état physiologique ou phénologique, stress hydrique, pathologies...) mais peuvent être, en revanche, obtenues par spectrométrie. Cette technologie se définit comme la mesure et l'étude de la lumière réfléchie, diffusée ou émise par un solide, un liquide ou un gaz en fonction de la longueur d'onde [Clark, 1995]. Les propriétés spectrales des matériaux varient selon leur composition chimique et leur structure moléculaire qui produisent différents phénomènes de réflexion, d'absorption et transmission des photons. La courbe de réflectivité spectrale ² (souvent appelée signature spectrale), peut être considérée comme la source à partir de laquelle les caractéristiques chimiques et physiques peuvent être retrouvées.

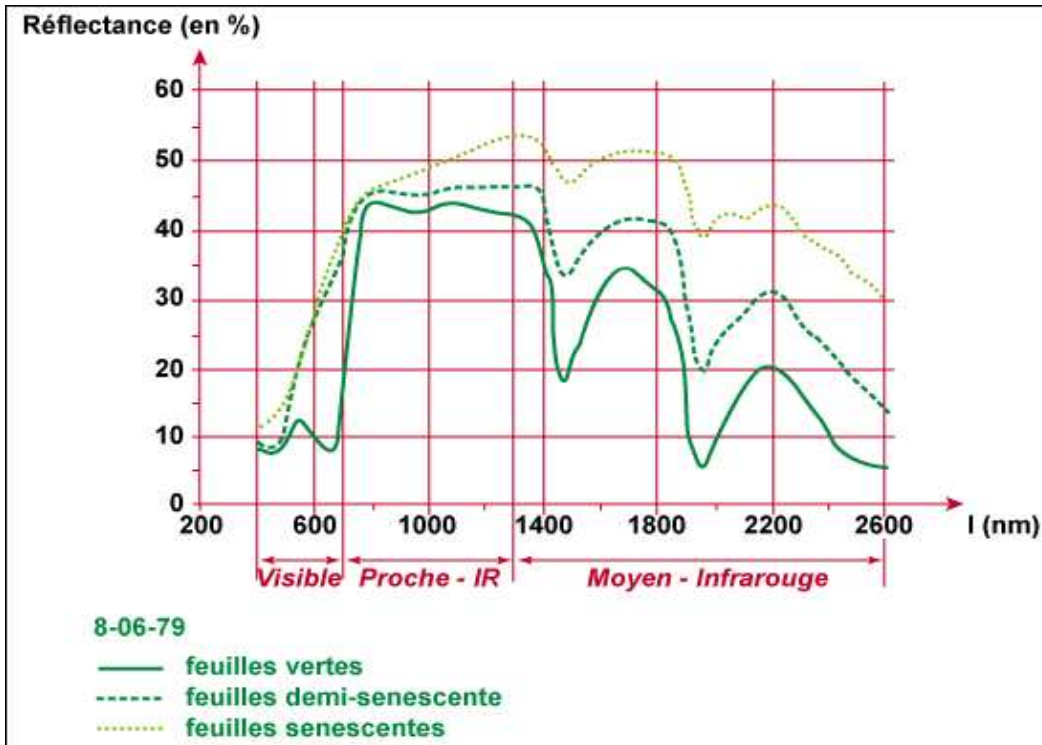
Dans le domaine agricole, cette technologie a été largement utilisée pour des applications en laboratoire et au champ et a montré tout son intérêt : caractérisation de la qualité des fruits au verger ou en ligne ([Kawano et al., 1989, Bellon et al., 1992]), évaluation des caractéristiques physiologiques de la vigne ([Chauchard et al., 2004]), qualification de diverses semences ([Wang et al., 2002, Dowell, 2000]), détection de maladies ou encore du stress hydrique sur diverses variétés de plantes ([Koch et al., 1990, Kraft et al., 1996, Malthus and Madeira, 1993, Lelong et al., 1998]...). En effet, comme le montre la figure 1.1, la courbe de réflectance de la végétation (ici une feuille de blé) dans le domaine du visible au proche infrarouge est largement affectée par les changements physiologiques intervenant lors de sa croissance (teneurs en pigment, structure interne des tissus, teneur en eau...).

La mesure et l'étude de la courbe de réflectance est donc un outil puissant pour atteindre des

¹Il est à noter que l'imagerie couleur peut également être considérée comme un cas particulier d'imagerie multispectrale trichrome dans le domaine visible.

²Courbe représentant l'évolution de la réflectance d'une surface en fonction de la longueur d'onde.

données pertinentes et essentielles à la caractérisation des productions végétales.



L'absorption des végétaux dans le visible est principalement gouvernée par la composition, la concentration et la distribution des pigments dans les feuilles. Lors d'une baisse du taux d'activité de la chlorophylle pour des raisons de sénescence naturelle ou de stress, la réflectance augmente légèrement dans le bleu (450 – 500nm) et fortement dans le rouge (620 – 700nm). L'absorption des végétaux est faible dans le proche infrarouge (730 – 1200nm). Elle est gouvernée par les interactions au sein des cellules végétales (parenchyme lacuneux) lieu d'échange entre l'oxygène et le dioxyde de carbone pour la photosynthèse et la respiration. Pour les plantes saines, la réflectance dans le proche infrarouge est grande. Dans l'infrarouge moyen (1300 – 2500nm), l'absorption est principalement due à l'eau présente dans la plante et peut servir par exemple, à détecter le stress hydrique [Bariou et al., 1985, Jensen, 2000]. Figure d'après www.cnerta.educagri.fr/infogeo/bienvenue.htm.

FIG. 1.1 – Effet de la sénescence sur la réflectance d'une feuille de blé

Cependant, la spectrométrie effectue une mesure locale. En combinant cette technique et la

vision numérique, on définit un nouvel outil appelé, imagerie hyperspectrale, qui permet ainsi d'acquérir pour chaque pixel de l'image un spectre de réflectance quasi-continu sur une gamme spectrale donnée.

La section suivante est dédiée à la description de cette technique. Ses caractéristiques, propriétés, capacités et limites seront étudiées ainsi que ses applications actuelles en particulier dans le domaine agro-alimentaire et agricole. Cette étude nous permettra finalement d'évoquer et de justifier la problématique scientifique de cette thèse.

1.2 L'Imagerie HyperSpectrale (IHS)

1.2.1 Définition et atouts

Une définition formelle de l'IHS est donnée par Kruse [Kruse, 2000] : "L'imagerie hyperspectrale consiste à acquérir des spectres pour tous les pixels d'une image, où un spectre est une mesure contiguë d'une distribution de longueur d'onde, avec une résolution suffisante pour résoudre la variabilité naturelle du système d'intérêt". Chang [Chang, 2007] précise cette définition en distinguant l'IHS de l'imagerie couleur et multispectrale par trois caractéristiques principales (voir figure 1.2 et table 1.1) :

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

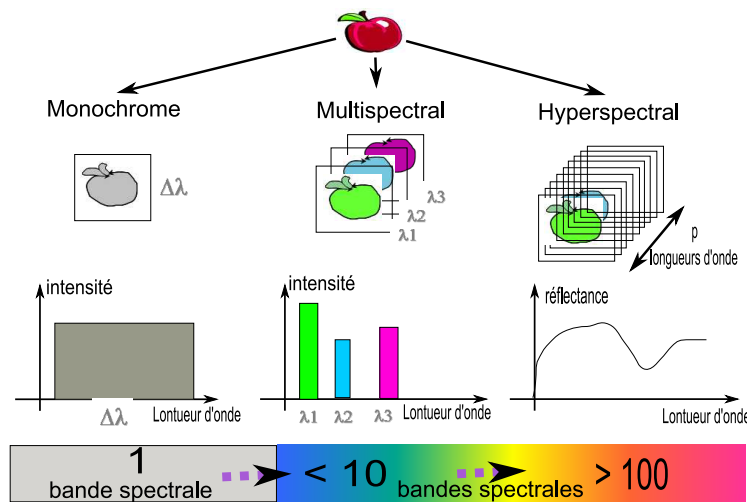


FIG. 1.2 – De la vision numérique monochrome à l’imagerie hyperspectrale

	Multispectral	Superspectral	Hyperspectral	Ultraspectral
nb de bandes	5-10	10-20	100-200	1000-10000
$\frac{\lambda}{\Delta\lambda}$	10	50	100	1000

TAB. 1.1 – Du multispectral à l’ultraspectral : définition numérique

Les images IHS fournissent donc une information plus détaillée des propriétés spectrales d’une scène et permettent de fait une identification et une discrimination plus précises des objets que les capteurs multispectraux (figure 1.3). Plus encore, le passage de l’imagerie multispectrale à l’imagerie hyperspectrale est souvent décrit comme le passage du domaine de la discrimination aux domaines de la quantification et de l’identification déterministe [Lennon, 2002, Kruse, 2000].

Ainsi, quel que soit le domaine d’application, l’émergence de cette technologie permet d’envisager un élargissement des applications potentielles : Koehler et ses co-auteurs [Koehler et al., 2002] ou encore Gowen et ses co-auteurs [Gowen et al., 2007], respectivement dans le domaine du contrôle de produits pharmaceutiques et dans le domaine du contrôle de la qualité alimentaire précisent que c’est une nouvelle méthode analytique excitante car elle permet de répondre à certaines questions telles que ‘combien de composés chimiques sont présents dans un échantillon’, ‘à quelle concentration’ et de plus de connaître la localisation de ces composés. Les chercheurs ont




FIG. 1.3 – Imagerie hyperspectrale : accès à une information spectrale spatialisée

ainsi un accès à des informations spatiales et spectrales permettant de caractériser un échantillon de manière rapide et avec une résolution spatiale et spectrale très fine et permettant ainsi une analyse étendue d'échantillons hétérogènes complexes. Gowen et ses co-auteurs [Gowen et al., 2007] donnent ainsi un bilan des possibilités étendues de l'IHS, pour l'environnement agro-alimentaire, à travers différentes caractéristiques en comparaison avec les techniques optiques plus classiques et évoquées dans la première section (imagerie couleur ou RGB, spectrométrie proche infrarouge notée NIRS, imagerie multispectrale notée IMS). Ce bilan est présenté table 1.2. Lennon [Lennon, 2002] complète ce bilan en se risquant à une nomenclature des utilisations étendues de l'IHS. Celle-ci est donnée sous forme schématique figure 1.4.

1.2.2 Développement et applications de l'IHS

Le premier facteur de développement de l'imagerie hyperspectrale a été indubitablement la disponibilité de détecteurs multi-canaux sensibles aux rayonnements proche infrarouge (InGaAs avec différents dopages) ou infrarouge (micro-bolomètres). Il est intéressant de remarquer que l'imagerie hyperspectrale s'est développée à deux extrémités de l'échelle spatiale, à savoir pour l'imagerie satellitaire, avec des résolutions de 20 m environ et à l'échelle microscopique, notam-

Caractéristiques	Imagerie RGB	NIRS	IMS	IHS
Information spatiale	∞		∞	∞
Information spectrale	Limitée	∞	Limitée	∞
Information Multi-composés	Limitée	∞	Limitée	∞
Sensibilité aux composés mineurs	Limitée	∞	Limitée	∞

TAB. 1.2 – Possibilités étendues de l’imagerie hyperspectrale en comparaison avec des techniques vision couleur (imagerie RGB), spectrométrie proche infrarouge (NIRS) et imagerie multispectrale (IMS), (d’après [Gowen et al., 2007])

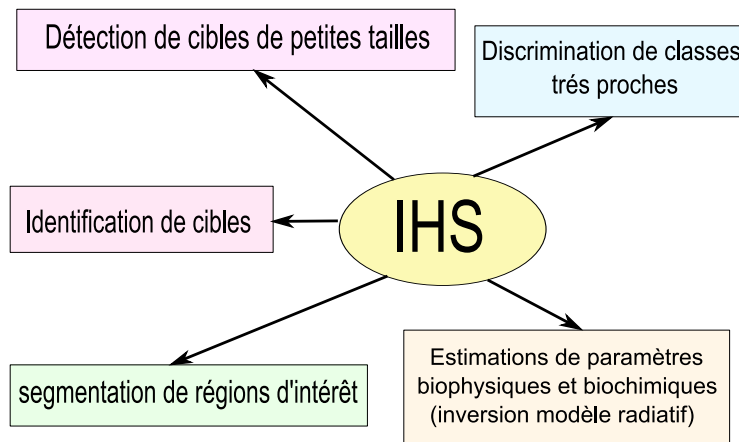


FIG. 1.4 – Possibilités étendues offertes par l’IHS pour des applications liées à l’agriculture ([Lennon, 2002])

ment en imagerie Raman ou moyen-infrarouge, avec des résolutions de l’ordre de la dizaine de microns, et ceci sans que les communautés ne communiquent vraiment entre elles. Nos objets d’étude (les produits agro-alimentaires et les procédés agricoles) se situent à une échelle intermédiaire, appelée ‘échelle macroscopique’ ou encore ‘proxi-détection’ avec des champs variant de quelques centimètres à quelques mètres. À cette échelle d’étude, la vision hyper-spectrale s’est développée de manière beaucoup plus récente à cause du coût prohibitif des équipements pour

les applications visées. Les progrès technologiques réalisés ces dernières années dans le domaine des capteurs optiques, ont permis l'avènement de systèmes d'imagerie hyperspectrale à des prix abordables pour des applications au champ ou en laboratoire à l'échelle macroscopique ou microscopique (proxi-détection).

Techniquement, deux grandes approches sont utilisées pour réaliser des images hyperspectrales [Polder and van der Heijden, 2001]. La première consiste à acquérir une séquence d'images 2D à différentes longueurs d'onde (staring system). Pour cela, on utilise des filtres variables (filtres AOTF ou LCTF) positionnés devant une caméra matricielle. La deuxième approche consiste à acquérir une séquence d'images lignes où pour chaque pixel d'une ligne, un spectre complet est mesuré (approche push-broom). Elle requiert un spectrographe imageur couplé à une caméra monochrome où une dimension permet d'enregistrer l'information spatiale et l'autre la dimension spectrale. La dimension spatiale manquante est alors acquise par déplacement du capteur ou de l'objet.

Aujourd'hui et à nos échelles de travail, les applications les plus avancées concernent la détection des contaminants dans des procédés alimentaires (corps étrangers, salissures...) ou agricoles (mauvaises herbes), la cartographie de composants chimiques (répartition des matières actives dans des comprimés pharmaceutiques, répartition eau/matière grasse dans des produits alimentaires) ou encore la détection de défauts invisibles à l'œil (car ayant la même réflectance colorimétrique que la partie saine). Ainsi, dans le domaine agro-alimentaire, l'IHS a été utilisée entre autres pour l'inspection des carcasses de poulet ([Park et al., 1998, Chao et al., 2002]), la détection des défauts ou la détermination de la qualité sur les pommes, tomates, melon, kiwi ([Xing and De Baerdemaeker, 2005, Tsuta et al., 2002, Martinsen and Shaare, 1998]). Pour une plus large revue des ces applications, le lecteur intéressé pourra se référer à [Gowen et al., 2007] ou encore à [Bellon-Maurel and Dubois, 2008]. Dans le domaine agricole, les données hyperspectrales sont utilisées en agriculture de précision pour l'évaluation de l'état des récoltes et du sol et pour les mesures quantitatives des principaux paramètres des récoltes tels que le

contenu en eau de la végétation, l'azote ([Guan et al., , Moran et al., 1997, Bechdol et al., 2000, Thenkabail et al., 2000, Goel et al., 2003a, Goel et al., 2003b], ou encore la chlorophylle et la surface foliaire [Hamid Muhammed and Larssolle, 2003, Karimi et al., 2006, Chion et al., 2008]). Elles concernent essentiellement des données acquises par des capteurs satellitaires ou aéroportés. Peu d'utilisations au champ (à nos échelles) sont reportées dans la littérature. On peut toutefois faire référence aux travaux de Inoue [Inoue and Peñuelas, 2001] ou encore Schut [Schut et al., 2006] et Ye [Ye et al., 2008] qui se sont intéressés à la détection des adventices au champ et à la caractérisation d'espèces végétales.

1.3 Problématiques liées à l'acquisition et au traitement des données hyperspectrales

Bien que les potentialités de la technologie hyperspectrale apparaissent relativement grandes, l'acquisition et le traitement de ces données est une procédure complexe et difficile. Ainsi, la communauté européenne, au travers d'un projet d'action nommé Hydressa (Hyperspectral Remote Sensing in Europe Specific Support Action), a lancé un vaste programme afin d'unir les travaux de la communauté sur ce champ émergent. Plusieurs verrous scientifiques et technologiques ont été identifiés et nécessitent des efforts importants de recherche. Ainsi, Hydressa a proposé de séparer la chaîne de traitement des données hyperspectrales en deux étapes et a identifié pour chacune d'entre-elles des besoins particuliers de recherche (voir figure 1.5) :

- La première étape concerne les fournisseurs de données et nécessite de travailler sur des problèmes permettant d'assurer une information de qualité et de ce fait, une large diffusion des images hyperspectrales : correction radiométrique, correction géométrique, correction atmosphérique et évaluation objective de la qualité des données.
- La deuxième, appelée étape utilisateur, doit permettre sur des données pré-traitées et corrigées, d'extraire des informations pertinentes. Elle nécessite de s'intéresser particulièrement aux méthodes de transformation de données, à la sélection de caractéristiques, de développer des bibliothèques spectrales et des algorithmes de classification et de détection de

caractéristiques.

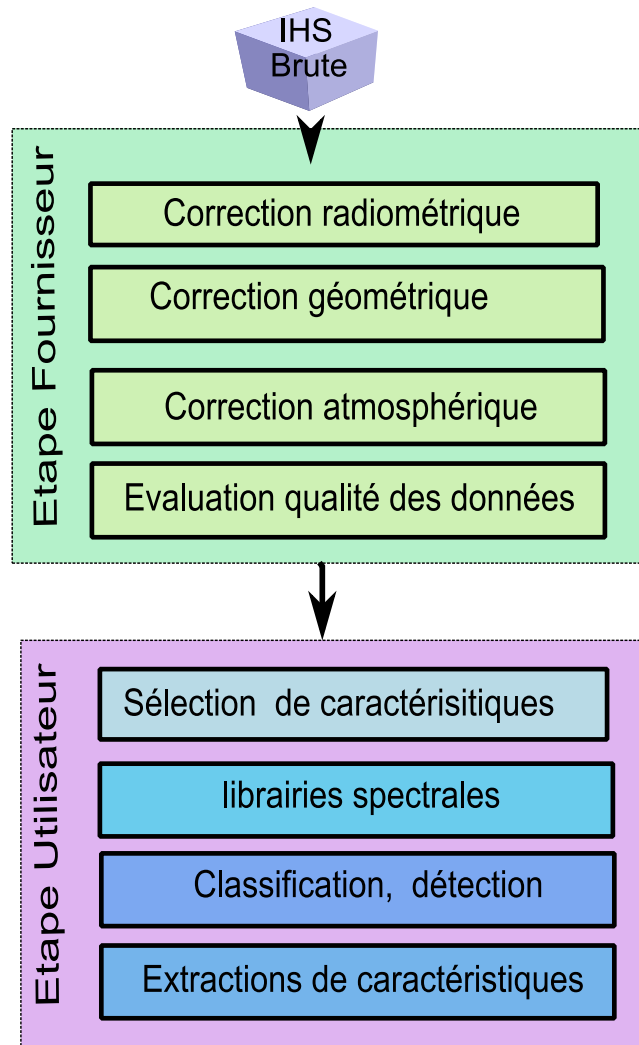


FIG. 1.5 – IHS : Identification de verrous scientifiques par HYDRESSA

Quels que soient la technologie et le type de capteur utilisés (pushbroom, staring system) ou la distance d'utilisation (satellitaire, aéroporté, proxi-détection) la nécessité d'un étalonnage étendu (radiométrique, géométrique et atmosphérique) est primordiale.

L'objectif de la correction radiométrique est de quantifier précisément le comportement radiométrique de chaque pixel de la matrice CCD. Il est ainsi nécessaire, d'une part, d'évaluer la fonction de réponse du pixel et d'autre part, d'identifier et de quantifier les hétéro-

généités spatiales dues aux composants du capteur d'imagerie afin de pouvoir s'en affranchir. Dans le domaine de l'imagerie satellitaire ou encore de l'imagerie aéroportée, cette caractérisation est réalisée par des laboratoires optiques spécialisés à l'aide d'une sphère d'intégration ([Lennon, 2002, Kohler et al., 2004]).

Pour les systèmes d'imagerie de proxi-détection ou de laboratoire, cette caractérisation est onéreuse et a conduit les utilisateurs de ce type de matériel à proposer des méthodes d'étalonnage alternatives (par exemple : étalonnage en deux points [Gat, 2000], étalonnage linéaire et du second ordre [Geladi et al., 2004], étalonnage par translation et transformée de Fourier [Gorretta et al., 2008]...). Ces approches ne donnent cependant pas de résultats suffisants.

Les corrections géométriques concernent d'avantage les images obtenues à partir de capteurs aéroportés ou satellitaires. Les corrections géométriques réalisées pour les images satellitaires tendent à prendre en compte les distorsions géométriques provenant essentiellement de la large prise de vue (fauchée) et de facteurs tels que la rotation ou la courbure de la terre. Dans le cas des images aéroportées, elles permettent de faire face aux déformations géométriques provenant des conditions de vol à savoir les paramètres d'attitude (roulis, tangage, lacet), de positionnement de l'appareil et de topographie du relief. En proxi-détection, l'ensemble de ces facteurs de déformation géométrique est limité.

Les corrections atmosphériques concernent l'ensemble des images prises en milieu extérieur. Dans ce cas, les valeurs de luminance sont influencées, entre autres, par l'éclairement solaire disponible et la constitution de l'atmosphère au moment de la prise de vue. Celle-ci comporte des bandes d'absorption étroites (bandes de Fraunhofer) qui inter-agissent avec le rayonnement solaire modifiant sensiblement la courbe d'éclairement spectral disponible. Les valeurs de luminance des pixels doivent donc être étalonnées relativement aux conditions de prise de vue à savoir éclairement solaire disponible, constitution de l'atmosphère, géométrie de la prise de vue...([Lennon, 2002]). Cet étalonnage est réalisé, entre autres, via des techniques de modélisation du transfert radiatif dans l'atmosphère et constitue un champ de recherche actif. Cette étape s'avère particulièrement nécessaire lorsque l'on désire extraire des paramètres biophysiques ou encore réaliser de la correspondance de spectres avec des bibliothèques spectrales (spectral

matching).

Sans négliger l'importance des étapes préalables à l'utilisation des données IHS (pré-traitement), nous nous intéressons ici uniquement à l'aspect traitement des données. Les particularités de données IHS (grande dimensionnalité en particulier) ne permettent pas l'utilisation des algorithmes de classification ou segmentation classiquement utilisés en imagerie multispectrale. Elles nécessitent ainsi le développement d'algorithmes de traitement dédiés, qui permettent, d'une part, de s'affranchir d'un phénomène touchant les espaces de grande dimension (effet de Hughes ou malédiction de la dimensionnalité [Hughes, 1968]) et d'autre part, prenant en compte les dimensions spectrale et spatiale des données.

1.3.1 Faire face au phénomène de Hughes [Hughes, 1968]

Un des problèmes majeurs dans l'analyse et le traitement des images hyperspectrales réside dans le fait qu'il est extrêmement difficile d'extraire des informations utiles dans les espaces de grande dimension. Si l'augmentation du nombre de bandes spectrales permet *a priori* d'augmenter la séparabilité entre classes, la précision de l'estimation statistique, par exemple, pour des approches de classification paramétriques, diminue avec la dimension de l'espace conduisant de fait à des résultats de classification médiocres (effet de Hughes [Hughes, 1968]). Pour contourner ce phénomène, plusieurs voies de recherche sont engagées : la première consiste à s'intéresser non plus aux propriétés statistiques des classes mais à leurs propriétés géométriques dans l'espace spectral. Ainsi, les supports à vastes marges ou SVM [Vapnik, 1998] (Support Vector Machine) ont-ils connu un regain d'intérêt ces dernières années. La deuxième approche, consiste à projeter les données dans un espace de dimension inférieure, tout en gardant l'information utile à la séparation des classes. Cette réduction de dimension est justifiée par les propriétés des espaces de grande dimension (espace vide, renforcement de l'hypothèse de normalité lors de projections linéaires...) mais aussi par les grandes redondances d'informations existantes entre bandes spectrales adjacentes.

1.3.2 Tenir compte des informations spectrale et spatiale

Il est intéressant de noter que la plus part des approches disponibles pour le traitement des données hyperspectrales ne prennent pas en compte la dimension spatiale des données. Les images hyperspectrales ne sont pas traitées comme des matrices (images) mais comme une liste non ordonnée de spectres sans aucun arrangement spatial particulier. Ce constat a été posé par de nombreux auteurs dont [Tadjudin and Landgrebe, 1998]. La prise en compte de l'information spatiale apparaît cependant très utile dans le cas de problème de classification très difficiles où les objets à discriminer sont très proches spectralement.

Ainsi, Fauvel [Fauvel, 2007], dans le domaine de la reconnaissance des zones urbaines, précise que l'utilisation simultanée de l'information spectrale et spatiale est une voie pour discriminer des structures variables réalisées à partir de matériaux identiques. L'utilisation d'une information de structuration des pixels telle que la taille ou la forme permettra par exemple, de discriminer le toit d'une maison privée de celui d'un large immeuble. Zwiggelaar [Zwiggelaar, 1998], dans le domaine de l'agriculture, indique que la distinction entre culture et adventice est parfois très délicate en particulier pour des sols ayant déjà une couverture végétale. Il explique alors que l'information spectrale seule n'est pas suffisante pour discriminer de façon robuste les adventices des cultures. En effet, la réflectance des plantes est extrêmement fluctuante en fonction de l'espèce, de l'état physiologique de la plante (stress hydrique, état de santé), de l'état de la feuille (orientation suivant la lumière incidente, âge, structure), de la nature et de l'état du sol, ainsi que de la structure complexe du couvert végétal. Cela nécessite l'introduction d'autres caractéristiques pour parvenir à un taux de classification correct. Dans le domaine de l'aménagement du territoire, Zhang et ses co-auteurs [Zhang et al., 2007] précisent que les méthodes pixel à pixel fonctionnent mal sur des images à haute résolution spatiale car elles ne permettent pas de s'affranchir des hétérogénéités locales. Il semble ainsi judicieux de mettre en place des approches orientées objets qui permettront d'une part de pallier à ce problème mais aussi d'avoir accès à la notion d'objet et donc à des informations géométriques ou structurelles des pixels très utiles, par exemple, pour distinguer une rivière d'un étang. La mise en oeuvre de telles approches n'est cependant pas immédiate mais elle constitue suite à l'avènement de capteurs hyperspectraux satellitaires ou

aéroportés à haute résolution spatiale, un champ de recherche émergent et en pleine effervescence [Plaza, 2007a]. Dans le cadre de la proxi-détection, compte tenu de la très haute résolution spatiale des images obtenues et de l'intérêt évident d'avoir accès, dans le cadre de nos applications, à la notion d'objet, la mise en place de telles stratégies a tout son sens.

1.4 Conclusion

Dans ce chapitre, nous avons évoqué les propriétés et les atouts des images hyperspectrales dans des problématiques de classifications de scènes complexes. L'avenir de ce type d'images apparaît prometteur mais nécessite un investissement de recherche sur des problématiques liées autant à l'acquisition qu'au traitement des images. Dans le cadre de cette thèse, nous nous sommes intéressés plus particulièrement à l'aspect traitement de données. Deux problématiques afférentes au traitement des données hyperspectrales ont été évoquées à savoir (1) comment s'affranchir de l'effet de Hughes, (2) Comment utiliser et mêler informations spectrale et spatiale. L'objectif de la thèse est de proposer une approche permettant en particulier, de traiter ce dernier point tout en évitant les phénomènes liés à l'effet de Hughes.

Chapitre 2

État de l'art : Méthodes de traitement des IHS liant informations spectrale et spatiale

Le chapitre précédent a permis d'évoquer le souci de combiner les aspects spatiaux et spectraux dans les approches de traitement des données hyperspectrales tout en prenant en compte les problématiques de classification de ces données liées en particulier au phénomène de Hughes. Ce chapitre est dédié à un état de l'art sur les méthodes de traitement des IHS liant ces deux espaces. Nous nous intéressons dans un premier temps aux approches de classification intégrant une contrainte spatiale (c-moyennes floues, svm, champs de Markov) puis aux approches empruntées au traitement des images scalaires ou couleur et étendues au cas des IHS. Cet état de l'art nous permettra d'appréhender les avantages et les inconvénients de chacune des méthodes évoquées, de proposer et de justifier les grandes lignes de l'approche de segmentation d'IHS présentée dans ce mémoire.

Sommaire

2.1	Approches de classification avec contrainte spatiale	24
2.1.1	Fuzzy-C-means contraint spatialement	25
2.1.2	Machines à Support Vecteurs contraint spatialement	27

2.1.2.1	Principe de base des SVM :	27
2.1.2.2	Cas non linéairement séparable	29
2.1.2.3	Travaux en imagerie hyperspectrale basés sur les SVM	30
2.1.3	Champs de Markov	33
2.1.3.1	Quelques définitions [Coquerez, 1995], [Sigelle and Tupin, 1999]	33
	Champ de Markov	34
	Equivalence entre champs de Gibbs et de Markov	34
2.1.3.2	Quelques travaux concernant le traitement des IHS par champs de Markov	36
2.2	Extension des outils de traitement d'images scalaires aux images IHS	37
2.2.1	Approche par croissance ou division de régions	37
2.2.2	Filtrage par diffusion anisotropique	40
2.2.3	Approches Morphologiques	42
2.2.3.1	Outils morphologiques	42
	Opérateurs fondamentaux pour les images scalaires	42
	Profil morphologique	43
	Extension des outils morphologiques au cas hyperspectral	44
2.2.3.2	Ligne de partage des eaux (LPE) ou watershed	46
2.3	Conclusion	48

L'imagerie hyperspectrale consiste à créer et à analyser des images de la même scène pour une succession de longueurs d'onde dans un domaine spectral donné. L'analyse et l'interprétation de telles images nécessitent généralement la réalisation d'une étape de classification dont l'objectif est de caractériser les individus i.e. les pixels en les regroupant en classes homogènes spectralement et en leur affectant éventuellement une étiquette sémantique (par exemple, type de végétaux, caractéristique physique ou chimique ...). Pour ce faire, des méthodes de classifications classiques supervisées ou non telles que les k-means, fuzzy-c-means, classification hiérarchique, par graphe, ou encore de modélisation linéaire telles que la régression linéaire PLS (Partial Least Squares) ([McDonald et al., 2003], [Huang et al., 2004]) ou non linéaires telles que les vecteurs supports (Support Vector Machine ou SVM) sont ainsi largement utilisées,

en télédétection comme dans les laboratoires de chimie analytique ou les analyses industrielles ([Van Den Broek et al., 1996]). Cependant, de par leur définition, ces méthodes n'intègrent pas de notion spatiale : ce sont des processus de caractérisation des individus sur la base de leurs valeurs physiques, qui ne prennent pas en compte leur disposition spatiale. Or, l'exploitation conjointe de l'informations spectrale et spatiale disponibles, du fait entre autres, de l'apparition d'imageurs spectraux de meilleure résolution, apparaît aujourd'hui essentielle. En effet, les images naturelles sont hautement structurées : les pixels exhibent de larges inter-dépendances, spécialement lorsque ils sont spatialement proches et ces dépendances apportent des informations importantes quant à la structure des objets de la scène. On peut citer Plaza et ses co-auteurs [Plaza et al., 2006] qui s'insurgent contre la non utilisation de la dimension spatiale des données : *"Il est important de souligner que la plupart des techniques pour l'analyse d'images hyperspectrales se sont focalisées sur l'analyse des données sans incorporation de l'information d'adjacence spatiale des données, i.e les images ne sont pas traitées comme des images mais comme une liste non ordonnée de mesures spectrales où les coordonnées spatiales peuvent être oubliées arbitrairement sans affecter l'analyse. Cependant, une des propriétés importantes des spectromètres imageurs est que l'information multivariée est couplée avec une représentation 2D (image). Ainsi, il est nécessaire d'incorporer l'information spatiale dans le développement de techniques automatiques d'exploitation d'images hyperspectrales."*

Un champ nouveau de développement de méthodes d'analyse d'images hyperspectrales a donc été ouvert : il consiste à élaborer des méthodes combinant les paramètres spectraux et spatiaux des pixels de l'image. Bien que très récent, ce souci de lier informations spectrale et spatiale a donné lieu à plusieurs types de méthodes dans la littérature. Nous les avons grossièrement classées en deux catégories :

- Les premières que nous nommons "classification avec contrainte spatiale" concernent les approches relevant d'avantage d'une extension de la classification individuelle des pixels telle que la proposerait une approche purement spectrale. L'information spatiale y est intégrée en tant que paramètre supplémentaire de classification.

