



uOttawa

L'Université canadienne
Canada's university

**FACULTÉ DES ÉTUDES SUPÉRIEURES
ET POSTDOCTORALES**



**FACULTY OF GRADUATE AND
POSTDOCTORAL STUDIES**

Yannick Lanthier

AUTEUR DE LA THÈSE / AUTHOR OF THESIS

M.Sc. (géographie)

GRADE / DEGREE

Département de géographie

FACULTÉ, ÉCOLE, DÉPARTEMENT / FACULTY, SCHOOL, DEPARTMENT

Apport de la segmentation d'image hyperspectrale à la précision de la classification en milieu agricole : analyse multi-échelles

TITRE DE LA THÈSE / TITLE OF THESIS

Dr. Abdou Bannari

DIRECTEUR (DIRECTRICE) DE LA THÈSE / THESIS SUPERVISOR

CO-DIRECTEUR (CO-DIRECTRICE) DE LA THÈSE / THESIS CO-SUPERVISOR

EXAMINATEURS (EXAMINATRICES) DE LA THÈSE / THESIS EXAMINERS

Dr. L. Copland

Dr. B. Lauriol

Gary W. Slater

Le Doyen de la Faculté des études supérieures et postdoctorales / Dean of the Faculty of Graduate and Postdoctoral Studies

Université d'Ottawa
Faculté des Arts
Département de géographie

**Apport de la segmentation d'image hyperspectrale à la précision
de la classification en milieu agricole : analyse multi-échelles**

Par

Yannick Lanthier

Thèse présentée à la Faculté des études supérieures et postdoctorales pour l'obtention d'une
Maîtrise ès Sciences en Géographie

© Yannick Lanthier, Ottawa, Canada, 2009



Library and
Archives Canada

Published Heritage
Branch

395 Wellington Street
Ottawa ON K1A 0N4
Canada

Bibliothèque et
Archives Canada

Direction du
Patrimoine de l'édition

395, rue Wellington
Ottawa ON K1A 0N4
Canada

Your file *Votre référence*
ISBN: 978-0-494-51846-5
Our file *Notre référence*
ISBN: 978-0-494-51846-5

NOTICE:

The author has granted a non-exclusive license allowing Library and Archives Canada to reproduce, publish, archive, preserve, conserve, communicate to the public by telecommunication or on the Internet, loan, distribute and sell theses worldwide, for commercial or non-commercial purposes, in microform, paper, electronic and/or any other formats.

The author retains copyright ownership and moral rights in this thesis. Neither the thesis nor substantial extracts from it may be printed or otherwise reproduced without the author's permission.

AVIS:

L'auteur a accordé une licence non exclusive permettant à la Bibliothèque et Archives Canada de reproduire, publier, archiver, sauvegarder, conserver, transmettre au public par télécommunication ou par l'Internet, prêter, distribuer et vendre des thèses partout dans le monde, à des fins commerciales ou autres, sur support microforme, papier, électronique et/ou autres formats.

L'auteur conserve la propriété du droit d'auteur et des droits moraux qui protègent cette thèse. Ni la thèse ni des extraits substantiels de celle-ci ne doivent être imprimés ou autrement reproduits sans son autorisation.

In compliance with the Canadian Privacy Act some supporting forms may have been removed from this thesis.

While these forms may be included in the document page count, their removal does not represent any loss of content from the thesis.

Conformément à la loi canadienne sur la protection de la vie privée, quelques formulaires secondaires ont été enlevés de cette thèse.

Bien que ces formulaires aient inclus dans la pagination, il n'y aura aucun contenu manquant.


Canada

RÉSUMÉ

Les techniques de classifications conventionnelles orientées pixels sont les plus fréquemment utilisées dans le domaine de la télédétection pour la restitution de cartes d'occupation du sol. Ces techniques sont basées sur des procédés statistiques qui séparent les pixels dans leurs classes respectives, en considérant uniquement leurs réflectances spectrales. Quant à la classification orientée objets, elle est basée sur une segmentation de l'image, est une alternative qui utilise l'information contextuelle (couleurs et formes des pixels), en plus de leurs caractéristiques spectrales. Cette recherche porte sur une étude de l'impact du changement d'échelle sur les classifications supervisées orientées pixels et orientées objets dans le contexte de l'agriculture de précision. Nous avons considérés trois images hyperspectrales sur un premier site, et sur le second site, une image hyperspectrale et une autre multispectrale. Les images du premier site, situé à la station de recherche et de développement en horticulture (Agriculture Canada) à L'Acadie, dans le sud du Québec, ont été acquises à l'aide du capteur *Compact Airborne Spectrographic Imager (CASI)* à trois différentes altitudes, procurant trois résolutions spatiales différentes: 1, 2 et 4 m. Pour le second site, situé au « Indian Head Agricultural Research Foundation » en Saskatchewan, les deux images, hyperspectrale et multispectrale, ont été acquises, respectivement, par le capteur aéroporté Probe-1 et le capteur satellitaire IKONOS. Après la standardisation et la correction des images, les classifications orientées pixels ont été effectuées à l'aide de l'algorithme du maximum de vraisemblance et les classifications orientées objets ont été faites avec un algorithme du plus proche voisin, après une segmentation par croissance des régions avec notion de hiérarchie. Après la segmentation, une analyse statistique comparative sur les différences spectrales moyennes aux objets voisins confirme que les segmentations ont un faible taux de mixture spectrale en fonction des différents niveaux de segmentations testés. Suite à l'analyse de la précision des classifications pour le premier site, le procédé de segmentation a permis l'utilisation d'une image hyperspectrale à résolution spatiale plus grossière (4 m avec un coefficient kappa de 0,8268) pour surpasser la classification orientée pixels d'une image à plus haute résolution spatiale (1 m avec un coefficient kappa de 0,7730) dans le cas de classes agricoles. Pour le second site, les résultats sont toujours aussi constants. Les résultats orientés objets de l'image hyperspectrale Probe-1 (kappa de 0,9628) surpassent considérablement les résultats orientés pixels (kappa de 0,9217). Il est de même pour l'image multispectrale IKONOS (kappa de 0,9371 orientée objets et kappa de 0,8926 orientée pixels). La segmentation d'images est donc un apport important et très significatif à la classification d'images (hyperspectrales et multispectrales) en milieu agricole. Toutefois, les images hyperspectrales ont un fort pouvoir de discrimination entre les différentes classes agricoles.

ABSTRACT

The conventional pixel-oriented classification is the most commonly used approach in remote sensing for land use product extraction. The object-oriented classification based on image segmentation is an alternative, which uses pixel context, texture and shapes, in addition to their spectral characteristics. This paper reports on a comparative study between supervised pixel-oriented and object-oriented classifications in a precision agriculture context using three hyperspectral images on our first study site, and a set of hyperspectral and multispectral images for a second site. The images for the first site, owned by the horticulture research and development centre (Agriculture Canada) at L'Acadie in southern Quebec, were acquired with the *Compact Airborne Spectrographic Imager* (CASI) sensor at three different altitudes, providing three different spatial resolutions: 1, 2 and 4 m. For the second site, located at the Indian Head Agriculture Research foundation in Saskatchewan, a Probe-1 hyperspectral image was acquired as well as a multispectral IKONOS image. After calibration and correcting the imagery, pixel-oriented classifications were carried out using the maximum likelihood algorithm and object-oriented classifications with a nearest neighbor classifier after region growing hierarchical segmentation. After segmentation, statistical comparison on the mean difference to neighbor objects confirmed that the segments had minimum mixing effects in respect to other segmentation levels and neighboring ground entities. After accuracy analysis on the classifications for the first site, the segmentation process allowed the use of a spatially coarser hyperspectral image (4 m with kappa of 0.8268) to achieve better results than pixel oriented classification of a spatially finer hyperspectral image (1 m with kappa of 0.7730), in the task of delineating agricultural classes. For the second site, results are still consistent. Object oriented results of the hyperspectral Probe-1 image (kappa of 0.9628) significantly exceed the pixel oriented results (kappa of 0.9217). Similarity is observed with IKONOS multispectral imagery (kappa of 0.9371 for object oriented and kappa of 0.8926 for pixel oriented). Image segmentation is therefore an important technique to achieve high accuracy in classification of land cover classes. Hyperspectral imagery also has a strong power of discrimination between many agricultural classes.

REMERCIEMENTS

Je remercie premièrement mes parents, Gilbert et Simone Lanthier, ainsi que ma sœur Marilyne qui m'ont toujours appuyé dans mes études. Merci à toute ma famille, de près et de loin, ainsi qu'à mes ami(e)s pour leur appui moral, physique et linguistique.

J'aimerais remercier mon superviseur de thèse, Dr. Abdou Bannari du département de géographie de l'Université d'Ottawa pour toutes les connaissances qu'il m'a partagées tout au long de la réalisation de cette thèse, de même que pour les nombreuses heures accordées lors des rencontres et des discussions sur la télédétection.

Merci également à Dr. Driss Haboudane, Dr. John R. Miller et M. Nicolas Tremblay pour leur aide sur les données des sites et lors de la rédaction de l'article d'IGARSS 2008 – Boston, États-Unis.

J'aimerais remercier la Faculté d'études supérieures et postdoctorales, le département de géographie de l'Université d'Ottawa et le régime de bourses d'études supérieures de l'Ontario (BESO) pour leur support financier lors de mes études supérieures, ainsi que dans le cadre de la conférence IGARSS 2008.

Enfin, un énorme merci à Véronique Coulombe pour son appui moral tout au long de nos études au cours des dernières années.

TABLE DES MATIÈRES

Résumé.....	ii
Abstract.....	iii
Remerciements.....	iv
Table des matières.....	v
Liste des figures.....	vii
Liste des tableaux.....	viii
Abréviations et Acronymes.....	ix
Chapitre 1 : Introduction	
1.1 Problématique.....	1
1.2 Objectifs.....	3
1.3 Hypothèses.....	3
1.4 Répartition de la thèse.....	4
Chapitre 2 : Étude Bibliographique	
2.1 Introduction.....	5
2.2 Méthodes de classifications orientées pixels.....	5
2.2.1 Maximum de vraisemblance.....	5
2.2.2 Distance minimale.....	9
2.2.3 Parallélépipède.....	10
2.3 Méthodes de classifications orientées objets.....	11
2.3.1 Détection des arêtes (edge detection).....	13
2.3.2 Croissance des régions et notion de hiérarchie.....	15
2.3.3 Classification des objets segmentés.....	23
2.4 Choix de la méthode.....	25
2.5 Conclusions.....	25
Chapitre 3 : Méthodologie	
3.1 Introduction.....	27
3.2 Sites d'étude.....	27
3.2.1 St-Jean-sur-Richelieu, Québec.....	27
3.2.2 Indian Head, Saskatchewan.....	29
3.3 Données images.....	30
3.3.1 CASI.....	31
3.3.2 PROBE-1.....	33
3.3.3 IKONOS.....	34
3.4 Prétraitements des données images.....	36
3.4.1 CASI.....	36
3.4.2 PROBE-1.....	37
3.4.3 IKONOS.....	39
3.5 Traitements.....	40
3.5.1 Classification par maximum de vraisemblance.....	40

3.5.2 Segmentation d'images	42
3.5.3 Classification orientée objets sur les segments	43
3.6 Analyse des résultats	44
3.6.1 Précision par classes	45
3.6.2 Précision globale	46
3.7 Conclusions	47
Chapitre 4 : Analyse des résultats	
4.1 Introduction	48
4.2 Segmentation	48
4.2.1 Segmentation des images CASI	51
4.2.2 Segmentation de l'image Probe-1	52
4.2.3 Segmentation de l'image IKONOS	54
4.3 Analyse selon les méthodes de classification	57
4.3.1 Classification orientée pixel	57
4.3.2 Classification orientée objet	59
4.4 Analyse selon l'échelle	61
4.4.1 Image CASI à 1 m	62
4.4.2 Image CASI à 2 m	65
4.4.3 Image CASI à 4 m	68
4.5 Validation sur les données Probe-1	72
4.6 Validation sur les données IKONOS	76
4.7 Conclusions	81
Chapitre 5 : Conclusions et recommandations	
5.1 Conclusions	83
5.2 Recommandations	84
Bibliographie	86
ANNEXES	
ANNEXE I : Matrices de confusion	98
ANNEXE II : LANTHIER, Y., A. BANNARI, D. HABOUDANE, J.R. MILLER et N. TREMBLAY. 2008, Hyperspectral Data Segmentation and Classification in Precision Agriculture: A Multi-Scale Analysis, IGARSS : International Geoscience and Remote Sensing Symposium. 6-11 Juillet 2008, Boston, États-Unis	103

LISTE DES FIGURES

Figure 2.1 : Représentation graphique de l'algorithme du maximum de vraisemblance	8
Figure 2.2 : Distance minimale aux moyennes des classes	10
Figure 2.3 : Parallélépipède des classes b et c.....	11
Figure 2.4 : Réseau hiérarchique des objets d'une image	18
Figure 2.5 : Distribution spectrale de deux classes (bleu et rouge) et de leurs fonctions d'appartenance dans un espace à deux dimensions	23
Figure 2.6 : Distribution spectrale de deux classes entraînées (bleu et rouge) dans un espace à deux dimensions	24
Figure 3.1 : Organigramme de la méthodologie.....	28
Figure 3.2 : Carte de localisation des sites de St-Jean-sur-Richelieu, Québec, et d'Indian Head, Saskatchewan.	30
Figure 3.3 : Données images du capteur CASI, 1 m (A), 2 m (B) et 4 m(C).....	32
Figure 3.4 : Cube hyperspectral des données images du Probe-1	34
Figure 3.5 : Données images IKONOS	35
Figure 3.6 : Réponses spectrales relatives d'IKONOS	40
Figure 4.1 : Moyenne des différences spectrales aux objets voisins, CASI 1 m.....	50
Figure 4.2 : Différents niveaux de segmentation de l'image CASI à 1 m.....	52
Figure 4.3 : Les paramètres idéaux de segmentation de l'image Probe-1	53
Figure 4.4 : Différents niveaux de segmentation de l'image Probe-1	54
Figure 4.5 : Différents niveaux de segmentation de l'image IKONOS	55
Figure 4.6 : Moyenne des différences spectrales aux objets voisins, IKONOS.....	56
Figure 4.7 : Classifications orientées pixels non-supervisées du <i>k-moyen</i> (30 classes aléatoires), à 1 m (A), 2 m (B) et 4 m (C).....	58
Figure 4.8 : Stabilité des classifications orientées objets des données images CASI à 1 m (A), 2 m (B) et 4 m (C).	60
Figure 4.9 : Classifications orientées objets (haut) et pixels (bas) des données images du capteur CASI, à 1, 2 et 4 m.....	62
Figure 4.10 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (CASI : 1 m)	63
Figure 4.11 : Distribution spectrale des objets classifiés avec les points de validation (CASI : 1 m, axe des X: Moyenne spectrale de la bande 7 - 799,86 nm; axe des Y: Moyenne spectrale de la bande 4 – 699,76 nm)	65
Figure 4.12 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (CASI : 2 m)	67
Figure 4.13 : Distribution spectrale des objets classifiés avec les points de validation (CASI : 2 m, axe des X: Moyenne spectrale de la bande 7 - 799,86 nm; axe des Y: Moyenne spectrale de la bande 4 – 699,76 nm)	67
Figure 4.14 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (CASI : 4 m)	69
Figure 4.15 : Distribution spectrale des objets classifiés avec les points de validation (CASI : 4 m, axe des X: Moyenne spectrale de la bande 7 - 799,86 nm; axe des Y: Moyenne spectrale de la bande 4 – 699,76 nm)	70
Figure 4.16 : Discrimination entre les objets d'entraînements pour les classes de maïs-3 (noir) et maïs-2 (bleu). (Bandes 1 à 7, CASI 1 m).....	71