- Les secondes font références aux méthodes qui sont des extensions des outils de traitement d'images scalaires aux images IHS. Elles concernent des approches visant soit à étendre directement des approches de traitement des images scalaires à des images IHS, soit à combiner les disciplines propres à chacune des dimensions à prendre en compte (spatial, spectral) développées depuis plusieurs décennies et reposant sur des outils théoriques bien établis à savoir la chimométrie (analyse des données issues de spectromètres) et le traitement d'image.

L'objectif des sections suivantes n'est pas de réaliser une présentation exhaustive des méthodes afférentes à chacune des catégories évoquées ci-dessus mais de présenter les approches qui ont suscité le plus grand nombre de travaux. Ainsi le paragraphe 2.1 présentera plusieurs processus utilisant les méthodes de classification à noyaux (fuzzy-C-means, SVM) et intégrant une contrainte spatiale et les Champs de Markov. Le paragraphe 2.2 s'intéressera aux approches dites "objets" recherchant à extraire une information structurelle dans l'image (recherche de structures spatiales sous-jacentes en rapport avec les objets à extraire) et faisant appel, de ce fait, à des approches de traitement d'images développées pour les images scalaires. Ces travaux concernent notamment l'extension au cas IHS des approches de segmentation en régions (division/fusion, croissance de régions) et des outils de la morphologie mathématique (profils morphologiques, watershed...).

2.1 Approches de classification avec contrainte spatiale

Dans ces approches, l'information spatiale peut être introduite à différents niveaux : à l'étape d'initialisation de la classification permettant de déterminer un certain nombre de paramètres nécessaires à une bonne classification (nombre de classes par exemple), dans le procédé de classification même ou encore en post-classification (régularisation) permettant de lutter contre les classes se superposant ou les erreurs de classification type poivre et sel. Nous nous focalisons ici sur les approches intégrant une contrainte spatiale dans le processus même de classification.

2.1.1 Fuzzy-C-means contraint spatialement

L'approche C-moyennes flous (Fuzzy-C-Means ou FCM) [Bezdek, 1981] est une technique de classification floue non supervisée qui permet de révéler la structure sous-jacente de données et de segmenter une image en régions spectralement homogènes sans toutefois prendre en compte les relations spatiales entre pixels. Étant donnée une image contenant n pixels à partitionner en c classes, chacun des n individus appartient à chacune des c classes, avec un coefficient d'appartenance u , u_{ik} étant le degré d'appartenance de l'individu k à la i classe. Appelons d_{ki}^2 la distance entre l'individu k et la classe i . Elle peut être définie simplement comme une distance euclidienne dans l'espace spectral mais aussi de façon plus générale sous la forme :

$$d_{ki}^2(x_k, v_i) = \|x_k - v_i\|_A^2 = (x_k - v_i)A(x_k - v_i)^T \quad (2.1)$$

A étant une matrice symétrique définie positive et v_i le prototype de la classe i .

Soit U la matrice des coefficients u_{ik} et V celle des coordonnées des centres des classes, l'objectif de l'algorithme est de trouver U et V minimisant une fonction de coût définie de la façon suivante :

$$J = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m d^2(x_k, v_i) \quad (2.2)$$

Sous les contraintes suivantes :

$$u_{ik} \in [0, 1], \quad \sum_{i=1}^c u_{ik} = 1, \forall k, \quad 0 < \sum_{k=1}^n u_{ik} < n \quad \forall i \quad (2.3)$$

m est un paramètre permettant de contrôler le degré de flou de la partition. En général, ce paramètre vaut 2.

Une solution pour la minimisation de la fonction d'objectif J peut être obtenue par une procédure itérative où les centres des classes v_i et les degrés d'appartenance de la donnée x_k au i classes (u_{ik}) en cours sont mis à jour via les équations suivantes :

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{ij}}\right)^{\frac{2}{m-1}}} \quad (2.4)$$

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m} \quad (2.5)$$

L'insertion d'une contrainte (spatiale ou spectrale) peut être réalisée via une modification de l'équation (2.2) telle que proposée par exemple par Pedrycz [Pedrycz, 1996] consistant en l'ajout d'une variable auxiliaire permettant d'introduire une information *a priori* pour influencer la classification. Il aboutit ainsi à une nouvelle formulation de l'algorithme des C-moyennes floues connue sous le nom de C-moyennes floues conditionnelles (Conditional Fuzzy C-means ou CFCM). L'idée est d'utiliser des pixels connus et labellisés pour diriger le processus de classification. Pour cela, une variable auxiliaire f_k est affectée à chaque pixel labellisé et introduite dans la fonction d'objectif de la façon suivante :

$$J = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m d^2(x_k, v_i) + \alpha \sum_{k=1}^n \sum_{i=1}^c (u_{ik} - f_{ik} b_k)^m d^2(x_k, v_i) \quad (2.6)$$

Le premier terme de la fonction de l'objectif est la fonction standard FCM. La variable b_k , dans le second terme, est une variable booléenne qui indique si une information est connue *a priori* pour l'objet k (b_k vaut 1 dans l'affirmative et 0 sinon). La variable f_{ik} contient l'information *a priori* (degré d'appartenance) concernant l'objet k vis à vis de la classe i . Le paramètre α est un facteur de pondération de l'effet des connaissances *a priori*. L'introduction de cette nouvelle fonction d'objectif conduit également à modifier la procédure de calcul des valeurs d'appartenance u_{ik} et du calcul des centres de classe v_i en cours de processus ($m = 2$) :

$$u_{ik} = \frac{1}{1 + \alpha} \left\{ \frac{1 + \alpha(1 - b_k \sum_{l=1}^c f_{lk})}{\sum_{l=1}^c \frac{d_{lk}^2}{d_{ik}^2}} + \alpha f_{ik} b_k \right\}, \quad v_i = \frac{\sum_{k=1}^n u_{ik}^2 x_k}{\sum_{k=1}^n u_{ik}^2} \quad (2.7)$$

Ainsi, les hautes valeurs de f_{ik} permettent d'augmenter le degré d'appartenance de l'objet k à la classe i alors que les faibles valeurs de f_{ik} vont au contraire affaiblir celui-ci : le 2ème terme de l'équation (2.7) introduit un coût supplémentaire quand on s'éloigne des informations *a priori*.

Noordam et Broek [Noordam and Broek, 2002] ont utilisé cette formulation et ont proposé un algorithme de c-moyennes floues conditionnelles guidé géométriquement (geometrically guided conditional fuzzy c-means clustering ou GGC-FCM). Dans cet algorithme, les valeurs des variables auxiliaires f_{ik} sont déterminées à chaque itération en prenant en considération le voisinage immédiat du pixel x_k (fenêtre de taille paire s) au travers d'une mesure calculée à partir des degrés d'appartenance.

De nombreuses autres approches permettant d'introduire une contrainte spatiale dans l'algorithme des C-moyennes floues ont été proposées dans la littérature. Parmi les plus récentes, on peut notamment citer celles de [Bandyopadhyay, 2005] ou encore [Chuang et al., 2006] et [Wang and Fei, 2008].

2.1.2 Machines à Support Vecteurs contraint spatialement

Les machines à vecteurs supports ou séparateurs à vaste marge (en anglais Support Vector Machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destiné à résoudre des problèmes de discrimination et de régression et sont particulièrement adaptées pour traiter les données de très hautes dimensions [Vapnik, 1998]. Elles permettent, en effet, de s'affranchir du phénomène de Hughes en s'intéressant à des propriétés géométriques (frontières) des ensembles à discriminer plutôt qu'à leurs propriétés statistiques. Elles ont été utilisées dans de nombreux domaines (reconnaissance de forme, imagerie médicale...) mais également dans le traitement des images hyperspectrales où elles ont donné des résultats encourageants [Karimi et al., 2006, Melgani and Bruzzone, 2004, Roli and Fumera, 2001, Gualtieri and Chettri, 2000]...

Dans les sections suivantes, nous rappelons brièvement les principes de base de ces approches puis nous intéressons aux méthodes développées par plusieurs auteurs pour incorporer une contrainte spatiale.

2.1.2.1 Principe de base des SVM :

Initialement les approches SVM ont été proposées pour rechercher la séparation optimale entre deux classes. Un problème de classification en deux classes peut s'énoncer de la façon sui-

vante : Soit X un ensemble de N exemples d'apprentissage dont chaque élément est représenté par une paire (\vec{x}_i, y_i) avec $i = 1 \cdots N$, y_i un label de classe pouvant prendre la valeur $+1$ ou -1 et \vec{x}_i un vecteur de dimension k ($x_i \in \mathbf{R}^k$). L'objectif d'un classifieur est de déterminer, à l'aide de ces données d'apprentissage, une fonction de décision $f(x, \alpha) \rightarrow y$ (avec α paramètres du classifieur) et de l'utiliser ensuite pour classifier de nouvelles données.

Dans le cas d'un classifieur linéaire, la fonction f peut être définie à l'aide d'un hyperplan d'équation $\vec{w} \cdot X + b = 0$ (où \vec{w} et b désignent les paramètres de l'hyperplan soit respectivement un vecteur normal au plan et le biais). La classification d'un vecteur \vec{x}_i est alors donnée par le signe de la fonction f , $\text{sgn} [f_{\vec{w},b}(\vec{x}_i)]$, ie $y_i = +1$ si $\text{sgn} [f_{\vec{w},b}(\vec{x}_i)] > 0$ ou $y_i = -1$ si $\text{sgn} [f_{\vec{w},b}(\vec{x}_i)] < 0$.

Le principe des approches SVM est de trouver l'hyperplan optimal parmi l'ensemble des hyperplans possibles (figure 2.1-a) permettant de classifier correctement les données (i.e. les données des classes de label $+1$ et -1 se trouvent de chaque côté de l'hyperplan) mais également tel que sa distance aux vecteurs (exemple d'apprentissage) les plus proches soit maximale (i.e. le plus loin possible de tous les exemples). Les vecteurs les plus proches sont alors dénommés "vecteurs supports" et la distance consitue la marge optimale.

Les vecteurs supports sont situés sur deux hyperplans parallèles (H_1 et H_2) à l'hyperplan optimal d'équation $\vec{w} \cdot X + b = 0$ et ont pour équation respective $\vec{w} \cdot X + b = -1$ et $\vec{w} \cdot X + b = +1$ (figure 2.1-b). Aucun exemple d'apprentissage ne devant être situé dans la marge, ils satisfont les équations suivantes :

$$\begin{aligned} \vec{w} \cdot \vec{x}_i + b &\geq +1 \text{ si } y_i = +1, \\ \vec{w} \cdot \vec{x}_i + b &\leq -1 \text{ si } y_i = -1 \quad \forall i = 1, \dots, N \end{aligned} \tag{2.8}$$

Ces contraintes peuvent être regroupées en une seule inégalité suivante : $y_i(\vec{w} \cdot \vec{x}_i + b) - 1 \geq 0$

Ainsi, la marge est au moins égale à la distance entre les deux hyperplans H_1 et H_2 soit $\frac{2}{\|\vec{w}\|}$, où $\|\vec{w}\|$ fait référence à la norme du vecteur \vec{w} . Maximiser cette marge revient donc à minimiser $\|\vec{w}\|$ sous la contrainte que l'hyperplan reste séparateur ie $y_i(\vec{w} \cdot \vec{x}_i + b) - 1 \geq 0, \forall i = 1, \dots, N$ (on retrouve ici la justification de l'appellation de "séparateur à vaste marge").

On peut ainsi montrer, en utilisant des méthodes d'optimisation adaptées (principe de dualité et multiplicateurs de Lagrange), que le vecteur \vec{w}^* réalisant l'optimum peut s'écrire sous la forme $\vec{w}^* = \sum_{i=1}^N \alpha_i^* y_i \vec{x}_i$. Les α_i^* sont les multiplicateurs de Lagrange déterminés et sont non-nuls uniquement pour les points \vec{x}_i se trouvant exactement "sur la marge" i.e. les vecteurs supports. Le calcul de b^* s'effectue soit en prenant un i particulier (un exemple d'apprentissage) soit en calculant la moyenne de tous les b^* obtenus pour chaque vecteur support.

Soit $vs = \{j \in \{1, 2, \dots, l\} \text{ tel que } \alpha_j^* \neq 0\}$ l'ensemble des indices des vecteurs supports. Une fois les paramètres α^* et b^* calculés, la règle de classification d'une nouvelle observation \vec{x} basée sur l'hyperplan à marge maximale est donnée par $sgn(\sum_{j \in vs} y_j \alpha_j^* \vec{x} \cdot \vec{x}_j + b^*)$.

2.1.2.2 Cas non linéairement séparable

Cependant, dans de nombreux cas, les échantillons d'entraînement ne sont pas linéairement séparables. La procédure consiste alors à introduire une fonction Φ permettant de projeter les données dans un espace de dimension supérieure (D) où elles deviennent linéairement séparables (voir figure 2.2) :

$$\begin{aligned} \mathbf{R}^d &\longrightarrow \mathbf{R}^D \quad \text{avec } D \gg d \\ \vec{x} &\longrightarrow \Phi(\vec{x}) \end{aligned}$$

De la même façon qu'en 2.1.2.1, on recherche dans ce nouvel espace, l'hyperplan optimal donné cette fois par $f^*(\vec{x}) = \vec{w}^* \cdot \Phi(\vec{x}) + b^*$ avec $\vec{w}^* = \sum_{i=1}^n \alpha_i y_i \Phi(\vec{x}_i)$ soit $f^*(\vec{x}) = \sum_{i=1}^n \alpha_i y_i \Phi(\vec{x}_i) \cdot \Phi(\vec{x}) + b^*$.

Une observation importante est que la seule connaissance des produits scalaires entre points est suffisante pour trouver et calculer la fonction f^* . On n'a donc nul besoin de trouver une représentation $\Phi(\vec{x})$ explicitement. Il suffit d'être capable de calculer $\Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) = k(\vec{x}_i, \vec{x}_j)$. Le terme $k(\vec{x}_i, \vec{x}_j)$ est appelé noyau. Vapnik [Vapnik, 1998] a montré que toute fonction satisfaisant les conditions de Mercer (symétrique, définie positive) peut être utilisée comme noyau.

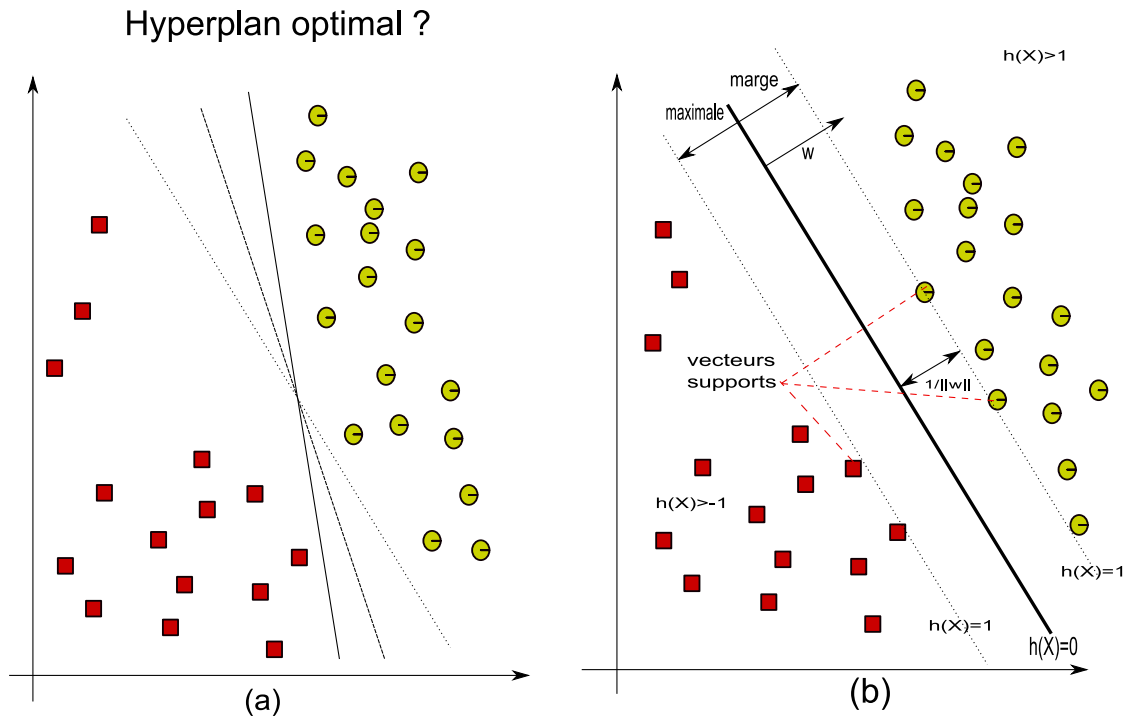


FIG. 2.1 – Principe des SVM : (a) Recherche de l'hyperplan optimal ; (b) Hyperplan optimal, marge et vecteurs supports

Parmi les noyaux les plus classiquement utilisés pour la classification des IHS, on trouve, le noyau gaussien ou noyau RBF (pour Radial Basis Function) $k(x, y) = \exp(-\frac{\|x-y\|^2}{2\sigma^2})$ ou encore le noyau polynomial $k(x, y) = (x \cdot y + 1)^p$ ([Gualtieri and Chettri, 2000, Huang et al., 2002, Camps-Valls et al., 2006a]...). Pour faire face aux variations d'illumination en cours d'acquisition et prendre en compte la notion de signature spectrale propre aux IHS, Mercier et ses co-auteurs ([Mercier et al., 2003]) ont introduit un noyau basé sur la distance angulaire spectrale (Spectral Angle Mapper ou SAM en anglais [Keshava, 2004]).

2.1.2.3 Travaux en imagerie hyperspectrale basés sur les SVM

Cependant, les travaux cités précédemment concernant l'imagerie hyperspectrale et basés sur les SVM utilisent uniquement l'information spectrale, les relations inter-pixels ne sont pas




FIG. 2.2 – Représentation de l’astuce du noyau (Trick Kernel)

utilisées. Des noyaux spécifiquement adaptés aux images hyperspectrales et utilisant des relations spatiales ou contextuelles ont été cependant proposées par divers auteurs dont Mercier [Mercier et al., 2003], Camps-Valls [Camps-Valls et al., 2006b] ou encore Fauvel [Fauvel, 2007, Fauvel et al., 2007].

L’introduction d’une contrainte spatiale ou d’une information contextuelle dans les approches SVM est réalisée via les fonctions noyaux. Camps-Valls et ses co-auteurs [Camps-Valls et al., 2006b] ont montré que toute fonction composite de noyaux de forme $K(x_i, y_j) = K_1(x_i, y_j) + K_2(x_i, y_j)$ et $K(x_i, y_j) = \alpha K_1(x_i, y_j)$ avec K_1, K_2 noyaux définis et vérifiant les conditions de Mercer et $\alpha > 0$ pouvait en effet être utilisée elle même comme noyau (conditions de Mercer vérifiées). Il propose donc de construire un noyau spectral K_s et un noyau spatial K_w est de les combiner via les fonctions composites décrites précédemment pour obtenir un noyau de la forme suivante :

$$K(x_i, x_j) = \mu K_s(x_i^s, x_j^s) + (1 - \mu) K_w(x_i^w, x_j^w)$$

Le terme μ est un paramètre réel positif ($0 < \mu \leq 1$) qui permet de moduler l’importance donnée au terme spatial et spectral.

Dans ces expérimentations, menées sur des images hyperspectrales AVIRIS (200 bandes spectrales utilisées), l’auteur a utilisé comme noyau spectral un noyau polynomial ($d = 1 \dots 10$). Les

termes x_i^s et x_j^s sont simplement les signatures spectrales associées aux pixels i et j . Le noyau spatial est construit sur la base d'un noyau gaussien où l'information spectrale x_i^w est calculée sur une fenêtre centrée sur le pixel (moyenne, écart type). Les noyaux intégrant une contrainte spatiale permettent d'améliorer de façon conséquente les résultats de la classification finale (en particulier le noyau obtenu par somme pondérée de noyaux). L'auteur a cependant constaté, du fait de l'utilisation d'une fenêtre carrée, que de nombreuses erreurs de classification interviennent sur les zones de transition (contour).

Mercier et ses co-auteurs [Mercier et al., 2003] utilisent ce même noyau pour classifier des images hyperspectrales en provenance d'un capteur CASI (17 bandes spectrales de 450 à 950 nm). Plusieurs noyaux spectraux et spatiaux de base sont testés (noyau gaussien, noyau basé sur la distance SAM...) et l'information spatiale pour un pixel i est obtenue par moyenne sur une fenêtre carrée centrée sur le pixel i .

Fauvel [Fauvel, 2007] propose de pallier aux phénomènes d'effet de bord (erreurs de classification sur les zones de transition) en définissant un voisinage spatial adaptatif. Pour ce faire, il utilise en premier lieu des filtres d'aires appelés filtres surfaciques auto-complémentaires proposés par Soille [Soille, 2005] permettant d'obtenir une image sur-segmentée préservant les structures importantes de l'image. Le filtrage d'aire est effectué sur la première composante principale de l'image hyperspectrale. Les régions connexes obtenues permettent ainsi de définir le système de voisinage. En notant Φ_x l'ensemble des pixels appartenant à la même région que le pixel x , l'auteur définit l'information spatiale comme $\Gamma_x = med(\Phi_x)$ avec *med* valeur médiane de l'ensemble des pixels de la région. La classification est ensuite réalisée via l'approche SVM utilisant un noyau composite $K_\gamma(x, y)$. Ce noyau est une somme pondérée d'un noyau gaussien spectral $k_\gamma^{spec}(x, y)$ et d'un noyau gaussien spatial $k_\gamma^{spat}(x, y) = exp(-\frac{\|\Gamma_x - \Gamma_y\|}{2\gamma^2})$ avec $0 \leq \mu \leq 1$ et $0 \leq \gamma$ (déterminés lors de la phase d'apprentissage). Cette approche testée sur des images satellitaires et aéroportées de zones urbaines permet d'obtenir des résultats de classification améliorés en comparaison à une approche SVM sans contrainte spatiale.

2.1.3 Champs de Markov

Les champs de Markov sont largement utilisés en imagerie scalaire ou multispectrale pour traiter des problèmes de classification, de segmentation ou encore de régularisation. L'intérêt de telles méthodes est de pouvoir prendre des « décisions » (classification, estimation, filtrage, restauration,...) localement à partir de toute l'information disponible dans l'image. Du fait de sa formulation vectorielle c'est une approche qui semble particulièrement adaptée au traitement des images hyperspectrales.

Après une introduction aux notions de base des champs de Markov, nous ferons une brève revue de quelques approches disponibles dans la littérature et utilisant les champs de Markov pour le traitement d'IHS.

2.1.3.1 Quelques définitions [Coquerez, 1995], [Sigelle and Tupin, 1999]

L'image est ici représentée comme une grille rectangulaire finie bidimensionnelle de taille $m \times n = N$ contenant un ensemble de sites $S = s_i$, avec $1 \leq i \leq N$ appelés pixels. À chaque site est associé un descripteur, représentant l'état du site et pouvant être un scalaire (niveau de gris, label) ou encore un vecteur (spectre), et prenant ses valeurs dans E .

L'image est considérée comme une réalisation d'un champ aléatoire. Soit s un site de l'image, on peut lui associer une variable aléatoire X_s prenant ses valeurs dans E . Le descripteur x_s associé à ce site n'est ainsi qu'une réalisation de la variable aléatoire X_s ³. On définit alors le champ aléatoire $X = (X_s, X_t, \dots)$ prenant ses valeurs dans $E^{|S|}$. On désigne par X^s le champ X privé de s . On note V_s le voisinage de s , un système de voisinage V se définissant comme suit :

$$V_s = \{t\} \text{ tels que } \begin{cases} s \notin V_s \\ t \in V_s \Rightarrow s \in V_t \end{cases} \quad (2.9)$$

Les deux systèmes de voisinage les plus couramment utilisés, car de cardinal faible, sont le 4-voisinage (ou 4-connexité) et le 8-voisinage (ou 8-connexité) (voir figure 2.3).

³Les lettres majuscules désignent ainsi les variables et champs aléatoires et les minuscules les valeurs des réalisations respectives

Champ de Markov Un champ de Markov X est un champ aléatoire vérifiant la propriété suivante :

$$P(X_s = x_s / X^s = x^s) = P(X_s = x_s / x_t, t \in V_s) \quad (2.10)$$

Cela signifie que la probabilité en un site s conditionnellement au reste du champ est égale à la probabilité en ce site connaissant uniquement ses voisins. Ainsi, tout l'intérêt d'une modélisation Markovienne réside donc dans la possibilité de spécifier localement un modèle qui est en fait global.

Equivalence entre champs de Gibbs et de Markov Si on introduit la condition de positivité ($P(X = x) > 0, \forall x$), le théorème de Hammersley-Clifford permet d'assimiler le champ de Markov à une distribution de Gibbs [?, Li, 1995] dont la formulation énergétique d'écrit alors :

$$P(X = x) = \frac{1}{Z} \exp(-U(x)) = \frac{1}{Z} \exp\left(-\sum_{c \in \mathbf{C}} V_c(x)\right) \quad (2.11)$$

Dans cette expression, Z est une constante appelée fonction de partition permettant de normaliser la distribution $P(X)$. $U(x)$ est appelée fonction d'énergie et \mathbf{C} est l'ensemble des cliques associées au voisinage V , c'est à dire regroupant tous les singletons et ensembles de sites tous voisins (figure 2.3). Cette équivalence permet en particulier d'appréhender les propriétés globales d'un champ dont nous aurons spécifié les propriétés locales par l'intermédiaire d'un système de voisinage et des fonctions de potentiels $U(x)$.

En fonction du système de voisinage, $U(x)$ peut prendre diverses formes ; par exemple, si on considère un champ de Markov de voisinage 4-connexe, nous pouvons écrire l'énergie de la configuration x sous la forme $U(x) = \sum_{c=(i) \in C_1} U_c(x_i) + \sum_{c=(i,j) \in C_2} U_c(x_i, x_j)$ où C_1 et C_2 sont respectivement les cliques d'ordre 1 et 2 (l'ordre de la clique étant donné par le nombre de pixels intervenant dans sa construction). C'est ensuite la définition des fonctions U_c qui va déterminer le comportement probabiliste adapté à une application donnée. Plusieurs modèles ont été proposés dans la littérature (Potts, Ising, ou champs de Markov Gaussiens...).

Le modèle de Potts est une généralisation du modèle d'Ising. Il est bien adapté au problème

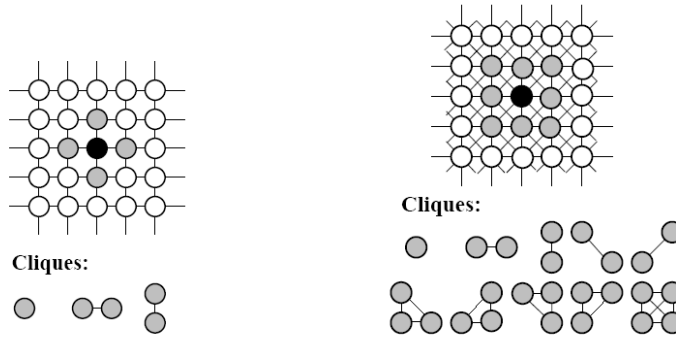


FIG. 2.3 – Représentation des cliques suivant le système de voisinage : (gauche) - connexité 4, (droite) - connexité 8

de classification des images (labellisation). Dans ce modèle, les potentiels d'ordre 1 (terme d'attache aux données) permettent de caractériser l'adéquation des étiquettes aux observations. Les potentiels d'ordre 2, appelés encore terme contextuel ou modèle *a priori*, introduisent un effet régularisant sur le champ des étiquettes. Ils sont calculés par la fonction $U_{c=(s,t)}$ telle que :

$$U_{c=(s,t)}(x_s, x_t) = \begin{cases} -\beta & \text{si } x_s = x_t \\ +\beta & \text{si } x_s \neq x_t \end{cases} \quad \text{avec } \beta \geq 0 \quad (2.12)$$

Ainsi, un voisinage non identique engendre une augmentation du potentiel et ainsi à une diminution de la probabilité, ce qui revient à privilégier l'établissement de voisinages homogènes.

Le modèle gaussien Markovien est réservé aux images en niveaux de gris. Le voisinage est 4 ou 8 connexe et la fonction de potentiel $U(x)$ est de la forme suivante :

$$U(x) = \beta \sum_{c=(s,t)} (x_s - x_t)^2 + \alpha \sum_{s \in S} (x_s - \mu_s)^2 \quad (2.13)$$

Le premier terme est un terme de régularisation qui favorise les faibles différences de niveaux de gris entre sites voisins pour $\beta > 0$. Le second terme est un terme d'attache aux données comparable à celui du modèle de Potts.

Une fois établies, les propriétés stochastiques de l'image, le traitement proprement dit consiste

à rechercher la réalisation d'image de probabilité maximale à l'aide d'une procédure itérative (recuit simulé, ICM ou Iterated Conditional Mode).

2.1.3.2 Quelques travaux concernant le traitement des IHS par champs de Markov

Pony [Prony et al., 2000] utilise les champs de Markov dans le cadre de la régularisation d'une classification d'image hyperspectrale de zone rurale et périurbaine obtenue par maximum de vraisemblance. Le champ Markovien est construit sur la base d'un modèle de Potts et un l'algorithme ICM puis de recuit simulé permet de trouver la configuration optimale x minimisant l'énergie ainsi définie. Le terme d'attache aux données est calculé, sous l'hypothèse d'égalité des probabilités *a priori* $P(x)$ et $P(y)$ (probabilité label), par la log-vraisemblance *a priori* ($\log(P(y_s/x_s))$). Le terme de régularisation β du modèle de Potts permet de pondérer l'effet de la régularisation. Une grande valeur de β favorisera le reclassement d'un pixel isolé dans la classe la plus présente parmi ses voisins. Des simulations sur différentes images ont permis de montrer que des valeurs de β inférieures à 3.0 permettaient d'obtenir les meilleurs résultats. Cette approche est cependant appliquée sur des images hyperspectrales comportant un nombre limité de bandes spectrales (11 bandes). Son extension à une image hyperspectrale à plusieurs centaines de bandes n'est pas immédiate et nécessite en particulier un pré-traitement afin de limiter la redondance des données et ainsi réduire les temps de calcul (réduction de données).

Relier [Relier, 2002] utilise également les champs de Markov dans le cadre de la classification d'images hyperspectrales texturées de zones urbaines. La modélisation de la texture est réalisée par un modèle markovien Gaussien vectoriel appelé modèle champ de Markov Gaussien Multivarié ou MGMRF (en anglais Multivariate Gaussian Markov Random Field) tel que proposé initialement par Hazel [Hazel, 2000] où les données vectorielles constituent les observations aux différentes longueurs d'onde d'un même site. Les interactions entre les valeurs à différentes longueurs d'onde ne sont pas modélisées explicitement, mais découlent des paramètres, ceux-ci étant estimés à partir des données. Ce champ est adapté aux images hyperspectrales moyennant une simplification permettant de diminuer drastiquement le nombre de paramètres. En couplant celle-ci avec une étape de réduction de données par poursuite de projection [Friedman and Tukey, 1974],

le modèle proposé permet d'éviter l'apparition des problèmes d'estimation statistiques inhérents aux espaces de grande dimension. L'application du modèle de texture ainsi construit sur des images réelles AVIRIS permet d'obtenir des résultats prometteurs.

De nombreux autres travaux s'intéressent à la régularisation ou à la segmentation d'IHS par champs de Markov. Parmi les plus récents, on peut citer [Huang et al., 2008] ou encore [Bali and Mohammad-Djafari, 2008], [Gong and Shu, 2007] et [Smartt and Tyo, 2006]...

2.2 Extension des outils de traitement d'images scalaires aux images IHS

Nous avons vu dans les sections précédentes des approches de classification intégrant une contrainte spatiale. Une autre démarche consiste à étendre la définition de certaines opérations ou notions élémentaires du traitement d'image à cette multi-dimensionnalité nouvelle. Elle concerne l'ensemble des approches développées dans le cadre de l'imagerie scalaire, méthodes de filtrage, de segmentation contour et régions... Ces méthodes, dans leur grande majorité, sont une étape préalable à une approche de classification. Ainsi, elles cherchent à aider le processus de classification en amont soit en "homogénéisant" les variabilités spectrales par des approches de filtrage soit en rassemblant les pixels similaires spectralement en régions connexes permettant d'avoir accès à la notion d'objet et donc par exemple à des notions de formes utiles à la discrimination (par exemple, la proxi-détection au champ).