Figure 4.17 : Exactitude des classifications en fonction des résolutions (CASI)	72
Figure 4.18 : Classifications orientées objets (A) et pixels (B) de l'image Probe-1	73
Figure 4.19 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (Probe-1)	74
Figure 4.20 : Discrimination entre les objets d'entraînements pour les classes de résidus (noir) et sol nu (bleu). (Bandes 37 à 59 - 958,9 nm à 1286,2 nm, Probe-1)	75
Figure 4.21 : Exactitude des classifications en fonction des méthodes de classification en considérant les deux capteurs : Probe-1 et IKONOS	76
Figure 4.22 : Classifications orientées objets (A) et pixels (B) de l'image IKONOS	78
Figure 4.23 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (IKONOS)	79
Figure 4.24 : Discrimination entre les objets d'entraînements pour les classes de résidus (noir) et sol nu (bleu). (5 bandes IKONOS, incluant le panchromatique)	79

LISTE DES TABLEAUX

Tableau 3.1 : Description des champs à l'étude à Indian Head	29
Tableau 3.2 : Spécification spectrale des détecteurs du capteur Probe-1	34
Tableau 3.3 : Caractéristiques du satellite IKONOS	35
Tableau 3.4 : Paramètres du modèle MODTRAN-3 pour les corrections atmosphériques de l'image Probe-1	38
Tableau 3.5 : Description du calcul du coefficient Kappa par classe	46
Tableau 4.1 : Pourcentage des pixels classifiés (Maximum de vraisemblance)	59

ABRÉVIATIONS ET ACRONYMES

AISI	Airborne Imaging Spectroradiometer for Applications
ASTER	Advanced Spaceborne Thermal Emission and Reflectance Radiometer
CASI	Compact Airborne Spectrographic Imager
CAM5S	Canadian Advanced Modified – Simulation du Signal Satellitaire dans le Spectre Solaire
CCD	Charged Coupled Device
CN	Compte Numérique
CRDH	Centre de recherche et de développement en horticulture
CRESTech	Centre for Research in Earth and Space Technology
ESSI	EarthSearch Sciences Inc.
ETM+	Enhanced Thematic Mapper +
EQM	Erreur Quadratique Moyenne
GPS	Global Positioning System
HalconSEG	Halcon Segmentation
HSWO	Hierarchical Step-Wise Optimization
HyMap	Hyperspectral Mapper
IHARF	Indian Head Agricultural Research Foundation
ISDAS	Imaging Spectrometer Data Analysis System
ISODATA	Iterative Self-Organizing Data Analysis Technique
LUT	Look-Up Table
MODTRAN	Moderate Resolution Atmospheric Transmission
NAD	North American Datum
Nm	Nanomètre
PAN	Panchromatique
RHSEG	Recursive Hierarchical Segmentation
SAM	Spectral Angle Mapper
SEGEN	Image Segmentation Engine
SegSAR	Segmentation of SAR (Synthetic Aperture Radar) Imagery
SNI	Système de Navigation Inertiel
Terra/MODIS	Moderate-resolution Imaging Spectroradiometer
TM	Thematic Mapper
UTM	Universal Transverse Mercator

CHAPITRE 1 : INTRODUCTION

1.1 Problématique

La télédétection est un domaine très actif qui ne cesse d'évoluer. Avec le développement de nouveaux capteurs satellitaires et aéroportés, les résolutions spatiale et spectrale s'améliorent continuellement. Toutefois, ce procédé est très coûteux à utiliser. C'est pour cela que plusieurs études ont été menées afin de pouvoir déterminer certaines combinaisons de méthodes de traitements et de sources d'images pour minimiser les coûts d'exploitation et optimiser les précisions des produits dérivés.

Pour la dérivation et la préparation de cartes thématiques, la classification orientée pixel est la plus connue et la plus conventionnelle. Chaque image est composée de milliers de pixels dans plusieurs bandes spectrales et qui peuvent se regrouper selon des caractéristiques de ressemblances dans diverses classes (Ait Belaid, 1990). Il s'agit donc d'un procédé statistique qui sépare les pixels dans leurs classes respectives, en fonction de leurs réflectances spectrales. La méthode la plus utilisée est celle dite par maximum de vraisemblance qui classe les pixels selon le degré d'appartenance statistique aux classes définies (Mather, 1987; Bolstad et Lillesand, 1991; Shettigara, 1991; Casals-Carrasco *et al.*, 2000; Repaka *et al.*, 2004). Cette méthode, tout comme les autres de classification supervisée, est très limitée, car il en revient à l'utilisateur de bien définir ses sites d'entraînements pour que la classification se fasse avec précision. Ensuite, l'algorithme ne peut qu'utiliser les statistiques générées à partir de ces sites d'entraînements (moyenne, écart type, etc.) pour l'attribution d'un pixel à une classe bien précise. Cependant, le choix des sites d'entraînement est une étape cruciale (Lillesand et Kieffer, 2004).

Différentes techniques existent pour améliorer la précision de la classification des images acquises à l'aide de capteurs multispectraux ou hyperspectraux, telles l'analyse de texture (Haralick *et al.*, 1973; Zhang *et al.*, 2003), l'analyse des fractales (Milne, 1992; Crawford *et al.*, 2006) et la segmentation (Pal et Pal, 1993; Baatz *et al.*, 2004). Cette dernière technique permet l'extraction de composantes à la fois spatiales et spectrales des

images acquises. La segmentation est très avantageée comparativement aux techniques conventionnel de classification par pixel puisqu'elle comprend de l'information sur les formes et les relations spatiales entre les pixels. La problématique vient donc à savoir si vraiment la segmentation permet une augmentation de la précision de classifications d'images, et ce, à différentes résolutions spatiales.

Le procédé de la segmentation est relativement nouveau comparativement aux algorithmes de classifications conventionnelles (maximum de vraisemblance, ISODATA, etc.) basées sur les statistiques. Également, c'est au cours de la dernière décennie seulement que les algorithmes ont été conçus pour appliquer la segmentation aux images satellitaires et d'en classer les objets segmentés.

Différentes études ont comparé les méthodes de classification orientée pixel supervisée et non supervisée avec les méthodes de classification orientée objet dans différentes applications de la télédétection. Notamment dans des contextes urbains (Repaka, 2004), de foreries (Wang et Boesch, 2007), de classification générale de l'occupation du sol (Xu *et al.*, 2004; Yan *et al.*, 2006) et d'agriculture de précision (Ait Belaid, 1990). Dans chacun des cas, les classifications orientées objets semblent améliorer les résultats de 10 à 30%. Par contre, la majorité des recherches sont effectuées à l'aide d'images multispectrales, ou à l'aide d'une image aérienne de haute résolution spatiale, mais toujours avec une faible résolution spectrale (Ehlers, 2005). Nous voulons donc observer comment la segmentation d'images hyperspectrales peut améliorer les résultats.

Cette recherche est un pas vers l'avenir en terme d'analyse de la classification par segmentation d'images hyperspectrales en fonction de différentes résolutions spatiales par rapport à la classification conventionnelle orientée pixel. En effet, cette thèse de maîtrise se veut la première étude effectuée sur l'apport de la segmentation dans le contexte de l'agriculture de précision à l'aide des images hyperspectrales à différentes résolutions spatiales.

1.2 Objectifs

L'objectif principal de cette recherche est d'analyser l'apport de la segmentation d'image hyperspectrale à la classification en fonction de différentes résolutions spatiales. Elle vise la mise au point sur la combinaison optimale afin d'assurer un meilleur compromis entre la précision de dérivation de cartes d'occupation du sol en milieu agricole et la résolution spatiale de l'image, autrement dit « l'investissement ». Il serait intéressant de pouvoir déterminer si une image hyperspectrale à moyenne résolution spatiale (moins coûteuse) peut être employée conjointement avec une technique de classification par segmentation d'image pour obtenir le même résultat qu'avec une image hyperspectrale à très haute résolution spatiale (plus coûteuse). Évidemment, cette technique de segmentation sera comparée à la classification conventionnelle du maximum de vraisemblance en considérant trois images à différentes résolutions spatiales (1m, 2m et 4m). Pour permettre une vérification accrue des résultats, les mêmes procédés de classifications seront appliqués à un second site d'étude, et ce, sur une image hyperspectrale (Probe-1) et une autre image multispectrale (IKONOS) pour permettre la contre-vérification des résultats.

1.3 Hypothèses

Dans le cadre de cette recherche, nous formulons les hypothèses suivantes :

1. L'image hyperspectrale possède un fort pouvoir de discrimination entre les différentes classes d'occupation du sol.
2. L'image hyperspectrale permettra de dériver des cartes d'occupation du sol avec précision en milieu agricole.
3. La segmentation d'image hyperspectrale devrait permettre une amélioration significative de la classification indépendamment de la résolution spatiale de l'image.
4. La segmentation d'image multispectrale devrait démontrer une amélioration significative des résultats, en étant en étroite relation avec l'image hyperspectrale.

1.4 Répartition de la thèse

La thèse a été rédigée en cinq chapitres. Elle débute par la démonstration de la problématique, qui est à la base de cette recherche scientifique, suivie des objectifs à atteindre et des hypothèses posées selon les résultats à atteindre. Le deuxième chapitre décrit les méthodes générales de classification d'images satellitaires qui seront à l'étude dans la recherche, soit la classification supervisée orientée pixels et la classification orientée objets, appliquée après une segmentation de l'image. Les différents algorithmes qui peuvent être employés dans ces deux méthodes seront décrits et comparés pour finalement faire notre choix de procédés d'analyse. Le processus méthodologique sera décrit dans le chapitre trois, ainsi qu'une description des sites d'études, les données images utilisées, les prétraitements et traitements à être appliqués aux images et comment l'analyse des résultats s'effectuera pour permettre une analyse comparative. Le chapitre quatre dévoilera les résultats obtenus et le dernier chapitre révélera les conclusions tirées de l'étude ainsi que les recommandations qui s'appliquent.

CHAPITRE 2 : ÉTUDE BIBLIOGRAPHIQUE

2.1 Introduction

L'un des buts de la télédétection est de pouvoir faire l'analyse de l'occupation du sol. Pour ce faire, nous devons appliquer des algorithmes pour classer les milliers, voire les millions de pixels par images, dans diverses classes d'occupation du sol. Dans cette revue littéraire, nous allons discuter de différentes méthodes de classification, reliées à la fois au multispectrale, à l'hyperspectrale, et ce, dans diverses applications, dont l'agriculture de précision. Nous allons également voir comment le procédé de la segmentation d'images facilite la classification en se basant sur le regroupement des pixels pour en faire la création de plusieurs objets qui représentent beaucoup mieux les entités au sol. Après avoir analysé les recherches effectuées dans la littérature, nous sélectionnerons un procédé de classification orientée pixel et une technique de segmentation d'images qui seront par la suite employés dans le cadre de cette recherche.

2.2 Méthodes de classifications orientées pixels

La classification orientée pixel est la plus utilisée dans le domaine de la télédétection. Au cours des dernières décennies, plusieurs algorithmes ont été développés pour permettre une classification précise des images satellitaires. La majorité de ces algorithmes sont contenus dans divers logiciels commerciaux qui facilitent leur utilisation. Il existe deux groupes de classification orientée pixel : les algorithmes de classifications supervisées et non supervisées. Ce dernier regroupe des algorithmes qui ne nécessitent pas des connaissances *a priori* des classes à identifier et sont souvent basés sur les « clusters » ou regroupements spectraux. Dans cette recherche, nous allons considérer les algorithmes de classifications supervisées, qui sont énumérés ci-bas.

2.2.1 Maximum de vraisemblance

L'algorithme paramétrique de la classification supervisée du maximum de vraisemblance est l'un des plus utilisés dans le domaine de la télédétection (Richards, 1993). Il est souvent employé dans des applications reliées à la foresterie (Shafri *et al.*,

2007), en occupation générale des sols (Bresci, 1992; Thomson, 1998; Su, 2000), en lithologie (Carranza, 2001; Zhang, 2007) et surtout en agriculture de précision (Lacar *et al.*, 2001; El-Magd et Tanton, 2003; Turker et Arikan, 2004).

Dans le domaine de la foresterie, Shafri *et al.* (2007) ont comparé l'algorithme du maximum de vraisemblance avec le « spectral angle mapper » (SAM), les réseaux de neurones artificiels et le classificateur à arbre de décision (Decision Tree Classifiers). En utilisant une image du capteur hyperspectral aéroporté AISI (Airborne Imaging Spectroradiometer for Applications; résolution spatiale de 1 m) sur la Malaisie, les algorithmes ont été soumis à la classification de sept espèces d'arbres tropicaux. Comme résultats, le maximum de vraisemblance atteint la meilleure précision globale de 85,6%, suivi des réseaux de neurones (83%), l'arbre à décision (51%) et le SAM (49%).

Plus spécifiquement en agriculture de précision, Lacar *et al.* (2001), Hossein *et al.* (2004) et Turker et Arikan (2004) sont d'excellents exemples de la performance de la classification orientée pixel du maximum de vraisemblance. Lacar *et al.* (2001) ont utilisé 12 bandes spectrales (dans le visible et le proche infrarouge) d'une image du capteur CASI (Compact Airborne Spectrographic Imager; résolution spatiale de 1 m) pour classifier deux types de variétés de raisins présents sur le site d'étude, en Australie. Une précision de 91,5% fut atteinte dans la classification des champs de vignes.

Hossein *et al.* (2004) ont effectué une étude comparative entre les algorithmes de distance minimale, parallélépipède et maximum de vraisemblance pour permettre une classification de l'occupation du sol possédant quatre classes agricoles (prés, riz, champs asséchés et blé). Une image du capteur Enhanced Thematic mapper (ETM+) du satellite Landsat 7 fut acquise dans le Nord de l'Iran pour ensuite la soumettre aux différents traitements. Ayant une précision globale de 85,8%, les résultats ont démontré l'aptitude de l'algorithme du maximum de vraisemblance à effectuer une classification orientée pixels avec précision. Les algorithmes de distance minimale et parallélépipède ont obtenu une précision de 73,7% et 34,37% respectivement. De plus, ils ont effectué une classification hiérarchique à l'aide du maximum de vraisemblance pour permettre de bien

dissocier les deux classes qui possédaient une faible séparabilité, soit les prés et le blé, deux classes agricoles. La classification hiérarchique atteint une précision de 94%. Ce procédé est très similaire à la technique de classification orientée objets, documentée à la section 2.3, qui permet facilement la séparation de deux classes en fonction de diverses caractéristiques hiérarchiques.

El-Magd et Tanton (2003) ont utilisé la classification par maximum de vraisemblance dans une application à l'agriculture de précision, dans le sud du Kazakhstan. En utilisant une image du capteur ETM+ du satellite Landsat 7, ils ont réussi à classifier 11 classes d'occupation du sol, dont 6 étant des classes de cultures agricoles, soit le coton, le riz, l'alfalfa, les cultures mixtes, les prés et la végétation herbacée. Ayant atteint une exactitude de classification moyenne de 86%, vérifié à l'aide de 200 points de validation par rapport à la vérité terrain, El-Magd et Tanton (2003) concluent que la classification supervisée du maximum de vraisemblance est très utile dans une application à l'agriculture de précision. Par contre, ils mentionnent également qu'il est très difficile d'extraire des paramètres d'irrigation à l'aide d'image du capteur ETM+, notamment dû à sa faible résolution spatiale de 30m dans le visible et 60 m dans l'infrarouge.

Turker et Arikan (2004) ont également démontré que la classification par maximum de vraisemblance permettait d'effectuer une excellente distinction entre 7 cultures agricoles, avec une précision de 88,4% en utilisant une image du capteur ETM+ du satellite Landsat 7.

La théorie du maximum de vraisemblance est basée sur la théorie de Bayes, qui définit la probabilité conditionnelle d'une classe C_i donnée, compte tenu du fait que le vecteur X soit retenu *a priori* par l'équation 2.1 (Freund, 1962).

$$P(C_i | X) = \frac{P(X | C_i) \cdot P(C_i)}{P(X)} \quad (2.1)$$

Où :

- $P(C_i)$: La probabilité d'occurrence de la classe i ,
 $P(X|C_i)$: La probabilité d'occurrence d'un pixel à la classe i , connu *a priori* par entraînement,
 $P(X)$: La probabilité d'occurrence du vecteur X .