2.2.1 Approche par croissance ou division de régions

Les approches dites par croissance ou division de régions sont ainsi naturellement utilisées. Très brièvement, ces approches utilisent des phases de regroupements ou de divisions d'ensemble de pixels connexes en utilisant des mesures de similarité (par exemple, distance euclidienne des niveaux de gris). À notre connaissance, la première approche basée sur ce principe et développée pour la segmentation d'images hyperspectrales est due à Landgrebe et Kettig

[Kettig and Landgrebe, 1977, Landgrebe, 1980] sous la forme d'un processus nommé ECHO pour Extraction and Classification of Homogeneous Objects. C'est une approche supervisée qui comporte une première étape de segmentation type division/fusion basée sur les statistiques des classes (fonction de densité de probabilité) puis une étape de classification par maximum de vraisemblance. La segmentation est réalisée en divisant l'image en blocs de $N \times N$ pixels (par exemple 2×2) puis en effectuant une étape de sélection de chaque cellule ainsi déterminée en comparant leurs statistiques à un seuil d'homogénéité. Les cellules ayant un test négatif (non homogènes) sont repérées comme singulières et comme étant des cellules à cheval sur des bordures. Chacun des pixels appartenant à ces cellules singulières est alors classifié. Une seconde étape de segmentation consiste à tester la similarité statistique de cellules non-singulières adjacentes en utilisant un test de vraisemblance. Les cellules considérées comme similaires sont fusionnées et ainsi un objet peut croître jusqu'à ses frontières naturelles. La classification est ensuite réalisée.

Cette approche est aujourd'hui encore disponible dans de nombreux logiciels de traitement d'images hyperspectrales tels ENVI (ITT, Visual Information Solutions). Cette méthode a été étendue au cas non supervisé par Jimenez et ses co-auteurs [Jimenez et al., 2005].

Une approche reposant également sur un processus de croissance de région a été proposée plus récemment par VanDerWerff [Van der Werff, 2006, Van der Werff and Van der Meer, 2008] ou encore par De Jong et ses co-auteurs [De Jong et al., 2001].

VanderWerff s'intéresse, entre autres, à la détection d'infiltrations naturelles à partir d'images Landsat. Il cherche à développer un algorithme prenant en compte les informations spectrales et spatiales lui permettant de reconnaître des objets de signatures spectrales identiques mais correspondant physiquement à des éléments naturels différents (en particulier étendues d'eau). Il introduit dans un premier temps un algorithme lui permettant de différencier des corps d'eau de signature spectrale identique mais morphologiquement différents. Il s'appuie, pour cela, sur un algorithme de croissance de région suivi d'une étape de regroupement. Les sources de croissance sont positionnées aux minima de variance spectrale calculés sur des voisinages 3×3 . La distance euclidienne inter-spectre est utilisée comme critère de similarité. Le seuil d'agrégation fixe l'échelle de la segmentation. Lorsque le processus de regroupement permet d'obtenir une

segmentation stable, l'auteur calcule divers paramètres de forme sur les régions identifiées. Une classification utilisant ces derniers et quelques bandes spectrales pertinentes est ensuite réalisée pour obtenir une carte thématique finale.

De Jong et ses co-auteurs ont proposé une approche appelée "The Spatial and Spectral Classification method" (SSC) qui se rapproche de la méthode proposée par Landgrebe et Kettig décrite précédemment. Elle est constituée de deux étapes. La première identifie les régions homogènes en s'intéressant à chaque pixel et à son voisinage selon une connexité 4. Une distance de similarité spectrale entre le pixel et son voisinage permet de décider de l'homogénéité de l'ensemble (seuillage). Les régions dites homogènes se voient alors assigner une réponse spectrale identique égale à la moyenne spectrale de la région et elles sont classées en utilisant des exemples d'apprentissage et un classifieur appelé "Minimum Distance To Mean ou MDTM" [Schowengerdt, 1997]. De façon très classique, ce classifieur affecte la région considérée à la classe (w^*) dont la distance spectrale euclidienne entre le spectre moyen de la classe et le spectre de référence de la région est minimale : $w^* = \min_w d_{wi}^{spec}$ avec d_{wi}^{spec} la distance choisie. La deuxième étape du processus consiste à classer les pixels hétérogènes par rapport à leur voisinage en utilisant à nouveau le classifieur MDTM mais en introduisant dans le calcul un terme spatial. Ainsi, $w^* = \min_w (\alpha \times d_{wi}^{spec} + (1 - \alpha)d_{wi}^{spat})$. Le terme α est un facteur permettant de pondérer l'impact du facteur spatial et spectral. La distance spatiale d_{wi}^{spat} donne une information de voisinage (proportion de pixels appartenant à la classe wi dans un rayon variable autour du pixel en cours). Cette approche a été testée sur des images acquises par un système d'imagerie aéroporté (Digital Airbone Imaging Spectrometer ou DAIS) comportant 72 bandes spectrales (visible au moyen infrarouge) sur des scènes végétales et donne des meilleurs résultats de classification en comparaison avec des méthodes de classification classiques.

Enfin, on termine sur les travaux de Tilton [Tilton, 1998] qui a proposé un algorithme d'optimisation de croissance hiérarchique (Hierarchical segmentation ou HSEG) sur la base des travaux de Beaulieu et de l'algorithme d'optimisation séquentiel hiérarchique (HSWO pour Hierarchical Step-Wise Optimal Segmentation [Beaulieu and Godberg, 1989] et adapté aux images hyperspectrales. Cet algorithme comporte trois étapes :

1. Affectation d'un label de région à chaque pixel de l'image (label unique pour chaque pixel si pas d'étape de pré-segmentation) ;
2. Calcul d'un critère de dissimilarité entre toutes les paires de régions adjacentes. Fusion des deux régions adjacentes qui présentent le critère minimal.
3. Arrêt si plus aucune fusion n'est souhaitée, sinon retour à l'étape 2.

Tilton propose un ensemble de fonctions de dissimilarité basé sur la norme vectorielle, l'entropie, l'information de divergence spectrale (SID ou "Spectral Information Divergence" en anglais), l'angle spectral (SAM ou "Spectral Angle Mapper") ou encore la distance vectorielle normalisée (NVD ou "Normalized Vector Distance"). Dans ces développements récents et afin de pallier l'important coût algorithmique de l'approche initiale HSEG, Tilton [Tilton, 2005] a développé un algorithme récursif d'approximation appelé RHSEG ("Recursive Hierarchical Segmentation"). Ces travaux ont été appliqués sur des images Landsat et médicales avec de bons résultats de segmentation.

2.2.2 Filtrage par diffusion anisotropique

L'utilisation de filtres classiques de lissage étendus au cas hyperspectral aboutit à une perte importante de détails de l'image [Pham, 2001, Lennon, 2002]. Ainsi, Lennon [Lennon, 2002] ou encore [Duarte-Carvajalino et al., 2006] ont proposé l'utilisation d'un processus de filtrage non linéaire basé sur une extension vectorielle de la diffusion anisotropique proposée initialement par Perona-Malik [Perona and Malik, 1990] pour le lissage d'images scalaires. La diffusion est un processus temporel permettant d'homogénéiser une image de même que la diffusion de température, en physique, homogénéise la température des objets. L'équation d'évolution de l'image est donnée par l'équation (2.14). Utilisée en traitement de l'image, la diffusion intervient en pré-traitement, de façon à supprimer les perturbations locales du signal. Ainsi, l'approche classique de filtrage par convolution de l'image avec un filtre gaussien est équivalente à un processus de diffusion dans lequel l'intensité de l'image est "diffusée" autour des pixels voisins durant un temps t proportionnel à la variance du noyau gaussien ([Lennon, 2002]).

$$\frac{\partial I(x, y, t)}{\partial t} = \text{div}(\vartheta \nabla I(x, y, t)) \quad (2.14)$$

conditions initiales : $I(x, y, 0) = f$

ϑ : coefficient de diffusion

(2.15)

Dans le cas d'un filtre gaussien, ϑ est une valeur constante et on retrouve l'équation classique de la diffusion de la chaleur qui se propage de façon homogène et isotrope. Perona et Malik [Perona and Malik, 1990] ont proposé de rendre ϑ variable et dépendant du contenu de l'image. Plus précisément, ils ont proposé de favoriser la diffusion dans les régions homogènes et de la réduire au voisinage des frontières de ces régions. Typiquement, ϑ est une fonction décroissante en fonction du module du gradient (par exemple, $\vartheta = e^{-\left(\frac{\|\Delta I\|}{k}\right)^2}$ ou encore $\vartheta = \frac{1}{1 + \frac{\|\Delta I\|^2}{k}}$ avec k paramètre de seuillage.

Weickert [Weickert, 1998] et Sapiro et Ringach [Sapiro and Ringach, 1996] ont été les premiers à étendre ce concept aux images multi-valuées sous la forme donnée par (équation (2.16)) :

$$\frac{\partial I_i(x, y, t)}{\partial t} = \text{div} \bullet (g(\theta) \nabla I_i(x, y, t)), \text{ avec } : i = 1 \dots M \quad (2.16)$$

Dans cette équation, g est le coefficient de diffusion, M le nombre de bandes spectrales de l'IHS I , I_i est l'image à la bande spectrale i et θ est une mesure vectorielle de contours (vector-valued edge strength) et est donnée par :

$$\theta = \sqrt{\frac{1}{M} \sum_{i=1}^M \|\nabla I_{\sigma,i}(x, y, t)\|^2} \quad (2.17)$$

avec $I_{\sigma,i}$ version lissée de I_i obtenue par convolution de I_i avec un noyau gaussien de déviation standard σ . $g(\theta)$ est une fonction décroissante de θ .

Lennon [Lennon, 2002] utilise le concept de diffusion anisotrope comme un prélude à une étape de classification basée sur les SVM. Il préfère cependant, afin de prendre en compte la redondance d'information entre composantes spectrales, réaliser une réduction de données préalable par une analyse en composantes principales ajustée au bruit (Noise-Adjusted Principal

Component Analysis ou NAPCA [Lee et al., 1990]) en intégrant dans la variable ϑ une mesure de distance vectorielle calculée dans l'espace support (espace initial). Enfin, il utilise le schéma numérique proposé par Perona et Malick pour discrétiser de manière efficace l'équation (2.14). Duarte [Duarte-Carvajalino et al., 2006] utilise directement l'approche proposée par Weickert mais propose d'améliorer considérablement les temps et la précision du calcul en utilisant d'autres approches de discrétisation. L'auteur montre alors que la classification de l'image filtrée avec des algorithmes de classification linéaires simples tels que l'analyse discriminante permet d'améliorer considérablement les résultats. Par ailleurs, l'auteur (Duarte) propose une approche intégrant directement ce processus de filtrage dans un processus de segmentation d'IHS hiérarchique utilisant les coupes normalisées [Shi and Malik, 1997]. La notion de coupe normalisée, basée sur un formalisme de graphe, sera décrite plus en détail dans le chapitre 4.

2.2.3 Approches Morphologiques

2.2.3.1 Outils morphologiques

Au préalable, nous introduisons les opérateurs qui fondent la morphologie mathématique dans le cas d'images en niveaux de gris. Nous débutons par des outils de base i.e. l'érosion et la dilatation à partir desquels des opérateurs plus complexes sont présentés i.e. ouverture, fermeture, profil morphologique. Enfin, nous présentons quelques travaux utilisant ces outils ou leur extension au cas multivarié pour le traitement des IHS.

Opérateurs fondamentaux pour les images scalaires En reprenant les notations proposées par Plaza et ses co-auteurs [Plaza et al., 2002], si on considère une image f en niveaux de gris définie sur Z^2 (espace 2D discret) et un élément structurant désigné par B tel que $B \subset Z^2$, l'opérateur d'érosion de f par B est défini par l'expression suivante :

$$(f \otimes B)(x, y) = \wedge_{(s,t) \in Z^2(B)} f(x + s, y + t), \text{ avec } (x, y) \in Z^2, \quad (2.18)$$

$Z^2(B)$ fait référence aux pixels appartenant au voisinage défini par B et l'opérateur \wedge fait référence au minimum.

De la même façon l'opérateur de dilatation de f par B est défini par l'expression ci-dessous où le symbole \vee désigne le maximum :

$$(f \oplus B)(x, y) = \vee_{(s,t) \in Z^2(B)} f(x - s, y - t), \text{ avec } (x, y) \in Z^2 \quad (2.19)$$

La dilatation aura pour effet d'élargir les zones claires par rapport aux zones sombres de l'image. L'érosion aura l'effet inverse.

À partir de ces deux opérateurs, on peut construire les opérateurs d'ouverture et de fermeture. L'ouverture est l'application d'une érosion suivie d'une dilatation, la fermeture est l'application d'une dilatation suivie d'une érosion. Ainsi, en utilisant les mêmes notations, les opérateurs d'ouverture et de fermeture sont respectivement définis formellement de la façon suivante :

$$\begin{aligned} (f \circ B)(x, y) &= [(f \otimes B) \oplus B](x, y) \\ (f \bullet B)(x, y) &= [(f \oplus B) \otimes B](x, y), (x, y) \in Z^2 \end{aligned} \quad (2.20)$$

Le but de la fermeture sera de supprimer les parties sombres de l'image trop petites pour pouvoir y insérer l'élément structurant B . Dualement, l'application d'une ouverture permettra de supprimer les parties claires trop petites pour contenir l'élément structurant. Par principe, ces opérateurs altèrent les contours de l'image.

Profil morphologique Le concept de profil morphologique est relié aux opérateurs d'ouverture et de fermeture par reconstruction. Pour un élément structurant donné, l'effet de ces opérateurs est lié à la taille ou à la forme des objets présents dans l'image. Les objets plus petits que l'élément structurant sont supprimés, tandis que ceux qui sont plus grands sont conservés. Toutefois, contrairement au cas des outils morphologiques classiques, les contours principaux ne sont pas altérés. Ces propriétés ont conduit Peraseri et Benediktsson [Peraseri and Benediktsson, 2001] à proposer le concept de profil morphologique dans le cadre de la caractérisation de structures urbaines dans des images satellitaire haute résolution.

Un profil morphologique (PM) est composé d'un profil d'ouverture (PO) i.e. un ensemble d'ouvertures par reconstruction utilisant des éléments structurants de taille variable et croissante et d'un profil de fermeture (PF) obtenu par l'opération duale. Il attribue à chaque pixel

(x, y) un ensemble de valeurs définis par $PM(x, y) = \{PF_k(x, y), \dots, f(x, y), \dots, PO_k(x, y)\}$ qui caractérise son appartenance à une région de taille plus ou moins étendue. Dans leurs travaux, Pesaresi et Benediktsson utilisent les profils morphologiques obtenus comme points d'entrée à un classifieur type réseau de neurone ou une machine à vecteurs supports permettant alors d'identifier certains types d'objets (routes, immeuble,...).

Extension des outils morphologiques au cas hyperspectral L'extension des outils morphologiques scalaires au cas multidimensionnel n'est pas immédiat. Une approche simple, appelée approche marginale, consiste à appliquer les techniques de morphologie mathématique scalaires sur chacune des bandes spectrales et à fusionner les résultats obtenus. Cette technique n'est cependant pas très séduisante. Une autre approche est de considérer une méthode vectorielle en traitant chaque pixel comme un vecteur. Il est alors nécessaire pour définir des opérateurs morphologiques multivariés de définir une relation d'ordre vectoriel, permettant la détermination du vecteur maximum et minimum parmi un ensemble de vecteurs $S = s_1, s_2, \dots, s_n$, avec n nombre de vecteurs.

Ainsi, afin de définir des opérateurs morphologiques d'ouverture et de fermeture hyperspectraux, Plaza ([Plaza, 2007a]) définit une distance cumulative $D_B[f(x, y)]$, entre un pixel $f(x, y)$ (où $f(x, y)$ est un vecteur à N dimensions à la coordonnée spatiale $(x, y) \in Z^2$) et tous les pixels situés dans le voisinage B :

$$D_B[f(x, y)] = \sum_s \sum_t Dist[f(x, y), f(s, t)], \forall (s, t) \in Z^2(B) \quad (2.21)$$

$Dist$ étant une distance entre deux vecteurs de dimension N . On peut sélectionner s_p tel que $D_B[s_p]$ soit le minimum de l'ensemble S , avec $1 \leq p \leq n$. De la même façon, on peut sélectionner s_k tel que $D_B[s_k]$ est le maximum de l'ensemble S , avec $1 \leq k \leq n$. Plaza définit ainsi les opérateurs morphologiques d'érosion $(f \ominus B)(x, y)$ et de dilation $(f \oplus B)(x, y)$ étendus de la façon suivante :

$$\begin{aligned} (f \ominus B)(x, y) &= argmin_{(s,t) \in Z^2 B} D_B[f(x + s, y + t)], (x, y) \in Z^2 \\ (f \oplus B)(x, y) &= argmax_{(s,t) \in Z^2 B} D_B[f(x + s, y + t)], (x, y) \in Z^2 \end{aligned} \quad (2.22)$$

Dans ces équations, l'opérateur *argmin* sélectionnera ainsi le pixel qui sera le plus hautement similaire aux autres vecteurs du voisinage B , en accord avec la distance $Dist$. L'opérateur *argmax* sélectionnera le pixel qui sera le plus différent des vecteurs du voisinage B . La distance choisie $Dist$ doit exprimer la relation d'ordre choisie en terme de similarité spectrale. Plaza utilise l'angle spectral ou SAM (spectral angle mapper) bien connue dans le domaine de l'imagerie hyperspectrale par son invariance aux effets de facteur d'échelle produit entre autres par des conditions d'illumination variables. Une ambiguïté importante, soulignée par Plaza, est due au fait que l'ordonnement proposé n'a pas la propriété d'injectivité. De fait, deux ou plusieurs vecteurs différents pourront avoir la même valeur minimale ou maximale. Une solution proposée pour pallier ce problème est l'utilisation d'un parcours de l'espace par exemple en utilisant les courbes de Peano mais cette approche n'est pas satisfaisante car l'ordre total ainsi créé n'a aucune réalité physique. Plaza [Plaza, 2007a] pense que la sélection d'une unique composante principale supprime de l'information utile pour la discrimination de différents matériaux et préfère utiliser une méthode de réduction de l'espace type PCA ou MNF en gardant un nombre suffisant de composantes. Il propose alors d'ordonner les vecteurs dans le nouvel espace ainsi construit en utilisant soit un D-ordre, soit un R-ordre sur les centres. Le D-ordre consiste simplement à utiliser la distance cumulative D_B sur le nouvel espace. Le R-ordre sur les centres, consiste à ordonner deux pixels $g(x', y')$ et $g(x'', y'')$ selon leur similarité spectrale (SAM ou SAD) avec la valeur moyenne du voisinage K dans le nouvel espace réduit. Les opérateurs morphologiques ainsi formulés pourront être utilisés, comme nous le verrons plus loin, dans le cadre de la définition d'un algorithme de partage des eaux étendu au cas des IHS.

De la même manière, l'extension de la notion de profils morphologiques au cas hyperspectral peut être réalisée soit par la construction d'un ordre vectoriel (marginal, conditionnel, partiel ou réduit) soit en faisant appel à des approches de réduction de données permettant d'obtenir une seule ou un nombre limité d'images à partir des composantes principales. La première approche est bien évidemment la plus satisfaisante mais de nombreuses difficultés conceptuelles persistent. La deuxième solution est celle finalement adoptée par de nombreux auteurs et abou-

tit à la définition du Profil Morphologique Étendu (PME). Ainsi Palmason et ses co-auteurs [Palmason et al., 2003] ou encore Dell'Acqua et ses co-auteurs [Dell'Acqua et al., 2004] utilisent une analyse en composantes principales (ACP) et ne conservent que la première composante principale. Benediktsson et ses co-auteurs ([Benediktsson et al., 2005]) proposent d'utiliser deux composantes principales et construisent ainsi un profil morphologique étendu (combinaison des profils morphologiques obtenus sur chacune des composantes principales). Cette dernière approche est également utilisée par Fauvel [Fauvel, 2007].

2.2.3.2 Ligne de partage des eaux (LPE) ou watershed

La ligne de partage des eaux est un outil de la morphologie mathématique largement utilisé dans le cadre de la segmentation d'images scalaires et a été initialement proposé par Beucher et Lantuejour [Beucher and Lantuejour, 1979] qui utilise une analogie topologique. Une implémentation courante consiste à l'appliquer sur la norme du gradient afin que les lignes de partage des eaux correspondent à des crêtes de gradient. L'image de la norme du gradient est alors assimilée à une surface topologique (les contours des objets sont alors les lignes de crêtes) et l'algorithme simule une montée des eaux depuis les minima locaux permettant de constituer des bassins versants. Lorsque deux bassins versants risquent de se rencontrer, un barrage de hauteur infinie est construit sur la ligne de crête correspondant à la jointure des deux bassins. Ces barrages constituent les contours finaux de la segmentation.

L'extension de ce principe aux images hyperspectrales n'est là aussi pas immédiate. Li [Li and Xiao, 2007] propose une extension de l'algorithme de partage des eaux au cas multispectral en utilisant les opérateurs de dilatation et d'érosion multidimensionnels définis par Plaza et ses co-auteurs [Plaza et al., 2002, Plaza, 2007a] (voir section 2.2.3.1) définis sur un R-ordre sur les centres et la distance euclidienne comme valeur de similarité spectrale. Afin d'obtenir une image de gradient multidimensionnel scalaire, il utilise la notion de gradient morphologique définie par Rivest et ses co-auteurs [Rivest et al., 1993] dans le cadre de l'image scalaire comme la différence arithmétique entre une image dilatée et la même image érodée par le même élé-

ment structurant (voir equation 2.23). Les opérations d'érosion et de dilatation scalaires sont alors remplacées par les opérations de dilatation et d'érosion multidimensionnelles proposées par Plaza. Le gradient multidimensionnel scalaire G_M est alors obtenu par l'expression 2.24 où $dist$ est la distance euclidienne. Un algorithme classique de ligne par partage des eaux par immersion est alors appliqué sur ce gradient.

$$G(f(x, y) = (f \oplus B)(x, y) - (f \otimes B)(x, y)) \quad (2.23)$$

$$G_M(f(x, y) = dist((f \oplus B)(x, y) - (f \otimes B)(x, y))) \quad (2.24)$$

Noyel [Noyel et al., 2007] propose également d'étendre la ligne de partage des eaux aux IHS en construisant l'image gradient de l'image hyperspectrale par différentes approches. Ayant noté que de fortes redondances de données existent, il propose de réaliser une étape préalable de réduction de données par deux processus. Le premier consiste en une analyse factorielle en correspondance (AFC), le deuxième en une approche dite modèle. Les images résultantes obtenus après réduction de données (image filtrée ou projection des données initiales sur les facteurs principaux de l'AFC, images construites sur l'évaluation des paramètres d'un modèle linéaire pour chaque pixel) sont le point d'entrée du calcul de divers gradients multidimensionnels :

- gradient morphologique (équation (2.23)) sur chaque bande spectrale (approche scalaire),
- gradient construit sur une distance i.e. distance euclidienne, distance de Mahalanobis, distance chi-squared (approche vectorielle),
- gradient maximum des gradients morphologiques obtenus sur chaque bande spectrale (approche marginale),
- gradient somme pondérée des gradients morphologiques sur chaque bande spectrale (approche vectorielle),

Il est à noter, qu'afin de limiter les phénomènes de sur-segmentation inhérents à l'algorithme LPE, l'auteur réalise une étape préalable de sélection de marqueurs en utilisant une approche type K-means. Ces diverses méthodologies sont appliquées sur des images hyperspectrales de thermographie active (60 longueurs d'ondes) dans le but de détecter des occlusions de colles sur

des couvercles plastiques. Les résultats de segmentation montrent que l'étape de réduction de données apparaît fortement souhaitable et que les gradients morphologiques vectoriels aboutissent à de meilleurs résultats de segmentation.

Enfin, sur cette même thématique, des travaux récents ont été réalisés par Tarabalka et ses co-auteurs [Tarabalka et al., 2008]. Cette fois, le gradient morphologique multidimensionnel scalaire est construit à l'aide d'une approche appelée gradient morphologique couleur et proposée par Evans et Liu [Evans and Liu, 2006]. Dans ce cas, afin de lutter contre la sur-segmentation, les auteurs réalisent avant l'application d'une procédure standard LPE (algorithme de Vincent et Soille [Vincent and Soille, 1991]) une étape préalable de filtrage de l'image gradient à l'aide de filtres d'aires ou de transformations morphologiques. Les résultats de la segmentation sont alors classifiés en utilisant une approche SVM.

D'autres auteurs se sont penchés sur l'extension de l'algorithme LPE au cas multidimensionnel. Parmi ceux ci, on peut citer [Soille, 1996], [Scheunders, 2001] ou encore [Plaza, 2007a].

2.3 Conclusion

Le tableau 2.3 rassemble les caractéristiques de l'ensemble des approches évoquées dans les sections précédentes en vue de traiter les images hyperspectrales en prenant en compte les dimensions spectrale et spatiale des données. Nous reprenons brièvement ces caractéristiques ci-dessous et les commentons :

Les approches SVM, parce qu'elles permettent de prendre en compte de façon naturelle la dimensionnalité des données sans se heurter au phénomène de Hughes, apparaissent particulièrement séduisantes. Par contre, l'introduction d'une contrainte spatiale au travers la définition du noyau ne permet pas de maîtriser parfaitement la notion spatiale. Ainsi, seule l'approche développée par Fauvel [Fauvel, 2007] et utilisant les filtres d'aires permet de l'appréhender de façon plus large et surtout de façon adaptative (i.e. le voisinage n'est pas fixe). Les SVM sont toutefois des approches supervisées qui nécessitent de choisir les exemples d'apprentissage certes en nombre limité mais de façon très rigoureuse.

Les approches de classification ou de segmentation par champs de Markov sont encore handi-

capées par leur lourdeur algorithmique. Par ailleurs, la notion spatiale est limitée au voisinage immédiat de chaque pixel. C'est le cas également pour l'approche par C-moyenne floues qui, néanmoins, est bien adaptée à la séparation de groupes de données de taille et de forme comparables. En revanche, ce sont toutes deux des méthodes de classification qui permettent des implémentations non supervisées.

Les approches par extension des méthodes de segmentation d'images scalaires ou couleur au cas des IHS, par leur définition même, permettent d'appréhender des notions spatiales plus larges et à l'échelle de l'objet. De ce fait, elles apparaissent bien adaptées à nos contraintes. Par ailleurs, ce sont des approches non supervisées. Les méthodes de division ou de fusion de région nécessitent la définition d'une métrique permettant de mesurer une similarité inter-pixel ou inter-région. Elles peuvent évoluer sur l'espace support initial ou sur un espace réduit. Dans le premier cas cependant, elles aboutissent à des approches lourdes en temps de calcul qui nécessitent la mise en oeuvre d'implémentations alternatives utilisant en particulier des algorithmes séquentiels (approche de Tilton par exemple) et sont par ailleurs soumises à l'effet de Hughes.

L'extension des approches morphologiques scalaires au cas multidimensionnel n'est pas aisée. Particulièrement, la définition d'un ordre vectoriel est un pré-requis indispensable. Des voies de recherches ont été envisagées mais des difficultés conceptuelles persistent. Ainsi, la solution communément adoptée est la réalisation d'une étape préalable de données via, par exemple, une ACP. Les approches morphologiques scalaires sont alors appliquées sur la première composante.

Cet état de l'art nous amène à plusieurs remarques importantes. Les premières concernent l'étape de réduction de données. Un point de vue que nous partageons avec de nombreux auteurs est que la réduction de l'espace support, du fait des particularités des espaces de grande dimension et des fortes corrélations inter-bande, apparaît tout à fait légitime voire même indispensable. Cependant, nous constatons que cette étape est réalisée, dans la majorité des cas, sans réellement se soucier des traitements ultérieurs en particulier des objectifs de traitement des données (i.e. extraction de structure spatiale dans notre cas). Or, il nous semble, que dans une démarche de segmentation d'image hyperspectrale, elle doit s'effectuer en intégrant un critère d'information

spatiale permettant de faciliter et d'optimiser la tâche du processus de traitement ultérieur. Ce point est d'ailleurs souligné de façon générique par Lennon [Lennon, 2002] et plus précisément par Rellier [Rellier, 2002] qui effectue, préalablement à une classification utilisant des champs de Markov Gaussiens multivariés, une étape de réduction de données à l'aide d'un algorithme de poursuite de projection avec un indice de projection adapté à une modélisation gaussienne.

La remarque suivante concerne, d'une manière plus générale, les approches que nous avons évoquées dans ce chapitre. Nous constatons que les diverses méthodes présentées privilégient un espace par rapport à l'autre. Ainsi, les méthodes de classifications telles que les SVM ou les C-Moyennes Floues favoriseront par nature l'espace spectral, alors que les méthodes de segmentation étendues ou les Champs de Markov favoriseront l'espace spatial. Il nous semble ainsi important de rétablir une certaine équité de traitement entre les deux espaces de façon à pleinement prendre en compte l'information qui y est présente et surtout de sa très certaine complémentarité.

Ces remarques nous permettent d'orienter notre démarche vers la proposition d'une méthode originale de segmentation d'images hyperspectrales. Ainsi, il nous semble que les approches de segmentation d'images scalaires étendues au cas multidimensionnel sont plus adaptées par nature à traiter la dimension spatiale des données. Ce sont en effet des méthodes spécialisées pour traiter ce type d'information et donc optimales dans ce cas. Elles permettront de ce fait, d'appréhender des configurations spatiales plus complexes. En revanche, la réduction de l'espace support nous semble également indispensable mais doit s'effectuer en intégrant un critère d'information spatiale permettant de faciliter et d'optimiser la tâche du processus de traitement ultérieur. Une approche pour y parvenir et établissant du même coup une équité de traitement entre espace spectral et spatial, est de mettre en place un schéma de collaboration entre processus de réduction de données et processus de segmentation chacun étant dépendant l'un de l'autre dans sa progression. L'approche présentée dans le chapitre suivant se propose de suivre ce schéma de principe.

Approche	Nature de l'algorithme	Avantages	Difficultés
C-moyennes Floues	Classification non Supervisée	Facilité d'implémentation	Notion de voisinage limitée
SVM	Classification supervisée	Prise en compte de l'effet de Hughes Peu d'échantillons d'apprentissage	Choix pertinent des échantillons Difficultés de réglage
Champs de Markov	Classification segmentation non supervisée	Prise en compte directe des notions spatiales et vectorielle	Difficultés d'implémentation Lourdeur algorithmique
Outils segmentation régions	Segmentation non supervisée	Facilité d'implémentation	Définir une métrique de similarité Lourdeur algorithmique
Morphologie Mathématique	Aide à la classification Extraction de composantes pures (EndMember)	Bien adaptée aux zones urbaines	Lourdeur algorithmique Structures d'objets particulières

FIG. 2.4 – Principales caractéristiques des techniques spectro-spatiales évoquées dans ce chapitre

Chapitre 3

Proposition scientifique

L'objectif de ce chapitre est de proposer une approche originale permettant la segmentation non supervisée d'une IHS. Pour cela, nous donnons dans un premier temps une définition de la segmentation d'une image et des difficultés inhérentes à ce processus dans le cadre d'un espace de grande dimension (phénomène de Hughes). Pour pallier ces difficultés, nous proposons par la suite un schéma générique appelé papillon et permettant de faire collaborer de façon équilibrée et symétrique le processus de réduction de l'espace spectral et de segmentation de l'espace spatial. L'approche proposée est générique. On propose en fin de chapitre une implémentation formelle du principe proposé.

Sommaire

3.1	Notations	54
3.2	Segmentation non supervisée d'une IHS : définition et problématique	55
3.3	Proposition	60
3.3.1	Extraction de structures spatiale et spectrale	60
3.3.1.1	Structure spatiale	60
3.3.1.2	Structure spectrale	61
3.3.2	Outils spectraux et spatiaux	62
3.3.2.1	Les outils spatiaux	62
3.3.2.2	Les outils spectraux	63
3.3.3	Coopération entre outils spatiaux et spectraux	65

3.3.4	Schéma définitif du papillon	66
3.4	Implémentation retenue	68
3.4.1	Principes généraux et préconisations	68
3.4.1.1	Dimension des espaces à retenir	68
3.4.1.2	Choix du nombre de divisions à réaliser pour une étape	70
3.4.1.3	Choix du nombre de fusions à réaliser pour une étape	71
3.4.1.4	Paramètres d'arrêt et de choix de meilleure partition	71
3.4.1.5	Choix du scénario de segmentation	71
3.4.2	Algorithmes	71
	Algorithme de division	72
	Algorithme de fusion	72

3.1 Notations

Les lettres majuscules grasses sont employées pour désigner des matrices, p.e. \mathbf{Z} . En cas de besoin, la dimension des matrices peut être indiquée par un indice multiple entre parenthèses, p.e. $\mathbf{Z}_{(n,p)}$ indique que la matrice \mathbf{Z} a n lignes et p colonnes. Tant que le contexte sera suffisamment clair pour éviter toute confusion, les matrices à 2 et 3 dimensions ne seront pas différenciées par une notation particulière. Les lettres minuscules grasses désignent des vecteurs colonnes, p.e. \mathbf{z}_j désigne la $j^{\text{ème}}$ colonne de \mathbf{Z} ; les vecteurs lignes sont désignés par l'opérateur de transposition, p.e. \mathbf{z}_i^T désigne la $i^{\text{ème}}$ ligne de \mathbf{Z} ; les lettres minuscules non grasses désignent des scalaires, p.e. des éléments de matrice z_{ij} ou des indices i .

Lorsque l'aspect spatial est privilégié, une image hyperspectrale est vue comme une fonction de \mathbb{R}^2 dans \mathbb{R}^p qui, à un point de coordonnées (x, y) associe un spectre $\mathbf{s}(x, y)$, vecteur de signaux mesurés à p longueurs d'onde. Lorsque l'on s'intéresse à sa topologie, l'image est vue comme un ensemble rectangulaire de $n \times m$ points, muni d'une partition \mathcal{P} de k régions connexes.

Lorsque l'aspect spectral est privilégié, une image hyperspectrale est une matrice 3D notée $\mathbf{Z}_{(n,m,p)}$, où n est le nombre de lignes et m le nombre de colonnes de l'image et p le nombre de longueurs d'onde mesurées. Pour des raisons calculatoires, cette image pourra être dépliée

(indifféremment en lignes ou en colonnes), pour devenir une matrice 2D, $(n \times m, p)$ $n \times m$ spectres par p longueurs d'onde. À toute partition \mathcal{P} d'une image on associe une matrice d'appartenance $\mathbf{Q}_{(n \times m, k)}$ qui contient, pour chaque pixel, les k degrés d'appartenance binaires aux k régions (codage disjonctif).

Soit \mathbf{Z} une image hyperspectrale, munie d'une partition \mathcal{P} . Soit $\bar{\mathbf{z}}$ le spectre moyen de l'image, et $\bar{\mathbf{Z}}$ l'image de même taille que \mathbf{Z} , dont tous les pixels valent $\bar{\mathbf{z}}$. Soit $\tilde{\mathbf{Z}}$ la matrice obtenue après centrage de \mathbf{Z} , i.e. $\tilde{\mathbf{Z}} = \mathbf{Z} - \bar{\mathbf{Z}}$. La matrice d'inertie totale de l'image est définie par : $\mathbf{T} = \tilde{\mathbf{Z}}^T \tilde{\mathbf{Z}}$, la matrice d'inertie inter classes est donnée par $\mathbf{B} = \tilde{\mathbf{Z}}^T \mathbf{Q} (\mathbf{Q}^T \mathbf{Q})^{-1} \mathbf{Q}^T \tilde{\mathbf{Z}}$ et la matrice d'inertie intra classes est donnée par $\mathbf{W} = \mathbf{T} - \mathbf{B}$. Dans la suite du chapitre et à des fins de clarté de l'exposé la notion d'inertie et de variance seront assimilées. Le Lambda de Wilks ([Wilks, 1960]) est défini par : $\Lambda(\mathbf{Z}, \mathcal{P}) = \text{trace}(\mathbf{B}) / \text{trace}(\mathbf{T})$. Cet indice varie entre 0 et 1 et mesure, de manière croissante, la séparation des régions dans l'espace spectral.

3.2 Segmentation non supervisée d'une IHS : définition et problématique

Soit une image hyperspectrale Z , l'objectif est d'obtenir une segmentation de cette image en régions où une région est un ensemble de pixels connexes partageant des propriétés communes. Une définition formelle de la segmentation d'image a été donnée par Horowitz et Pavlidis [Horowitz and Pavlidis, 1974] : Si nous définissons un prédicat P_r , la segmentation de Z est définie comme une partition de Z en k sous-ensembles $R_1 \dots R_k$ tels que :

$$Z = \bigcup R_i, i \in [1 \dots k] \quad (3.1)$$

$$\forall i \in [1 \dots k], R_i \text{ est connexe} \quad (3.2)$$

$$\forall i \in [1 \dots k], P_r(R_i) \text{ est vrai} \quad (3.3)$$

$$\forall i, j \in [1 \dots k]^2 / R_i \text{ est adjacent à } R_j \text{ et } i \neq j \Rightarrow P_r(R_i \cup R_j) = \text{faux} \quad (3.4)$$

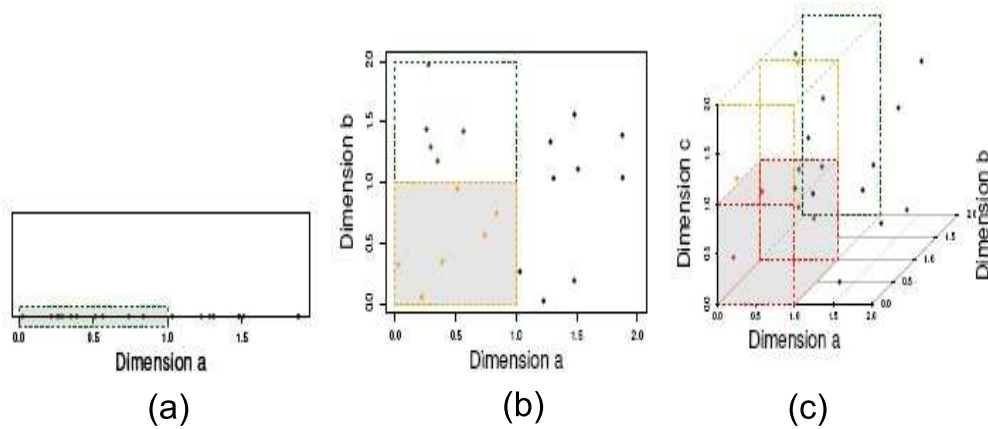
où \cup représente une union d'ensemble disjoints

Le prédicat P_r est utilisé pour tester l'homogénéité des ensembles R_i vis à vis d'une caractéristique donnée par exemple la radiométrie ou encore la texture.

L'opération de segmentation consiste donc à rassembler les données en ensembles de pixels connexes partageant des propriétés communes respectivement à une mesure de distance ou de similarité au travers le prédicat P_r . Si le calcul de ces distances ou similarités est relativement simple à réaliser dans un espace de faible dimension, il est mal adapté à la grande dimensionnalité des données hyperspectrales. On se heurte aux propriétés des espaces à grande dimension et en particulier au fléau ou malédiction de la dimension, appelé phénomène de Hughes [Hughes, 1968, Bellman, 1957] (Curse of dimensionality). Ce phénomène fait référence au fait que le nombre d'échantillons nécessaire à l'estimation d'une fonction de plusieurs variables croît exponentiellement avec le nombre de bandes (estimation des paramètres d'un modèle statistique paramétrique par exemple). Il est en partie dû au phénomène dit de l'espace vide : à mesure que le nombre de dimensions dans un ensemble de données augmente, les mesures de distance ou des similarités ont de moins en moins de signification rendant caduque l'utilisation des algorithmes de classification classiquement utilisés en faible dimension. En effet, la différence relative entre les « courtes » et les « grandes » distances se réduit rapidement pour tendre vers 0 lorsque la dimension de l'espace augmente [Parsons et al., 2004, Beyer et al., 1994]. Ce phénomène est illustré par la figure 3.1 empruntée à Parsons [Parsons et al., 2004].

Une autre approche pour bien "visualiser" cette notion d'espace vide est de calculer la complexité de la mesure C définie en mathématique comme étant le nombre total de valeurs discrètes dans l'espace support (espace d'origine), c'est à dire le nombre de valeurs distinctes que peut prendre une variable dans cet espace ⁴. Ainsi, comme le montre Lennon [Lennon, 2002], la valeur de la complexité de la mesure pour une image hyperspectrale est très élevée comparée à celles d'une image scalaire ou couleur (voir tableau 3.1). La complexité de la mesure est à comparer avec les dimensions spatiales des images, c'est à dire le nombre total de pixels $m \times n$. Pour une

⁴On a ainsi $C = Dyn^{dim}$, avec D_{yn} dynamique des données scalaires dans chaque dimension et dim dimension de l'espace



Le jeu de données est composé de 20 individus dont les coordonnées x, y, z ont été tirées aléatoirement (avec x, y ou $z \in [0 - 2]$). La figure (a) montre les données projetées dans un espace 1D. Les individus sont très proches les uns des autres et la moitié d'entre eux sont situés dans l'intervalle $[0 - 1]$. La figure (b) montre les données étendues dans un espace 2D. Les individus sont nettement plus éloignés les uns des autres et désormais, seulement 1/4 d'entre eux sont situés dans le domaine $([0 - 1][0 - 1])$. Dans l'espace de dimension 3D, les individus sont encore plus éloignés les uns des autres et désormais seulement 1/8 se situent dans le cube unité.

FIG. 3.1 – Éparpillement des données

image scalaire par exemple de taille 1024×1024 , cette comparaison montre qu'il est possible d'échantillonner l'espace des possibles avec une seule image. Pour une image hyperspectrale de même taille ce n'est pas le cas (pour une image hyperspectrale comportant 224 canaux spectraux, il faudrait pour cela une image de taille $10^{540} \times 10^{540}$ pixels!). Ceci montre que l'espace vectoriel

image	(D_{yn})	dim	C
image binaire	8 bits	1	$C = 256 \approx 10^{2.4}$
image couleur	8 bits	3	$C = 2^{24} \approx 10^{7.2}$
IHS	16 bits	224	$C = (2^{16})^{224} \approx 10^{1079}$

TAB. 3.1 – Comparaison de la complexité de la mesure pour des images binaires, couleur (dynamique 8 bits) et hyperspectrale (dynamique 16 bits) (d’après [Lennon, 2002])

support d’une image hyperspectrale est quasiment vide et que la probabilité d’occurrence d’une valeur est quasiment nulle. Cette caractéristique induit une complexité de traitement que les méthodes classiques de partitionnement ne sont pas capables d’appréhender.

Pour faire face à ce phénomène, une approche largement usitée consiste à réaliser une réduction de la dimension. Le but de cette réduction est de projeter les données originelles dans un espace de dimension réduite en préservant l’information, en la mettant en évidence, en la dissociant du bruit et possiblement en révélant une structure sous jacente qui ne serait pas immédiatement apparente dans les données d’origine [Vincent, 2001, Lennon, 2002]. La nature des données sous entend l’existence d’une dimension intrinsèque i.e. une dimension inférieure à celle de l’espace support (nombre de bandes spectrales) permettant d’expliquer toutefois la totalité de l’information présente. Physiquement, cette notion de dimension intrinsèque peut être reliée au nombre de composés chimiques purs présents dans la scène, nombre forcément limité. Par ailleurs, mathématiquement, de nombreuses méthodes de classification nécessitent l’inversion de la matrice de variance-covariance des données (\mathbf{T}). Même si cette dernière apparaît bien dimensionnée ($n > p$)⁵, les variables étant fortement corrélées (figure 3.2), on obtient un problème dit mal conditionné qui implique une inversion instable et donc aboutira à un modèle discriminatif très incertain. Pour toutes les raisons évoquées ci-dessus, la réduction de l’espace support apparaît nécessaire.

Ainsi, de nombreuses méthodes de réduction, linéaires ou non, ont été développées. Or, la

⁵Dans le cas contraire, les estimations de ces matrices seront singulières et leur inversion sera numériquement impossible (les $p - n + 1$ plus petites valeurs propres seront estimées par 0).




FIG. 3.2 – Exemple de corrélation inter-bandes pour des spectres obtenus sur des pommes

majorité d'entre elles réalisent cette réduction de données en tenant compte uniquement de l'information spectrale. L'information spatiale, lorsqu'elle est prise en compte, n'est utilisée que *a posteriori*, dans un processus complémentaire de traitement de données (classification, segmentation).

La prise en compte de l'information spatiale lors du traitement de l'image IHS est primordiale et permettra sans aucun doute d'améliorer considérablement les résultats d'une classification ([Fauvel, 2007], [Plaza, 2007b]). Par ailleurs, il apparaît judicieux de prendre en compte cette information précocement dans le processus de traitement afin qu'elle y participe pleinement.

Afin de pallier le phénomène de Hughes et d'utiliser toute l'information disponible (spectrale, spatiale) et ce au plus tôt dans le processus de traitement, nous proposons une approche liant de façon symétrique et équilibrée le processus de réduction de l'espace et celui de la segmentation de l'image hyperspectrale.

La section suivante est dédiée à la description de cette approche.

3.3 Proposition

Le principe de l'approche proposée repose sur un processus itératif qui a pour objectif d'extraire, à chaque pas, une structure spectrale prenant en compte une structure spatiale et réciproquement une structure spatiale prenant en compte une structure spectrale. Les deux structures extraites sont ainsi raffinées peu à peu au fil des itérations pour aboutir à une segmentation finale de l'IHS. Ce procédé d'association entre les deux espaces via le processus itératif doit permettre en définitive de résoudre la complexité initiale due à la dimensionnalité des données. Le principe générique de cette approche est donné par le schéma nommé "*papillon*" représenté figure 3.3.

Pour mettre en œuvre ce processus, nous proposons de nous intéresser séparément aux deux espaces (spectral, spatial) et de les faire coopérer via des outils adaptés à l'espace dans lequel ils évoluent. Ce sont des outils chimiométriques pour l'espace spectral et des outils de segmentation d'images pour l'espace spatial.

La problématique initiale c'est à dire la segmentation d'une image hyperspectrale est alors découpée en deux sous problématiques à traiter à savoir (1) extraction d'une structure spatiale tenant compte d'une structure spectrale, (2) extraction d'une structure spectrale tenant compte d'une structure spatiale.

Il nous faut désormais préciser ce que nous entendons par structures spatiale et spectrale puis définir les outils qui nous permettront de réaliser la collaboration envisagée et ainsi de résoudre les deux problématiques énoncées précédemment.

3.3.1 Extraction de structures spatiale et spectrale

3.3.1.1 Structure spatiale

L'extraction de l'information spatiale consiste à révéler une structure spatiale des pixels i.e. un ensemble d'entités caractérisées par des attributs et permettant d'avoir accès à une certaine description de l'image au travers des notions topologiques. Ces notions sont toutefois diverses et parfois difficiles à appréhender [Bezerra, 2001, Couprie, 2004, Kong and Rosenfeld, 1989]. Dans

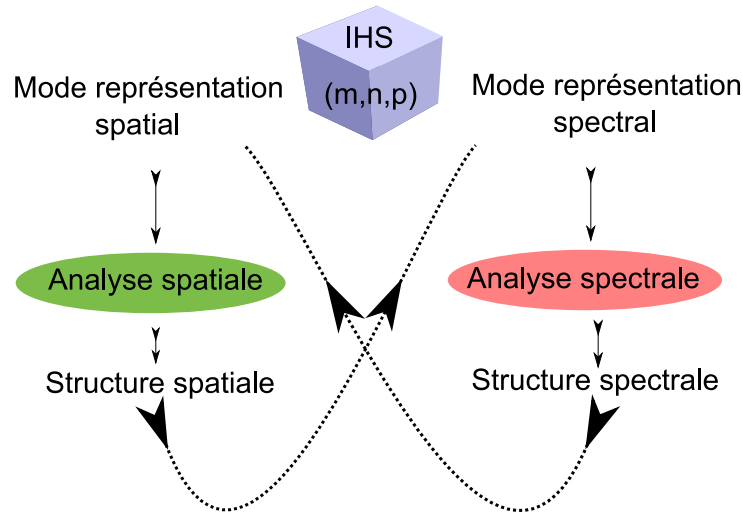


FIG. 3.3 – Notre approche : ébauche du processus

le cadre de cette thèse, nous nous limiterons aux notions topologiques permettant de décrire les relations entre les pixels de l'image au travers des propriétés de voisinage et d'adjacence aboutissant aux notions d'ensembles connexes ou régions.

3.3.1.2 Structure spectrale

L'extraction de l'information spectrale consiste à identifier une structure c'est à dire un ensemble de spectres communs à tous les pixels de l'image et définissant un sous espace vectoriel dont la dimension (l) est inférieure à celle de l'espace initial (p). Ces spectres n'ont pas toujours une signification physique et portent une dénomination différente suivant les approches chimiométriques utilisées pour les déterminer : spectres purs, variables latentes, composantes principales, lignes de base...

D'une manière générale et pour les approches linéaires, l'objectif est de déterminer un système de vecteurs \mathbf{K} tel que :

$$\mathbf{Z} = \mathbf{C}\mathbf{K}^T + \mathbf{R} \quad (3.5)$$

La matrice \mathbf{C} représente alors une décomposition de la matrice \mathbf{Z} sur le système de vecteurs

$\mathbf{K} = \{\mathbf{k}_1, \dots, \mathbf{k}_l\}$ et \mathbf{R} les résidus.

Dans le cadre de notre approche, ces vecteurs doivent nous permettre de caractériser les variations de la partition en cours ou plus précisément encore l'évolution des structures spatiales extraites à chaque pas du processus itératif. Le choix de l'approche d'extraction de structures spectrales devra donc prendre en compte cette composante.

3.3.2 Outils spectraux et spatiaux

Nous nous intéressons ici aux outils dédiés aux deux ailes du *papillon* i.e. à chacun des espaces à prendre en compte (outils chimiométriques pour l'espace spectral et outils de segmentation d'image pour l'espace spatial) permettant la réalisation du schéma de coopération évoqué précédemment.

3.3.2.1 Les outils spatiaux

La segmentation s'appuie sur des notions de différence et de similarité et ceci donne naissance à deux approches qualifiées d'approche frontière et d'approche région [Coquerez, 1995]. La notion de frontière est associée à une variation d'intensité ou à une discontinuité entre les propriétés de deux ensembles connexes de points. La notion de région fait référence à des regroupements de points ayant des propriétés communes. Les méthodes de l'approche région (ou méthodes de segmentation en région) aboutissent directement à une partition de l'image, chaque pixel étant affecté à une région unique. De ce fait, elles permettent d'avoir un accès direct à la notion topologique qui nous intéresse et apparaissent ainsi comme un outil de choix dans le cadre de notre démarche.

Les stratégies employées pour réaliser une segmentation en régions sont ascendantes ou descendantes suivant qu'elles exploitent des mécanismes de croissance ou de division de régions. Dans le premier cas, on parle de méthodes d'agrégation de pixels ou de croissance de régions, qui partant de la représentation de l'image comme un ensemble de pixels (sur-segmentation), les regroupe selon un double critère d'homogénéité et d'adjacence. Dans le deuxième cas, on parle de méthode de division. Le point de départ est une sous-segmentation, l'image entière étant considérée

comme une région à raffiner. Le principe est alors de découper successivement les régions non homogènes au sens d'un prédicat défini *a priori*.

Deux situations sont donc à envisager lors d'un processus de segmentation d'une IHS. La première est une situation de sous-segmentation initiale de l'image (à l'extrême, l'image est une région) et l'on va chercher à augmenter le nombre de régions initiales en divisant celles-ci en entités plus petites vérifiant un critère d'homogénéité et en augmentant de ce fait l'homogénéité intra-régions. La deuxième est une situation de sur-segmentation initiale de l'image (à l'extrême, chaque pixel de l'image est une région) et l'on va rechercher à diminuer le nombre de régions en rassemblant celles dont l'union permettra d'obtenir une région vérifiant un critère d'homogénéité tout en maintenant la variabilité inter-régions.

De nombreuses approches de segmentation en régions sont disponibles dans la littérature, qu'il s'agisse des approches de croissance de région (par exemple algorithme Union-Find proposé par Fiorio et ses co-auteurs [Fiorio and Gustedt, 1996]), des approches de division de régions (par exemple approche quadtree [Horowitz and Pavlidis, 1974]), des approches de partitionnement par graphe (par exemple algorithme des coupes minimales ou des coupes normalisées [Shi and Malik, 1997]) ou encore des approches utilisant les outils de la morphologie mathématique telle que la méthode de la ligne de partage des eaux (LPE ou watershed en anglais) [Vincent and Soille, 1991].

3.3.2.2 Les outils spectraux

L'extraction d'une structure spatiale, i.e. la mise en exergue d'un sous espace vectoriel formé d'un ensemble de vecteurs que nous nommerons désormais variables latentes peut être réalisée via de nombreuses techniques de réduction de données. Cependant, si nous souhaitons que cette structure spectrale soit également liée à une structuration spatiale des pixels, il est nécessaire qu'elle permette d'accéder à des propriétés pertinentes pour la partition en cours. Ainsi, compte tenu des éléments évoqués dans la section précédente (section 3.3.2.1) la notion de région doit faire partie intégrante du processus de détermination de la structure spectrale. Ce lien peut être

réalisé via les notions de variance intra et inter-régions. Il est donc nécessaire de faire appel à des méthodes de réduction d'espace utilisant ces notions.

Une approche *a priori* toute indiquée parce qu'elle s'intéresse directement à ces propriétés est l'analyse discriminante (AD). C'est une technique supervisée qui, connaissant \mathbf{Q} la matrice des degrés d'appartenance des individus de \mathbf{Z} aux classes, recherche un sous-espace maximisant les dissimilitudes entre classes, tout en réduisant les variations à l'intérieur des classes (séparation optimale des classes). Ce sous-espace est engendré par la matrice \mathbf{U} maximisant le critère suivant ([Lebart et al., 1984]) :

$$J(\mathbf{U}) = \frac{\|\mathbf{U}^T \mathbf{B} \mathbf{U}\|}{\|\mathbf{U}^T \mathbf{T} \mathbf{U}\|} \text{ où } \mathbf{B} \text{ et } \mathbf{T} \text{ ont été définies section 3.1} \quad (3.6)$$

Les solutions \mathbf{U} étant les vecteurs propres de $\mathbf{T}^{-1} \mathbf{B}$, l'application directe de cette approche n'est pas possible dans le cadre de nos applications. Elle nécessite en effet l'inversion de la matrice \mathbf{T} qui du fait de la forte corrélation des variables est à proscrire.

Une autre approche particulièrement simple est de s'intéresser aux matrices de variance intra et inter régions de la partition en cours. Ainsi, suivant le processus de segmentation engagé (sous-segmentation ou sur-segmentation initiale) la diagonalisation de l'une ou l'autre de ces matrices permettra la construction de variables latentes révélatrices des variations inter ou intra des régions de la partition en cours.

Il est également possible d'utiliser des techniques de réduction de données telles que l'Analyse en Composantes Indépendantes (ICA) [Hyvärinen, 1999] ou la résolution de courbes multivariées (Multivariate Curve Resolution ou MCR) [Tauler et al., 1991, Tauler et al., 1995] ou encore la régression moindres carrés discriminante (PLS-DA) [Roussel, 1998]. L'ICA, moyennant un recentrage préalable des régions, permettra d'accéder aux variations internes des régions de la partition en cours, et sera donc employée lors d'un processus de segmentation descendant (processus de division). La MCR pourra être également employée lors d'un processus de division. La PLS-DA permettra au contraire de construire des variables latentes permettant d'accéder aux variations inter-régions et sera de ce fait utilisée lors d'un processus de segmentation ascendant

(processus de fusion).

3.3.3 Coopération entre outils spatiaux et spectraux

Le processus de segmentation par division a pour objectif d'augmenter le nombre de régions en diminuant l'hétérogénéité intra-régions (\mathbf{W}). Le processus de segmentation par fusion a pour objectif de diminuer le nombre de régions (en supprimer) en préservant l'hétérogénéité inter-région (\mathbf{B}).

En transférant les notions de régions, d'homogénéité intra et inter régions (espace spatial) aux notions respectivement de classes, homogénéité intra et inter classes (espace spectral) on bascule, par simple franchissement d'une frontière sémantique, de l'espace spatial à l'espace spectral (figure 3.4). De la même façon, en faisant correspondre les notions de variables latentes aux notions de plans ou fausses couleurs, on parvient à passer de l'espace spectral à l'espace spatial.




FIG. 3.4 – Basculement sémantique : de l'espace spatial à l'espace spectral

On aboutit ainsi à une définition complète des chemins liant les deux espaces et ainsi du principe de collaboration envisagé par le processus itératif. Le schéma du *papillon* tel que nous l'avons exposé section 3.3 est ainsi en partie complété. La figure 3.5 donne un aperçu du schéma du *papillon* avec les éléments de coopération exposés.

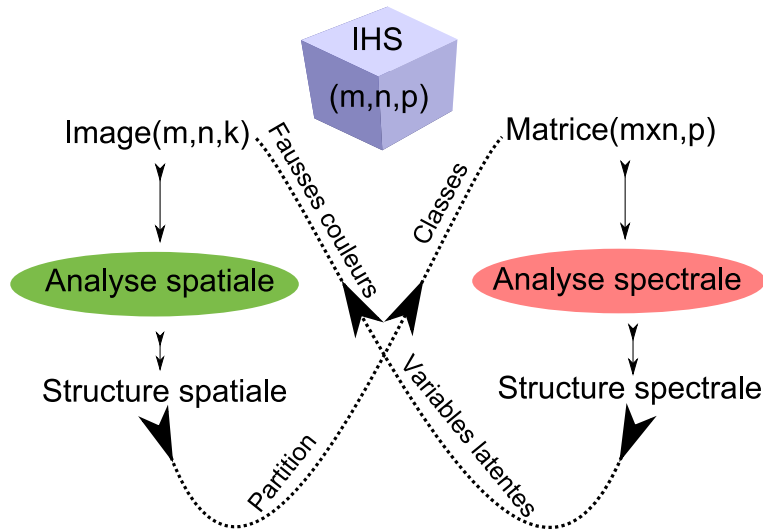
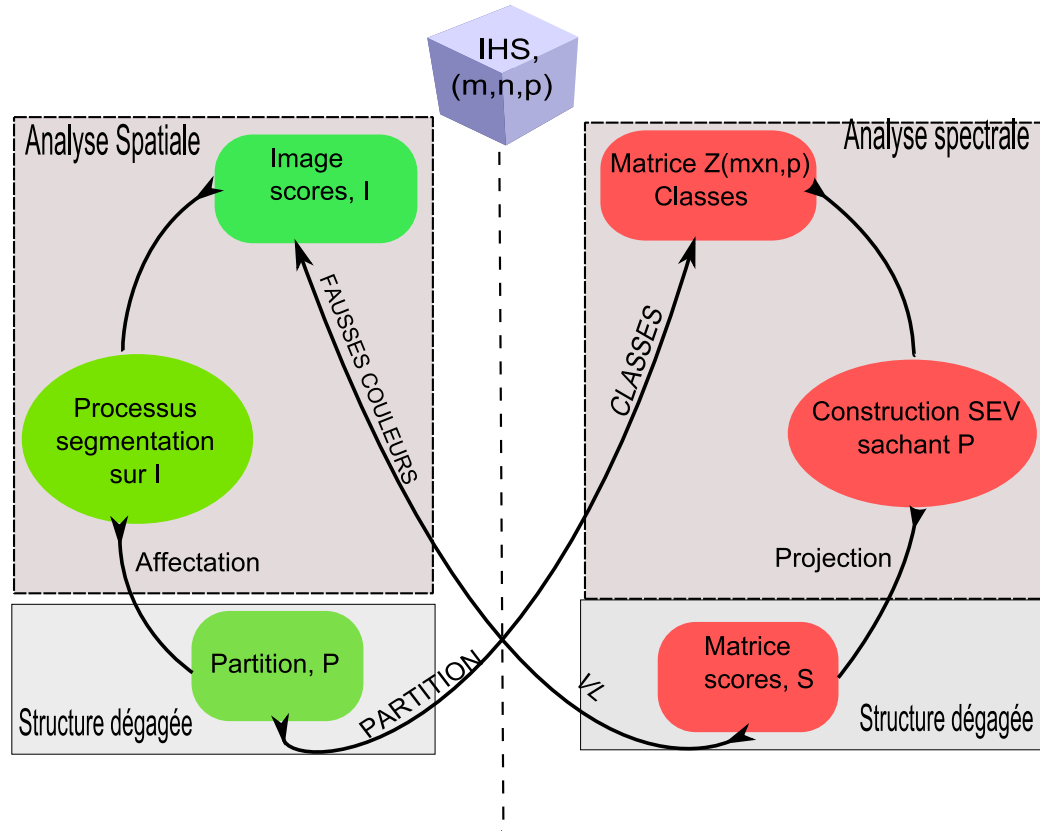


FIG. 3.5 – Le schéma du papillon amélioré

3.3.4 Schéma définitif du papillon

Les sections précédentes ont permis de proposer et de justifier une collaboration entre outils de segmentation et outils de réduction de l'espace via un processus itératif dont les fondements ont été posés. Ainsi, la combinaison spectro/spatiale proposée repose d'une part sur la construction de variables latentes dépendant de l'information topologique, et d'autre part sur la génération d'une topologie à partir de variables latentes. La notion d'information topologique est limitée à la notion de région. Pour permettre une réelle coopération entre les deux espaces, la notion de région (qui concerne l'espace spatial) est transposée à celle de classes (qui concerne l'espace spectral) et celle de variables latentes à celle de fausses couleurs (ou plans). Les étapes d'analyse spectrale et spatiale se déclinent alors sous la forme d'opérations unitaires simples décrites et représentées figure 3.6.

La méthode proposée est une approche générique. Les outils spectraux et spatiaux peuvent être adaptés en fonction du contenu ou de la complexité de l'IHS traitée ou encore du domaine applicatif. On obtient alors les deux processus de collaboration spectral-spatial représentés figure 3.7 en correspondance avec l'opération de segmentation envisagée (fusion, division). Cette figure présente pour chacune des opérations de base d'un processus de segmentation en régions (division,



Côté spectral, nous disposons d'une matrice de données $\mathbf{Z}_{(m \times n, p)}$, composée de $m \times n$ vecteurs de p dimensions. À cette matrice est associée une matrice d'appartenance $\mathbf{Q}_{(n \times m, r)}$ avec r nombre de régions. L'analyse spectrale a pour objectif de déterminer le meilleur sous espace descriptif de ces données en correspondance avec la matrice d'appartenance \mathbf{Q} . La projection des données dans ce sous espace vectoriel de dimension réduite permet d'obtenir une matrice de données projetée appelée matrice scores et notée \mathbf{S} . Cette matrice une fois repliée, pour former une image scores $I_{(m, n, l)}$ (avec l dimension du sous espace vectoriel ou nombre de variables latentes conservées avec $l \leq p$), est le point d'entrée de l'analyse spatiale. Côté spatial, l'analyse de l'image score I via un algorithme de segmentation d'image va permettre d'obtenir une nouvelle partition des données P qui sera par la suite utilisée par l'analyse spectrale.

FIG. 3.6 – Schéma complet de l'approche papillon : découpage des étapes d'analyse spatiale et spectrale sous la forme d'opérations unitaires simples et processus de coopération

fusion) les possibilités offertes telles qu'elles ont été évoquées dans ce chapitre.

3.4 Implémentation retenue

3.4.1 Principes généraux et préconisations

Quelle que soit l'implémentation choisie, i.e. quels que soient les outils de construction des variables latentes et de régions, certains principes généraux nécessitent d'être précisés. Dans certains cas, ces compléments permettront d'aboutir à des préconisations afin de satisfaire les fondements même du schéma du *papillon* ou encore de permettre un bon déroulement de celui-ci. Ainsi, dans cette section, nous allons nous intéresser successivement à la dimension de l'espace à retenir pour chaque processus de segmentation évoqué (division, fusion), au nombre de régions à créer à chaque pas du processus de division et au nombre de régions à fusionner lors du processus de fusion, aux paramètres d'arrêt et de choix de la meilleure partition et enfin aux divers scénarios de segmentation possibles.

3.4.1.1 Dimension des espaces à retenir

Il est important de remarquer que les processus de division et de fusion sont fondamentalement différents. Cela nécessite comme nous l'avons vu, de privilégier une méthode de réduction de données différente pour chacune de ces deux approches de segmentation. Cependant, dans chacun de ces processus de segmentation, la qualité de l'information recherchée est différente. Dans le cas du processus de division, on recherche un espace permettant de révéler au mieux les différences entre régions. Dans le cas du processus de fusion, au contraire, on recherche un espace permettant de révéler au mieux les similarités entre régions voisines pour fusionner celles qui se ressemblent le plus. On conçoit donc que la dimension de l'espace à retenir est différente.

Finalement, on peut arguer que dans le processus de division, on sera d'autant plus sûr que deux régions sont différentes que le nombre de variables latentes utilisé pour les décrire sera petit. Nous préconisons donc d'utiliser pour ce processus un sous espace vectoriel minimal c'est à dire limité à une variable latente. Cela permet d'une part de fixer un paramètre et d'utiliser des approches




FIG. 3.7 – Schéma du papillon lors d'une segmentation par division (haut) et par fusion (bas)

de segmentation régions dédiées aux images scalaires.

De la même façon, dans le processus de fusion, on sera d'autant plus sûr que deux régions sont similaires que le nombre de variables latentes utilisé pour les décrire sera grand (une analogie simple est celle du chameau et du dromadaire qui vus de face ne sont pas identifiables, il faudra une deuxième vue i.e. une vue de profil pour parvenir à les dicerner). Nous préconisons donc d'utiliser pour ce processus un sous espace vectoriel maximal c'est à dire de dimension égal au nombre de classes moins une. Cependant, dans le cas où le nombre de régions est important on se limitera à un nombre de variables latentes expliquant un taux de variance proche de 100%. Cette préconisation peut paraître antagoniste vis à vis de l'étape de réduction de données mais ces variables latentes décrivent au mieux la variabilité inter des régions et présentent également des propriétés d'orthogonalité ou d'indépendance (suivant la méthode de réduction choisie) qui permettent de l'appliquer.