Sur ce, la probabilité d'occurrence du vecteur X est formée par les valeurs de réflectances d'un pixel dans l'espace spectral à N dimensions, soit le nombre de bandes spectrales utilisées lors de la classification. Le vecteur X est représenté par l'équation 2.2 suivante, où M est le nombre total de classes :

$$P(X) = \sum_{i=1}^M P(X | C_i) \cdot P(C_i) \quad (2.2)$$

En somme, un pixel sera alors classifié dans la classe i si sa probabilité d'occurrence dans la classe i est supérieure à sa probabilité d'occurrence à une autre classe, soit j . Comme exprimé dans l'équation 2.3 :

$$P(C_i | X) > P(C_j | X) \quad (2.3)$$

La figure 2.1 illustre graphiquement comment les statistiques spectrales sont distribuées lors de la sélection des sites d'entraînements de trois classes. Les ellipses sont des distributions gaussiennes des statistiques dérivées des pixels connus pour chacune des classes à l'étude.




Figure 2.1 : Représentation graphique de l'algorithme du maximum de vraisemblance (Lillesand and Kiefer, 2004)

La classification par maximum de vraisemblance est très avantageuse, car elle prend en considération plusieurs statistiques des sites d'entraînements, tels la moyenne, l'écart type, la variabilité et la matrice des covariances. Par contre, l'algorithme nécessite beaucoup de temps pour les calculs des statistiques et la classification. Également, la précision des résultats en revient à la sélection des sites d'entraînements qui doivent être distribués normalement, ou de façon uni-modale, dans toutes les bandes spectrales soumises à la classification.

2.2.2 Distance minimale

L'algorithme de la distance minimale est non-paramétrique, c'est-à-dire qu'elle n'assume pas une distribution normale aux pixels d'entraînements mais elle effectue un calcul des distances spectrales entre les pixels à classifier et ceux entraînés. La distance minimale est la distance entre les pixels et la moyenne des pixels entraînés pour chacune des classes à l'étude. L'équation 2.4 (Hodgson, 1988; Demirci, 2005) permet le calcul des distances euclidiennes à la moyenne des différentes classes pour chacun des pixels.

$$Dist = \sqrt{(BV_{ijk} - \mu_{ck})^2 + (BV_{ijl} - \mu_{cl})^2} \quad (2.4)$$

Où :

μ_{ck} et μ_{cl} : Vecteurs moyens pour la classe c dans les bandes k et l ,
 BV_{ijk} et BV_{ijl} : Valeurs numériques du pixel i,j dans les bandes k et l .

La figure 2.2 illustre un pixel à classifier, D , et ses vecteurs aux moyennes des classes a , b et c dans la dimension des bandes k et l . Le pixel sera assigné à la classe à laquelle la distance à la moyenne sera la plus courte. Ce type d'algorithme est très rapide à exécuter et il ne donnera jamais de pixels non-classifiés, étant donné que tous les pixels possèdent une certaine distance aux moyennes des classes définies. Par contre, l'algorithme ne tient pas compte de la variabilité des pixels, par exemple le milieu urbain possède une très grande variabilité spectrale et sera donc des zones à confusion.

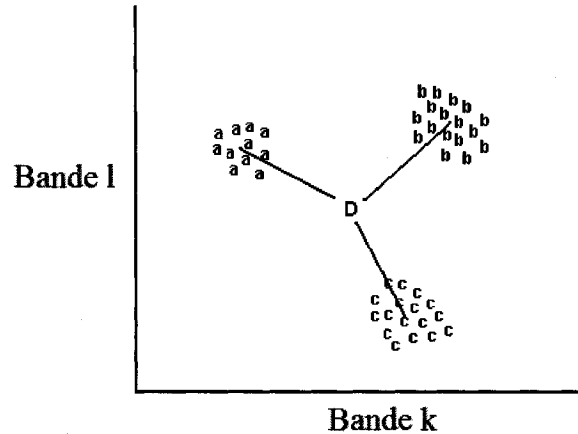


Figure 2.2 : Distance minimale aux moyennes des classes (Lillesand and Kiefer, 2004)

2.2.3 Parallélépipède

La méthode du parallélépipède est également non-paramétrique, elle considère les valeurs maximales et minimales des pixels d'entraînements de trois différentes méthodes :

1. les valeurs spectrales minimales et maximales des pixels d'entraînements dans n bandes;
2. la moyenne de chaque classe pour chacune des bandes, en additionnant ou déduisant un certain nombre d'écart types ou;
3. l'utilisateur assigne manuellement les valeurs minimales et maximales en fonction de certains critères d'évaluation des données et résultats escomptés.

Selon Demirci *et al.* (2005), la classification parallélépipède s'effectue selon une logique booléenne. L'algorithme décide si le pixel BV_{ijk} doit être associé à la classe c si :

$$\mu_{ck} - S_{ck} \leq BV_{ijk} \leq \mu_{ck} + S_{ck} \quad (2.5)$$

Où :

S_{ck} : Un écart type des données entraînées de la classe c dans le bande k , dans m classes et n bandes.

La figure 2.3 illustre de façon graphique, l'algorithme du parallélépipède. La zone ombragée représente la zone de confusion des classes b et c , dans la dimension des bandes k et l .

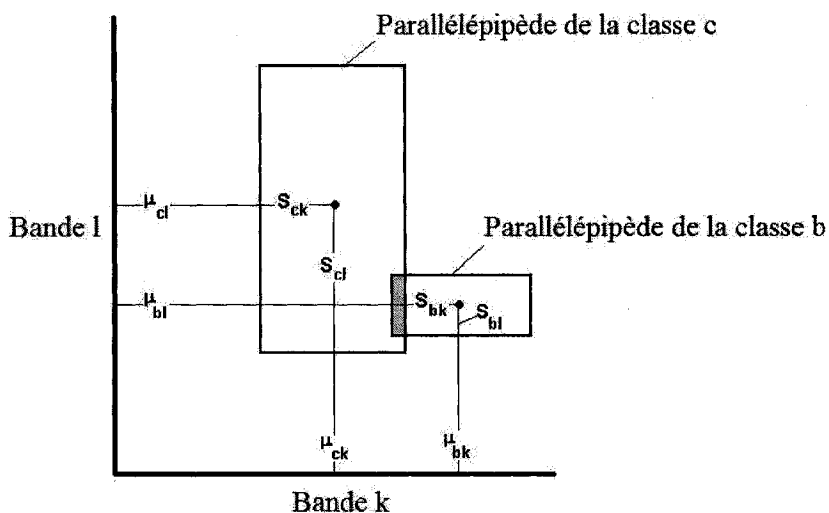


Figure 2.3 : Parallélépipède des classes b et c . (Demirci *et al.*, 2005)

L'un des avantages du parallélépipède est sa simplicité et sa rapidité d'exécution. Il en est limité aux simples valeurs minimales et maximales de chacune des classes, et ce, dans chacune des bandes spectrales disponibles. Il est souvent utilisé pour un aperçu rapide des résultats de classifications supervisées. D'une autre part, il est très désavantagé par ses représentations rectangulaires des distributions des valeurs des classes dans l'espace à n dimensions, où diverses classes peuvent se superposer spectralement (Campbell, 1996).

2.3 Méthodes de classifications orientées objets

La classification orientée objet débute par une segmentation de l'image qui regroupe les pixels en plusieurs objets, ou segments, selon certains critères d'homogénéité. La segmentation d'images satellitaires est un procédé mathématique nouveau, comparativement aux algorithmes de classification conventionnelle. Ce n'est seulement qu'au cours des deux dernières décennies que les algorithmes de segmentation se sont développés (Zhang, 1997; Haralick et Shapiro, 1984). Cette méthode révolutionnaire de

classification par objets nous donne accès à une multitude de caractéristiques des objets créés. Par exemple, avec la méthode de maximum de vraisemblance, ou tout autre algorithme de classification orientée pixel, nous sommes limités à la valeur de chaque et unique pixel et nous ne pouvons pas utiliser son entourage ou son contexte par rapport aux pixels qui l'entoure et qui, par conséquent, font partie de certaines entités telles une rivière ou une forêt.

La segmentation, tant qu'à elle, crée des objets qui possèdent des informations sur leurs couleurs, textures, formes, et dans certains cas, leurs hiérarchies. Par la suite, nous pouvons manuellement sélectionner, ou créer, une fonction d'appartenance pour les centaines de caractéristiques qui définissent les objets créés ou segmentés, et ce, pour chacune des classes ou catégories de classification. Le procédé de la segmentation a donc comme but de créer des entités qui sont formées par des pixels voisins qui ont des propriétés similaires (Haralick et Shapiro, 1985, Béné, 1987, Mansor, 2002, Barlow *et al.*, 2003, Wulder *et al.*, 2003, Repaka, 2004).

À la base, les procédés de segmentations se divisent en deux grands groupes (Ballard et Brown, 1982) : la segmentation par détection des contours et la segmentation par détection des régions (Carleer, 2005). La segmentation par détection des contours effectue une segmentation en se basant seulement sur la discontinuité des pixels à travers l'image. Un procédé de détection des arêtes (edge detection) doit également être appliqué pour que les contours deviennent des segments. Deux procédés de segmentation par détection des contours qui sont souvent considérés dans la littérature sont l'algorithme de détection optimale des arêtes (optimal edge detector; Canny, 1986; Cocquerez et Philipp, 1995) et la segmentation par bassin (watershed segmentation; Vincent et Soille, 1991, Debeir, 2001).

Le deuxième groupe, par détection des régions, se caractérise par deux procédés de choix, soit la technique de seuil à plusieurs niveaux (multilevel thresholding technique; Deravi et Pal, 1983) et l'algorithme de croissance des régions (region growing; Tilton, 1989; Burnett et Blaschke, 2003; van der Sande *et al.*, 2003; Baatz *et al.*, 2004). Plusieurs

comparaisons des algorithmes ci-dessus, et ainsi que plusieurs autres, ont déjà été publiées (Fu et Mui, 1981; Haralick et Shapiro, 1985; Bénéié *et al.*, 1989; Pal et Pal, 1993; Karantzas et Argialas, 2003; Neubert et Meinel, 2003; Carleer *et al.*, 2005). Dans ce chapitre, nous allons décrire brièvement leurs paramètres, leurs points forts ainsi que leurs utilisation dans diverses applications pour finalement en adopter une pour les traitements de nos images dans le cadre de cette recherche.

2.3.1 Détection des arêtes (*edge detection*)

Le procédé de segmentation par détection des arêtes est basé sur les différences spectrales des pixels (Ait Belaid, 1989). Des lignes de contours sont construites pour délimiter certaines zones de l'image segmentée, toujours en se basant sur la variance entre les pixels de l'image qui varient d'un endroit à l'autre.

Gupta *et al.* (1975) expliquent l'algorithme de la détection des arêtes qui débute par la délimitation de l'image en plusieurs objets, définie par des contours qui identifient les zones de grandes variances des pixels qui les séparent. Par la suite, chacun des objets est soumis à un test d'hypothèse pour déterminer leur similarité spectrale. Supposons deux objets, objet 1 et 2, soumis au test de leur fusion dans l'équation 2.6, si H_{01} est rejeté, l'algorithme conclut que l'objet 1 est différent de l'objet 2. Les deux objets en question ne sont donc pas regroupés.

$$\begin{aligned} H_{01} : \sigma_1^2 &= \sigma_2^2 \\ H_{a1} : \sigma_1^2 &\neq \sigma_2^2 \end{aligned} \quad (2.6)$$

Où :

σ_1^2 : Variance de l'objet testé 1,

σ_2^2 : Variance de l'objet testé 2.

Si l'hypothèse nulle (H_{01}) est acceptée, nous passons à l'équation 2.7 :

$$\begin{aligned} H_{02} : \mu_1 &= \mu_2, \sigma_1^2 = \sigma_2^2 = \sigma^2 \\ H_{a2} : \mu_1 &\neq \mu_2, \sigma_1^2 = \sigma_2^2 = \sigma^2 \end{aligned} \quad (2.7)$$

Où :

μ_1 : Moyenne spectrale de l'objet testé 1,

μ_2 : Moyenne spectrale de l'objet testé 2.

Si l'hypothèse nulle (H_0) est rejetée, l'algorithme conclut que les objets sont différents spectralement; si elle est acceptée, les objets sont fusionnés. Chacun des objets de l'image sont donc soumis à ses tests, et ce, pour toutes les bandes spectrales disponibles à la segmentation.

Gupta *et al.* (1975) ont également appliqués leur algorithme à la segmentation d'une image multispectrale aéroportée à 12 canaux (résolution spatiale de 1 m). Après segmentation, une classification orientée objets fut appliquée pour être comparée à une classification supervisée orientée pixel par maximum de vraisemblance. Les classes à l'étude sont des cultures agricoles, forêt et eau. Gupta *et al.* (1975) concluent que l'apport de la segmentation de l'image multispectrale a permis une amélioration considérable (4 à 7%) dans la classification des classes de maïs et de forêt.

Un article de Neubert *et al.* (2006) cite une étude comparative entre différentes techniques de segmentation. Quatre logiciels utilisant l'algorithme de croissances des régions, et deux logiciels utilisant l'algorithme par détection des arrêtes, sont comparés de façon qualitative et quantitative pour créer une segmentation d'une image IKONOS. L'évaluation quantitative est effectuée en comparant le nombre de segments créés, ou l'index de fragmentation (Strasters et Gerbrands, 1991), le « Area-Fit-Index » (Lucieer, 2004) et les caractéristiques des formes des objets par rapport à certains segments de références (Yang *et al.*, 1995). L'évaluation qualitative révèle que le logiciel SEGEN, utilisant un algorithme par croissance des régions, donne les objets qui ressemblent le plus à des entités au sol. De façon quantitative, Neubert *et al.* (2006) démontrent que les logiciels SegSAR et HalconSEG, les logiciels à algorithmes de détection des arêtes, sont ceux qui ont les mieux performés pour la délimitation des objets, le nombre d'objets créés et dans la forme moyenne des segments. Cependant, Neubert *et al.* (2006) mentionnent dans leur article que les logiciels évalués n'atteignent toujours pas les résultats des

segmentations, basés sur la croissance des régions créées par les logiciels eCognition et « Minimum Entropy Approach », évalués dans d'autres articles publiés (Meinel et Neubert, 2004).

Ait Belaid (1989) mentionne que si les différences spectrales entre les pixels des classes à l'étude sont très minimales, l'algorithme de la détection des arêtes n'est pas recommandé, car elle effectue une meilleure segmentation dans une image possédant une très grande variance spectrale, telles des images en milieu urbain (Massalabi, 2006). Dans notre recherche, les classes de cultures agricoles sont souvent mélangées avec la signature spectrale du sol sous-jacent, la méthode de segmentation par détection des arêtes ne sera donc pas considérée.

2.3.2 Croissance des régions et notion de hiérarchie

La segmentation par croissance des régions peut être effectuée selon différentes méthodes. Le principe de cette méthode est basé sur la sélection aléatoire de certains pixels qui vont sélectionner les pixels voisins qui ont les mêmes propriétés d'homogénéité, jusqu'à ce qu'un seuil d'hétérogénéité soit atteint (Blaschke *et al.*, 2000). La méthode classique de cet algorithme fut conçue par Horowitz et Pavlidis (1974). Par la suite, Beaulieu (1984) intégra la notion de hiérarchie dans son algorithme de la croissance des régions, soit le « hierarchical step-wise optimization » (HSWO). Suite à cette technique, Tilton (1998) ajouta le principe de groupage spectrale, ou « spectral clustering » à l'algorithme de segmentation, soit le « recursive hierarchical segmentation » (RHSEG). Ces techniques sont bien décrites dans la littérature mais ne sont souvent utilisées qu'à des fins expérimentales et toujours dans une version non-opérationnelle sans interface graphique qui faciliterait leurs utilisations.