Dans les deux cas, une ambiguïté ou une équivalence sera résolue par le processus itératif. Ainsi, par exemple dans le cas du processus de division, si une variable latente ne permet pas de statuer sur la division d'une région, celle-ci, si elle est opportune, sera reportée à une étape de division ultérieure avec le changement d'espace spectral. De même, dans le cas d'un processus de fusion, si un ensemble de variables latentes ne permet pas de statuer sur la fusion de deux régions, celle-ci si elle est opportune, sera réalisée ultérieurement dans un autre espace spectral.

3.4.1.2 Choix du nombre de divisions à réaliser pour une étape

Le choix du nombre de division à réaliser pour chaque étape est lié à l'algorithme de segmentation choisi. Cependant, afin de bien maîtriser le processus de partitionnement et de limiter les risques de sur-segmentation importante il est préférable de limiter le nombre de régions extraites à chaque pas du processus. Ainsi, nous préconisons de nous placer dans une approche minimale en choisissant un nombre coupes égal à 1 pour chaque étape du processus de division.

3.4.1.3 Choix du nombre de fusions à réaliser pour une étape

Le choix du nombre de fusions est dicté comme dans le cas précédant par le souci d'avancer progressivement et peu à peu vers la partition optimale. Ainsi, nous préconisons de fixer le nombre de fusions à 1 à chaque pas du processus de fusion.

3.4.1.4 Paramètres d'arrêt et de choix de meilleure partition

Ces deux critères peuvent être identiques et dépendront de l'application envisagée. Ils doivent permettre d'atteindre une mesure de qualité de la segmentation obtenue au travers des caractéristiques pouvant correspondre à la notion de régions, de contours, texture... Nous préconisons cependant d'utiliser un critère global. On pourra, par exemple, employer le lambda de Wilks défini dans les notations (voir section 3.1).

3.4.1.5 Choix du scénario de segmentation

Il est à noter, que suivant le processus de segmentation imaginé, les étapes de fusion et de division pourront soit se succéder, soit s'alterner. On peut également certainement concevoir des procédures de segmentation n'utilisant qu'une série de division ou de fusion. La figure 3.8 donne un aperçu des divers scénarios possibles. Nous ne préconisons aucun des scénarios envisagés.

3.4.2 Algorithmes

Les concepts présentés ci-dessus peuvent être implémentés de différentes façons. Nous proposons ici une implémentation des opérations de fusion et de division permettant d'aboutir à une segmentation finale de l'image hyperspectrale ne dépendant pas d'un parcours quelconque de la partition de l'image en cours de procédure. Pour cela, à chaque étape de fusion ou de division, l'opération est réalisée en choisissant la meilleure fusion ou division parmi toutes celles possibles à cet instant au sens d'un critère défini préalablement. Nous choisissons par contre de respecter les préconisations données dans la section précédente et de suivre le scénario de segmentation repéré 1 sur la figure 3.8 i.e. processus de division suivi d'un processus de fusion. L'implantation formelle des procédures de division et de fusion respectant les éléments évoqués précédemment




FIG. 3.8 – Processus de segmentation d’IHS utilisant l’approche papillon : scénarios possibles suivant l’approche de segmentation utilisée

est donnée ci-dessous :

Algorithme de division L’opération de division est constituée d’une succession d’étapes. Soit Z une image hyperspectrale et $\tilde{\mathbf{Z}}_{(n \times m, p)}$ sa matrice centrée associée, \mathcal{P} la partition réalisée, r le nombre de régions et $Arret$ le prédicat d’arrêt de l’algorithme. À chaque étape, l’image est projetée sur 1 variable latente calculée à l’aide d’une approche de réduction de dimension permettant d’accéder aux notions de variance intra et révélatrice de l’hétérogénéité interne aux régions de la partition en cours \mathcal{P} . La division de chaque région en 2 régions est testée et celle qui maximise un critère noté Θ est retenue (critère de qualité de la segmentation obtenue). L’arrêt de la procédure intervient lorsque un nombre maximum de régions est atteint ou lorsque un critère (Ω) atteint un seuil donné (S_D) aboutissant à l’ordre $Arret$. L’algorithme 1 décrit formellement cette démarche.

Algorithme de fusion L’opération de fusion est constituée d’une succession d’étapes. Soit Z une image hyperspectrale et $\tilde{\mathbf{Z}}_{(n \times m, p)}$ sa matrice associée (supposée centrée), \mathcal{P} la partition

Entrées: \mathbf{Z} , Image hyperspectrale

Sorties: \mathcal{P}_f , Partition finale de l'image

Initialisation

$r \leftarrow 1$, Nombre de région ;

$\mathcal{P} \leftarrow \{Z\}$, Partition ;

Arret = faux ;

tant que *Arret = faux faire*

$\mathbf{W} \leftarrow$ inertie intra de \mathbf{Z} , selon \mathcal{P} ;

$\mathbf{U}_{(p,k)} \leftarrow$ 1 variable latente, premier vecteur propre de la méthode de réduction choisie ;

$\mathbf{S}_{(m \times n, k)} \leftarrow \tilde{\mathbf{Z}}\mathbf{U}$ scores sur la variable latente ;

pour $i = 1 : r$ **faire**

 division en 2 régions de $R_i \rightarrow \{A_1, A_2\}$;

 création d'une partition $\mathcal{Q}_i \leftarrow \mathcal{P} - \{R_i\} + \{A_1, A_2\}$;

$\lambda_i \leftarrow \Theta(\mathbf{S}, \mathcal{Q}_i)$;

fin

$I \leftarrow \text{ArgMax}_i(\lambda_i)$;

$\mathcal{P} \leftarrow \mathcal{Q}_I$; $r \leftarrow r + 1$;

si $\Theta(\mathcal{P} \geq S_D)$ **alors**

$\mathcal{P}_f \leftarrow \mathcal{P}$;

Arret = vrai ;

fin

fin

Algorithm 1 – Algorithme de la procédure de division

réalisée, r le nombre de régions et *Arret* le prédicat d'arrêt de l'algorithme. À chaque étape, l'image est projetée sur $nbVl$ variables latentes expliquant la variance inter, et révélatrice de la partition en cours. Le nombre de variables latentes $nbVl$ sera égal à $r - 1$, sauf dans le cas où r est trop important où on se limitera à un seuil de variance expliqué proche de 100%. Toutes les fusions de deux régions voisines sont alors testées. Celle qui maximise un critère noté Θ' est retenue (critère de qualité de la partition obtenue). Comme pour la phase de division, l'arrêt peut être contrôlé par le nombre de régions désiré ou par l'évolution d'un paramètre Ω' . Cette phase est décrite formellement par l'algorithme 2 :

L'implémentation de ces algorithmes a été optimisée de façon à réduire drastiquement la complexité en temps. Ces optimisations sont présentées en annexe B.

Entrées: r , nombre de régions, \mathcal{P} , partition initiale de l'image

Sorties: \mathcal{P}_f , Partition finale de l'image

Initialisation

$Arret = faux$;

tant que $Arret = faux$ **faire**

$\mathbf{B} \leftarrow$ inertie inter de \mathbf{Z} , selon \mathcal{P} ;

$\mathbf{U}_{(p,k')} \leftarrow nbVl$, premiers vecteurs propres de la méthode de réduction choisie ;

$\mathbf{S}_{(m \times n, k')} \leftarrow \tilde{\mathbf{Z}}\mathbf{U}$ scores sur la variable latente ;

pour tous les *couple* R_i et R_j *de régions adjacentes* **faire**

 Fusionner $(R_i, R_j) \rightarrow R$;

 création d'une partition $\mathcal{Q}_i \leftarrow \mathcal{P} - \{R_i, R_j\} + \{R\}$;

$\lambda_i \leftarrow \Theta'(\mathbf{S}, \mathcal{Q}_i)$;

fin

$I \leftarrow \text{ArgMax}_i(\lambda_i)$;

$\mathcal{P} \leftarrow \mathcal{Q}_I$; $r \leftarrow r - 1$;

si $\Theta'(\mathcal{P} \geq S_F)$ **alors**

$\mathcal{P}_f \leftarrow \mathcal{P}$;

$Arret = vrai$;

fin

fin

Algorithm 2 – Algorithme de la procédure de fusion

Chapitre 4

Validation de la méthode et résultats

L'objectif de ce chapitre est d'illustrer, à l'aide d'exemples réels et simulés, le fonctionnement et certaines caractéristiques de notre schéma du papillon. Plusieurs images synthétiques et réelles nous permettront de décrire précisément le fonctionnement de notre approche et mettront en lumière sa capacité à mêler information spectrale et spatiale de façon conjointe et équilibrée.

Sommaire

4.1	Introduction	78
4.2	Méthodes de segmentation d'images investies (phase de division)	79
4.2.1	Segmentation quad-tree	79
4.2.2	Segmentation par partitionnement et coupes normalisées	80
4.2.3	Segmentation par ligne de partage des eaux	81
4.3	Résultats	84
4.3.1	Description des exemples synthétiques et réels	84
4.3.1.1	Images de synthèse	84
4.3.1.2	Images Réelles	85
4.3.2	Au c œur du papillon	87
4.3.2.1	Fonctionnement de l'algorithme	87
4.3.2.2	Illustration de la prise en compte de l'information spatiale et spectrale	91
4.3.2.3	De l'intérêt d'utiliser une variable latente et une coupe par itération	98

4.3.2.4	De l'intérêt de mixer informations spectrale et spatiale	102
4.3.2.5	Critères d'arrêt	107

4.1 Introduction

L'ensemble des résultats présentés a été obtenu à l'aide d'une procédure de segmentation type division et fusion classique. Ainsi, nous réalisons une phase de divisions suivie d'une phase de fusions pour aboutir à une segmentation finale. Par ailleurs, nous appliquons le principe d'implémentation proposé dans le chapitre précédent (chapitre 3) et utilisons le critère de Wilks (voir chapitre 3 section 3.1) pour décider des divisions ou fusions les plus opportunes (paramètres Θ et Θ'). Le critère d'arrêt fait l'objet d'une attention particulière et est traité dans la section 4.3.2.5. Plusieurs approches de segmentation par division ont été investies : approche quad-tree, partitionnement par coupes normalisées puis algorithme de partage des eaux. Nous les utilisons successivement sur chacun des exemples présentés. Par contre, l'extraction des structures spectrales est toujours réalisée par diagonalisation de la matrice de variance intra et inter pour respectivement la phase de division et la phase de fusion.

Ce chapitre est découpé en plusieurs sections. Dans la première, nous présentons brièvement les approches de segmentation descendantes investies. La deuxième section est entièrement dédiée à la présentation de la méthode. Dans un premier temps les images synthétiques et réelles utilisées sont décrites puis nous nous intéressons à plusieurs caractéristiques de l'approche *papillon* :

- La première section (4.3.2.1) s'attache à montrer le fonctionnement de notre algorithme sur un exemple simple et didactique i.e. une image de synthèse.
- La seconde section (4.3.2.2) s'attache à montrer la capacité de notre approche à prendre en compte l'information spatiale et spectrale.
- La troisième section (4.3.2.3) s'attache à justifier l'intérêt des préconisations données dans le chapitre précédent (3) et concernant le nombre de variables latentes à utiliser dans la phase de division et de fusion puis le nombre de coupes ou de fusions à réaliser lors de ces deux processus.

- La quatrième section (4.3.2.4) s'attache à montrer l'intérêt de l'approche itérative et mêlant information spectrale et spatiale.
- Enfin, le cinquième paragraphe (4.3.2.5) propose un critère d'arrêt en particulier pour la phase de fusion.

4.2 Méthodes de segmentation d'images investies (phase de division)

L'approche proposée dans le chapitre précédent (chapitre 3) nécessite l'utilisation côté spatial d'une stratégie de division de l'image permettant d'extraire à chaque pas un nombre de régions limité et idéalement égal à 2. Nos recherches nous ont amené à nous intéresser successivement à 3 approches décrites succinctement ci-dessous et dont les caractéristiques principales sont rassemblées dans le tableau 4.1.

4.2.1 Segmentation quad-tree

La première est une stratégie de division classique empruntée à l'algorithme de segmentation Split and Merge (Division et Fusion) développée par Horowitz [Horowitz and Pavlidis, 1974]. Le point de départ est une sous-segmentation, l'image entière étant considérée comme une région unique à raffiner. Le principe est alors de découper successivement les régions non homogènes suivant un prédicat défini *a priori*. L'opération de division standard divise l'image originale en 4 quadrants de taille égale et réitère l'opération de division récursivement sur chacun des quadrants si cela est nécessaire (prédicat d'homogénéité). La figure 4.1 illustre le fonctionnement de l'algorithme pour une image en niveau de gris et utilisant un critère de variance pour l'opération de division. L'inconvénient majeur de cette approche réside dans la rigidité du découpage qu'elle impose. Par contre, son implémentation logicielle est relativement aisée et d'un coût algorithmique faible.

Cette méthode de segmentation ne nécessite pas de modification pour s'intégrer directement dans le schéma du papillon. Si toutefois, lors de l'étape de division, on désire limiter le nombre de




FIG. 4.1 – Principe de l’opération de division standard dans l’algorithme Split and Merge (d’après [Baillie, 2005])

coupe à 1, une étape de fusion intermédiaire sera nécessaire entre chaque étape de division.

4.2.2 Segmentation par partitionnement et coupes normalisées

La deuxième est une approche de classification de données appliquée à la segmentation d’image et utilisant une représentation de l’image sous forme d’un graphe. L’image est représentée par un graphe non orienté $G = (V, E)$ où les pixels constituent les sommets (V) et les liaisons inter-pixel les arêtes (E). Le poids des liaisons inter-pixels est défini par des fonctions de similarité (noyaux) pouvant prendre en compte un ou plusieurs critères tels que l’intensité ou encore l’adjacence. L’objectif est alors de partitionner le graphe G en deux sous graphes (bi-partition) A et B tel que $A \cup B = G$ et $A \cap B = \Phi$. Wu [Wu and Leahy, 1993] a modélisé ce problème en utilisant la notion de coupe minimale ⁶ et a proposé une solution par un algorithme de flot maximal (Théorème de Ford-Fukderson [Ford and Fulkerson, 1962]). Shi

⁶La capacité d’une coupe, notée $|C|$, est égale à la somme des poids des arêtes coupées et qui séparent A et B . Le problème de la coupe minimale consiste alors à trouver la coupe de capacité minimale dans le graphe G .

[Shi and Malik, 1997, Shi and Malik, 2000] a cependant montré que ce critère de coupe comporte plusieurs défauts (en particulier, il favorise les petits regroupements de pixels isolés) et a proposé un nouveau critère à minimiser appelé coupes normalisées (Ncut) permettant en partie de s'affranchir des biais de l'algorithme des coupes minimales. Cependant, il n'existe pas de solution exacte à ce problème (NP Complet). Une approximation pour la minimisation du critère de coupe normalisée par une approche empruntée à la théorie spectrale des graphes [Fowlkes et al., 2004, Dhillon et al., 2007] a été proposée par Shi [Shi and Malik, 1997]. L'inconvénient majeur de cette approche est son coût algorithmique (construction de la matrice de similarité, détermination de la solution approchée). Cependant, elle permet effectivement d'obtenir directement une bi-partition de la région en cours de traitement sans toutefois garantir la connexité des régions. La figure 4.2 présente les concepts de l'approche des coupes normalisées tels que présentés ci-dessus. Les notions de graphe, de matrice de similarité (noyau) et le critère de coupes normalisées sont ainsi illustrées.

Cette approche de segmentation s'intègre également immédiatement dans le schéma du papillon. Le calcul de la matrice de similarité est réalisé de la façon suivante :

$$W_{ij} = \exp\left(-\frac{\|F_i - F_j\|^2}{\sigma_I^2}\right) \times \begin{cases} \exp\left(-\frac{\|X_i - X_j\|^2}{\sigma_x^2}\right) & \text{si } \|X_i - X_j\| < r \\ 0 & \text{sinon} \end{cases} \quad (4.1)$$

Dans cette équation F_i correspond à la valeur radiométrique du pixel i et X_i la position du pixel i . Les termes σ_x et σ_I permettent de moduler le poids attribué à l'information radiométrique et à l'information spatiale. Le terme r (rayon) permet d'affecter une valeur de similarité nulle pour des pixels étant trop éloignés du pixel en cours.

4.2.3 Segmentation par ligne de partage des eaux

Enfin, la troisième est une approche de segmentation par Ligne de Partage des Eaux (LPE ou watershed en anglais). Elle est basée sur l'analogie entre une image à niveaux de gris et une surface topographique. Ce relief comporte un certain nombre de structures topographiques (i.e

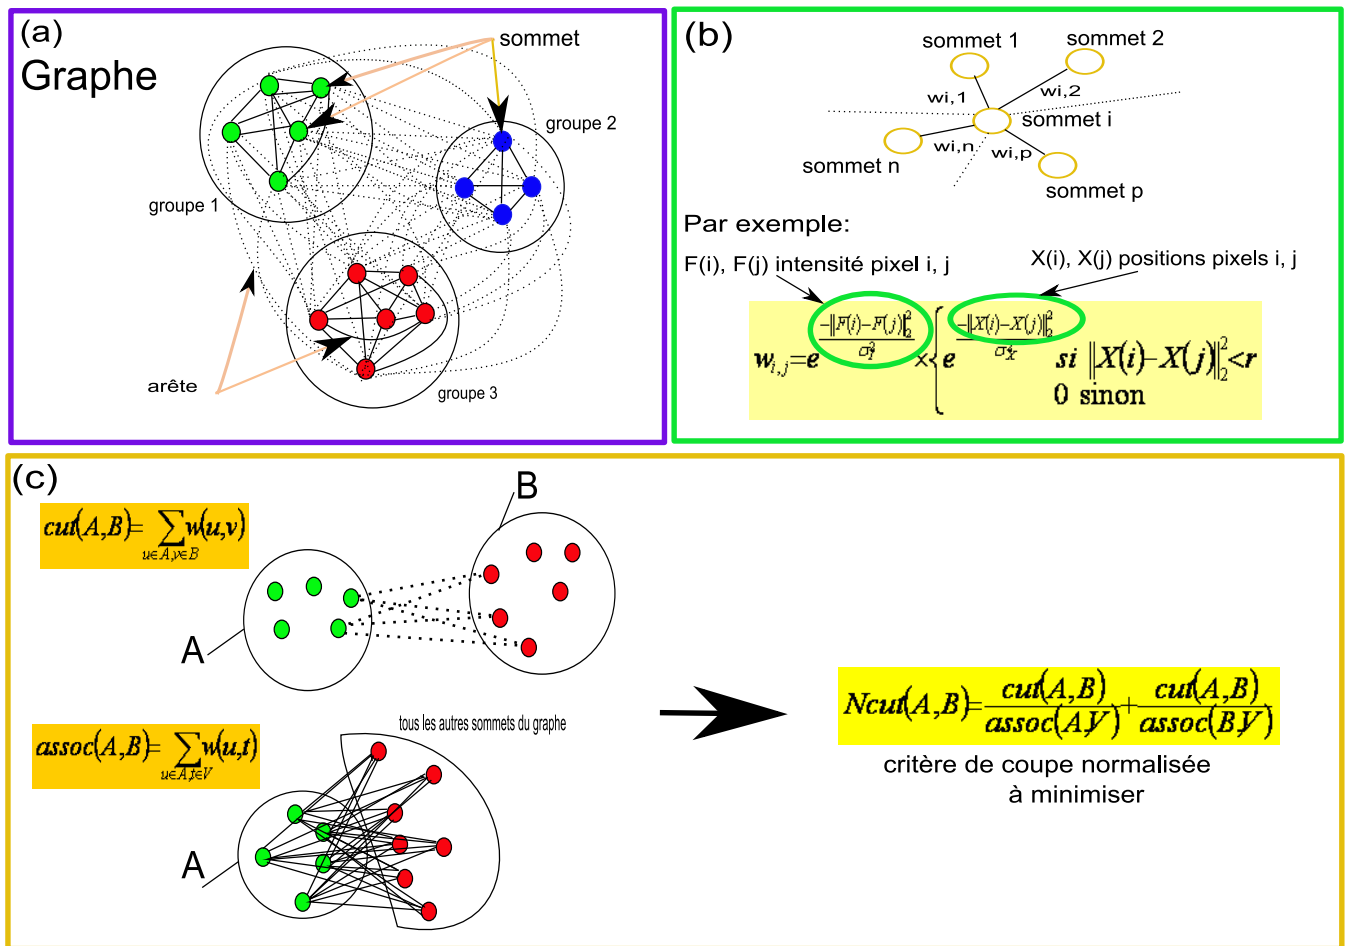


FIG. 4.2 – (a) : notions de graphe, sommet, arêtes ; (b) : Représentation des connexions du sommet i avec ses n voisins et exemple de définition d’une similarité inter-pixel (poids des liaisons inter-pixels) liant intensité et adjacence ; (c)- Définition du critère des coupes normalisées. (D’après [Enberg and Boonaert, 2008])

dômes, vallées, lignes de crêtes) qui sont utiles pour nous renseigner sur le contenu de l’image. Plus particulièrement, les lignes de crêtes ou ligne de partage des eaux sont assimilées aux contours de l’image. Retrouver les structures contenues dans l’image revient alors à rechercher les bassins versants c’est-à-dire, en reprenant l’analogie hydrologique, une zone géographique pour laquelle toute goutte d’eau, suivant la ligne de plus grande pente (ligne de crête) arrivera dans un même minimum. Tous les bassins de l’image sont connexes et leur ensemble forme une partition de

l'image. La frontière de ces bassins constitue la ligne de partage des eaux ou LPE. Une méthodologie courante pour la détermination des LPE d'une image est basée sur un processus d'immersion de l'image [Digabel and Lantujoul, 1978, Vincent and Soille, 1991, Meyer, 1991]. Dans les applications de segmentation d'images, cette approche utilise généralement la norme du gradient de l'image initiale comme point d'entrée. En effet, l'objectif étant de déterminer des régions homogènes, ce sont des zones de fort gradient qui doivent constituer les frontières (les lignes de crêtes) recherchées. Cette image de gradient est inondée de manière récursive par ses minima locaux. Lorsque deux bassins versants se rejoignent et risquent de se mélanger, on construit une digue. Lorsque le relief est totalement immergé, les digues ainsi formées constituent les lignes de partage des eaux (figure 4.3).

Les algorithmes de calcul de la ligne de partage des eaux les plus efficaces ont une complexité qui dépend linéairement du nombre de pixels de l'image, ce qui les classe parmi les méthodes de segmentation les plus rapides. Ceci les rend particulièrement attrayants dans des applications traitant des images de grande taille. Par ailleurs, les contours obtenus sont systématiquement fermés et ont un positionnement précis en correspondance avec les objets à détourner. Cependant, cette approche a tendance à générer une sur-segmentation importante de l'image. De nombreuses solutions à ce problème ont été proposées comme, par exemple, l'introduction de marqueurs (on ne s'intéresse alors qu'à certains minima locaux lors du processus d'immersion), l'ajout de pré-traitement de type filtrage passe bas, l'ajout d'étape de fusion de régions... Une adaptation de ce principe était cependant nécessaire pour insertion dans notre algorithme, à savoir division en deux régions seulement. Pour ce faire, une approche combinant la détection de marqueurs et une descente des eaux a été développée. Cette méthode est décrite en annexe A.

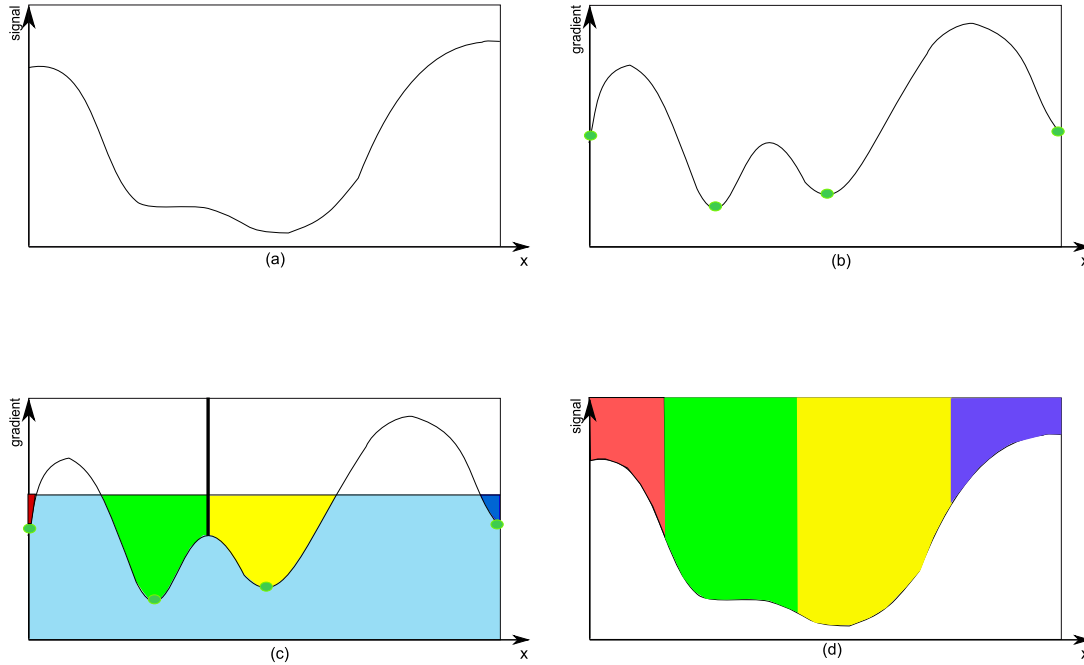


FIG. 4.3 – Illustration mono-dimensionnelle du principe de segmentation par Ligne de Partage des Eaux : (a) Signal initial. (b) Gradient correspondant au signal initial. Les minima locaux sont indiqués par les points verts (c) Processus ascendant d’inondation à partir de chaque minima local. Lorsque deux bassins se rencontrent, un barrage est construit pour éviter le mélange. Ces barrages sont les contours finaux de la segmentation (d) Résultats de la segmentation du signal initial (4 régions déterminées). (d’après [Roudier, 2008])

4.3 Résultats

4.3.1 Description des exemples synthétiques et réels

4.3.1.1 Images de synthèse

Les images hyperspectrales de synthèse utilisées, de taille $(n = 100) \times (m = 100) \times (p = 256)$, ont été construites à l’aide du processus décrit ci-dessous :

Une image couleur $(n = 100) \times (m = 100)$ est dessinée manuellement à l’aide d’un logiciel de gestion d’images (type Le Gimp), en juxtaposant des régions de taille et de couleur variables. La

Type approche	Nombre régions extraites	Complexité algorithmique	Commentaire
Split (and Merge)	4	Faible	Régions contraintes par le découpage Mise en oeuvre simple
Coupes Normalisées	2	Très élevée	Approche classification Segmentation non assurée Utilisation mémoire importante
LPE modifiée	2	Faible	Sensible au bruit Extraction de petites régions Utilisation mémoire importante Contours fermés et bien positionnés

TAB. 4.1 – Bilan des approches investies

structure de cette image de base est choisie pour permettre une illustration aisée d'une propriété particulière de notre approche papillon. L'image est ensuite dépliée pour former une matrice $\mathbf{X}_{(10000,3)}$. Un ensemble de 3 spectres de $p = 256$ bandes spectrales, $\mathbf{S}_{(3,256)}$ est synthétisé par combinaison linéaire aléatoire de 5 gaussiennes de centre et de largeur aléatoires. La figure 4.4 reporte les spectres purs obtenus. L'image hyperspectrale est ensuite calculée par $\mathbf{Z} = \mathbf{XS} + \varepsilon\mathbf{E}$, où ε est un coefficient d'atténuation et $\mathbf{E}_{(10000,256)}$ est une matrice de spectres synthétiques, chacun construit de manière indépendante des autres, avec la même méthode que précédemment. Une valeur de 0.10 a été choisie pour ε .

4.3.1.2 Images Réelles

Les images réelles sont au nombre de deux. Nous les nommons *IR1* et *IR2*.

- La première (*IR1*) est une image acquise à l'aide d'une caméra ligne HYSPEX VNIR 1600 pixels (Hypspec, Norsk Elektro Optikk AS, Norway) montée sur un banc assurant la translation et donnant accès à la dimension spatiale manquante (x). L'acquisition s'effectue sur




FIG. 4.4 – Spectres utilisés comme base des images de synthèse, par combinaison linéaire avec les composante RGB des images couleurs.

une bande spectrale allant du visible au très proche infrarouge ($400 - 1000nm$) avec une résolution spectrale de $3.7nm$ permettant d'acquérir 160 plans spectraux. L'image a été acquise avec une profondeur de 12 bits. La focale utilisée permet d'obtenir une résolution spatiale de $0.15mm$ par pixel dans la direction y et pouvant varier de 0.15 à $0.15 \times b$ dans la direction de la translation (x), avec b facteur de binning spatial. Un temps d'intégration variable permet de s'adapter aux conditions de prise de vue i.e. d'éclairage.

L'image IR1 (figure 4.5-a) est une image réalisée en milieu extérieur par temps clair sur une cible d'environ $20 \times 15cm^2$ composée d'adventices en pots (deux variétés qui sont repérées 1 et 2 sur la figure 4.5- gauche). La distance de prise de vue était de $30cm$, le binning spatial dans la direction x fixé à 2, le temps d'intégration réglé à $1000ms$. L'image initiale de taille $(n = 1600) \times (m = 1120) \times (p = 160)$ a été regroupée par blocs pour former une image finale de taille $(n = 80) \times (m = 115) \times (p = 160)$.

- La deuxième (image *IR2*) est une image DAIS (Digital Airborne Imaging spectrometer)

mise à disposition par le département de télécommunication et de télédétection de l'université de Pavie en Italie (figure 4.5-b). Cette image représente une vue aéroportée de la ville de Pavie en Italie et comporte 80 bandes de $496nm$ à $20000nm$. Afin de réduire les temps de calcul, l'image de taille initiale $(n = 400) \times (m = 400) \times (p = 80)$ a été réduite pour former une image finale de taille $(n = 144) \times (m = 161) \times (p = 80)$.




FIG. 4.5 – Images hyperspectrales réelles : (a) image IR1, couleur, (b) image IR2, bande spectrale 50

4.3.2 Au c œur du papillon

4.3.2.1 Fonctionnement de l'algorithme

Dans un premier temps, nous allons illustrer sur un exemple simple et didactique le fonctionnement du processus papillon présenté au chapitre 3. Pour cela nous utilisons une image de synthèse de structure simple (nommée *IS1*) qui nous permet d'interpréter les structures spatiales et spectrales extraites à chaque étape du processus de division puis de fusion. Cette image a été réalisée avec la procédure décrite précédemment (section 4.3.1.1) et utilise l'image couleur d'origine représentée figure 4.6. Elle comporte 3 zones couleurs (1 rouge, 1 verte et 1 bleue) dimensionnées et positionnées pour être complètement circonscrites par un nombre de division réduit.




FIG. 4.6 – Image RVB utilisée comme base de la première image de synthèse.

Sur cet exemple, nous avons utilisé l'algorithme de segmentation LPE modifié avec un paramètre de lissage fixé à 1 et une taille de région minimale égale à 5. L'algorithme du papillon mis en place dans cet exemple est alors celui illustré figure 4.7. Ainsi, lors du processus de fusion, l'analyse spectrale est réalisée par diagonalisation de la matrice de variance intra de la partition en cours et l'analyse spatiale par la segmentation LPE modifiée. Le choix de la meilleure division est effectuée au regard du Λ de Wilks (maximum) calculé sur le sous espace vectoriel déterminé. Lors du processus de division, l'analyse spectrale est réalisée par diagonalisation de la matrice de variance inter de la partition en cours. La meilleure fusion est choisie au regard du Λ de Wilks (maximum) calculé sur le sous espace vectoriel déterminé.

La figure 4.8 montre le déroulement de l'algorithme sur l'image de synthèse décrite ci-dessus pour la phase de division (haut) et de fusion (bas). L'arrêt des phases de division et de fusion a été contrôlé au moyen du nombre de régions i.e. 5 régions finales à l'issue de la phase de division (soit 4 étapes de division) et 3 régions finales à l'issue de la phase de fusion (soit 2 étapes de fusion). En deux étapes de divisions (D1, D2), les trois régions initiales sont complètement cernées. Les deux étapes de divisions supplémentaires (D3, D4) n'étaient pas nécessaires. Nous les avons réalisées pour permettre à la phase de fusion de s'exprimer. Puis, les deux phases de fusion (F1, F2) font passer la partition de 5 régions à 3, correspondant aux régions de l'image RVB.