Depuis près d'une décennie, un algorithme de croissance des régions qui utilise la notion de hiérarchie, est disponible sur le marché commercial. La compagnie allemande Definien's a conçu un logiciel permettant la segmentation d'images à multi-résolution (Baatz et Schäpe, 2000). Ce logiciel permet d'appliquer la segmentation par croissance des régions en regroupant les pixels selon quatre critères de bases : le poids des bandes

spectrales à utiliser, couleur (spectrale) ou forme, sinuosité (smoothness), et compacité (compactness). Ces critères définissent donc l'hétérogénéité des segments et déterminent leur homogénéité, leur complexité spatiale et leur taille (Carleer *et al.*, 2005). Cette technique de segmentation basée sur la croissance des régions, est légalement brevetée (Baatz et Schäpe, 1999), mais il est possible de comprendre les multiples techniques de bases (Haralick et Shapiro, 1985 ; Tilton, 1989; Adams et Bischof, 1994) et certains algorithmes utilisés lors de la création des multiples caractéristiques dérivées des objets segmentés. L'équation 2.6 (Baatz *et al.*, 2004) représente le calcul de l'hétérogénéité spectrale, soit la somme des écarts types selon le poids attribué aux différentes bandes spectrales.

$$h_{spectrale} = \sum_c w_c \cdot \sigma_c \quad (2.6)$$

Où :

$h_{spectrale}$: hétérogénéité spectrale des objets lors de la segmentation,

w_c : Le poids attribué à la bande spectrale c ,

σ_c : L'écart type de la bande c .

L'équation 2.7 représente le calcul de la moyenne spectrale pour tout objet segmenté. Une multitude de caractéristiques spectrales et spatiales sont calculées pour chacun des objets créés. La moyenne spectrale est la plus importante, car il s'agit tout simplement de calculer la moyenne des pixels pour chacune des bandes spectrales disponibles à la segmentation et la classification de l'image. La classification peut donc être effectuée en sélectionnant des objets d'entraînements qui sont représentatifs des classes à l'étude.

$$\bar{c}_L = \frac{1}{n} \cdot \sum_{i=1}^n c_{Li} \quad (2.7)$$

Où :

\bar{c}_L : Moyenne spectrale dans la bande L ,

c_{Li} : La valeur spectrale dans la bande L du pixel i ,

n : Le nombre de pixels regroupés dans l'objet.

De plus, le critère de l'hétérogénéité spatiale est calculé pour permettre de manipuler la définition ou la forme des objets segmentés. L'équation 2.8 est utilisée pour calculer ce critère spatial qui est basé sur les paramètres de sinuosité et de compacité. Ces critères ont également leurs calculs d'hétérogénéité appliqués lors de la segmentation. Les pixels sont regroupés pour former des objets et lorsqu'ils ont atteints le seuil du paramètre d'échelle, le procédé de segmentation se termine (Burnett et Blaschke, 2003; van der Sande *et al.*, 2003). L'équation 2.9 représente le calcul du critère de compacité et l'équation 2.10, le calcul de la sinuosité.

$$h_{spatiale} = w_c \cdot h_{comp} + (1 - w_c) \cdot h_{sin} \quad (2.8)$$

Où :

$h_{spatiale}$: Hétérogénéité spatiale d'un objet lors de la segmentation,

w_c : Le poids attribué au paramètre de compacité (ou inverse du poids de la sinuosité),

h_{comp} : La valeur de la compacité d'un objet,

h_{sin} : La valeur de la sinuosité d'un objet.

$$h_{comp} = \frac{l}{\sqrt{n}} \quad (2.9)$$

Où :

h_{comp} : La valeur de la compacité de l'objet,

l : La longueur du périmètre de l'objet,

n : Le nombre de pixels qui forme l'objet.

$$h_{sin} = \frac{l}{b} \quad (2.10)$$

Où :

h_{sin} : La valeur de la sinuosité d'un objet,

l : La longueur du périmètre l'objet,

b : La longueur d'une boîte rectangulaire ou « bounding box » qui pourrait entourer l'objet.

Lors des multiples itérations de la segmentation, ces équations précédentes (modifiées de Baatz *et al.*, 2004 ; Benz *et al.*, 2004; Vietti-Violi, 2007) sont appliquées à chacun des objets segmentés pour vérifier s'ils n'excèdent pas le seuil du paramètre d'échelle. L'équation 2.11 regroupe donc les critères d'hétérogénéité spectrale et spatiale (qui incorporent les valeurs de compacité et de sinuosité) pour permettre le calcul du paramètre d'échelle f . Ce paramètre d'échelle, calculé pour chacun des objets, doit être inférieur ou égal au paramètre d'échelle inscrit par l'utilisateur lors de l'application de l'algorithme de segmentation. Comme mentionné ultérieurement, c'est à cette étape initiale que l'utilisateur peut attribuer différentes combinaisons de poids pour chacune des bandes spectrales à être employées pour la segmentation.

$$f = w \cdot h_{\text{spectrale}} + (1 - w) \cdot h_{\text{spatiale}} \quad (2.11)$$

Où :

f : Paramètre d'échelle calculé pour chacun des objets lors des itérations de la segmentation,

w : Le poids attribué à l'hétérogénéité spectrale qui est inversement proportionnelle au poids attribué à l'hétérogénéité spatiale.

Tous ces calculs nous permettent donc de contrôler la segmentation grâce à l'information spectrale et spatiale des bandes utilisées pour la segmentation et sur les objets segmentés. Comme illustré à la figure 2.4 (modifiée de Baatz *et al.*, 2004), plusieurs segmentations peuvent être interreliées spatialement pour apporter la notion d'échelle et de hiérarchie.




Figure 2.4 : Réseau hiérarchique des objets d'une image (Baatz *et al.*, 2004)

Il est essentiel de bien sélectionner les paramètres de segmentation, car la qualité des objets va influencer directement les résultats de la classification de ceux-ci (Meinel et Neubert, 2004). Dans le chapitre 4, nous observerons de façon quantitative les différentes possibilités de segmentations, appliquées à nos données images. L'algorithme de la croissance des régions utilisé conjointement avec une hiérarchie nous permet également d'utiliser des objets d'un niveau inférieur à un niveau supérieur pour permettre une bonne représentation des entités au sol. Dans des applications de l'agriculture, il serait possible d'utiliser un niveau supérieur de segmentation, plus grossier, dû aux grandes zones homogènes, et nous pourrions nécessiter également l'apport de petits objets qui ont été segmentés à un niveau inférieur, plus fins, pour bien définir certaines zones de culture qui sont moins grandes en superficie (Schiewe *et al.*, 2001).

La segmentation par croissance des régions fut utilisée dans plusieurs recherches appliquées à l'agriculture de précision. Blaschke et Strobl (2001) citent que cette technique de segmentation est fréquemment utilisée pour une classification dite par-parcelle ou par-champs, telles celles de Janssen (1993), Aplin *et al.* (1999) et Smith et Fuller (2001) qui mentionnent que la segmentation par régions permet une excellente délimitation des champs agricoles, car ils sont spatialement stable, alors que les couverts végétaux à l'intérieur de ces champs sont plutôt variables.

Brooks *et al.* (2006) comparent le procédé de segmentation par croissances des régions avec la classification supervisée du maximum de vraisemblance du logiciel ERDAS dans le but d'effectuer la classification de différentes cultures agricoles à l'aide d'images Landsat « Thematic Mapper » (TM), ASTER et Terra/MODIS. Les cultures à l'étude sont le maïs, le soya, le blé, l'alfalfa et l'herbe. L'importante conclusion tirée de cette recherche est l'étonnante exactitude de la délimitation des champs agricoles à l'aide de la segmentation. La classification orientée pixel effectue beaucoup de mixage des pixels à l'intérieur des différents champs à l'étude. Par contre, le résultat de la classification orientée objets (68%) ne dépasse pas le résultat orientée pixel (69,8%). Brooks *et al.* (2006) suggèrent que la forte présence de nuages dans certaines images a pu nuire aux résultats.

La recherche de Radoux et Defourny (2006) évalue de façon quantitative la segmentation par croissance des régions. Une délimitation manuelle à l'échelle de 1/10'000 fut utilisée comme vecteurs de validation à la segmentation dirigée. Les objets, créés selon différents critères de forme, compacité et homogénéité, seront évalués selon leurs positions par rapport aux vecteurs de références ainsi que par la consistance spectrale des objets. Trois classes étaient à l'étude, soit les forêts de conifères, de feuillus et les champs agricoles. La segmentation fut effectuée sur une image du capteur IKONOS, qui subit une fusion de la bande panchromatique avec les bandes multispectrales. Radoux et Defourny (2006) concluent qu'il existe une étroite relation ($R^2 = 0,98$) entre les paramètres d'homogénéité de la segmentation et l'erreur de positionnement des objets par rapport aux vecteurs de validations. Également, la séparabilité spectrale des objets s'accroît avec l'augmentation des paramètres de segmentation, telle la compacité. La recherche mentionne que l'utilisation du paramètre de la forme des objets, ainsi que l'apport de la compacité a permis l'amélioration de la segmentation. Une segmentation à l'aide d'un faible paramètre d'homogénéité semble très bien performée. Les champs agricoles ont connu le plus haut taux de succès de segmentation, mais la délimitation des deux types de forêts ne semble s'améliorer avec différentes paramètres de segmentation (Radoux et Defourny, 2006).

Dans une application de la classification de l'occupation du sol, Xu *et al.* (2004) ont utilisés une image Quickbird (5 bandes spectrales, 0,61 m de résolution spatiale dans le panchromatique et 2,4 m dans le multispectral), ainsi que la segmentation hiérarchique par croissance des régions. Leur site, situé en Chine, regroupe différentes classes d'occupation du sol mais majoritairement des champs agricoles qui sont occupés par des cultures de soya, maïs et plantations. Xu *et al.*, (2004) concluent que la segmentation a permis une excellente délimitation des champs agricoles et la classification à l'aide des ensemble flous a contribué au haut taux de succès de classification de l'image (97%).

L'étude de Repaka (2004) avait permis une comparaison entre les méthodes de classification orientée pixel supervisée et non supervisée contre la méthode orientée objet

dans le but de faire l'extraction d'entités de transports d'un système routier. Ces chercheurs ont obtenu comme résultat que la classification supervisée du maximum de vraisemblance, sur leur image du satellite à haute résolution spatiale Quickbird, a obtenu une précision de 69,42%, alors qu'une classification orientée objet sur la même image a obtenu une précision de 82,55%. Il est donc démontré que la segmentation d'image à haute résolution spatiale peut améliorer le résultat des classifications significativement.

La plupart des recherches effectuées sur la classification orientée objet en considérant la segmentation, utilise des images multispectrales. Ces images regroupent l'information spectrale dans un nombre limité de bandes, ayant de larges résolutions spectrales. Toutefois, ce type d'images ne permet pas d'extraire suffisamment d'informations sur les caractéristiques spectrales des entités au sol. Certaines recherches emploient des images hyperspectrales qui possèdent une multitude de bandes spectrales avec des résolutions spectrales beaucoup moins larges. Dans un contexte d'application urbaine, Greiwe et Ehlers (2005) ont intégré une ortho-photo segmentée avec une image hyperspectrale acquise par le capteur Australien HyMap pour la classification SAM (spectral angle mapper). Ils ont démontré qu'en intégrant la segmentation d'images à la classification SAM, la précision des résultats passe de 51,8 à 73,3%. Ils concluent donc que l'apport de la résolution spectrale de l'image hyperspectrale et l'apport de la haute résolution spatiale de l'ortho-photo, permettent une excellente extraction des classes urbaines. Globalement, dans le contexte de l'agriculture de précision, Bannari *et al.* (2006) ont démontré que l'utilisation de l'imagerie hyperspectrale est beaucoup plus avantageuse du point de vue des résolutions spatiales et spectrales qu'un capteur satellitaire multispectral pour la cartographie de différents types de couverts végétaux en milieu agricole.

Dans une application d'agriculture de précision, une segmentation d'image HRV (Haute Résolution dans le Visible) du satellite SPOT fut réalisée dans le nord de l'Afrique pour délimiter les parcelles agricoles (Ait Belaid, 1990). Cette étude a démontré que la segmentation d'images permet une amélioration de la précision de la classification à 90%, comparativement à la précision de la classification orientée pixel qui est de 68%. Hill *et al.* (2002) ont utilisé une image acquise par le capteur hyperspectral aéroporté

CASI pour effectuer une classification orientée objet sur des parcelles agricoles. Lors de la validation des résultats avec la vérité terrain, ils ont obtenu 88% de précision. Dans une application de cartographie de l'occupation du sol dans une région du nord de la Chine, en utilisant une image multispectrale ASTER, Yan *et al.* (2006) ont obtenu une précision de 83% lors d'une classification orientée objet et uniquement une précision de 46% pour une classification par maximum de vraisemblance.

En résumé, les principaux avantages de la segmentation d'images sont, d'une part, la présence des relations spatiales qui est créée entre les segments à travers les différentes hiérarchies ou niveau de segmentation. La segmentation tient compte du contexte et de l'homogénéité des pixels qui peuvent se regrouper. Différentes caractéristiques peuvent être dérivées après une segmentation pour ensuite être utilisées comme règles de classification. Finalement, elle permet de réduire la taille de l'image en nombre de pixels qui deviennent un nombre limité d'objets et les objets créés facilitent une intégration à un SIG (Smith et Fuller, 2001). D'une autre part, la segmentation a comme désavantage l'augmentation au risque de fausse délimitation des entités au sol. Cela peut contribuer à une perte de la résolution au sol et à un faux résultat de classification.

Dans cette section, nous avons vu comment il est utile d'employer la segmentation dans divers domaines et à l'aide de plusieurs sources d'images différentes. Pour l'occupation générale du sol et l'agriculture en particulier, la segmentation par croissance des régions permet d'obtenir une multitude d'informations spectrales pour obtenir une forte séparabilité entre les objets qui sont et qui ne sont pas de la végétation arbustive et agricole. Également, des images multispectrales à faible résolution spatiale sont segmentées en utilisant leur bande panchromatique, si disponible, pour augmenter la définition des objets en relation aux entités au sol, mais ceci peut également causer des problèmes lors de l'extraction de l'information spectrale lors de la classification de ces objets. Il ne faut surtout pas oublier les prétraitements qui sont essentiels à une bonne classification, car les valeurs spectrales des images sont la base des paramètres de classification, et permettent une bonne précision des résultats (Bannari *et al.*, 1999).

2.3.3 Classification des objets segmentés

Après avoir effectué une segmentation d'images, trois techniques de classification des objets sont possible : les fonctions d'appartenance, la classification par plus proche voisin et les ensembles flous. Illustré à la figure 2.5 (modifiée de Baatz *et al.*, 2004), la classification par fonctions d'appartenance ressemble de près à la classification orientée pixel du parallélépipède.




Figure 2.5 : Distribution spectrale de deux classes (bleu et rouge) et de leurs fonctions d'appartenance dans un espace à deux dimensions (Baatz *et al.*, 2004)

Les fonctions d'appartenances sont des règles de classification qui sont définies manuellement à l'aide d'une connaissance *a priori* des valeurs de certaines caractéristiques (moyenne spectrales dans diverses bandes ou toutes autres mesures relevées au sol qui sont quantifiables) des classes à l'étude ou par interprétation visuelle de leur distribution. La figure 2.5 démontre trois fonctions d'appartenance (rectangles) pour les deux classes (bleu et rouge). Les trapézoïdes sur les axes représentent l'étendue des fonctions selon les caractéristiques 1 et 2. Pour la classe bleue, les valeurs des deux fonctions se retrouvent à l'intérieur de la fonction d'appartenance de la classe rouge. Ce sont dans ces situations qu'il peut y avoir confusion dans la classification, mais dans d'autres cas, ces fonctions permettent d'améliorer les résultats lorsqu'une caractéristique réussit à bien séparer les classes.

La deuxième technique, par plus proche voisin, est très similaire à l'algorithme du maximum de vraisemblance, alors qu'elle calcule les distances spectrales aux diverses caractéristiques sélectionnées lors de l'entraînement des classes à l'étude. La figure 2.6 (modifiée de Baatz *et al.*, 2004), représente les objets d'entraînements de la classe bleu et rouge, ainsi que leur étendue statistique selon les caractéristiques (axes) 1 et 2.

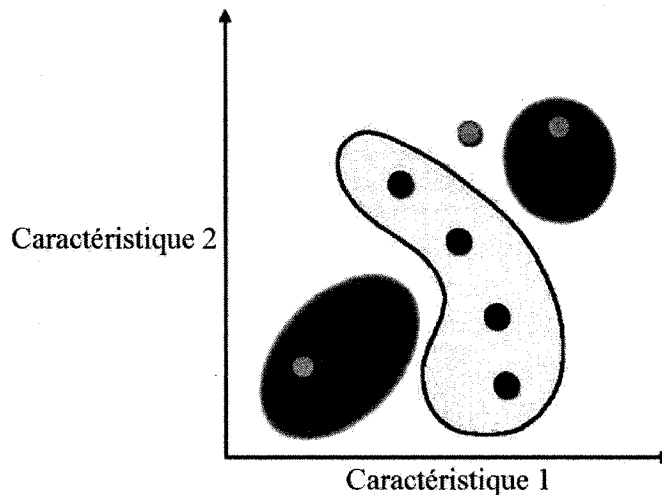


Figure 2.6 : Distribution spectrale de deux classes entraînées (bleu et rouge) dans un espace à deux dimensions (Baatz *et al.*, 2004)

Tout comme la classification orientée pixel, les classes doivent être entraînées en sélectionnant les objets qui les représentent le mieux, et ce, dans toutes les caractéristiques spectrales qui peuvent bien classifier les objets dans leurs classes respectives. Dans la figure 2.6, l'objet vert sera soumis à l'algorithme du plus proche voisin pour déterminer dans quelle classe il devra être attribué. Tout comme la classification par maximum de vraisemblance, les objets sélectionnés pour représenter les classes à l'étude doivent être sélectionnés selon une distribution normale ou uni-modale. Le fort avantage de la technique de classification après segmentation est l'utilisation des multiples caractéristiques dérivées de la segmentation pour entraîner les classes. Il est donc possible d'entraîner une classe dans une caractéristique de forme et une autre classe par des caractéristiques spectrales. La troisième technique, soit les ensembles flous, permet d'établir un degré d'attribution des objets aux classes à l'étude. Les objets s'y voient donc attribué des valeurs de 0 à 1, pour certaines classes, 0 étant aucun

appartenance et 1 une parfaite association. Ces ensembles sont souvent utilisés conjointement avec des données terrain pour insérer la notion d'incertitude et de diverses possibilités à la classification.

2.4 Choix de la méthode

Après avoir considéré et révisé les différentes techniques de classification d'images mentionnées ci-haut, nous avons choisi d'utiliser les méthodes les plus documentées et adaptées aux applications à l'agriculture de précision. Après avoir observé les points forts des différentes techniques, leur utilisation en fonction des différents champs d'applications, les méthodes sélectionnées dans cette recherche seront la classification supervisée du maximum de vraisemblance orientée pixel, ainsi que la classification orientée objet sur une segmentation d'images par croissance des régions. Étant donné la grande complexité du mixage spectral des classes agricoles à l'étude, le maximum de vraisemblance est beaucoup plus avantageux sur différents aspects, tels le calcul des probabilités de classification, le calcul des distances spectrales et la répartition normale des statistiques des classes à l'étude. Pour la classification orientée objets, la segmentation par croissance des régions est la plus utilisée en agriculture, car elle exécute une bonne délimitation des parcelles, effectue une excellente segmentation des milieux homogènes à faible variabilité, tel un champ agricole, et permet un contrôle sur les paramètres de segmentation (homogénéité, compacité, forme, etc.).

2.5 Conclusions

Ce chapitre a fait état des diverses méthodes de classification et de segmentation d'image considérées dans le cadre de cette recherche. Nous avons analysé comment elles étaient utilisées dans différentes applications pour finalement sélectionner les méthodes optimales pour atteindre les objectifs de la présente recherche. Pour effectuer une comparaison solide entre deux procédés qui n'utilisent pas les mêmes paramètres, les deux techniques de classifications retenues sont estimées les plus robustes et fiables. La

segmentation par croissance des régions semble être optimale pour évaluer l'apport de la segmentation à la classification hyperspectrale, et ce, à diverses échelles. Le prochain chapitre documente les sites d'études, les données images utilisées, ainsi que la méthodologie appliquée dans le cadre de cette recherche. Nous allons décrire les prétraitements auxquels les images seront soumises avant d'appliquer les procédés de segmentation et de classification dans le but d'extraire des informations sur les différentes cultures agricoles.

CHAPITRE 3 : MÉTHODOLOGIE

3.1 Introduction

Dans ce chapitre, nous décrivons le cheminement méthodologique que nous allons utiliser pour atteindre nos objectifs (figure 3.1). Les images acquises à différentes résolutions spatiales seront soumises à des prétraitements, à des traitements, et à des analyses statistiques des résultats. Dans le cadre de ce projet, pour des fins de validation des résultats, nous disposons de deux sites d'études. Le premier site servira à l'application de notre méthodologie en considérant les différentes résolutions spatiales du capteur CASI. Quant au second site, il servira à des fins de validations pour nos méthodes de classifications pour contre-vérifier nos procédés de traitements d'images et d'analyses comparatives en considérant une image hyperspectrale acquise par le capteur Probe-1 (résolution spatiale de 5m) et une image multispectrale acquise par le capteur IKONOS (résolution spatiale de 4m).

3.2 Sites d'étude

Deux sites agricoles possédant une variété de cultures différentes sont utilisés pour l'étude. Le premier site est localisé dans le sud du Québec, alors que le second site de validation est situé dans le sud de la Saskatchewan.

3.2.1 *St-Jean-sur-Richelieu, Québec*

Notre site d'étude principale est un site expérimental pour l'agriculture de précision. Il est localisé à L'Acadie, au centre de recherche et de développement en horticulture, agriculture et agroalimentaire Canada à St-Jean-sur-Richelieu, Est de Montréal (45° 17' 40''N, 73° 20' 10''O; figure 3.2). Ce site fut acquis par le centre de recherche en 1964 et possède une superficie de 84 hectares de terre agricole de type « loameux-argileux » (30% sable, 30% silt et 30% argile) (CRDH, 2007), réservé à la culture des légumes, des petits fruits et des plantes ornementales.

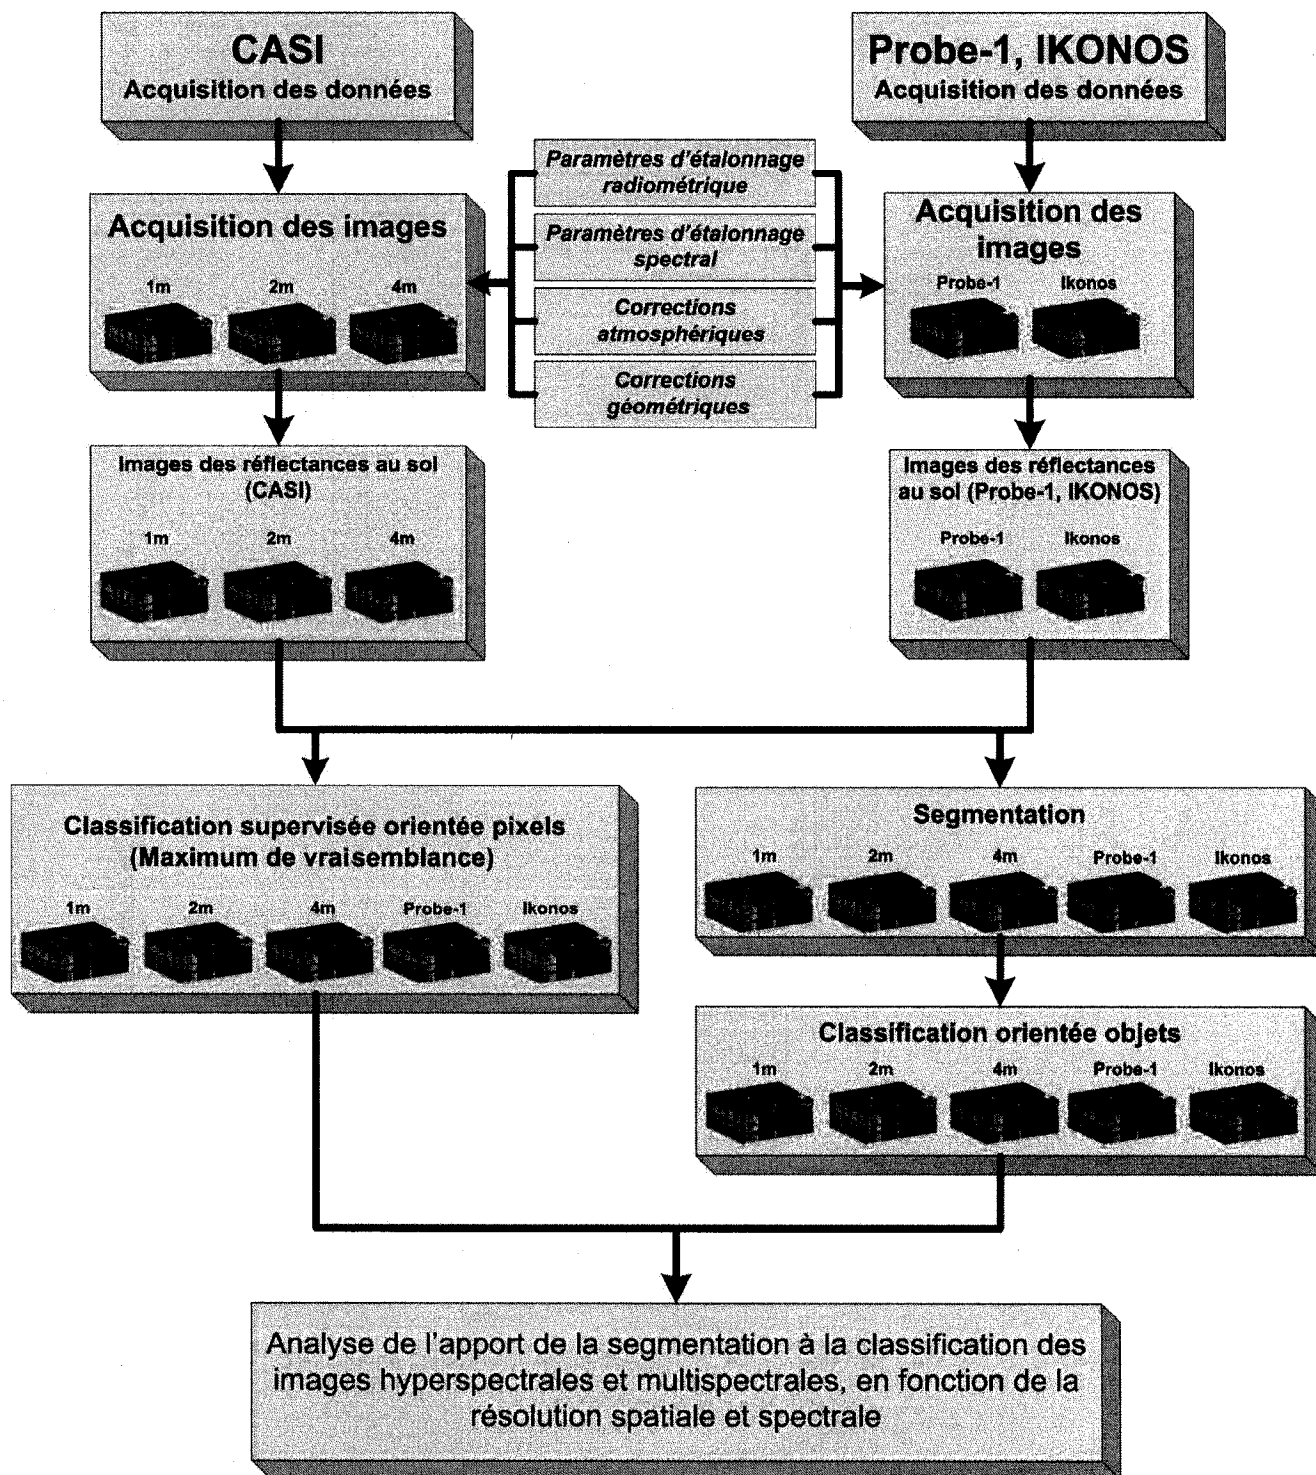


Figure 3.1 : Organigramme de la méthodologie

Étant localisé dans les plaines du St-Laurent, le site d'étude se caractérise par une topographie très plane avec une élévation d'environ 41m ±1m, et un climat continental humide du sud québécois permettant une saison agricole de mai à septembre (Haboudane *et al.*, 2002). Lors des acquisitions de nos images, les trois champs agricoles à l'étude (figure 3.3) étaient ensemencés de maïs (sud), haricots (nord-ouest) et pois (nord-est).

3.2.2 Indian Head, Saskatchewan

Le second site d'étude, situé à l'est de Regina en Saskatchewan, fait partie de la ferme expérimentale du « Indian Head Agricultural Research Foundation » (50° 33'N, 103° 36'O; figure 3.2). Huit champs de 12 hectares ont été choisis pour la recherche, soit 4 de blés (*Triticum aestivum L.*), 2 de pois (*Lathyrus aphaca L.*) et 2 de canola (*Brassica napus L.*). Chacun des champs fut divisé en quatre sections de 3 hectares pour effectuer la semence et la fertilisation. Le tableau 3.1 donne une description des champs étudiés à Indian Head. Étant situé dans les prairies canadiennes, à une élévation de 578 m, le site possède un relief relativement plat, à l'exception d'un fossé qui croise le site de façon diagonale. Le site fut utilisé fréquemment dans des applications reliées à l'agriculture de précision (Champagne *et al.*, 2003; Basnyat *et al.*, 2004; Pacheco 2004; Bannari *et al.*, 2007, Bannari *et al.*, 2008)

Tableau 3.1 : Description des champs à l'étude à Indian Head (Pacheco, 2004).

Nom du champ	Type de semence	Date et taux de semence	Traitements au Nitrogène
Canola-1	Canola	17 mai – 27.2 kg/ha	Variable
Canola-2	Canola	9 mai – 27.2 kg/ha	Variable
Pois-1	Pois	3 mai – 180.8 kg/ha et 244.8 kg/ha	Aucun
Pois-2	Pois	5 mai – 180.8 kg/ha et 244.8 kg/ha	Aucun
Blé-1	Blé	17 mai – 134.8 kg/ha	Variable
Blé-2	Blé	20 mai – 134.8 kg/ha	Variable
Blé-3	Blé	20 mai – 134.8 kg/ha	Variable
Blé-4	Blé	20 mai – 134.8 kg/ha	Variable




Figure 3.2 : Carte de localisation des sites de St-Jean-sur-Richelieu, Québec, et d'Indian Head, Saskatchewan.

3.3 Données images

En tout, cinq acquisitions d'images ont été effectuées, trois sur le site de St-Jean-sur-Richelieu en utilisant le capteur hyperspectral aéroporté CASI et deux sur le site d'Indian Head en utilisant le capteur hyperspectral aéroporté Probe-1 et le capteur satellitaire IKONOS. Sur chacun des sites, une acquisition d'images hyperspectrales va permettre d'établir une bonne comparaison de l'utilisation des images à hautes résolutions spectrales dans l'application à l'agriculture de précision. Quant à l'image multispectrale IKONOS effectuée sur le site d'Indian Head, elle va nous permettre d'observer comment nos procédés peuvent être également appliqués sur ces types d'images à plus faible résolution spectrale.

3.3.1 CASI

Les données utilisées sur le site de St-Jean-sur-Richelieu ont été acquises par le capteur hyperspectral aéroporté CASI (Compact Airborne Spectrographic Imager). Celui-ci fut développé par Itres Research Limited, localisé à Calgary, à la fin des années 1980 (Babey et Anger, 1993). Le capteur CASI fut employé dans différentes recherches et il est surtout utilisé dans les applications agricoles (Jago et al., 1999; Haboudane *et al.*, 2002; Haboudane et al., 2004; Liu *et al.*, 2005) et en foresteries (Zarco-Tejada *et al.*, 2001; Fernandes *et al.*, 2002; Bunting et Lucas, 2006). Le CASI est un capteur à balayage qui utilise un système CCD (Charged Coupled Device). Il permet l'acquisition des images dans le sens du déplacement de l'avion dans le visible et le proche infrarouge du spectre électromagnétique (430 à 870nm, répartie en 72 canaux). Les données considérées pour cette recherche sont trois images acquises le 14 août 2003, à différentes altitudes, assurant trois différentes résolutions spatiales: 1m, 2m et 4m (figures 3.3 a, b et c, respectivement). L'acquisition a été effectuée en août, période de l'année où le couvert végétal est au stade maximal du développement phénologique. Selon les données climatiques acquises à l'aéroport de Dorval (Montréal) par Environnement Canada, les données images ont été acquises dans des conditions optimales: ciel complètement dégagé avec une température moyenne de 24°C et une excellente visibilité.