Les figures 4.9 et 4.10 présentent en détails les différentes étapes des itérations pour respecti-




FIG. 4.7 – Principe du papillon utilisé sur l'image de synthèse $IS1$ (haut : processus de division, bas : processus de fusion)

vement le processus de division et de fusion. Les informations données par chacune des colonnes de ces figures sont répertoriées dans le tableau 4.2.

A la première itération du processus de division, l'image est constituée d'une région unique




FIG. 4.8 – Déroulement approche papillon sur image de synthèse *IS1* : Haut : phase de division, itérations D1 à D4; Bas : phase de fusion, itérations F1 à F2.

Processus	Colonne				
	(a)	(b)	(c)	(d)	(e)
Division	Partition en cours	1ère VL Inertie Intra	Image Score	Image gradient	Choix région à diviser
Fusion	Partition en cours	1ère VL Inertie Inter	2ème VL Inertie Inter	3ème VL Inertie Inter	Choix régions à fusionner

TAB. 4.2 – Contenu des colonnes figures 4.9 et 4.10

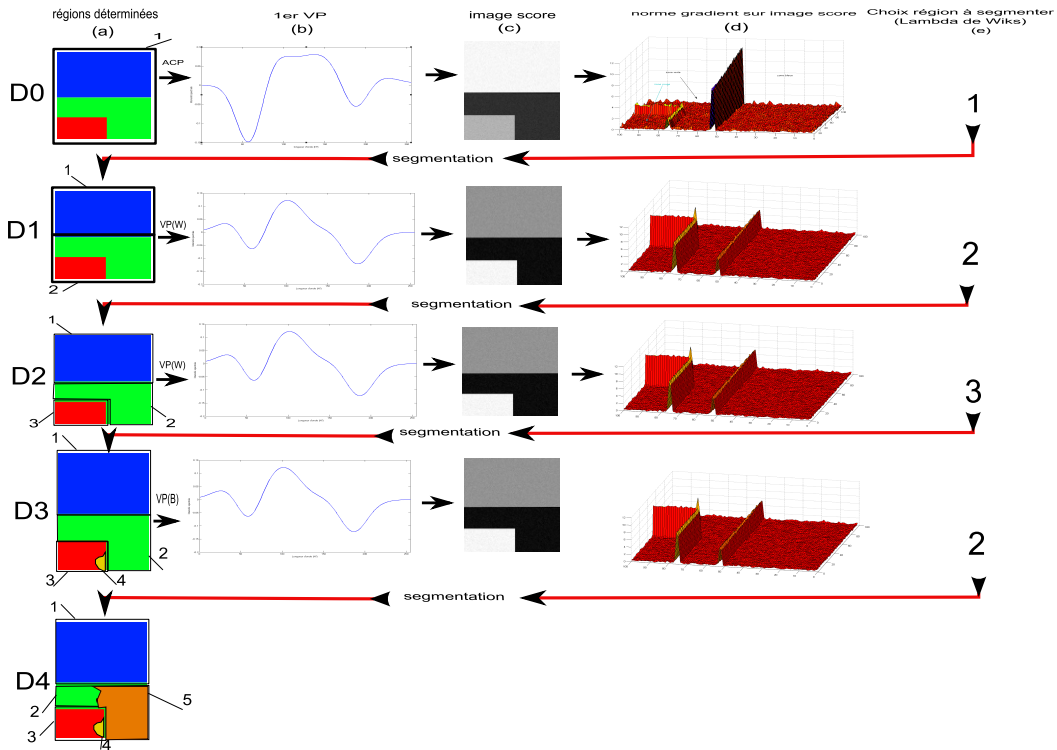
(figure 4.9-a, étape D0). L'inertie intra-classe est alors identique à l'inertie totale de l'image. La recherche du premier vecteur propre de la matrice d'inertie intra-classe ($VP(\mathbf{W})$) (figure 4.9-(b), étape D0) revient alors à réaliser une ACP et à ne conserver que la première variable latente. Cette variable latente permet à l'évidence d'opposer la région bleue aux régions verte et rouge : la variable latente obtenue est quasi identique au spectre obtenu en réalisant la différence entre le spectre pur bleu et les spectres purs rouge et vert pondérés par la surface respective des régions

concernées (figure 4.11). La projection des données image sur cette variable latente permet ainsi d'obtenir l'image score représentée figure 4.9-(c), étape D0. Un niveau de gris différent est affecté aux régions rouge, verte et bleue. Cependant, le contraste le plus important sépare la région bleue des autres régions. Les spectres purs R, V et B n'étant pas orthogonaux, le niveau de gris affecté aux régions rouge et verte dépend de la proportion de bleu présente dans les spectres purs de ces régions. Le calcul du gradient de l'image score et de sa norme va permettre d'appliquer notre algorithme de segmentation LPE qui va naturellement aboutir à une partition de l'image telle que représentée figure 4.9-(a), étape D1. Cette partition est composée de deux régions. La première (label 1) est spectralement uniforme (région bleue). La seconde (label 2) est composée de deux régions différentes (l'une verte, l'autre rouge). C'est cette région qui présente la plus grande inertie intra, due à la présence de deux sous régions rouge et verte. Ainsi, la variable latente calculée sur l'inertie intra de cette nouvelle partition (figure 4.9-(b), étape D1) est donc devenue quasiment indépendante du bleu. En la superposant à la différence des spectres purs associés au rouge et au vert, comme représenté figure 4.12, on constate qu'elle réalise une séparation entre les deux directions spectrales associées au rouge et au vert. La deuxième étape de division aboutira donc à la séparation des régions rouge et verte. Les deux étapes de division suivante (D3, D4) ne sont pas nécessaires. Les vecteurs propres calculés n'évoluent plus (figures 4.9-(b) D3 et D4), indiquant que aucune information importante complémentaire n'est extraite lors de ces opérations.

4.3.2.2 Illustration de la prise en compte de l'information spatiale et spectrale

L'objectif de cette section est de montrer la capacité de notre approche à prendre en compte la structuration spatiale de l'image.

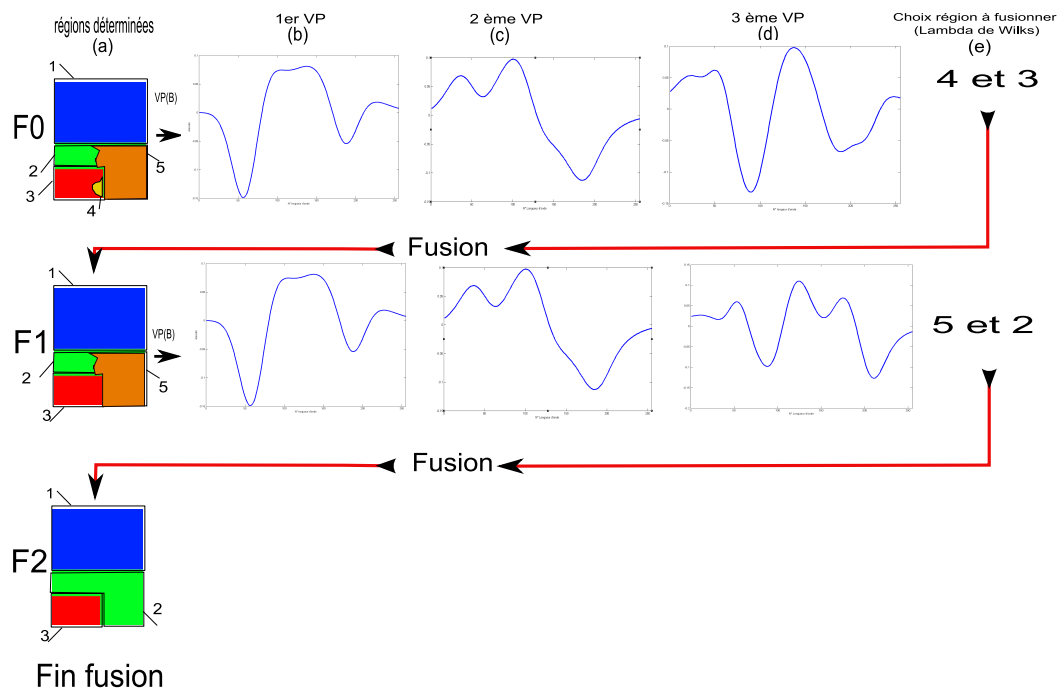

Pour cela, nous utilisons deux images de synthèse que nous nommons $IS2_A$ et $IS2_B$. Ces images sont construites avec les mêmes spectres purs que dans le cas de l'image $IS1$ (voir figure 4.4) mais en utilisant les images couleurs supports représentées figure 4.13. La première image (figure de gauche) est composée de 3 régions rouge verte et bleue dont les proportions sont bien établies. La deuxième image est constituée d'un fond rouge et de plusieurs régions vertes et bleues


 FIG. 4.9 – Déroulement détaillé de la phase de division sur l'image de synthèse $IS1$

(14 régions bleues et 12 régions vertes exactement) correspondant à "l'éclatement" des régions verte et bleue de la première image. La proportion de ces "couleurs" (nombre de pixels affecté à chaque région) dans l'image $IS2_B$ est donc identique à celle de l'image $IS2_A$.

Comme dans l'exemple précédent, on a représenté figure 4.14 les partitions successives obtenues par l'algorithme du papillon sur l'image $IS2_A$ lors du processus de division puis figure 4.15 un aperçu détaillé. Dans ce cas, nous avons limité le processus de division en 2 étapes permettant d'obtenir 3 régions correspondant normalement aux régions initiales. La phase de fusion n'a pas été employée. L'évolution des partitions au cours des itérations du processus de division est conforme à celle décrite dans l'exemple précédent (image $IS1$), à savoir :

- La première variable latente de l'inertie intra-régions (figures 4.15 (b), étape D0 et 4.16) lors de la première itération de division permet d'opposer les régions rouge et verte à la région bleue. On obtient ainsi une nouvelle partition composée de deux régions labellisées 1 et 2. La région 1 est composée d'un fond rouge et d'une région verte. La région 2 correspond

FIG. 4.10 – Déroulement détaillé de la phase de fusion sur l'image de synthèse *IS1*FIG. 4.11 – Variable latente utilisée pour la première étape de division, en superposition au spectre de différence entre spectre pur bleu et spectres purs vert et rouge pondérés ($1.3 \cdot R - V - 0.2 \cdot R$) pour l'image de synthèse *IS1*




FIG. 4.12 – Variable latente utilisée pour la deuxième étape de division en superposition au spectre de différence entre spectre pur vert et spectre pur rouge pour l’image de synthèse $IS1$.




FIG. 4.13 – Images RVB utilisées comme base des images de synthèse $IS2_A$ (gauche) et $IS2_B$ (droite)

à la région bleue initiale (figure 4.15 (a), étape D1).

- La première variable latente de l’inertie intra-région lors de la deuxième itération de division permet d’opposer la région rouge à la verte (figures 4.15 (b), étape D1 et 4.17). En effet, la région bleue étant quasi uniforme, elle ne participe plus à l’inertie intra-régions. La variable latente est donc devenue quasiment indépendante du bleu. En la superposant à la différence des spectres purs associés au rouge et au vert, comme représenté figure 4.17, on constate

qu'elle réalise une séparation entre les deux directions spectrales associées au rouge et au vert. La deuxième étape de division aboutira donc à la séparation des régions rouge et verte. En deux étapes de division, les trois régions initiales sont totalement circonscrites.




FIG. 4.14 – Déroulement de l'algorithme (phase de division) sur l'image de synthèse $S2_A$: D_1 à D_2 phases de division.

On s'intéresse désormais à l'image de synthèse $IS2_B$. Comme dans l'exemple précédent, on a représenté figure 4.18 les partitions successives obtenues par l'algorithme du papillon sur l'image $IS2_B$ lors du processus de division puis figure 4.19 un aperçu détaillé de chaque itération. On constate ainsi que la première étape de division aboutit dans un premier temps à une variable latente (figure 4.20) qui a la même allure que celle obtenue lors de la première étape de division de l'image $IS2_A$ (figure 4.16).

Cela n'a rien de surprenant puisque les deux images contiennent exactement la même information spectrale et que, à cette étape, aucune information spatiale n'est utilisée. Ainsi, comme dans le cas de l'image $IS2_A$, cette première variable latente va permettre d'opposer la région rouge aux régions vertes et bleues. Le processus de segmentation LPE va alors aboutir à une nouvelle partition contenant deux régions (figure 4.19-(a)-D1) : la première (labellisée 1) correspond au fond rouge et à toutes les autres régions vertes et bleues moins une ; la deuxième

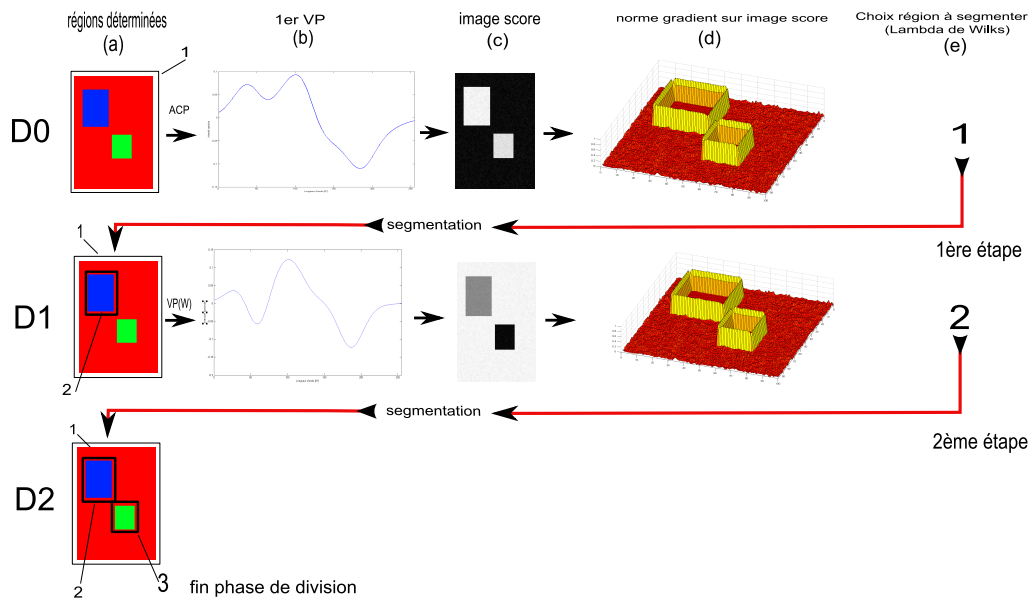


FIG. 4.15 – Déroulement détaillé de la phase de division sur l'image de synthèse $S2_A$




FIG. 4.16 – Variable latente utilisée pour la première étape de division, en superposition au spectre de différence entre spectre pur rouge et spectres purs vert et bleu pondérés ($V+2B-3R$) pour l'image de synthèse $S2_A$




FIG. 4.17 – Variable latente utilisée pour la deuxième étape de division (trait bleu), en superposition au spectre de différence entre le spectre pur rouge et le spectre pur vert (R-V) (trait pointillé noir) pour l’image de synthèse $S2_A$

(labellisée 2) correspond à une région bleue. A la deuxième itération, la première variable latente déterminée sur l’inertie intra de cette nouvelle partition a la même allure que celle déterminée au pas d’itération précédent. En effet, seule une petite région bleue ne participe plus à l’inertie intra. De fait, la variable latente extraite va toujours opposer la région rouge aux régions vertes et bleues. Le processus de division est ensuite poursuivi jusqu’à la 26ème itération où toutes les régions vertes et bleues et la région rouge ont été circonscrites. Comme le montre la figure 4.19, colonne (b)- division D0 à D27, la variable latente extraite à chaque itération est quasi identique. En effet, tant que toute l’information spectrale concernant les régions vertes et bleues n’aura pas été traitée, le processus va continuer à opposer région rouge à régions vertes et bleues. Ainsi, le processus itératif va éroder peu à peu l’espace spectral et spatial en traitant successivement une région verte ou bleue. Cet exemple illustre clairement la prise en compte de la structure spatiale de l’image par l’approche proposée.

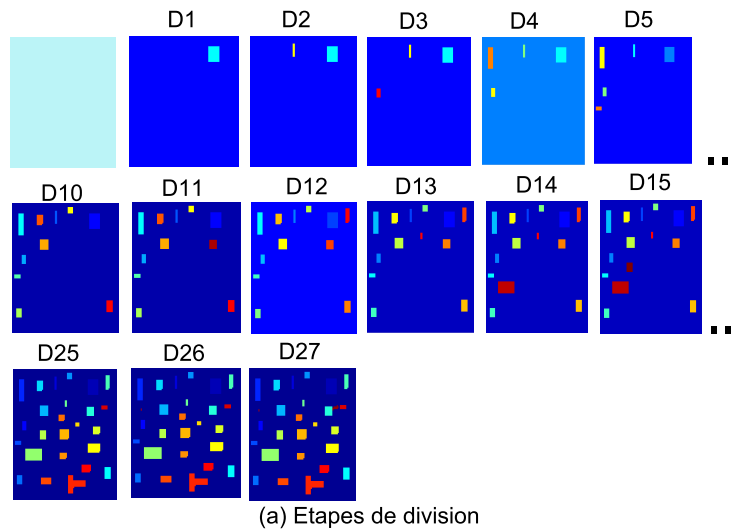



FIG. 4.18 – Déroulement de l'algorithme (phase de division) sur l'image de synthèse $IS2_B$: itération D_1 à D_{27} .

4.3.2.3 De l'intérêt d'utiliser une variable latente et une coupe par itération

L'objet de cette section est de justifier le choix du nombre de variable latente et du nombre de coupes pour la phase de division et de fusion de l'approche papillon. Pour cela, nous appliquons l'approche papillon sur une image réelle (image $IR1$) et faisons varier ces paramètres. Nous utilisons cette fois pour la phase de division, l'algorithme de segmentation par coupes normalisées avec $\sigma_i = 0.8$, $\sigma_x = 20$ et $r = 15$. Pour chacune de ces simulations, le nombre de pas de division a été réglé de façon à obtenir à l'issue de cette phase un nombre de régions égal à 10 (soit 9 et 3 phases de division pour un nombre de coupes égal respectivement à 1 et 2). Le nombre de régions final à l'issue de phase de fusion a été réglé à 5.

Le tableau 4.3 rassemble les divers scénarios testés pour la phase de division et de fusion et les figures résultantes.

La figure 4.21 nous permet de comparer les résultats obtenus lors de l'étape de division en faisant varier le nombre de variables latentes. On voit clairement que l'étape de division réalisée avec 2 variables latentes donne des résultats très mauvais. Il semble que la deuxième variable latente extraite soit très influencée par les effets de trame de la caméra (voir figure 4.22) abou-

FIG. 4.19 – Déroulement détaillé de la phase de division sur l'image de synthèse $IS2B$




FIG. 4.20 – Variable latente utilisée pour la première étape de division, (trait bleu) en superposition au spectre de différence pondéré entre spectres purs bleu et vert et spectre pur rouge ($V+2B-3R$) (trait pointillé rouge) pour l'image $S2_B$

tissant ainsi à ce type de segmentation.

Dans l'étape de division, le nombre de coupe influe également sur le résultat mais, comme on pouvait s'y attendre, de façon moins spectaculaire. Si une division utilisant 1 variable latente et 1 coupe permet en partie l'identification des deux espèces d'adventices présentes dans l'image (voir figure 4.21 - Haut, étape de division 5 où les adventices de type 1 et 2 correspondent en partie à deux régions i.e. régions jaune pour l'adventice de type 1 et bleue pour celui de type 2), il semble que le fait d'aller plus vite dans le découpage de l'image ne permette pas cette distinction (en nombre de régions déterminées équivalent soit 10 régions extraites). En poursuivant la division, on ne parvient toujours pas à réaliser cette distinction attestant qu'un nombre de coupe égal à 1 est préférable pour permettre la distinction de détails pertinents de l'image.

Pour l'étape de fusion, l'effet du nombre de variable latente est moins marqué que dans le cas de la division. On remarque cependant que l'utilisation de plusieurs variables latentes permet, dès




FIG. 4.21 – Algorithme du papillon, étape de division, variation du nombre de variables latentes : Résultats obtenus sur image réelle *IR1* avec un nombre de variable latente et un nombre de coupe égal respectivement à 1 et 2 (haut) puis avec ces paramètres fixés respectivement à 2 et 1 (bas).

Phase	nb de Var latentes	nb de coupes	Figure résultat
Division	1	1	figure 4.21 - HAUT
	2	1	figure 4.21 - BAS
	1	2	figure 4.23
Fusion	(Nombre de classe -1)		figure 4.24 - HAUT
	1		figure 4.24 - BAS

TAB. 4.3 – Les diverses configurations testées pour la phase de division et la phase de fusion : nombre de variables latentes et nombre de coupes

la deuxième itération, de fusionner les régions correspondant à des adventices de types différents (fusion des régions labellisées 3 et 4 sur la figure 4.24 - haut). Ces régions étant par nature très similaires (elles correspondent toutes deux à des objets très proches spectralement), il est ainsi normal qu'elles soient parmi les premières à être fusionnées. Cette fusion n'intervient qu'à l'itération de fusion suivante dans le cas d'une procédure utilisant uniquement 1 variable latente (4.24 - bas, pas de fusion 3). Sur cet exemple, les régions extraites en fin d'étape de division sont suffisamment différentes spectralement pour être différenciées par 1 variable latente.

4.3.2.4 De l'intérêt de mixer informations spectrale et spatiale

Dans cette section, nous nous intéressons à l'intérêt de mixer information spatiale et spectrale à travers le processus itératif du schéma papillon. Pour cela, nous comparons visuellement les résultats obtenus sur deux images réelles ($IR1$, $IR2$) avec notre approche et ceux obtenus avec les trois méthodes décrites succinctement ci-dessous. L'objectif de cette comparaison n'est pas de statuer sur les résultats mêmes de la segmentation (i.e. dire qu'une segmentation est meilleure que l'autre) mais d'évaluer les segmentations en termes de structures spatiales extraites.

- Une approche croissance de région utilisant un algorithme type Union-Find et implémentée sous sa forme linéaire (algorithme scanline [Fiorio and Gustedt, 1996]) précédée d'une analyse en composantes principales et en ne conservant qu'une variable latente. Le nombre de régions est fixée par l'intermédiaire du seuil d'agrégation T .




FIG. 4.22 – Algorithme du papillon, étape de division : images scores obtenues sur la première (gauche) et la deuxième (droite) variable latente extraite lors de la première itération.

- L’approche Union-Find précédente mais suivie d’une étape de fusion. Afin de garantir une équité de traitement entre cette méthode et notre approche, l’étape finale de regroupement des régions (fusion) a été réalisée en utilisant un procédé identique à celui développé dans notre approche, i.e. à chaque étape de fusion, test de toutes les fusions possibles et réalisation de la meilleure selon la valeur du Λ de Wilks. Pour la première étape, le seuil d’agrégation T est fixé de façon à obtenir environ 900 régions initiales.
- Une approche de classification type coupes normalisées avec une contrainte spatiale iden-

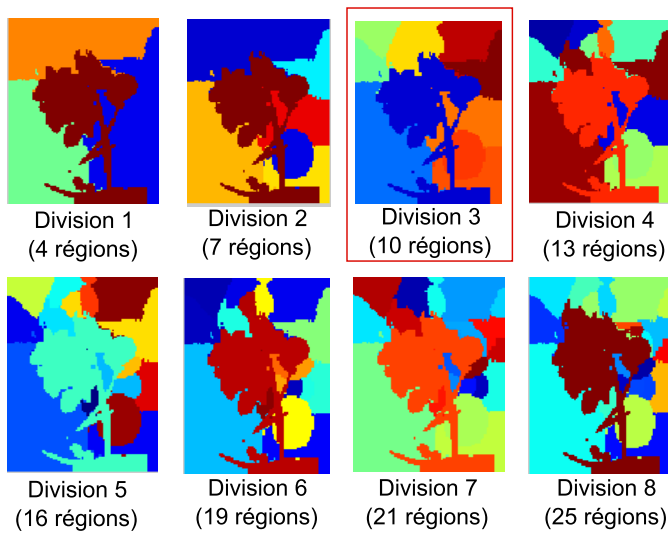
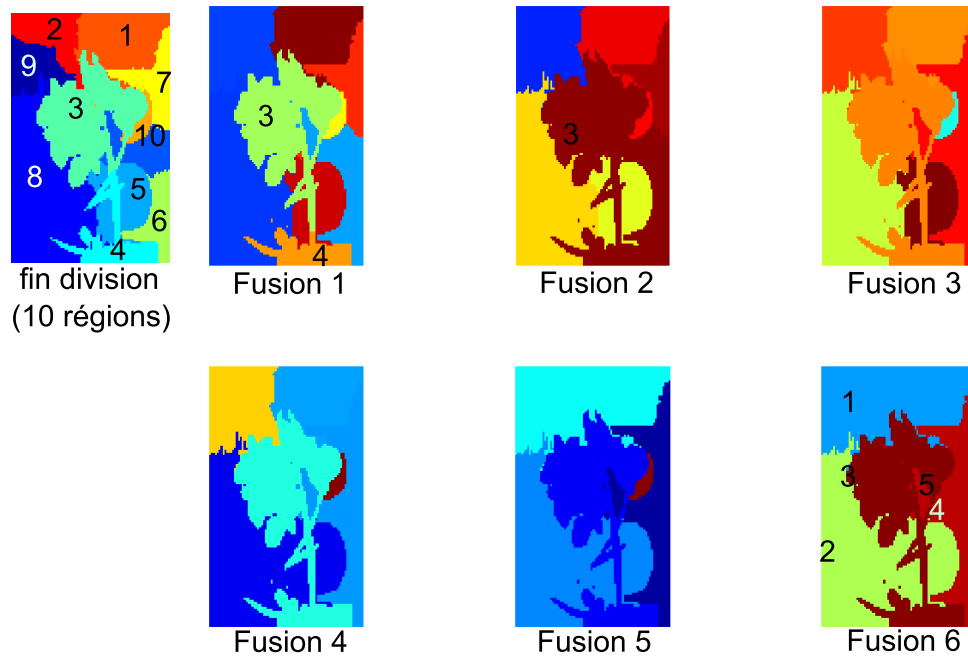


FIG. 4.23 – Algorithme du papillon, étape de division : nombre de variable latente égal à 1 et nombre de coupe égal à 2


tique à celle appliquée dans le cadre du processus papillon précédée d’une analyse en composantes principales et en ne conservant qu’une variable latente.

L’approche papillon utilise un processus de division et fusion classique. La procédure de division est effectuée à l’aide de l’algorithme quad-tree avec un nombre de variables latentes fixé à 1, un nombre de phase de divisions élevé i.e. 300 divisions (soit 901 régions générées). Pour la première image traitée (image Hypsax *IR1*) comportant optimalement 5 régions à déterminer (à savoir 2 adventices de variété 1, 2 adventices de variété 2 et le fond), le nombre de régions finales à été fixé à 5, 9 et 20. Pour la deuxième image (image DAIS *IR2*), le nombre de régions optimal est difficile à estimer et dépendra très certainement des applications envisagées. De la même façon que la première image, nous l’avons fixé à 5, 10 et 30.

La figure 4.25-A montre les résultats des segmentations obtenus avec l’approche papillon et un nombre de régions finales respectivement de 5, 9 et 20 pour l’image Hypsax (*IR1*). Il apparaît ainsi que 5 régions ne sont pas suffisantes pour discriminer fond et plantes : la région 1 correspond à un mélange plantes-fond, les régions 3, 4 et 5 correspondent au fond (mélange terre-contenant), la région 2 contient une partie de feuille. La segmentation comprenant 9 régions permet de mieux séparer végétal et fond, avec l’apparition de nouveaux détails, i.e. région 9 correspondant à un



Nombre de variable latente maximal (nombre de classe-1)



Nombre de variable latente fixé à 1

FIG. 4.24 – Algorithme du papillon, étape de fusion : Résultats obtenus sur image réelle *IR1* avec un nombre de variables latentes variable

morceau de bois, région 7 correspondant à une feuille d'adventice de type 2. Enfin, la segmentation comportant 20 régions montre une sur-segmentation évidente. La segmentation obtenue est très marquée par le découpage carré de l'image lors du processus de division mais permet de dégager les objets "plante" du reste de l'image.

Les figures 4.25-B et 4.25-C montrent respectivement les segmentations obtenues avec les techniques d'Union-Find et des coupes normalisées avec 5, 10 et 20 régions finales. L'approche Union-Find, si elle permet par principe même d'avoir accès à la notion d'objet, ne parvient pas à dégager les grands ensembles de l'image. Partant du pixel, cette approche a tendance à "s'intéresser" aux régions très hétérogènes de l'image et ne permet pas, de ce fait, de dégager une vue d'ensemble de celle-ci. L'approche par les coupes normalisées, est par construction plus pertinente pour dégager les grands ensembles de l'image (objets) et permet dans le cas de cette image d'obtenir des résultats très corrects en particulier pour un nombre de région finales égal à 9.

La figure 4.26-A montre les résultats des segmentations obtenus avec notre approche et une phase de 300 divisions et un nombre de régions finales respectivement de 5, 10 et 30 pour l'image Pavie (*IR2*). Les figures 4.26-B-C montrent les résultats des segmentations obtenues pour un nombre de régions finales équivalent et pour respectivement les approches Union-Find et l'approche par coupes normalisées. La segmentation obtenue avec notre approche et cinq régions finales permet d'avoir un aperçu des grands ensembles de l'image à savoir (1) la zone fluviale, (2) une zone d'habitation, (3) une zone de bâtiments industriels, (4) une zone nue d'habitation (5) un bâtiment. En augmentant le nombre de régions finales, on peut affiner cette segmentation et isoler des zones ou des structures particulières. L'approche Union-Find dans les deux versions proposées ne permet pas d'avoir accès à une vue globale de la scène (faire ressortir les grands ensembles). Plus encore que dans le cas de l'image *IR1*, elle s'intéresse aux détails et a donc tendance à privilégier les zones très hétérogènes de la scène en les sur-segmentant. L'approche par coupes normalisées parvient à extraire de grandes zones mais visiblement la liaison spectrospatiale réalisée à l'aide du noyau amène des erreurs de segmentation telle que la division de la zone fluviale.

Ces deux exemples permettent de montrer que notre approche, en mixant pas à pas informations spectrale et spatiale, permet d'extraire de façon pertinente les structures présentes dans l'image.

4.3.2.5 Critères d'arrêt

Dans les exemples précédents, le critère d'arrêt pour les phases de division et de fusion était lié au nombre de régions à obtenir. Un critère basé uniquement sur cette notion paraît particulièrement frustrant. Cependant, définir un critère d'arrêt c'est-à-dire un critère d'évaluation de la segmentation en cours ceci de manière non supervisée n'est pas chose aisée. Ainsi, dans le cadre de la vision numérique noir et blanc ou couleur, aucun critère ne fait l'unanimité et il n'existe à l'heure actuelle aucun critère absolu et générique permettant de réaliser cette tâche d'évaluation [Chabrier et al., 2006].

Nous nous sommes donc intéressés à des critères "propres" à notre approche. Un critère s'intéressant à la pertinence des régions extraites en terme de statistiques (variance intra en particulier) semble adapté ⁷. Ainsi, dans un premier temps, nous nous sommes intéressés au critère du Λ de Wilks. En effet, celui-ci est d'une part immédiatement disponible (car utilisé lors du processus) et il permet d'autre part d'atteindre une mesure de la variance intra classes des régions. Cependant, qu'il soit calculé sur l'espace spectral complet (Lambda complet) ou sur l'espace des variables latentes (Lambda partiel), son évolution au cours de ces deux phases ne permet pas de statuer sur l'opportunité de les stopper. Un exemple de l'évolution de ce critère, dans le cas du traitement de l'image réelle *IR1*, obtenu par un processus papillon utilisant une implémentation identique à la section précédente est donné figure 4.27.