Figure 3.3 : Données images du capteur CASI, 1m (A), 2m (B) et 4 m(C).
 (Rouge : 774,05nm; Vert : 699,76nm; Bleu : 549,68nm)

3.3.2 PROBE-1

Les données hyperspectrales, du site d'Indian Head, ont été acquises le 28 juin 2000 à 11h00 AM à l'aide du capteur aéroporté Probe-1 (ESSI Inc., 2001). La figure 3.4 illustre un cube 3D hyperspectrale de l'image exploitée dans cette recherche. Probe-1 est également de style à balayage perpendiculaire à l'axe d'acquisition, tandis que le mouvement de l'avion permet le mouvement dans l'axe d'acquisition. Il capte les valeurs de radiance dans la partie visible, proche infrarouge et infrarouge à ondes courtes (Short Wave Infra Red : SWIR) du spectre électromagnétique. L'acquisition s'effectue à l'aide de 4 détecteurs qui chacun capte l'information spectrale sur 32 bandes, pour un total de 128 bandes spectrales (tableau 3.2). Dix bandes spectrales étaient saturées de bruits et ont donc été éliminées pour cette recherche. Cent dix-huit bandes spectrales ont donc été utilisées. Les longueurs d'ondes enregistrées sont situées entre 437,9 nm à 2506,7 nm de façon contigüe, à l'exception de quelques intervalles dans les longueurs d'ondes de 1380 nm à 1870 nm, dues aux fortes absorptions de vapeur d'eau atmosphérique. Lors de l'acquisition, l'avion survolait le site à une altitude moyenne de 2780 m (au-dessus du niveau de la mer). Possédant un angle de vue de 60°, l'étendue spatiale d'acquisition fut donc de 2,56 km, soit 512 pixels, et une résolution spatiale de 5 m à la position nadir.

Lors de l'acquisition, le capteur est positionné sur une girouette à 3 axes pour le stabiliser et réduire les effets de mouvements de l'avion. Un GPS non différentiel fut utilisé lors de l'acquisition pour enregistrer la position de l'appareil pendant le vol. Des conditions optimales d'acquisition ont permis d'obtenir une image sans aucun nuage et l'acquisition a eu lieu un mois après la semence, ce qui permet de bien faire la distinction entre le sol sous-jacent, les résidus de culture et la végétation en croissance continue (Basnyat *et al.*, 2004).




Figure 3.4 : Cube hyperspectral des données images du Probe-1
(Rouge : 780.7nm, Vert : 690.9nm, Bleu : 552.8nm)

Tableau 3.2 : Spécification spectrale des détecteurs du capteur Probe-1 (Pacheco, 2004)

Détecteurs	Étendues spectrales	Largeurs spectrales	Intervalles d'échantillonnages spectrales
1	437.9 – 904.3 nm	13.7 – 20.7 nm	10.7 – 18.3 nm
2	896.3 – 1355.3 nm	13.3 – 22.3 nm	12.5 – 19.8 nm
3	1394.7 – 1801.1 nm	14.6 – 17.8 nm	11.7 – 15.6 nm
4	1977.6 – 2506.7 nm	16.7 – 21.5 nm	13.9 – 18.9 nm

3.3.3 IKONOS

Les données multispectrales acquises par le capteur IKONOS au-dessus du site d'Indian Head ont été acquises le même jour que les données hyperspectrales acquises par le capteur Probe-1, soit le 28 juin 2000 (figure 3.5). Ce capteur multispectral, sur une

plateforme satellitaire, a comme but premier d'acquérir des images de hautes résolutions spatiales permettant la cartographie et les études de suivis continues. Le capteur est à la fois multispectrales (résolution spatiale de 4 m dans le bleu, vert, rouge et proche infrarouge) et panchromatique (1m). Le tableau 3.3 représente les caractéristiques spectrales et spatiales du satellite IKONOS. Il évolue sur une orbite polaire à une altitude moyenne de 681 km, lui donnant une étendue spatiale au sol de 11 km. Ce satellite fut utilisé dans plusieurs champs d'applications, notamment dans l'agriculture (Bannari *et al.*, 2006), la foresterie (Van Coillie *et al.*, 2007) et des applications urbaines (Lhomme *et al.*, 2004).




Figure 3.5 : Données images IKONOS (Composé proche infrarouge, rouge, vert)

Tableau 3.3 : Caractéristiques du satellite IKONOS

Bandes	Étendues spectrales	Résolutions spatiales
1 (Bleu)	445 à 516 nm	4 m
2 (Vert)	506 à 595 nm	4 m
3 (Rouge)	632 à 698 nm	4 m
4 (Proche infra rouge)	757 à 853 nm	4 m
5 (Panchromatique)	450 à 900 nm	1 m

3.4 Prétraitements des données images

Toutes les données images ont été soumises à différentes étapes de prétraitements. Nous avons débuté par les données CASI sur le site de St-Jean-sur-Richelieu, suivi des données Probe-1 et IKONOS sur le site d'Indian Head. Trois prétraitements ont été appliqués aux données images pour obtenir les réflectances au sol, soit les corrections radiométriques, atmosphériques et géométriques.

3.4.1 CASI

Trois étapes majeures de prétraitements ont été effectuées. Premièrement, les corrections radiométriques sont appliquées pour normaliser l'information fournie par les différents détecteurs du capteur, à l'aide du logiciel « Imaging Spectrometer Data Analysis System » (ISDAS; Staenz *et al.*, 1998). L'étalonnage relatif est calculé pour uniformiser l'information reçue par les détecteurs, pour minimiser certains effets, tels le délignage, le dérayage et les stries (Bannari *et al.*, 1999). L'étalonnage absolu est calculé pour permettre une conversion des comptes numériques (CN, connus en anglais sous le nom de DN : digital numbers) en luminances apparentes au capteur. Ces dernières ont été calculées au niveau du capteur en utilisant les paramètres d'étalonnage calculés au laboratoire du CRESTech (Centre for Research in Earth and Space Technology) (Sampson *et al.*, 2003).

Deuxièmement, les corrections atmosphériques ont été appliquées pour contrevenir à deux effets : l'absorption et la diffusion. Ces effets sont exercés conjointement par les gaz et les aérosols présents dans l'atmosphère. L'absorption cause un affaiblissement du signal mesuré dû au fait que les photons entrent en contact avec les principaux gaz atmosphériques. Quant à la diffusion, elle cause des changements de directions du signal lorsqu'il entre en contact avec les molécules des gaz et les particules atmosphériques (Lillesand et Kiefer, 2000). Il existe plusieurs techniques de correction atmosphérique, telles les méthodes empiriques de régression et de calcul minimal de l'histogramme. D'autres méthodes physiques sont plus robustes et considèrent tous les paramètres atmosphériques qui interfèrent lors de l'acquisition de l'image. Dans le cas du CASI, le

modèle de corrections atmosphériques physiques CAM5S (Canadian Advanced Modified - Simulation du Signale Satellitaire dans le Spectre Solaire) adapté par O'Neill *et al.* (1997) a été appliqué pour calculer les valeurs de réflectances au sol par le CRESTech. Le CAM5S est dérivé du modèle 5S (Tanré *et al.*, 1986) qui est l'un des modèles le plus utilisé pour la correction des images CASI (Sampson *et al.*, 2003; Moorthy *et al.*, 2003). Il tient compte de la géométrie du capteur et d'ensoleillement (Chen *et al.*, 1999) et de l'altitude du terrain.

Finalement, avant de procéder à un géo-référencement, les images CASI ont été corrigées des distorsions causées par les mouvements de l'avion (tangage, roulis, lacet, variations de la vitesse et de l'altitude). Tous ces paramètres ont été enregistrés à l'aide d'un système de navigation inertiel (SNI ; Bannari *et al.*, 1997) et appliqués aux images par le CRESTech. Une fonction polynomiale du second ordre fut considérée pour le géo-référencement des images dans la projection UTM et le géoïde NAD-83. Cette méthode permet une excellente répartition des distorsions de l'image en assurant une erreur quadratique moyenne (EQM) inférieure à un pixel, ce qui est largement acceptable pour des applications thématiques (Bannari *et al.*, 1995).

3.4.2 PROBE-1

Pour le Probe-1, les comptes numériques ont été convertis en luminances apparentes au capteur en utilisant les « gains » et « offsets » des bandes spectrales qui ont été calculées en laboratoire après l'acquisition des données. Par la suite, pour obtenir les réflectances au sol, un modèle de transfert radiatif fut appliqué, soit le MODTRAN-3 (Berk, 1989) en combinant des tables de correspondance ou « Look-Up Table » (LUT; Staenz et Williams, 1997). Les réflectances dérivées ont été ensuite analysées pour déterminer les longueurs d'ondes centrales de certaines caractéristiques d'absorption atmosphérique : 780 nm (oxygène), 940 nm et 1130 nm (vapeur d'eau) et ainsi que 2005 nm et 2055 nm (dioxyde de carbone). Des déphasages de longueurs d'ondes ont ensuite été corrigés pour obtenir un signal continu dans ces zones d'absorption atmosphérique. Pour plus d'informations sur les procédés d'étalonnage et de corrections atmosphériques,

veuillez vous référer aux travaux de Champagne (2003), Pacheco (2004) et Bannari (2006).

Lors d'une acquisition d'image aéroportée, l'avion effectue plusieurs mouvements dans les trois dimensions, soit le tangage, le roulis et le lacet. Dans le cas de l'acquisition des données images CASI, un système de navigation inertiel a permis le calcul de ces mouvements, nécessaire pour une correction géométrique rigoureuse, mais lors de l'acquisition de l'image Probe-1, un système GPS différentiel était présent à bord de l'appareil. Malheureusement, le GPS n'était pas opérationnel lors de l'acquisition, et par conséquent aucune donnée de positionnement de l'image ne fut enregistrée. Nous allons voir dans la prochaine section comment les données IKONOS ont été corrigées géométriquement et utilisées par la suite pour le géoréférencement des données Probe-1.

Tableau 3.4 : Paramètres du modèle MODTRAN-3 pour les corrections atmosphériques de l'image Probe-1 (Pacheco, 2004)

Paramètres	Valeurs
Date	2000:06:28
Temps Moyen de Greenwich (GMT)	17:10:00
Direction de l'avion	110°
Altitude du capteur (au dessus du niveau de la mer)	2780 m
Élévation du terrain (au dessus du niveau de la mer)	579 m
Angle Zénithal Solaire	34,35°
Angle d'Incidence Solaire	132,55°
Modèle Atmosphérique	Été, Latitude Moyenne
Modèle d'Aérosol	Rural, Continentale
Indice de Vapeur d'Eau	1,5 g/cm ²
Ozone (selon le modèle)	0,319 cm-atm
CO2 (selon le modèle)	357,5 ppm
Visibilité à l'horizon	50 km

3.4.3 IKONOS

En ce qui a trait aux données images d'IKONOS, les comptes numériques ont été convertis en luminances apparentes au capteur en utilisant les coefficients de calibration, livrés avec les données (Peterson, 2001). L'équation 3.1 est donc appliquée à chacun des pixels des différentes bandes spectrales de l'image IKONOS pour obtenir les luminances au capteur.

$$L_{\lambda}(mW/cm^2 * sr) = \frac{DN}{CalCoef_{\lambda}} \quad (3.1)$$

Où :

- L_{λ} : radiance spectrale au capteur en $mW/cm^2 * sr$ pour la longueur d'onde λ ,
- DN : Compte numérique,
- CalCoef $_{\lambda}$: Coefficient de calibration pour la longueur d'onde λ .

Le calcul des réflectances au sol pour IKONOS a été effectué grâce au MODTRAN-3, le même modèle que celui appliqué aux données Probe-1, basé sur les données captées au sol lors de l'acquisition de l'image en utilisant les réponses spectrales relatives aux bandes spectrales d'IKONOS, figure 3.6 (Bowen, 2002; Space imaging, 2002). Pour les corrections géométriques, l'image IKONOS fut livrée avec un positionnement géographique très précis (< 2 m; Cook *et al.*, 2001). Il n'y a donc pas eu de corrections géométriques pour l'image IKONOS.

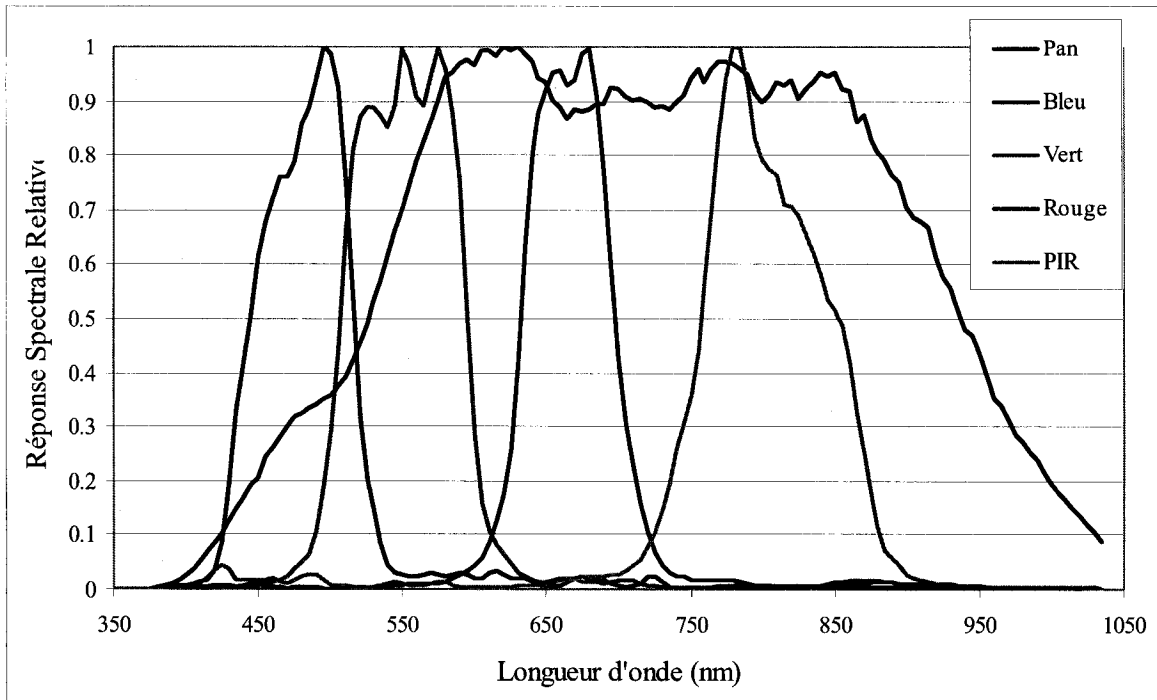


Figure 3.6 : Réponses spectrales relatives d'IKONOS

3.5 Traitements

Toutes les données images ont été soumises aux mêmes traitements. Nous avons débuté par les données CASI sur le site de St-Jean-sur-Richelieu, suivi des données Probe-1 et IKONOS sur le site d'Indian Head. Pour permettre une analyse comparative, les différentes classifications ont été effectuées en fonction des mêmes classes d'occupation du sol. Pour St-Jean-sur-Richelieu, les classes ont été considérées à trois différents niveaux ou densité, de maïs, deux classes d'haricots, deux classes de pois et ainsi qu'une classe de sol nu. Pour Indian Head, il s'agit de blé, canola, pois, résidu de culture et sol nu.

3.5.1 Classification par maximum de vraisemblance

La classification supervisée par maximum de vraisemblance est une méthode paramétrique qui considère normale la distribution statistique des pixels formant les images. Ce sont ces statistiques qui servent à assigner la probabilité de classification de

chacun des pixels de l'image dans les classes les plus probables. La classification par maximum de vraisemblance s'est effectuée en six étapes (Joyce, 1978).