Une approche, pour la phase de fusion, est de s'intéresser à l'évolution des vecteurs propres en cours de cette phase. Nous avons vu, sur les images de synthèse, qu'à chaque pas, ils opposent des structures spectrales deux à deux. Si à chaque pas, un vecteur propre reste constant, il oppo-

⁷On constate que les critères d'évaluation de segmentation développés pour l'imagerie scalaire s'intéressent dans de nombreux cas à cette notion

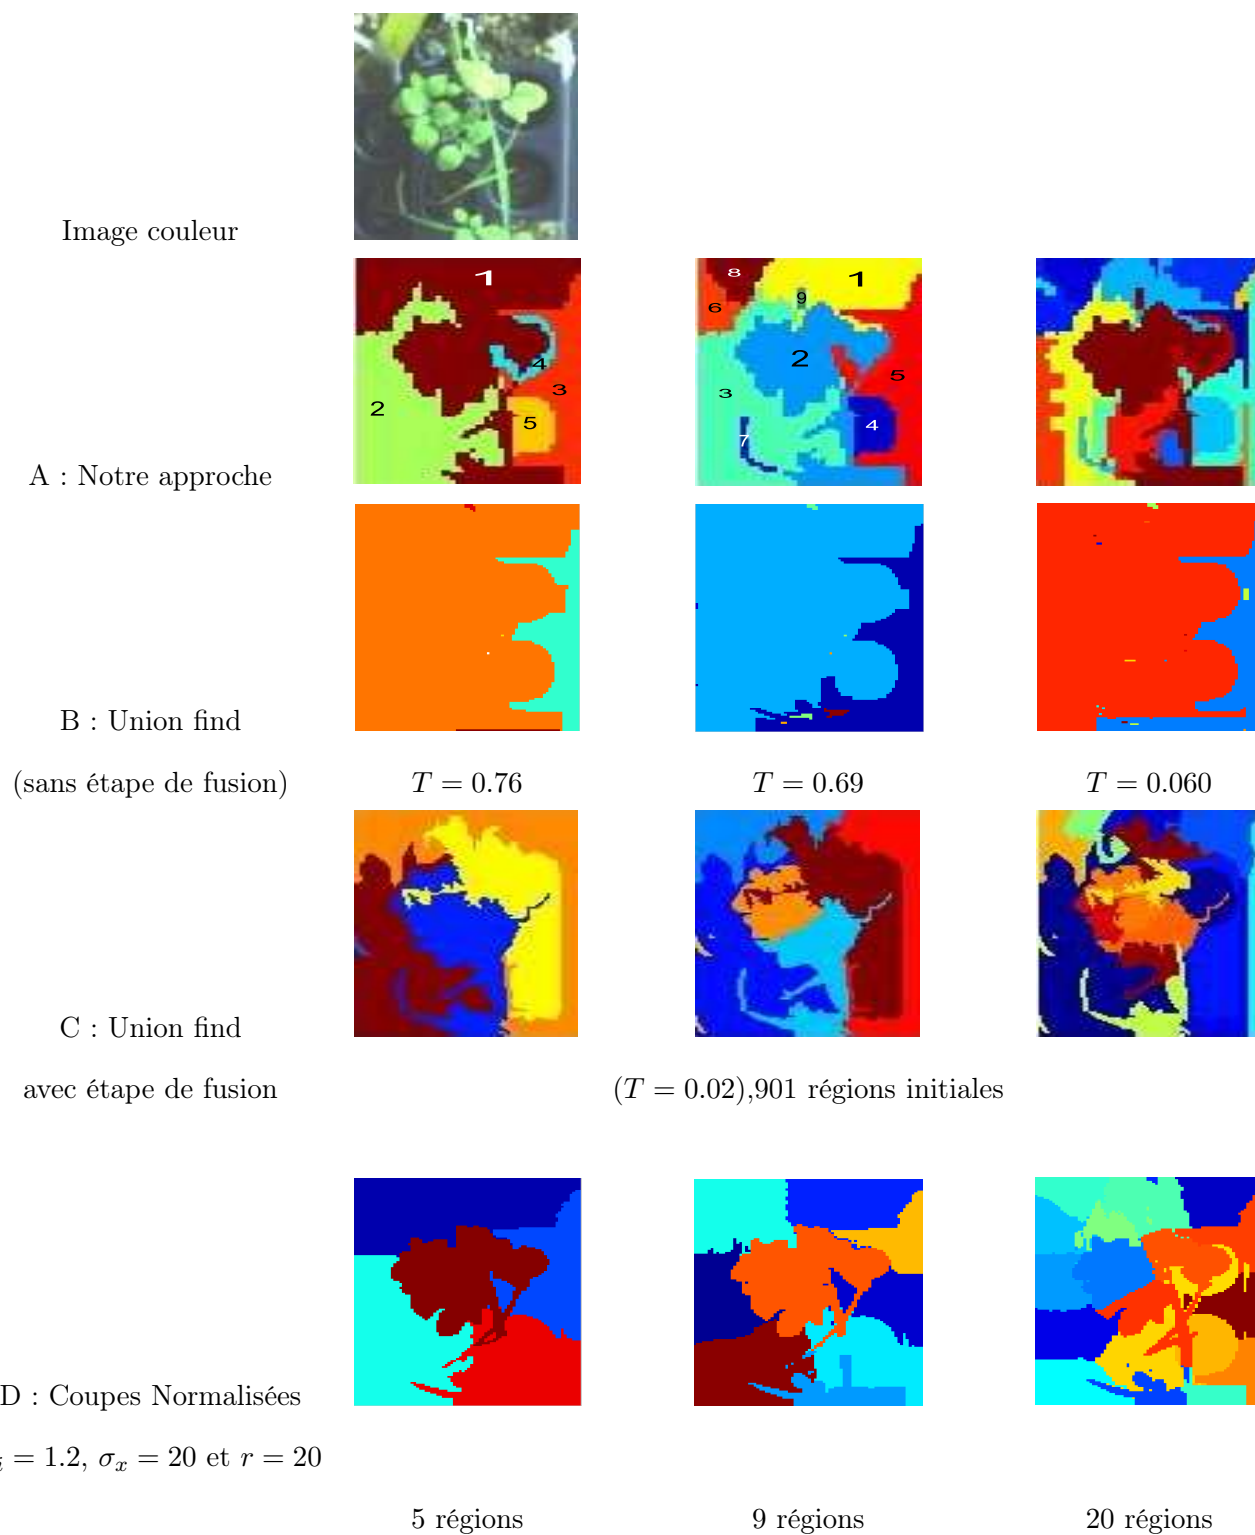


FIG. 4.25 – Segmentation de l'image Hypspx obtenues avec diverses approches et un nombre variable de régions finales.




FIG. 4.26 – Segmentation de l'image DAIS obtenue avec diverses approches et un nombre variable de régions finales.




FIG. 4.27 – Évolution du Λ de Wilks au cours de la phase de division et de fusion : en gras sur l'espace des variables latentes, en fin sur l'espace support (espace complet initial)

sera toujours ces deux structures spectrales. Ainsi, le nombre de structures spectrales présentes dans l'image pourra *a priori* être donné par une mesure de l'évolution de ces vecteurs. A titre d'exemple, nous donnons figures 4.28 et 4.29, l'évolution des huit premiers vecteurs propres au cours d'une phase de fusion réalisée sur l'image *IR1* et comportant 12 pas (la phase de division réalisée avec l'approche par coupes normalisées, comporte 15 phases et aboutit donc à 16 régions, les 13 pas de fusion aboutiront donc à une segmentation finale comportant 3 régions). Le nombre de vecteurs propres à chaque pas a été fixé au maximum possible soit au nombre de classes moins 1. Ainsi, on peut constater que les trois premiers vecteurs propres ne subissent aucune évolution notable durant les 13 étapes de fusion. Le quatrième vecteur propre subit de

légères variations, celles-ci sont plus marquées pour le cinquième et sixième vecteur propre et deviennent importantes pour le septième et huitième vecteur propre. Ainsi, on peut attester que le nombre de régions présentes dans l'image est très certainement compris entre 5 et 6. La figure 4.30 montre le déroulement de l'étape de fusion. On peut constater qu'une segmentation en 5 ou 6 régions apparaît en effet pertinente pour cette image.







FIG. 4.28 – Évolution des 4 premiers vecteurs propres extraits au cours de la phase de fusion (13 pas)




Cinquième VP



Sixième VP



Septième VP



Huitième VP

FIG. 4.29 – Évolution des 4, 5, 6 et 8ème vecteurs propres extraits au cours de la phase de fusion (13 pas)

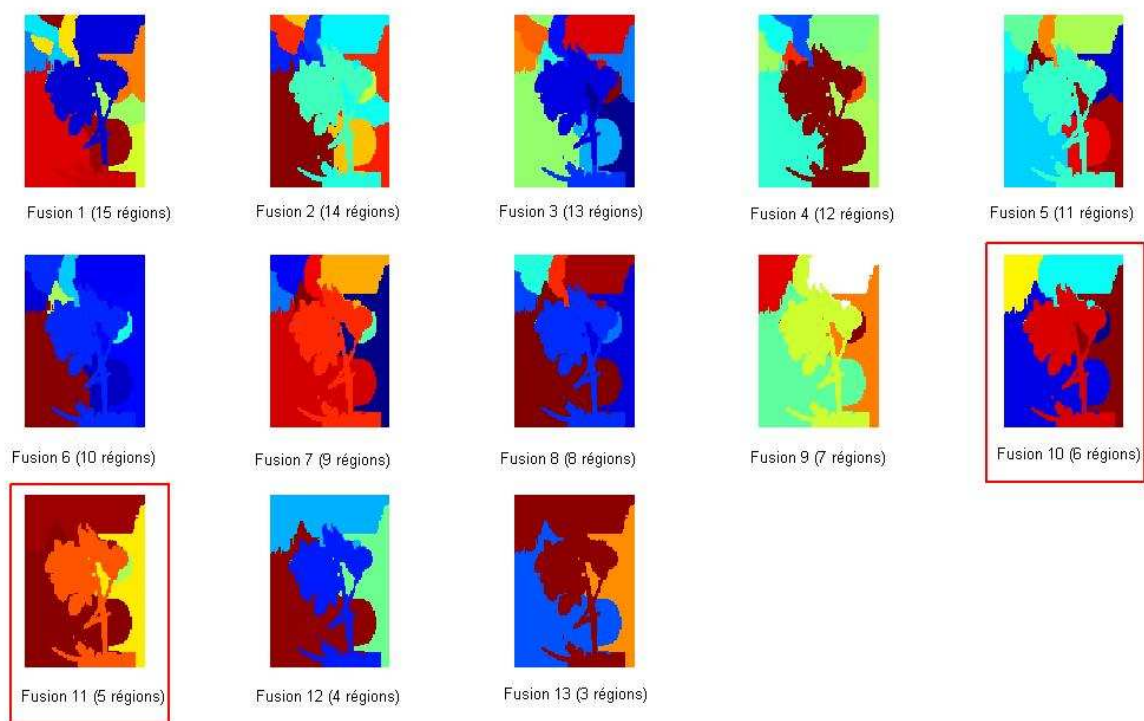


FIG. 4.30 – Évolution de la segmentation de l'image *IR1* au cours du processus de fusion

Chapitre 5

Conclusions et perspectives

5.1 Conclusions

Le Cemagref s'intéresse depuis de nombreuses années à la caractérisation des productions agricoles. Celle-ci consiste, en autres, à caractériser les agro ou éco-systèmes c'est-à-dire à proposer des indicateurs pertinents sur le plan agronomique pour en permettre une gestion raisonnée et durable (évaluation des impacts des productions agricoles, évaluation de la qualité...). L'utilisation d'outils optiques tels que la vision numérique ou la spectrométrie permet d'obtenir des résultats encourageants mais se heurte à la complexité des scènes naturelles (variabilité, conditions d'éclairage...) ou encore aux limites propres à ces technologies i.e. mesure spatiale mais limitée spectralement pour la vision numérique et mesure spectrale mais localisée pour la spectrométrie. L'imagerie hyperspectrale, qui consiste à acquérir des images d'une même scène à travers plusieurs dizaines de bandes spectrales consécutives, permet de disposer d'un spectre complet pour chaque pixel de la scène visualisée. Cette richesse d'information spectrale est particulièrement attractive dans le cadre de nos activités, dès lors que nous traitons des objets biologiques, dotés de propriétés spectrales spécifiques.

Cependant, on constate dans la littérature scientifique du domaine, que dans la majorité des cas, l'image hyperspectrale n'est considérée que comme la juxtaposition d'informations spectrométriques. Les pixels sont alors traités individuellement comme un simple tableau de mesures spectrales sans prendre en compte leurs relations de voisinage et les corrélations qu'elles sous-

entendent. *L'objectif principal de la thèse était donc de proposer un mode de traitement tirant parti des deux dimensions disponibles.*

Cependant, préalablement à la réalisation des ces travaux, la mise en oeuvre de dispositifs expérimentaux et leur étalonnage est apparu essentiel pour la réalisation d'une banque d'images de bonne qualité. Les phénomènes de déformation spatiale, d'aberration chromatique et de vignettage inhérent à notre système d'imagerie (i.e. caméra munie d'un filtre variable ou LCTF ⁸) devaient être impérativement pris en compte. Les premiers travaux théoriques ont donc porté sur la modélisation de la chaîne d'acquisition puis sur la mise au point d'une méthode originale de détermination du vignettage basée sur la transformée de Fourier. Ces approches n'ont toutefois pas permis de résoudre en totalité les variabilités spectrales et spatiales observées. Ces travaux ont toutefois mis en évidence les insuffisances de la technologie employée en terme de qualité optique et de reproductibilité.

Dans un deuxième temps, nous nous sommes attachés au cœur de la thèse c'est-à-dire au développement d'une méthode de segmentation non supervisée d'images hyperspectrales. Nous sommes partis du constat (posé suite à la réalisation d'une revue bibliographique sur le sujet) que pour obtenir une segmentation optimale au sens de nos applications, l'approche développée devait satisfaire impérativement les critères suivants :

- Réaliser une réduction de dimension,
- Tenir compte des contraintes liées à l'approche de traitement ultérieur dans cette approche de réduction,
- Etablir une réelle équité de traitement entre espaces spectral et spatial de façon à ne privilégier aucun espace par rapport à l'autre et ainsi profiter de toute l'information disponible
- Utiliser des outils dédiés et donc adaptés à chacun des espaces i.e. outils chimiométriques pour l'espace spectral et outils de segmentation d'images pour l'espace spatial.

Nous avons ainsi proposé un schéma générique itératif, appelé " papillon ", mettant en oeuvre :

✓ côté spectral une approche de réduction de données permettant d'extraire des structures

⁸Liquid Crystal Tunable Filter

spectrales i.e. un ensemble de spectres communs à toute l'image
 √ côté spatial une approche de segmentation d'images permettant d'extraire des structures spatiales i.e. une partition de l'image.

L'idée essentielle est qu'à travers le processus itératif et une collaboration des deux espaces au travers les structures extraites, l'espace spectral est peu à peu érodé au regard de l'espace spatial et vice-versa.

Nous avons suggéré un schéma d'implémentation utilisant un processus de division suivi d'un processus de fusion dans lequel le lambda de Wilks permet de décider des divisions ou de fusions les plus opportunes et avons préconisé et justifié les valeurs de réglage d'un certains nombre de paramètres tels que le nombre de variables latentes à utiliser dans la phase de division et de fusion mais aussi le nombre de divisions et de fusions à réaliser à chaque pas de la procédure. Nous avons ensuite validé et testé le schéma du papillon à l'aide de cette implémentation dans un procédé utilisant la diagonalisation des matrices de variances inter et intra (respectivement pour les phases de division et fusion) et trois approches de segmentation d'images sur des images de synthèses puis réelles à différentes échelles (image de proxi-détection et image aéroportée). La phase de validation a permis d'une part de montrer la capacité de notre approche à prendre en compte les dimensions spectrale et spatiale des données mais également de prouver la pertinence des préconisations données. La phase de test a permis de constater que l'approche développée aboutit à des résultats de segmentation intéressants de façon non supervisée et ceci à deux échelles de travail .

5.2 Perspectives

L'approche de segmentation d'images hyperspectrales que nous avons proposée, basée sur un schéma itératif s'avère intéressante car elle permet effectivement de prendre en compte les dimensions spatiales et spectrales des données en respectant l'ensemble des contraintes que nous nous étions imposés suite à l'état de l'art. Plusieurs travaux peuvent cependant être engagés pour compléter cette approche, la rendre plus performante ou l'adapter à de nouvelles problématiques.

Ainsi, la méthode implémentée sous sa forme actuelle peut être largement améliorée en uti-

lisant une approche de segmentation descendante adaptée à la notion de coupe. Nous avons, en effet, pu constater qu'aucune des méthodes proposées (i.e. division quadtree, coupes normalisées avec contrainte spatiale, ligne de partage des eaux) n'est vraiment adaptée à cette étape. Ainsi, la division quad-tree a un découpage rigide qui marque considérablement les résultats de la segmentation finale. L'approche par coupes normalisées, du fait de sa nature d'approche de classification et malgré l'utilisation d'un noyau intégrant une contrainte spatiale, ne permet pas de garantir la connexité des régions. Enfin, l'approche par Ligne de Partage des Eaux modifiée aboutit à une sur-segmentation qu'il est possible de réduire drastiquement mais au prix d'un coût algorithmique très important. Ainsi, il nous semble important de réfléchir à une approche de segmentation plus optimale au sens de l'obtention d'une coupe. L'approche par graphe (coupes normalisées) et les techniques de classification afférentes (partitionnement spectral) semblent particulièrement intéressantes. On pourra ainsi réfléchir à la définition d'un noyau permettant de garantir la connexité des régions.

Un aspect intéressant de notre approche est sa généralité. Ainsi, il est possible en utilisant d'autres outils de réduction de données ou de traitement d'images de l'adapter à des problématiques particulières en s'intéressant à d'autres notions topologiques. Par exemple, dans l'implémentation proposée, nous nous sommes attachés à définir une approche permettant d'extraire côté spectral et spatial des structures en adéquation avec une notion de topologie i.e. la notion de région. Ainsi, l'extraction de ces structures s'effectue en utilisant une contrainte d'homogénéité. Nous pourrions étendre ou compléter celle-ci à l'aide d'informations concernant les contours des régions à extraire. Cependant, dans l'implémentation proposée, ces informations, du fait de l'étape de division utilisant le concept de coupe, sont limitées et peuvent concerner uniquement des contraintes de régularité. Des informations de forme, par exemple, ne peuvent être intégrées. A titre d'exemple, nous donnons figure 5.1 une implémentation du papillon pouvant gérer ce type de contrainte dans un contexte applicatif concernant la détection de fruits et de feuilles (deux classes). Ainsi, côté spectral, une première partition grossière obtenue par exemple par une approche k-means suivie d'une étape de sélection de zone de l'image appartenant de façon sûre à

une des deux classes (indice de végétation par exemple) est le point d'entrée d'une approche de réduction de dimension permettant d'obtenir un sous espace vectoriel optimisant la séparation inter-classe. L'image score obtenue par projection de l'image originale sur ce sous espace vectoriel permet de raffiner par une approche de segmentation adaptée utilisant des contraintes de forme (par exemple forme circulaire ou ellipsoïde des objets) et/ou d'homogénéité la partition initiale et ainsi de suite.

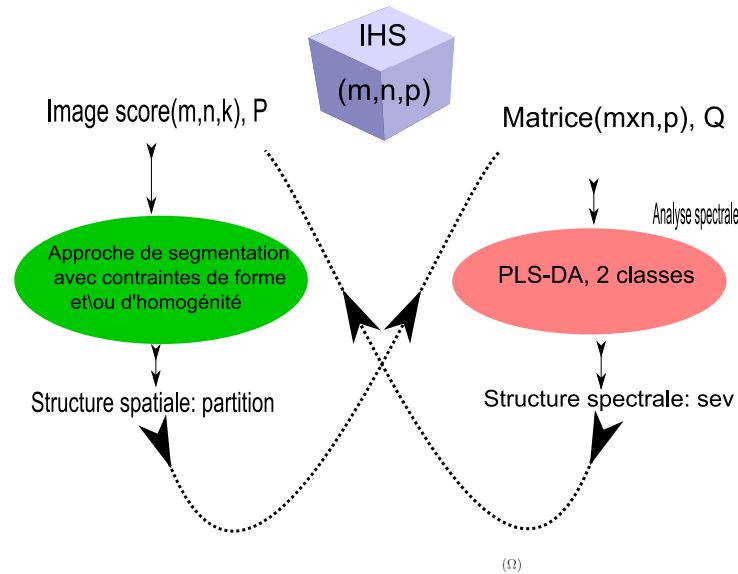


FIG. 5.1 – Une implémentation du papillon permettant de gérer des contraintes liées à la forme des objets

Pour finir et quelle que soit l'implémentation choisie il sera important de s'intéresser à des approches algorithmiques de faible complexité en temps et en mémoire. Le fait de travailler sur des images hyperspectrales et qui plus est avec un processus itératif (schéma du papillon) nécessite l'utilisation de procédures algorithmiques particulièrement peu gourmandes en temps de calcul et réalisant une gestion efficace de la mémoire. Ce souci a été constant tout au long de ces travaux mais nécessite des approfondissements. Dans un contexte applicatif, le développement d'algorithmes performants et réalisant une gestion mémoire efficace est une étape indispensable.

Annexe A

Algorithme LPE modifié

Algorithme LPE modifié

Objectif

L'objectif est de développer un algorithme de division en deux parties (coupe) d'une image en niveaux de gris (image score), qui soit bien adaptée à une utilisation dans le cadre d'un algorithme de segmentation descendant et de l'étape de division du schéma du papillon.

Principe



Le principe général est inspiré de l'algorithme de partage des eaux de Vincent et Soille [Vincent and Soille, 1991] par simulation d'immersion, mais adapté de façon à s'arrêter à l'obtention de deux régions. L'algorithme se décompose en plusieurs étapes qui sont décrites ci-après et par la figure A.1.

- La première étape applique classiquement l'algorithme de partage des eaux sur le gradient de l'image obtenu par filtrage de Deriche et permet d'associer à chaque minima local (un pixel ou un ensemble de pixels connexes dans le cas d'un minimum en plateau) un bassin versant. Les frontières des bassins versants et donc les contours des régions sont ainsi définies.
- Une étape de watershed inversé, où le relief (image à niveaux de gris de la norme du gradient

de l'image originale) est totalement immergé puis, le niveau d'eau est progressivement abaissé jusqu'à obtention d'au moins deux régions distinctes. Ces régions sont disjointes et ne permettent la formation d'une bipartition de la région ou de l'image initiale. L'une peut éventuellement entourer l'autre.


- La dernière étape a pour objectif de fournir une bipartition de l'image ou de la région initiale. Elle utilise pour cela les résultats obtenus lors des deux étapes précédentes, i.e. étape 1 : minima locaux et bassins versants associés, étape 2 : deux régions non jointives. Ainsi, pour chaque région issue de l'étape 2, on recherche dans l'ensemble des minima obtenus à l'étape 1 ceux qui l'intersecte puis on calcule l'union de tous les bassins correspondants. C'est l'union de ces bassins qui constitue la région finale.

Remarque : L'implémentation de cette stratégie nécessite la gestion, à chaque étape de division, d'une nouvelle image i.e. une région initiale. Cela impose, en particulier, d'adapter la dynamique de travail à chaque pas de division. On doit donc d'une part réaliser l'étape 2 en calculant une norme de gradient "adaptée" à la région en cours et d'autre part, par soucis de cohérence (modification du sous espace vectoriel), recalculé un watershed complet sur l'image entière. Cela conduit à une procédure lourde en temps de calcul.



Etape 1 : watershed

Etape 2 : processus de descente des eaux



Union des résultats de l'étape 1 et 2

FIG. A.1 – Illustration du principe de l'algorithme LPE modifié utilisé pour obtenir une bipartition de l'image ou d'une région

Annexe B

Optimisation pour le calcul de l'inertie à chaque itération

Les algorithmes, tel que décrit chapitre 3 section 3.4.2 , sont très gourmands en temps de calcul. Leur optimisation était donc absolument nécessaire.

Dans les deux phases, la partie la plus rentable à optimiser, parce qu'elle est répétée souvent est le calcul de λ_i . Dans la boucle de recherche de la meilleure division ou de la meilleure fusion, l'espace spectral est toujours le même, à savoir celui des variables latentes. Le dénominateur du Lambda de Wilks (la trace de l'inertie totale) est donc constant. Une première optimisation a donc consisté à ne calculer que le numérateur du Lambda de Wilks, c'est à dire la trace de l'inertie inter classes. Une deuxième optimisation a consisté à calculer la variation d'inertie inter classes due à la division ou à la fusion. Soit $\mathbf{G}_{(r,p)}$ la matrice des centres de gravité (dans l'espace spectral) des r classes et $\mathbf{N}_{(r,r)}$ la matrice diagonale contenant les effectifs des r classes. On montre facilement que :

$$\mathbf{B} = \mathbf{G}^T \mathbf{N} \mathbf{G}$$
$$\mathbf{B} = \sum_{i=1}^p n_i \mathbf{g}_i \mathbf{g}_i^T$$

En d'autre termes, la contribution de la classe i à l'inertie inter classes est le produit externe de son vecteur centre de gravité par lui même, pondéré par l'effectif de la classe. Comme la trace

d'une somme de matrices est la somme des traces, on a :

$$\begin{aligned}\text{trace}(\mathbf{B}) &= \sum_{i=1}^p n_i \text{trace}(\mathbf{g}_i \mathbf{g}_i^T) \\ \text{trace}(\mathbf{B}) &= \sum_{i=1}^p n_i \mathbf{g}_i^2\end{aligned}$$

La contribution de la classe i à la trace de l'inertie inter classes est donc le carré de la norme de son vecteur centre de gravité, pondéré par l'effectif de la classe. Partant de cette propriété, l'optimisation de l'algorithme a consisté (en reprenant les notations précédemment employées) :

- Pour une phase de division, à remplacer le calcul de λ_i , par : $\lambda_i = \sum_{j=1}^q n_{A_j} \mathbf{g}_{A_q}^2 - \sum_{j=1}^q n_{A_j} \mathbf{g}_{R_i}^2$
- Pour une phase de fusion, à remplacer le calcul de λ_i , par : $\lambda_i = n_R \mathbf{g}_R^2 - n_{R_i} \mathbf{g}_{R_i}^2 - n_{R_j} \mathbf{g}_{R_j}^2$

où \mathbf{g}_X est le vecteur (de dimension p) du centre de gravité de la région X , dans l'espace spectral et n l'effectif de la région X .

Annexe C

Contributions de l'auteur

C.1 Contributions de l'auteur

Publication dans des revues internationales à comité de lecture

[RI1] **Gorretta, N.** and Roger, J-M. and Aubert, M. and Campan, F. and Roumet, P. and Bellon-Maurel, V. *Determining vitreousness of durum wheat kernels using near infrared hyperspectral imaging*. J. Near Infrared Spectrosc. 14(4), 231239 (2006).

[RI2] **Gorretta, N.** and Rabatel, G. and Fiorio, C. and Roger, J-M. and Lelong, C. and Bellon-Maurel, V. *Hyperspectral imaging system calibration using image translations and Fourier transform*. J. Near Infrared Spectrosc. 16(4), 371380 (2008).

Publication dans des revues nationales à comité de lecture

[RN1] **Gorretta, N.** and Rabatel, G. and Fiorio, C. and Roger, J-M. and Lelong, C. and Bellon-Maurel, V. *Proposition d'une stratégie de segmentation d'images hyperspectrales*. Revue traitement du signal, Numéro spécial télédétection, Accepté pour publication, 2008.

Présentation à des conférences internationales à comité de lecture

[CI1] Bellon-Maurel, V. and **Gorretta, N.** and Rabatel, G. and Roger, J-M. From Multispectral to Hyperspectral Imaging for Analysing Agricultural Product Quality : A critical review and Opportunities. 12th International Conference on Near-Infrared Spectroscopy, Auckland, New Zealand (2005).

[CI2] **Gorretta, N.** and Roger, J-M. and Bellon-Maurel, V. *Hyperspectral Imaging : An Alternative Calibration Method.* 12th International Conference on Near-Infrared Spectroscopy, Auckland, New Zealand (2005).

[CI3] **Gorretta, N.** and Rabatel, G. and Roger, J-M. and Bellon-Maurel, V. *Hyperspectral Imaging : A review of segmentation methods* EASIM Conference : hyperspectral imaging, Gembloux, Belgium (2-3 March, 2009).

Groupe de travail

[WS1] **Gorretta, N.** and Rabatel, G. and Roger, J.M. and Bellon-Maurel, V. *Estimation of NIR hyperspectral imaging system response by image shifting and Fourier transform.* Workshop on hyperspectral imaging, Umeå Sweden, 14-16 february (2006).

Bibliographie

- [Baillie, 2005] Baillie, J. (2005). Cours de segmentation (e322).
- [Bali and Mohammad-Djafari, 2008] Bali, N. and Mohammad-Djafari, A. (2008). Bayesian approach with hidden markov modeling and mean field approximation for hyperspectral data analysis. *IEEE Transactions on Image Processing*, 17(2) :217–225.
- [Bandyopadhyay, 2005] Bandyopadhyay, S. (2005). Satellite image classification using genetically guided fuzzy clustering with spatial information. *International Journal of Remote Sensing*, 26(3) :579–593.
- [Bariou et al., 1985] Bariou, R., Lecanu, D., and Le Hennaff, F. (1985). Indices de végétation. *Dossiers de la télédétection*, 2.
- [Beaulieu and Godberg, 1989] Beaulieu, J. and Godberg, M. (1989). Hierarchy in picture segmentation : a stepwise optimization approach. *IEEE Transactions on pattern analysis and machine intelligence*, 11(2) :150–163.
- [Bechdol et al., 2000] Bechdol, M. A., Gualtieri, J. A., Hunt, J. T., Chettri, S., and Garegnani, J. (2000). Hyperspectral imaging : a potential tool for improving weed and herbicide management. In *The 5th International Conference on Precision Agriculture*, Madison, WI, USA.
- [Bellman, 1957] Bellman, R. (1957). *Dynamic programming*. Princeton University Press.
- [Bellon et al., 1992] Bellon, V., Vigneau, J., and Leclercq, M. (1992). Feasibility and performances of a new, multiplexed, fast and low-cost fiber optic NIR spectrometer for the on-line measurement of sugars in fruits. *Applied Spectroscopy*, 47(7) :1079–1083.
- [Bellon-Maurel and Dubois, 2008] Bellon-Maurel, V. and Dubois, J. (2008). Nir hyperspectral

imaging in food and agricultural science. In Siesler, R. S. and Hanz, editors, *"Infrared and Raman Spectroscopic Imaging*. Wiley-VCH.

[Benediktsson et al., 2005] Benediktsson, J., Palmason, J., and Sveinsson, J. (2005). Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3) :480–491.

[Beucher and Lantuejour, 1979] Beucher, B. and Lantuejour, C. (1979). Use of watersheds in contour detection. In *The international workshop on image processing : real time and motion detection/estimation*, Rennes, France.

[Beyer et al., 1994] Beyer, K., J., G., Ramakrishnan, R., and , S. U. (1994). When is "nearest neighbor" meaningful. In *Proceedings of the 7th International Conference on Database Theory (ICDT)*, volume 1, pages 217 – 235.

[Bezdek, 1981] Bezdek, J. (1981). *Pattern recognition with fuzzy objective functions*. Plenum Press, New York.

[Bezerra, 2001] Bezerra, F. (2001). *Opérateurs topologiques pour le traitement d'images en niveaux de gris*. PhD thesis, Université de Marne la Vallée, France.

[Bossu, 2007] Bossu, J. (2007). *Segmentation d'images pour la localisation d'adventices. Application à la réalisation d'un système de vision pour une pulvérisation spécifique en temps réel*. PhD thesis, Université de Bourgogne, France.

[Burks et al., 2000] Burks, T. F., Shearer, S. A., and Payne, F. A. (2000). Classification of weed species using color texture features and discriminant analysis. *Transactions of the ASAE*, 43(2) :441–448.

[Camps-Valls et al., 2006a] Camps-Valls, G., Gomez-Chova, L., Calpe, J., Soria, E., Martin, J., Alonso, L., and Moreno, J. (July,2006a). Robust vector support method for hyperspectral data classification and knowledge discovery. *IEEE Transactions on Geoscience and Remote sensing*, 42(8) :1530–1542.

[Camps-Valls et al., 2006b] Camps-Valls, G., Gomez-Chova, L., Munoz-Mari, J., Vila-Frances,

-
- J., and Calpe-Maravilla, J. (2006b). Composite kernels for hyperspectral image classification. *Geoscience and Remote Sensing Letters*, 3(1) :93–97.
- [Chabrier et al., 2006] Chabrier, S., Emile, B., Rosenberger, C., and Laurent, H. (2006). Unsupervised performance evaluation of image segmentation. *EURASIP Journal on Applied Signal Processing*, 2006(1) :217–217.
- [Chang, 2007] Chang, C. (2007). *Hyperspectral Data Exploitation*. Wiley Edition.
- [Chao et al., 2001] Chao, K., Chen, Y., Hruschka, W., and Park, B. (2001). Chicken heart disease characterization by multi-spectral imaging. *Applied Engineering in Agriculture*, 17(1) :99–106.
- [Chao et al., 2002] Chao, K., Mehl, P., and Chen, Y. (2002). Use of hyper and multi-spectral imaging for detection of chicken skin tumors. *Transactions of the Asae*, 18(1) :113–119.
- [Chauchard et al., 2004] Chauchard, F., Cogdill, R., Roussel, S., Roger, J., and Bellon-Maurel, V. (2004). Application of LS-SVM to non-linear phenomena in NIR spectroscopy : development of a robust and portable sensor for acidity prediction in grapes. *Chemometrics and Intelligent Laboratory Systems*, 71 :141–150.
- [Chion et al., 2008] Chion, C., Landry, J., and Da Costa, L. (2008). A genetic-programming-based method for hyperspectral data information extraction : Agricultural applications. *IEEE Transactions on Geoscience and Remote Sensing*, 46(8) :2446–2457.
- [Chuang et al., 2006] Chuang, K., Tzeng, H., Chen, S., Wu, J., and Chen, T. (2006). Fuzzy c-means clustering with spatial information for image segmentation. *Computerized Medical Imaging and Graphics*, 30(1) :9–15.
- [Clark, 1995] Clark, R. (1995). *AGU handbook of physical constants*, chapter Reflectance spectra, pages 178–188.
- [Coquerez, 1995] Coquerez, J. (1995). *Analyse D’images - Filtrage Et Segmentation*. Masson.
- [Couprie, 2004] Couprie, M. (2004). *Notions et opérateurs topologiques pour le traitement d’images, Habilitation à diriger des recherches soutenue le 25 Juin 2004 à l’Institut Gaspard Monge*. Habilitation, Institut Gaspard Monge.