La première consiste au choix des classes d'informations pertinentes et représentatives du phénomène à étudier. La seconde étape permet la localisation des zones homogènes et la sélection des sites d'entraînements. La troisième étape est de visualiser l'information spectrale et la distribution statistique des pixels sélectionnés dans l'espace spectral à n dimensions (n étant le nombre de bandes spectrales) pour évaluer le niveau de séparabilité entre elles. Nous devons nous assurer que la distribution statistique et spectrale pour chacune des classes est normale et uni-modale. L'analyse des scatterplots et des histogrammes permet d'observer la distribution de chacun des sites d'entraînements et d'en raffiner la sélection et la précision. Une fois satisfait des précisions des paramètres analysés dans l'étape précédente, l'étape suivante permet d'appliquer la méthode paramétrique de classification par maximum de vraisemblance. La cinquième étape porte sur l'analyse quantitative des résultats en utilisant la matrice de confusion et le coefficient Kappa. Cette analyse est décrite de façon plus détaillée à la section 3.6. Quant à la dernière étape, elle nous permet de valider nos résultats, soit de façon statistique ou par vérité terrain. Dans le cadre de cette recherche, les logiciels utilisés permettent une validation des résultats de façon statistique, en se basant sur les sites d'entraînements.

Finalement, si les résultats obtenus ne sont pas satisfaisants, nous devons revenir soit à l'étape de l'identification des classes à l'étude ou à l'étape de la sélection des sites d'entraînements et de l'analyse de la séparabilité et des scatterplots pour améliorer les statistiques des classes. Nous avons choisi d'utiliser cette technique parmi d'autres car elle est la plus populaire, la mieux documentée et relativement la plus précise (Campbell, 1996). Toutefois, son désavantage majeur est relié à la sélection des sites d'entraînements qui s'avère être la plus grande source d'erreur. La variation spectrale et la présence d'une distribution bimodale (sous classes) de certaines classes peuvent causer une forte confusion dans les résultats.

3.5.2 Segmentation d'images

La segmentation d'image numérique de télédétection est un procédé qui permet la création d'objets ou de segments qui regroupent plusieurs pixels selon leurs caractéristiques de formes, tailles, texture et contexte (Mansor, 2002; Barlow *et al.*, 2003; Wulder *et al.*, 2003; Repaka, 2004). Différentes techniques de segmentation existent, soit par détection des arêtes (Robinson, 1977), par extraction des régions, par agrégation des pixels (Freuder, 1976) et par la segmentation hiérarchique (Tilton, 1989). Chacune de ces techniques possède ses avantages et ses inconvénients, qu'elles soient limitées par le bruit de l'image qui vient aléatoirement établir une confusion de la limitation des segments ou par la distribution aléatoire des points centraux des objets.

La technique par segmentation hiérarchique sera considérée dans cette recherche. Il s'agit d'une segmentation qui peut se faire à différents niveaux, spatialement limités les uns aux autres, c'est-à-dire que chaque sous-niveau ou super-niveau doit inclure les objets sous ou sus-jacents. La technique de segmentation hiérarchique peut être un apport à une autre technique, tel l'algorithme de l'extraction des régions, « region growing ». Les différents niveaux que nous pouvons considérer sont reliés directement aux différentes résolutions d'images dont nous effectuons l'analyse. Les images seront soumises au même procédé de segmentation et diverses caractéristiques sont créées selon les pixels regroupés en objets. Il nous faut connaître *a priori* certains paramètres d'échelle, de compacité, de sinuosité et d'homogénéité. Le poids des différentes bandes spectrales peut être également sélectionné comme paramètre initial.

Après avoir effectué la segmentation en fonction des différentes résolutions spatiales de nos données images, nous devons comparer ces résultats pour nous assurer que nous ne perdons pas l'information spatiale et que la taille des objets est représentative des entités aux sols. Nous tenons à réduire le mixage entre les classes à l'étude et les ombrages créés par la végétation croissante. En ayant créé des objets de trop grosses tailles, nous réduisons nos chances, par exemple, d'extraction de la classe des résidus de cultures et nous augmentons le mixage spectral entre elles.

3.5.3 Classification orientée objets sur les segments

La classification orientée objet, exécutée après la segmentation hiérarchique d'extraction des régions, est un procédé de classification qui s'effectue sur les classes d'objets créés par le processus de la segmentation. Des caractéristiques sont choisies pour définir nos classes et lors de la classification, un algorithme soumet chacun des objets au test d'appartenance aux diverses classes. Chaque objet obtient donc un taux d'appartenance aux multiples classes disponibles et celle ayant le plus haut taux de probabilité d'appartenance est la classe dans laquelle l'objet sera assigné. La classification orientée objet peut s'effectuer selon deux méthodes.

La première consiste à utiliser les données de la campagne de terrain, ou de classifications non-supervisées, pour choisir des sites d'entraînements qui sont des objets étant représentatifs des classes à définir. Par la suite, le « feature space optimizer » (Santos *et al.*, 2006) nous permet de sélectionner les caractéristiques qui vont créer la meilleure séparabilité entre les classes, et ce, basé sur nos sites d'entraînement. Cette méthode, nommée du plus proche voisin (« nearest neighbour »), peut causer certaines erreurs, mais nous pouvons, lors de la classification, les limiter en utilisant un haut taux d'appartenance aux classes (Yan *et al.*, 2006).

La deuxième méthode porte sur les fonctions d'appartenances, c'est-à-dire que les usagers peuvent choisir exactement les valeurs des caractéristiques et paramètres qui définissent les classes requises. Par exemple, comme nous avons vu dans la section de la segmentation, cette dernière crée des caractéristiques qui décrivent tous les objets créés, donc si nous voulons isoler la classe du maïs, il nous suffit tout simplement de trouver les valeurs qui qualifient cette classe. Plusieurs caractéristiques sont basées sur les valeurs spectrales et contextuelles des objets, tels la moyenne spectrale, le ratio, l'écart type, l'écart de la moyenne à la scène, le rapport longueur largeur et dans certains cas, la différence aux voisins, et ce, disponible pour toutes les bandes spectrales disponibles (Batz *et al.*, 2004).

La méthode de la classification par plus proche voisin sera retenue pour cette étude. Elle est très facile à utiliser et nous permet un meilleur contrôle sur les statistiques utilisées lors de l'application de la classification logique et elle permet la visualisation de chacune des caractéristiques dérivées des objets. La classification par plus proche voisin orientée objets est très similaire à l'algorithme de classification orientée pixel de la distance minimale. Pour ressembler à l'algorithme du maximum de vraisemblance, une fonction d'appartenance gaussienne sera assignée à chacun des paramètres applicables à la classification orientée objets. Cette fonction forcera donc l'utilisation d'une distribution uni-modale dans l'ensemble des objets d'entraînements, tout comme l'algorithme de maximum de vraisemblance l'applique. Les fonctions d'appartenance peuvent également s'exécuter de façon logique booléenne ou par ensembles flous (« fuzzy logic ») (Baatz *et al.*, 2004). Le principe des ensembles flous peut être très utile pour augmenter la séparabilité entre certaines classes qui portent à confusion, car le principe apporte la notion de possibilité d'association à diverses classes.

Cette technique d'appartenance nous permet également de mieux raffiner nos résultats de classification. Après analyse à l'aide de la matrice de confusion, les objets d'entraînements de chacune des classes peuvent être raffinée manuellement de façon statistique pour établir une meilleure séparabilité entre elles et pour obtenir de meilleurs résultats. Tout comme les étapes de la classification du maximum de vraisemblance, la précision de chacune des classes considérées et la précision de la classification globale seront analysées par le biais de la matrice de confusion et du coefficient Kappa.

3.6 Analyse des résultats

Dans cette recherche, l'analyse des résultats s'effectuera grâce à la matrice de confusion et les coefficients Kappa, et ce, par classes individuelles ou par classification globale.

3.6.1 Précision par classes

Il existe deux façons de comparer quantitativement deux résultats de classification : la matrice de confusion normalisée (Congalton, 1983) et les coefficients Kappa individuels (Baatz *et al.*, 2004). Pour le but de cette recherche, nous allons utiliser les coefficients Kappa. Le logiciel de classification orientée objets, eCognition, nous permet de faire une analyse statistique de nos résultats de classification en reprenant de nouveaux sites d'entraînements qui ont les mêmes caractéristiques que les sites utilisés lors de l'exécution de la classification. Dans ce logiciel, la matrice de confusion calcule déjà pour nous les coefficients Kappa de chacune des classes. Dans le cas du logiciel de classification orientée pixels, PCI Geomatica, la matrice de confusion générée à partir des sites d'entraînements sur les résultats contient seulement les pourcentages de précision de chacune des classes. Nous devons donc appliquer l'équation 3.2 de Baatz *et al.* (2004) pour standardiser nos coefficients Kappa pour l'analyse comparative entre les résultats des classifications orientées pixels et objets, sur les différentes données images. Ce coefficient permet d'observer l'exactitude des résultats et il prend en considération tout les paramètres calculés dans la matrice de confusion.

$$K(class_i) = \dots \frac{a_{ii} (\sum_{ik} a_{ik}) - \sum_k a_{ik} \sum_k a_{ki}}{\sum_k a_{ki} \sum_{ik} a_{ik} - \sum_k a_{ik} \sum_k a_{ki}} \quad (3.2)$$

Où :

a_{ii} : Nombre d'observations dans la cellule (i, i),

a_{ik} : Le total marginal de la rangée i,

a_{ki} : Le total marginal de la colonne i,

$\sum_{ik} a_{ik}$: Le nombre d'observations total.

Tableau 3.5: Description du calcul du coefficient Kappa par classe
(équation 3.2 ; Baatz *et al*, 2004)

		Classification de référence				
		Classe 1	Classe 2	...	Classe N	
Classification	Classe 1	a_{11}	a_{12}		a_{1N}	$\sum_{k=1}^N a_{1k}$
	Classe 2	a_{21}	a_{22}		a_{2N}	$\sum_{k=1}^N a_{2k}$

	Classe N	a_{N1}	a_{N2}		a_{NN}	$\sum_{k=1}^N a_{Nk}$
		$\sum_{k=1}^N a_{k1}$	$\sum_{k=1}^N a_{k2}$		$\sum_{k=1}^N a_{kN}$	$n = \sum_{i,k=1}^N a_{ik}$

3.6.2 Précision globale

Ce type d'analyse est fort simple : comparer les coefficients Kappa globaux sur les résultats des classifications. Il s'agit donc d'une mesure de la différence entre les valeurs observées, ou bien classifiées, et les valeurs mal classifiées (Campbell, 1996). En prenant en considération tous les paramètres calculés dans les matrices de confusion, ce coefficient peut donc être comparé entre les résultats, en autant que nous ayons utilisé les mêmes classes pour effectuer les classifications. L'équation 3.3 (Caloz et Collet, 2001) nous démontre comment le coefficient Kappa globale se calcule. Il est très similaire au coefficient Kappa individuel aux classes.

$$K = \frac{(T_{classés}) \sum m(i,i) - \sum [m(i,+) \cdot m(+,i)]}{(T_{classés})^2 - \sum [m(i,+) \cdot m(+,i)]} \quad (3.3)$$

Où :

$m(i,i)$: Pixels de la classe i correctement classifiés,

$m(+,i)$: Total des pixels classifiés, devant appartenir à la classe i ,

$m(i,+)$: Total marginal de la ligne i ,

$T_{classés}$: Total des pixels classifiés dans toutes les classes.

3.7 Conclusions

Ce chapitre a fait état de la méthodologie appliquée aux diverses données images sur les deux sites d'étude. Nous avons décrit comment ces images ont été prétraitées, traitées par des procédés de classifications et analysées statistiquement. Nous savons maintenant comment analyser et comparer deux classifications, exécutées dans deux environnements différents, et ce, de façon statistiquement fiable.

Le chapitre suivant fera état de l'analyse des résultats, pour chacune des classifications selon les deux méthodes discutées dans ce chapitre. Ces résultats seront comparés en fonction des sites d'étude, des résolutions spatiales des images considérés et des techniques de classifications. Les techniques d'analyse des résultats décrites à la section 3.6 seront mises en applications.

CHAPITRE 4 : ANALYSE DES RÉSULTATS

4.1 Introduction

Le chapitre 4 regroupe l'analyse des résultats et se divise en cinq parties. La première partie traite de la description du procédé de la segmentation et des paramètres analysés pour optimiser les segments employés dans les classifications orientées pixels. La deuxième partie révèle l'analyse des classifications en fonction des procédés utilisés, suivie de la troisième partie qui analyse les résultats selon l'échelle des images employées sur le site de St-Jean-sur-Richelieu. Les quatrième et cinquième parties documentent la validation des procédés à l'aide du second site à l'étude. Cette validation est nécessaire pour permettre de confirmer si nos conclusions demeurent valables en utilisant d'autres données images et en considérant d'autres types de cultures. Nous pourrions par la suite déterminer si l'apport de la segmentation d'images est réellement significatif au niveau de la précision de la classification en milieu agricole.

4.2 Segmentation

Le procédé de segmentation par extraction des régions, décrit dans le chapitre précédent, nécessite la mise en place de quelques paramètres de base. Ces paramètres doivent être sélectionnés minutieusement pour obtenir une segmentation qui représente, de façon uniforme, les entités aux sols. Plusieurs variations des paramètres engendreront des objets ou segments très différents.

Nous avons vu dans le chapitre 2 plusieurs techniques de segmentation d'images qui sont différentes les unes des autres. Après avoir choisi la technique appropriée à notre étude, nous devons effectuer une évaluation des segmentations créées sur nos données images. Dans la littérature, plusieurs méthodes d'évaluation de la segmentation existent. Meinel et Neubert (2004) effectue une évaluation qualitative, alors que Béné et al. (1989) utilisent la validation qualitative et quantitative. Dans le cadre de notre recherche, la validation qualitative, dite visuelle, ne suffisait pas pour choisir un niveau de

segmentation représentatif. Nous voulions être en mesure de quantifier les résultats de segmentation pour pouvoir l'optimiser. De plus, la validation quantitative utilisée par Bénéié *et al.* (1989) ne pouvait être considérée, car nous ne disposons pas de vecteur de référence pour comparer les segments. Notre technique de validation quantitative utilise une caractéristique dérivée de la segmentation pour comparer les objets aux différents niveaux créés. Cette caractéristique, la différence spectrale moyenne aux objets voisins, se fait selon un calcul qui compare la moyenne des pixels regroupés dans chacun des objets contre la moyenne de tous les objets qui lui sont adjacents, et ce, pour chacune des bandes spectrales utilisés dans la segmentation (équation 4.1).

$$\Delta c_L = \frac{1}{l} \cdot \sum_{i=1}^n l_{Si} \cdot (\bar{c}_L - \bar{c}_{Li}) \quad (4.1)$$

Où :

- l : longueur du périmètre de l'objet en question,
- l_{Si} : longueur du périmètre partagé avec l'objet voisin i ,
- \bar{c}_L : moyenne spectrale de l'objet en question dans la bande L ,
- \bar{c}_{Li} : moyenne spectrale de l'objet voisin i dans la bande L ,
- n : nombre de voisins adjacents.