- [De Jong et al., 2001] De Jong, S., Hornstra, T., and Maas, H. (2001). An integrated approach to the classification of mediterranean land cover types : the SSC method. *International Journal for Applied Earth Observation and Geo-information*, 3(2) :176–183.
- [Dell’Acqua et al., 2004] Dell’Acqua, F., Gamba, P., Ferrari, A., Palmason, J., and Benediktsson, J. (2004). Exploiting spectral and spatial information in hyperspectral urban data with high resolution. *IEEE Geoscience and Remote Sensing Letters*, 1(4) :322–326.
- [Derras et al., 1994] Derras, M., Debain, C., Berducat, M., Bonton, P., and Galice, J. (1994). Unsupervised Regions Segmentation : Real Time Control of an Upkeep Machine of Natural Spaces. pages 207–212.
- [Dhillon et al., 2007] Dhillon, I., Guan, Y., and Kulis, B. (2007). Weighted graph cuts without eigenvectors : a multilevel approach. *IEEE Transactions on pattern analysis and machine intelligence*, 29(11) :1944–1957.
- [Digabel and Lantujoul, 1978] Digabel, H. and Lantujoul, C. (1978). Iterative algorithm. *Quantitative analysis of microstructures in materials sciences*, 1 :8599.
- [Dowell, 2000] Dowell, F. (2000). Differentiating vitreous and nonvitreous durum wheat kernels by using near-infrared spectroscopy. *Cereal chemical*, 77(2) :155–158.
- [Du and Sun, 2004] Du, C. J. and Sun, D. W. (2004). Recent developments in the applications of image processing techniques for food quality evaluation. *Trends in Food Science and Technology*, 15(5) :230–249.
- [Duarte-Carvajalino et al., 2006] Duarte-Carvajalino, J., Vález-Reyes, M., and Castillo, P. (2006). Scale-space in hyperspectral image analysis. volume 6233, pages 344–345.
- [Enberg and Boonaert, 2008] Enberg, B. and Boonaert, B. (2008). Coupes normalisées et segmentation d’images.
- [Evans and Liu, 2006] Evans, A. and Liu, X. (2006). A morphological gradient approach to color edge detection. *IEEE Transactions on Image Processing*, pages 1454–1463.
- [Fauvel, 2007] Fauvel, M. (2007). *Spectral and Spatial Methods for the Classification of Urban Re-*

mote Sensing Data. PhD thesis, Grenoble Institute of Technology and Faculty of Engineering, University of Iceland.

- [Fauvel et al., 2007] Fauvel, M., Chanussot, J., and Benediktsson, J. (2007). Classification en imagerie hyperspectrale haute résolution : utilisation conjointe de l'information spatiale et spectrale. In *Colloque GRETSI*, pages 737–740, Troyes, France.
- [Fiorio and Gustedt, 1996] Fiorio, C. and Gustedt, J. (1996). Two linear time union-find strategie for image processing. In *Theoretical Computer Sciences*, 54 :165–181.
- [Ford and Fulkerson, 1962] Ford, L. and Fulkerson, D. (1962). *Flows in Network*. Princeton Unviersity Press.
- [Fowlkes et al., 2004] Fowlkes, C., Belongie, S., Chung, F., and Malik, J. (2004). Spectral grouping using Nyström method. *IEEE Transactions on pattern analysis and machine intelligence*, 26(2) :1–12.
- [Friedman and Tukey, 1974] Friedman, J. and Tukey, J. (1974). A projection pursuit algorithm for exploratory data analysis. *IEEE Transactions on Computers*, 23 :881–889.
- [Gat, 2000] Gat, N. (2000). Imaging spectrometry using tunable filters : a review. *SPIE*, 4056 :50–64.
- [Geladi et al., 2004] Geladi, P., Burger, J., and Lestander, T. (2004). Hyperspectral imaging : calibration problems and solutions. *Chemometrics and Intelligent Laboratory Systems*, 72 :209–217.
- [Gerrish et al., 1997] Gerrish, J., Fehr, B., Van Eg, G., and Wetch, D. (1997). Self-steering tractor guided by computer vision. *Applied Engineering Agriculture*, 13 :559–563.
- [Goel et al., 2003a] Goel, P., Prasher, S., Landry, J., Patel, R., Bonnell, R., Viau, A., and Miller, J. (2003a). Potential of airborne hyperspectral remote sensing to detect nitrogen deficiency and weed infestation in corn. *Computers and Electronics in Agriculture*, 38(2) :99–124.
- [Goel et al., 2003b] Goel, P., Prasher, S., Landry, J.-A., Patel, R., Viau, A., and Miller, J. (2003b). Estimation of crop biophysical parameters through airborne and field hyperspectral

remote sensing. *Transactions of the American Society of Agricultural Engineers*, 46(4) :1235–1246.

[Gong and Shu, 2007] Gong, Y. and Shu, N. (2007). Texture segmentation of multispectral remote sensing image based on markov random field. *Geomatics and Information Science of Wuhan University*, 32(3) :212–215.

[Gorretta and Bellon-Maurel, 2001] Gorretta, N. and Bellon-Maurel, V. (2001). Détection des débris de noyaux sur oreillons de pêches par vision multispectrale. Technical report, Cemagref.

[Gorretta et al., 2008] Gorretta, N., Rabatel, G., Fiorio, C., Roger, J.-M., Lelong, C., and Bellon-Maurel, V. (2008). Hyperspectral imaging system calibration using image translations and fourier transform. *Journal of near infrared spectroscopy*.

[Gowen et al., 2007] Gowen, A., O'Donnell, C., Cullen, P., Downey, G., and Frias, J. (2007). Hyperspectral imaging an emerging process analytical tool for food quality and safety control. *Trends in Food Science and Technology*, 18(12) :590–598.

[Gualtieri and Chettri, 2000] Gualtieri, J. and Chettri, S. (2000). Support vector machines for classification of hyperspectral data. In *Geoscience and Remote Sensing Symposium (IGARSS)*, volume 2, pages 813–815, Honolulu, HI.

[Guan et al.,] Guan, Y., Guo, S., Liu, J., and Zhang, X. Application of airborne hyperspectral data for precise agriculture. In *International Geoscience and Remote Sensing Symposium (IGARSS)*.

[Hamid Muhammed and Larsolle, 2003] Hamid Muhammed, H. and Larsolle, A. (2003). Feature-vector based analysis of hyperspectral crop reflectance data for discrimination quantification of fungal disease severity in wheat. *Biosystems Engineering*, 86(2) :125–134.

[Hazel, 2000] Hazel, G. (2000). Multivariate gaussian mrf for multispectral scene segmentation and anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing (GRS)*, 38(3) :1199–1211.

[Horowitz and Pavlidis, 1974] Horowitz, S. and Pavlidis, T. (1974). Picture segmentation by a

-
- directed split-and-merge procedure. *Proceedings of the Second International Joint Conference on Pattern Recognition*, pages 424–433.
- [Huang et al., 2002] Huang, C., Davis, L., and Townshend, J. (2002). An assessment of support vector machine for land cover classification. *International Journal of Remote Sensing*, 23(4) :725–749.
- [Huang et al., 2008] Huang, T. Z., Huang, X. Q., and Jiang, Z. Y. (2008). Hyperspectral image labeling using mrf and gm models. *Dianzi Keji Daxue Xuebao/Journal of the University of Electronic Science and Technology of China*, 37(5).
- [Huang et al., 2004] Huang, Z., Turner, B., Dury, S., Wallis, I., and Foley, W. (2004). Estimating foliage nitrogen concentration from hmap data using continuum removal analysis. *Remote Sensing of Environment*, 93(1-2) :18–29.
- [Huete et al., 1997] Huete, A., Liu, H., Batchily, K., and Van Leeuwen, W. (1997). A comparison of vegetation indices over a global set of tm images for eos-modis. *Remote Sensing of the Environment*, 59(3) :440–451.
- [Hughes, 1968] Hughes, G. (1968). On the mean accuracy of statistical pattern recognizers. *IEEE Transaction Information Theory*, 14(1) :55–63.
- [Hyvärinen, 1999] Hyvärinen, A. (1999). Survey on independent component analysis. *Neural Computing Survey*, 2 :94–128.
- [Inoue and Peñuelas, 2001] Inoue, Y. and Peñuelas, J. (2001). An AOTF-based hyperspectral imaging system for field use in ecophysiological and agricultural applications. *international Journal of Remote Sensing*, 22(18) :3883–3888.
- [Jensen, 2000] Jensen, J. (2000). *Remote Sensing of the Environment and Earth Resource Perspective*. Geographic Information Science. Pearson Education, Prentice Hall edition.
- [Jimenez et al., 2005] Jimenez, L., Rivera-Medina, J., Rodriguez-Diaz, E., Arzuaga-Cruz, E., and Ramirez-Velez, M. (2005). Integration of spatial and spectral information by means of unsupervised extraction and classification for homogenous objects applied to multispectral and hy-

- perspectival data. In *Geoscience and Remote Sensing, IEEE Transactions on*, volume 4, pages 844–851.
- [Karimi et al., 2006] Karimi, Y., Prasher, S. O., Patel, R. M., and Kim, S. H. (2006). Application of support vector machine technology for weed and nitrogen stress detection in corn. *Computers and Electronics in Agriculture*, 51(1-2) :99–109.
- [Kawano et al., 1989] Kawano, S., Watanabe, H., and Iwamoto, M. (1989). Measurement of Sugar content In Intact peaches by NIRS. In Iwamoto and Kawano, National Food Research Institute, editor, *The Second International Near infrared Spectroscopy Conference*, pages 343–352, Tsukuba, Japan.
- [Keshava, 2004] Keshava, N. (2004). Distance metrics and band selection in hyperspectral processings with applications to material identification and spectral libraries. *IEEE Transactions on geoscience and remote sensing*, 42(7) :1552–1565.
- [Kettig and Landgrebe, 1977] Kettig, R. and Landgrebe, D. (1977). Classification of multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on geoscience Electronics*, GE-14(1) :12–29.
- [Koch et al., 1990] Koch, B., Ammer, U., Schneider, T., and Wittmeier, H. (1990). Spectroradiometer measurements in the laboratory and in the field to analyse the influence of different damage symptoms on the reflection spectra of forest trees. *International Journal of Remote Sensing*, 11(7) :1145 – 1163.
- [Koehler et al., 2002] Koehler, F., Lee, E., Kidder, L., and Lewis, E. (2002). Near infrared spectroscopy : The practical chemical imaging solution. *Spectroscopy Europe*, 14(3) :12–19.
- [Kohler et al., 2004] Kohler, D., Bissett, W., Steward, R., and Davis, C. (2004). New approach for the radiometric calibration of spectral imaging systems. *Optics express*, 12(11) :2463–2477.
- [Kong and Rosenfeld, 1989] Kong, T. Y. and Rosenfeld, A. (1989). Digital topology : introduction and survey. *Computer Vision, Graphics, and Image Processing*, 48(3) :357–393.
- [Kraft et al., 1996] Kraft, M., Weigel, H., Mejer, G., and Brandes, F. (1996). Reflectance measu-

-
- rements of leaves for detecting visible and non-visible ozone damage to crops. *Journal of Plant Physiology*, 148 :148–154.
- [Kruse, 2000] Kruse, F. (2000). Introduction to hyperspectral data analysis. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Honolulu, HI, USA.
- [Landgrebe, 1980] Landgrebe, D. (1980). The development of a spectral-spatial classifier for earth observational data. *Pattern Recognition Letters*, 12(3) :165–175.
- [Lebart et al., 1984] Lebart, L., Morineau, A., and Warwick, K. (1984). *Multivariate Descriptive Statistical Analysis*. Wiley and Sons, New York.
- [Lee et al., 1990] Lee, J., Woodyatt, S., and Berman, M. (1990). Enhancement of high spectral resolution remote sensing data by noise-adjusted principal component transform. *IEEE Transactions on Geoscience and Remote Sensing*, 28(3) :295–204.
- [Lelong et al., 1998] Lelong, C., Pinet, P., and Poilve, H. (1998). Hyperspectral imaging and stress mapping in agriculture : a case study on wheat Beauce (France). *Remote Sensing of Environment*, 66 :179–181.
- [Lennon, 2002] Lennon, M. (2002). *Méthodes d’analyses d’images hyperspectrales ; Exploitation du capteur aéroporté CASI pour des applications de cartographie agro-environnementales en Bretagne*. PhD thesis, Université de Rennes 1, France.
- [Li and Xiao, 2007] Li, P. and Xiao, X. (2007). Multispectral image segmentation by a multichannel watershed-bases approach. *International Journal of Remote Sensing*, 28(19-20) :4429–4452.
- [Li, 1995] Li, S. (1995). *Markov Random Field Modeling in Computer Vision*. Springer-Verlag.
- [Malthus and Madeira, 1993] Malthus, T. and Madeira, A. (1993). High resolution spectroradiometry : spectral reflectance of field bean leaves infected by botrytis fabae. *Remote Sensing of Environment*, 45 :107–116.
- [Manh, 2001] Manh, A. (2001). *Modèles déformables pour la reconnaissance d’adventices*. PhD thesis, Université de Montpellier II, France.
- [Martin-Chefson et al., 1999] Martin-Chefson, L., Chapron, M., Philipp, S., Assémat, L., and Boisard, L. (1999). A two-dimensional method for recognising weeds from multiband image pro-

cessing. In *2nd european conference on precision agriculture*, pages 473–483, Odense, Denmark. Sheffield academic press ; sheffield UK.

[Martinsen and Shaare, 1998] Martinsen, P. and Shaare, P. (1998). Measuring soluble solids distribution in kiwifruit using near-infrared imaging spectroscopy. *Postharvest Biology and Technology*, 14 :271281.

[Marty-Mahe et al., 2002] Marty-Mahe, P., Loisel, P., Brossard, D., Monin, D., and Santé, V. (2002). Color image analysis method for prediction of turkey carcass meat transformation yield. In *First European Conference on Color in Graphics, Image and Vision, CGIV' 2002*, Poitiers, France.

[McDonald et al., 2003] McDonald, S., Niemann, K., Goodenough, D., Dyk, A., West, C., and Tian Han Murdoch, M. (2003). Hyperspectral remote sensing of conifer chemistry and moisture. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, volume 1, pages 552–554, Toulouse, France.

[Melgani and Bruzzone, 2004] Melgani, F. and Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machine. *IEEE Transactions on geoscience and remote sensing*, 42(8) :1778–1790.

[Mercier et al., 2003] Mercier, G., Derrode, S., and Lennon, M. (2003). Hyperspectral image segmentation with markov chain model. In IEEE, editor, *Geoscience and Remote Sensing Symposium (IGARSS)*, volume 6, pages 3766– 3768, Toulouse, France.

[Meyer, 1991] Meyer, F. (1991). Un algorithme optimal de ligne de partage des eaux. In *8ème Congrès AFCET Reconnaissance des Formes et Intelligence Artificielle*, page 847857.

[Miller and Delwiche, 1991] Miller, B. and Delwiche, M. (1991). Spectral analysis of peach surface defects. *Transactions of ASAE*, 34(6) :2509–2515.

[Moran et al., 1997] Moran, M., Inoue, Y., and Barnes, E. (1997). Opportunities and limitations for image-based remote sensing in precision crop management. *Remote Sensing of Environment*, 61(3) :319–346.

[Noordam and Broek, 2002] Noordam, J. C. and Broek, W. V. d. (2002). Multivariate image seg-

-
- mentation based on geometrically guided fuzzy c-means clustering. *Journal of Chemometrics*, 16 :1–11.
- [Noyel et al., 2007] Noyel, G., Angulo, J., and Jeulin, D. (2007). Morphological segmentation of hyperspectral images. *Image Analysis and Stereology*, 26 :101–109.
- [Palmason et al., 2003] Palmason, J., Benediktsson, J., and Arnason, K. (2003). Morphological transformations and feature extraction for urban data with high spectral and spatial resolution. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, volume 1, pages 470–472, Toulouse, France.
- [Park et al., 1998] Park, B., Chen, Y., and Nuyen, M. (1998). Multi-spectral analysis using neuronal network algorithm for inspection of poultry carcasses. *Journal of Agricultural Engineering Research*, 69 :351–363.
- [Parsons et al., 2004] Parsons, L., Haque, E., and Liu, H. (2004). Subspace clustering for high dimensional data : A review. *SIGKDD Explorations, Newsletter of the ACM Special Interest Group on Knowledge Discovery and Data Mining*, 6(1) :90–105.
- [Pedrycz, 1996] Pedrycz, W. (1996). Conditional fuzzy c-means. *Pattern Recognition Letters*, 17 :625–631.
- [Peraseri and Benediktsson, 2001] Peraseri, M. and Benediktsson, J. (2001). A new approach for the morphological segmentation of high-resolution satellite imagery. *IEEE Transactions on geoscience and remote sensing*, 39(2) :309–320.
- [Perona and Malik, 1990] Perona, P. and Malik, J. (1990). Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(7) :629–639.
- [Pham, 2001] Pham, D. (2001). Spatial model for fuzzy clustering. *Computer vision and understanding*, 84 :285–297.
- [Plaza, 2007a] Plaza, A. (2007a). Recent developments and future directions in hyperspectral data classification. In *Proceedings of Spie*, volume 6748. SPIE, The internationale Society of Optical Engineering.

- [Plaza, 2007b] Plaza, A. (2007b). Recent developments and future directions in hyperspectral data classification. In Bruzzone, L., editor, *Image and Signal Processing for Remote Sensing XIII*, volume 6748. The Internationale Society of Optical Engineering (SPIE).
- [Plaza et al., 2006] Plaza, A., Benediktsson, J., Boardman, J., Brazile, J., Bruzone, L., Camps-Valls, G., Chanussot, J., Fauvel, M., Gamba, P., Gualtieri, A., Tilton, T., and Trianni, G. (2006). Advanced processing of hyperspectral images. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 1974 – 1978, Denver, CO, USA. IEEE.
- [Plaza et al., 2002] Plaza, A., Martinez, P., and Perez, R. (2002). Spatial/spectral endmember extraction by multidimensional morphological operations. In IEEE, editor, *Geoscience and Remote Sensing*, volume 40, pages 2025–2041.
- [Polder and van der Heijden, 2001] Polder, G. and van der Heijden, G. W. (2001). Calibration and characterization of spectral imaging systems. In Tong, Q., Zhu, Y., and Zhu, Z., editors, *the Society of Photo-Optical Instrumentation Engineers (SPIE)*, volume 4548, pages 10–17. SPIE.
- [Prony et al., 2000] Prony, O., Descombes, X., and Zerubia, J. (2000). Classification des images satellitaires hyperspectrales en zone rurale et périurbaine. Rapport de recherche 4008, INRIA.
- [Rabatel et al., 2001] Rabatel, G., Manh, A.-G., Aldon, M.-J., and Bonicelli, B. (2001). Skeleton-based shape models with pressure forces : Application to segmentation of overlapping leaves. In Springer-Verlag, editor, *4th International Workshop on Visual Form, IWVF4*, pages 249–259, Capri, Italy.
- [Rellier, 2002] Rellier, G. (2002). *Analyse de texture dans l'espace hyperspectral par des méthodes probabilistes*. PhD thesis, Nice Sophia-Antipolis, France.
- [Ridgway and Chambers, 1998] Ridgway, C. and Chambers, J. (1998). Detection of insects inside wheat kernels by nir imaging. *Journal of Near Infrared Spectroscopy*, 6.
- [Rivest et al., 1993] Rivest, J., Soille, P., and Beucher, S. (1993). Morphological gradients. *Journal of Electronic Imaging*, 2(4).
- [Roli and Fumera, 2001] Roli, F. and Fumera, G. (2001). Support vector machine for remote-

-
- sensing image classification. In SPIE, editor, *Image and Signal Processing for Remote Sensing VI*, volume 4170, pages 160–166.
- [Roudier, 2008] Roudier, P. (2008). *Zonage Intra-Parcellaire Guidé par des Contraintes Opérationnelles*. PhD thesis, Montpellier SupAgro, France.
- [Rouse et al., 1973] Rouse, J., Haas, R., J.A., S., and Deering, D. (1973). Monitoring vegetation systems in the great plains with erts. In NASA, editor, *Proceedings of Third Earth Resources Technology Satellite Symposium*.
- [Roussel, 1998] Roussel, S. (1998). *Optimisation des capteurs d’arômes et fusion multisensorielle appliquée à la caractérisation des produits agro-alimentaires*. PhD thesis, Ecole Nationale Supérieure Agronomique de Montpellier, France.
- [Sapiro and Ringach, 1996] Sapiro, G. and Ringach, D. (1996). Anisotropic diffusion of multivalued images with applications to color filtering. *IEEE Transactions on Image Processing*, 5(11) :1582–1585.
- [Scheunders, 2001] Scheunders, P. (2001). Multivalued image segmentation based on first fundamental form. In *Proceedings of 11th International IEEE Conference on Image Analysis and Processing*, pages 185–190.
- [Schowengerdt, 1997] Schowengerdt, R. (1997). *Remote Sensing : Models and Methods for Image Processings*. Academic Press, San Diego, USA.
- [Schut et al., 2006] Schut, A., VanderHeijden, G., Hoving, I., Stienezen, M., Van Evert, F., and Meuleman, J. (2006). Imaging spectroscopy for on-farm measurement of grassland yield and quality. *Agronomy journal*, 98(5) :1318–1325.
- [Shi and Malik, 1997] Shi, J. and Malik, J. (1997). Normalized cuts and image segmentation. In *IEEE Conference Computer Vision and Pattern Recognition(CVPR)*, Puerto Rico.
- [Shi and Malik, 2000] Shi, J. and Malik, J. (2000). Normalized cuts and image segmentation. *IEEE Transactions on pattern analysis and machine intelligence*, 22(8) :888–905.
- [Sigelle and Tupin, 1999] Sigelle, M. and Tupin, F. (1999). Champs de markov en traitement d’images.

- [Smartt and Tyo, 2006] Smartt, H. and Tyo, J. (2006). Classification of hyperspectral spatial/spectral patterns using gauss-markov random fields. In *Proceedings of SPIE - The International Society for Optical Engineering*, volume 6233 I.
- [Soille, 1996] Soille, P. (1996). Morphological partitioning of multispectral images. *Journal of Electronic Imaging*, 5(3) :252–263.
- [Soille, 2005] Soille, P. (2005). Beyond self-duality in morphological image analysis. *Image and Vision Computing*, 23 :243–257.
- [Tadjudin and Landgrebe, 1998] Tadjudin, S. and Landgrebe, D. (1998). Classification of high dimensional data with limited training samples. Technical Report TR-ECE 98-8, PhD Thesis and School of Electrical Computer Engineering.
- [Tarabalka et al., 2008] Tarabalka, Y., Chanussot, J., Benediktsson, A., Angulo, J., and Fauvel, M. (2008). Segmentation and classification of hyperspectral data using watershed. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Boston, USA.
- [Tauler et al., 1991] Tauler, R., Casassas, E., and Izquierdoridorsa, A. (1991). Self-modeling curve resolution in studies of spectrometric titrations of multi-equilibria systems by factor-analysis. *Analytica Chimica Acta*, 248 :447–458.
- [Tauler et al., 1995] Tauler, R., Izquierdoridorsa, A., Gargallo, R., and Casassas, E. (1995). Application of a new multivariate curve resolution procedure to the simultaneous analysis of several spectroscopic titrations of the copper(ii)-polyinosinic acid system. *Chemometrics and Intelligent Laboratory Systems*, 27 :163–174.
- [Taylor and McCure, 1989] Taylor, S. and McCure, W. (1989). NIR imaging spectroscopy : Measuring the distribution of chemical components. In *Second International NIR Conference*, pages 393–404, Tsukuba, Japan.
- [Terawaki et al., 2003] Terawaki, M., Kataoka, T., Okamoto, H., and Hata, S. (2003). Development af automatic weeding thinner for sugar beet. In *ASAE Annual International Meeting*, volume Paper number 03 3076.
- [Thenkabail et al., 2000] Thenkabail, P., Smith, B., and DePauw, E. (2000). Hyperspectral vege-

-
- tation indices and their relationships with agricultural crop characteristics. *Remote Sensing of Environment*, 71 :158–182.
- [Tian et al., 1997] Tian, L., Slaughter, D., and Norris, R. (1997). Outdoor field machine vision identification of tomato seedlings for automated weed control. *Transactions of the ASAE*, 40 :1761–1768.
- [Tilton, 1998] Tilton, J. (1998). Image segmentation by region growing and spectral clustering with a natural convergence criterion. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Seattle, WA.
- [Tilton, 2005] Tilton, J. (2005). A split-remerge method for eliminating processing window artifacts in recursive hierarchical segmentation. Technical Report GSC 14994-1, NASA.
- [Tsuta et al., 2002] Tsuta, J., Sugiyama, J., and Sagara, Y. (2002). Near-Infrared imaging spectroscopy based on sugar absorption for melons. *Journal of Agricultural and Food Chemistry*, 50(1) :48–52.
- [Van Den Broek et al., 1996] Van Den Broek, W., Derks, E., Van De Ven, E., Wienke, D., Geladi, P., and Buydens, L. M. C. (1996). Plastic identification by remote sensing spectroscopic NIR imaging using kernel partial least squares (KPLS). *Chemometrics and Intelligent Laboratory Systems*, 35(2) :187–197.
- [Van der Werff, 2006] Van der Werff, H. (2006). *Knowledge-based remote sensing of complex object : recognition of spectral and spatial patterns resulting from natural hydrocarbon seepages*. PhD thesis, Utrecht University.
- [Van der Werff and Van der Meer, 2008] Van der Werff, H. and Van der Meer, F. (2008). Shape-based classification of spectrally identical objects. *Journal of Photogrammetry and Remote Sensing (ISPRS)*, 63 :251–258.
- [Vapnik, 1998] Vapnik, V. (1998). *Statistical Learning Theory*. Wiley, New York.
- [Vincent and Soille, 1991] Vincent, L. and Soille, P. (1991). Watershed in digital spaces, an efficient algorithm based on immersion simulation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(6) :583–598.

- [Vincent, 2001] Vincent, P. (2001). *Modèles noyaux à structure locale*. PhD thesis, Montréal.
- [Wang et al., 2002] Wang, D., Dowell, F., and Dempster, R. (2002). Determining vitreous subclasses of hard red spring wheat using visible/near-infrared spectroscopy. *Cereal chemistry*, 79(3) :418–422.
- [Wang and Fei, 2008] Wang, H. and Fei, B. (2008). A modified fuzzy c-means classification method using multiscale diffusion filtering scheme. *Medical image analysis*.
- [Weickert, 1998] Weickert, J. (1998). *Anisotropic Diffusion in Image Processing*. Teubner-Verlag, Stuttgart.
- [Whu and Leahy, 1993] Whu, Z. and Leahy, R. (1993). An optimal graph theoretic approach to data clustering : theory and application to image segmentation. *IEEE Transactions on pattern analysis and machine intelligence*, 15 :1101–1113.
- [Wilks, 1960] Wilks, S. (1960). *Multidimensional scatter*. Stanford Press.
- [Xing and De Baerdemaeker, 2005] Xing, J. and De Baerdemaeker, J. (2005). Bruise detection on jonagold apples using hyperspectral imaging. *Postharvest Biology and Technology*, 37(2) :152–162.
- [Ye et al., 2008] Ye, X., Sakai, K., Okamoto, H., and Garciano, L. (2008). A ground based hyperspectral imaging system for characterizing vegetation spectral features. *Computers and electronics in Agriculture*, 63 :13–21.
- [Zhang et al., 2007] Zhang, X., Wu, B., and Li, Q. (2007). Research on classification of high-resolution remote sensing image. In *Proceedings of SPIE - The International Society for Optical Engineering*, volume 6786. Art. No. : 67862Z.
- [Zwiggelaar, 1998] Zwiggelaar, R. (1998). A review of spectral properties of plants and their potential use for crop/weed discrimination in row-crops. *Crop Protection*, 17(3) :189–206.
- [Zwiggelaar et al., 1996] Zwiggelaar, R., Qingsheng, Y., Garcia-pardo, E., and Bull, R. (1996). Use of spectral information and machine vision for bruise detection on peaches and apricots. *Journal of Engng Res*, 63 :323–332.

Résumé

L'imagerie hyper-spectrale (IHS) consiste à créer et à analyser des images de la même scène pour une succession de longueurs d'onde dans un domaine spectral donné. De telles images apportent des informations sur la constitution chimique des objets et permettent ainsi de distinguer des objets de même couleur mais de compositions chimiques différentes. Cependant, quel que soit le domaine d'application, la plupart des méthodes développées pour le traitement des images hyperspectrales analysent les données sans prendre en compte l'information spatiale. Les pixels sont alors traités individuellement comme un simple tableau de mesures spectrales sans arrangement particulier. Cependant, l'exploitation conjointe de l'information spectrale et spatiale disponibles, du fait entre autres, de l'apparition d'imageurs spectraux de meilleure résolution, apparaît aujourd'hui essentielle pour permettre le traitement d'images de contenu complexe. Dans le cadre de nos travaux concernant l'IHS, nous nous sommes intéressés à cette problématique. Nous avons ainsi proposé un schéma itératif générique appelé *papillon* permettant de mêler les aspects spatiaux et spectraux de manière symétrique, de façon à ne pas privilégier un espace par rapport à l'autre et de manière conjointe, de façon à ce que l'information spatiale se nourrisse de l'information spectrale et vice-versa, pour avancer dans le processus de traitement de l'image. Pour ce faire, la combinaison spectro/spatiale proposée repose, d'une part, sur la construction d'un espace spectral adapté à l'information topologique (construction de variables latentes), et d'autre part, sur la génération d'une topologie sur l'espace spatial. Dans nos développements récents, la notion d'information topologique est limitée à la notion de région.

L'approche proposée apparaît comme une procédure générique dont le contenu et l'implémentation peuvent être choisis et adaptés aux images traitées. Dans le cadre de cette thèse, nous avons proposé une implémentation utilisant une étape de division suivie d'une étape de fusion. La construction d'un espace adapté pour chacune de ces deux étapes a été réalisée respectivement par la diagonalisation de la matrice de variance intra-région et inter-région. Nous avons

également utilisé, pour l'étape de division, plusieurs approches de segmentation régions dont les coupes normalisées avec contrainte spatiale et une version modifiée de l'algorithme de partage des eaux ou LPE. Pour finir, nous avons validé le fonctionnement de notre approche et illustré ces principales caractéristiques à l'aide d'images synthétiques et réelles.

Mots-clés: Imagerie hyperspectrale, segmentation, réduction de données, Lambda de Wilks

Abstract

Hyper-Spectral Imaging (HIS) consists in the acquisition and analysis of images of the same view for a set of wavelengths, in a given spectral domain. Such images raise some information on the chemical constitution of objects thus allowing to differentiate objects of same colour but with different chemical composition. Yet, whatever is the application domain, most of the methods developed for HIS processing, perform data analysis without taking into account the spatial information. Each pixel is considered individually, as a simple array of spectral measurements, with no specific arrangement. Yet, considering the available spectral and spatial information altogether, as a consequence of new spectral image analysers with a higher resolution, appears to be of a main importance to allow the processing of complex images. Inside our HIS work field, we got involved with such a problematic. And thus, we proposed an iterative schema called butterfly, allowing to tight closely the spectral and spatial aspects in a symmetric way, so not to enforce one space against another and in a conjunctive way as to enable the spatial and spectral information to feed each other in the task of image processing. On this process, the spectral and spatial combination proposed resides in one hand, in building a spatial space adapted to the topological information (latent variables) and in another hand, in a topology generation on the spatial space. In our recent developments, we limit the topological aspect to the region concept. The proposed approach appears to be a generic proceeding, where one can choose the suitable content and implementation to the processed images. In the subject field of this thesis, we proposed an implementation using a two step process, consisting of a division followed by a fusion. The building of an adjusted space for both steps was realised respectively

by diagonalising the intra-region and inter-region matrices. For the division step, we also tested many segmentation approaches, among which the spatially constrained normalised cuts and a modified version of the watershed algorithm. At the end, as to show how it is operating and its main characteristics, we processed our approach with some synthetic as well as with some real images.

Keywords: Hyperspectral imaging, segmentation, dimension reduction