Cette caractéristique est un indice de la séparabilité spectrale entre les objets segmentés. Une faible séparabilité, ou différence spectrale, signifie une faible discrimination dans les objets segmentés qui, par conséquent, sont une fausse représentation entre les entités au sol. Une grande différence spectrale signifie une bonne discrimination des entités au sol et sera idéale pour une classification, car ces objets vont contribuer à une forte séparabilité spectrale entre les classes à l'étude. En additionnant toutes les moyennes spectrales des objets à chacun des niveaux à l'étude, nous obtenons une moyenne globale des différences spectrales pour tous les niveaux. La figure 4.1 représente les différences spectrales moyennes des objets voisins pour chacun des trois niveaux testés lors de la segmentation de l'image CASI à 1 m. Nous pouvons observer comment les différences spectrales des objets sont assez regroupés pour les quatre premières bandes spectrales (partie visible) dans les trois niveaux de segmentation. Pour les trois dernières bandes qui regroupent l'information du proche infrarouge, les différences spectrales sont idéales dans le niveau 2. Une deuxième caractéristique des

objets segmentés fut prise en considération pour déterminer la segmentation optimale et il s'agit du nombre moyen de pixels par objet. Il est bien évident qu'à 1m, beaucoup plus de pixels peuvent se retrouver à l'intérieur d'un même objet étant donné leur petite taille. Par contre, la superficie moyenne des objets va être considérablement inférieure à une résolution de 4 m. Selon notre analyse, les trois niveaux de segmentations de l'image à 1 m possèdent une superficie moyenne de 1, 3 et 13m² (1m² étant le niveau le plus détaillé, possédant des segments très petits, et 13m² le niveau le plus grossier qui regroupe beaucoup plus de pixels par objet créé). À une résolution de 4 m, les objets des trois niveaux ont une superficie moyenne de 18, 31 et 84 m². En combinant l'analyse de la moyenne des différences aux objets voisins, nous concluons que les niveaux 2 seront utilisés, car les objets représentent une moyenne aux différences spectrales et une superficie moyenne significative qui nous permettent de bien distinguer les entités au sol en utilisant leur informations spectrales qui sont maintenant regroupées en divers objets hautement hétérogènes.

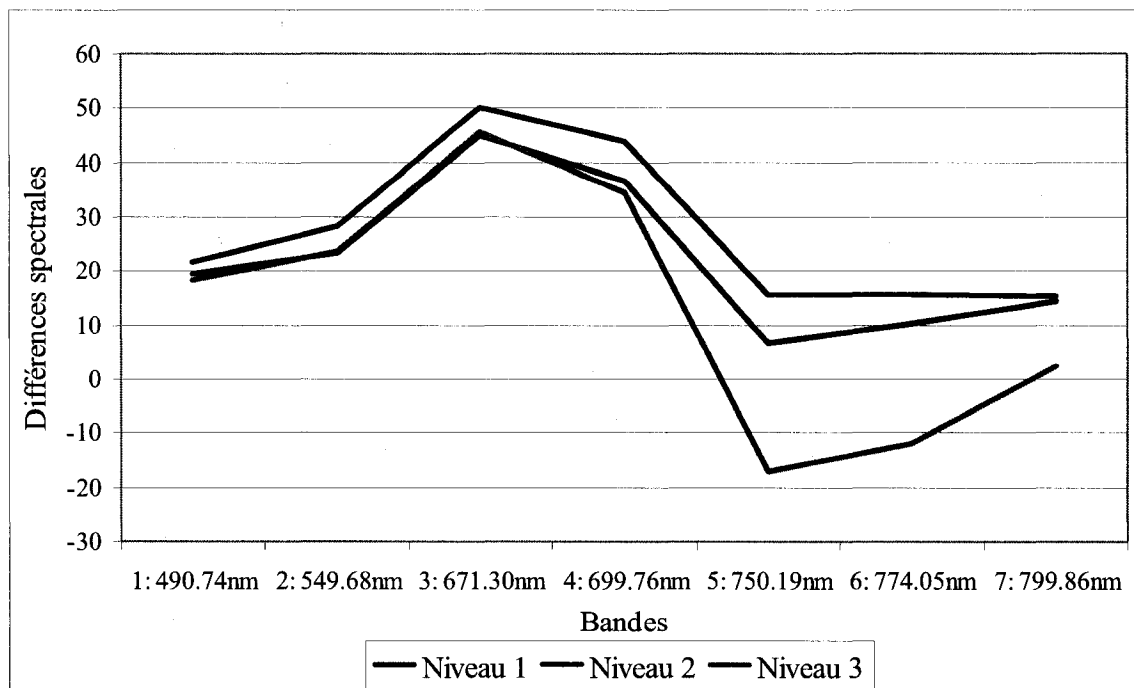


Figure 4.1 : Moyenne des différences spectrales aux objets voisins, CASI 1 m.

4.2.1 Segmentation des images CASI

La segmentation des images CASI du site de St-Jean-sur-Richelieu ont été traitées, observées et analysées non seulement par rapport aux différents paramètres possibles pour chacune des images mais également en fonction de toutes les résolutions spatiales (1, 2 et 4 m). L'augmentation de la taille des pixels au sol en réduit directement leur nombre pour couvrir la zone d'étude. Par conséquent, les objets créés vont regrouper beaucoup moins de pixels à 4 m qu'à 1 m (voir section 4.4 pour plus de détails sur l'analyse multi-échelles). Pour assurer une segmentation significative et représentative qui minimise l'effet de mixage selon les diverses résolutions spatiales, nous avons observé de façon visuelle les objets obtenus lors des segmentations des différentes images. De plus, nous avons toujours utilisé les mêmes bandes spectrales pour effectuer les segmentations. Les longueurs d'ondes de 671,30 nm, 699,76 nm et 750 nm ont été utilisées étant donnée leur forte variation spectrale entre les diverses cultures au sol. Ces bandes d'infrarouge à ondes sont celles qui possèdent le plus d'information sur la signature spectrale unique des différentes végétations à l'étude. Une inspection visuelle des différents résultats de segmentations et l'analyse de la séparabilité spectrale de ces bandes ont permis de déterminer la meilleure combinaison possible de bandes à utiliser pour les segmentations des images CASI.

Après avoir effectué l'analyse des moyennes des différences spectrales aux objets voisins, l'image de résolution de 1 m fut segmentée en employant un paramètre d'échelle de 15; 0,2 de forme et 0,5 de compacité (figure 4.2B). À 2 et 4 m, les mêmes paramètres de compacité et de forme ont été utilisés, mais des paramètres d'échelles de 18 et 20 respectivement, ont été optimaux pour la segmentation. La figure 4.2 illustre les différents niveaux de segmentation, dont 4.2A est une sur-segmentation et 4.2C une sous-segmentation. Pour la résolution de 1 m, le procédé de segmentation a permis le regroupement de 71 604 pixels en 37 603 objets. À 2 m, 18 207 pixels ont été regroupés en 8 035 objets et à 4 m, 4 680 pixels ont été regroupés en 1 709 objets. Ces chiffres sont divulgués pour observer à quel point la segmentation permet une diminution des entités à être soumis au procédé de classification. Les pixels sont donc beaucoup plus nombreux à

l'intérieur d'images que les objets, ce qui permet d'alléger le procédé de classification effectué par l'algorithme et l'ordinateur.




Figure 4.2 : Différents niveaux de segmentation de l'image CASI à 1 m.
Paramètre d'échelle de 10 (A), 16 (B) et 30 (C)

4.2.2 Segmentation de l'image Probe-1

Dans le cas de la segmentation de l'image Probe-1, les bandes possédant un écart type supérieur à une valeur de 700 (une valeur relative aux bandes spectrales générée par le logiciel d'analyse) ont été utilisées pour segmenter l'image. Ces bandes, soit les canaux 22 à 35, sont situées principalement dans le proche infrarouge (longueurs d'ondes de 750

à 929 nm). Quant aux valeurs de l'écart type, elles ont été calculées par le logiciel lors de l'importation de l'image. Chacune des bandes possède un écart type en fonction de la variabilité de ses valeurs de pixels. Les bandes 22 à 35 possédaient la plus grande variabilité spectrale, et ont donc été sélectionnées comme les bandes idéales pour la segmentation (Wei *et al.*, 2005). Un poids de segmentation d'une valeur de 1 leur fut donc attribué, et une valeur de 0 pour toutes les autres bandes qui ne seront pas incluses dans la segmentation. La figure 4.3 illustre les paramètres utilisés lors de la segmentation la plus significative de l'image Probe-1 (figure 4.4B), sur le site d'Indian Head.

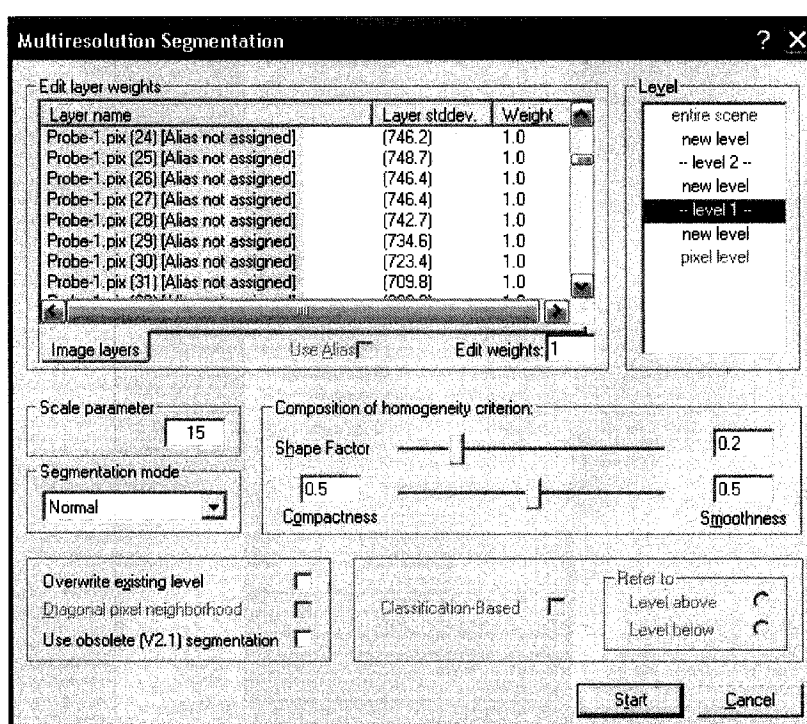


Figure 4.3 : Les paramètres idéaux de segmentation de l'image Probe-1.

Un paramètre d'échelle de 15; 0,2 de forme et 0,5 de compacité sont donc les paramètres optimaux calculés pour la segmentation du Probe-1 (figure 4.4B). Nous pouvons également observer les différentes valeurs d'écart type de chacune des bandes spectrales dans la colonne centrale ainsi que la distribution des poids de segmentation. Les autres niveaux de segmentation qui ont été testés avaient des paramètres d'échelle de 10 (figure 4.4A) et 50 (figure 4.4C), ce qui fut observé comme une sur-segmentation et

sous-segmentation respectivement. La segmentation de l'image Probe-1 a permis le regroupement de 96 330 pixels en 27 137 objets.

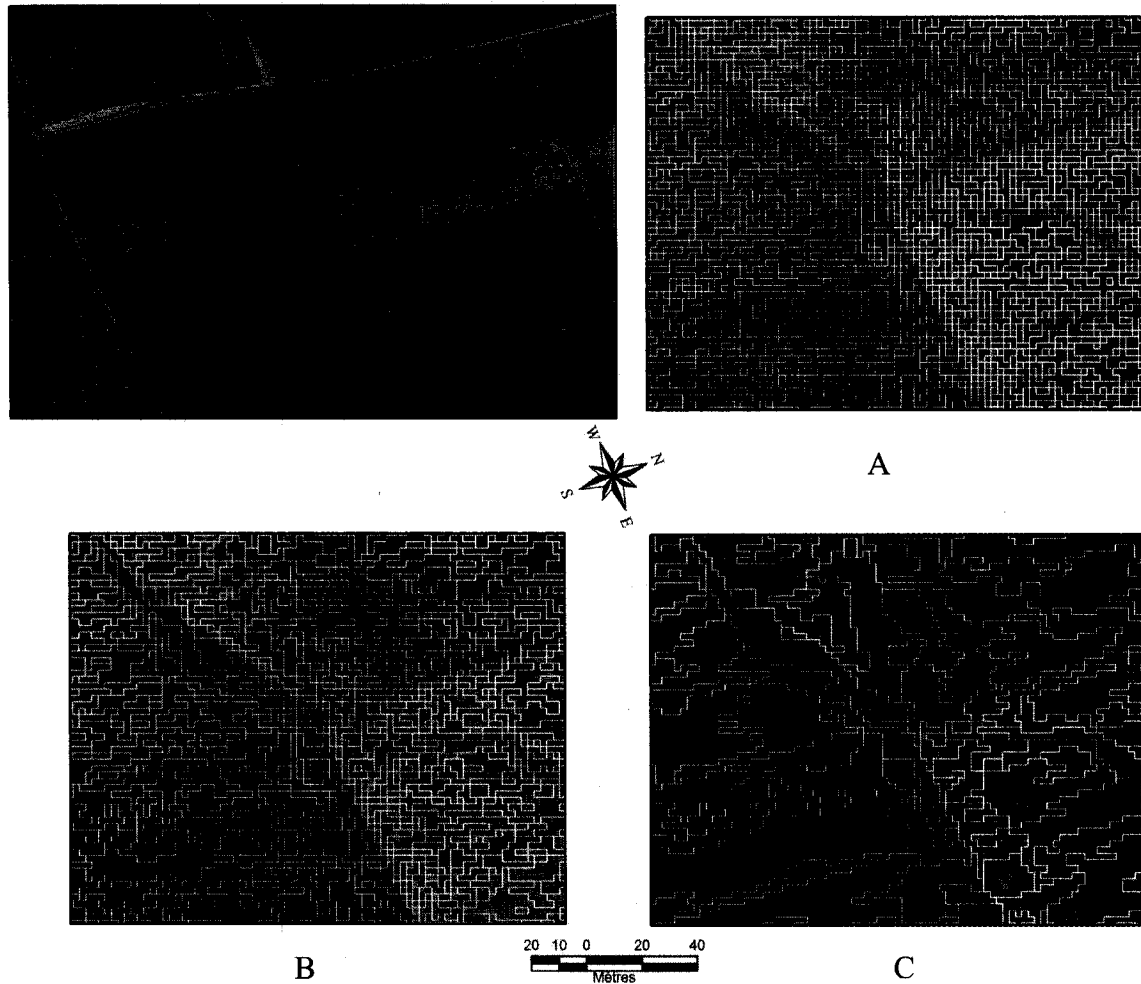


Figure 4.4 : Différents niveaux de segmentation de l'image Probe-1
Paramètre d'échelle de 10 (A), 15 (B) et 50 (C)

4.2.3 Segmentation de l'image IKONOS

Nous pouvons également observer la tendance des différences spectrales moyennes dans les résultats de la segmentation de l'image multispectrale IKONOS. La figure 4.5A illustre une sur-segmentation de l'image multispectrale au niveau inférieur 1. En utilisant les paramètres d'échelle de 5; 0,2 de forme et 0,5 de compacité, les objets sont beaucoup trop nombreux et les entités au sol y sont délimitées par plusieurs segments. À la figure

4.6, nous pouvons observer comment les différences spectrales des objets voisins sont très faibles dans toutes les bandes disponibles (visible et proche infrarouge). À la figure 4.5C, nous pouvons observer une sous-segmentation qui signifie des objets de trop grande taille en fonction des entités au sol. Le paramètre d'échelle d'une valeur de 100 fut utilisé et est donc très élevé mais représente toutefois une grande différence spectrale en fonction des objets voisins (figure 4.6).




Figure 4.5 : Différents niveaux de segmentation de l'image IKONOS
Paramètre d'échelle de 5 (A), 15 (B) et 100 (C)

Le logiciel utilisé est doté d'un outil d'analyse de la segmentation qui permet de visualiser interactivement les segments qui pourraient être éliminés en fonction de diverses valeurs d'échelle, ou bien de différence spectrales aux objets voisins. En utilisant cet outil, il fut possible de déterminer les paramètres d'un niveau de segmentation favorable. La figure 4.5B fut donc la segmentation utilisée pour l'image IKONOS, soit un paramètre d'échelle de 15; 0,2 de forme et 0,5 de compacité. Il est très important de mentionner que seulement la bande panchromatique fut utilisée dans la segmentation. Cette bande possède une résolution spatiale de 1 m, comparativement à 4 m pour les autres bandes spectrales. Seulement ces dernières ont été utilisées lors de la classification, car elles possèdent l'information spectrale qui permet la séparabilité des classes à l'étude. La différence spectrale moyenne de ce niveau de segmentation est également très bien divisée dans le proche infrarouge, soit la bande la plus utile pour la séparation de la végétation pour ce type de capteur (figure 4.6). La segmentation de l'image IKONOS a réduit les 1 496 162 pixels en 27 841 objets.

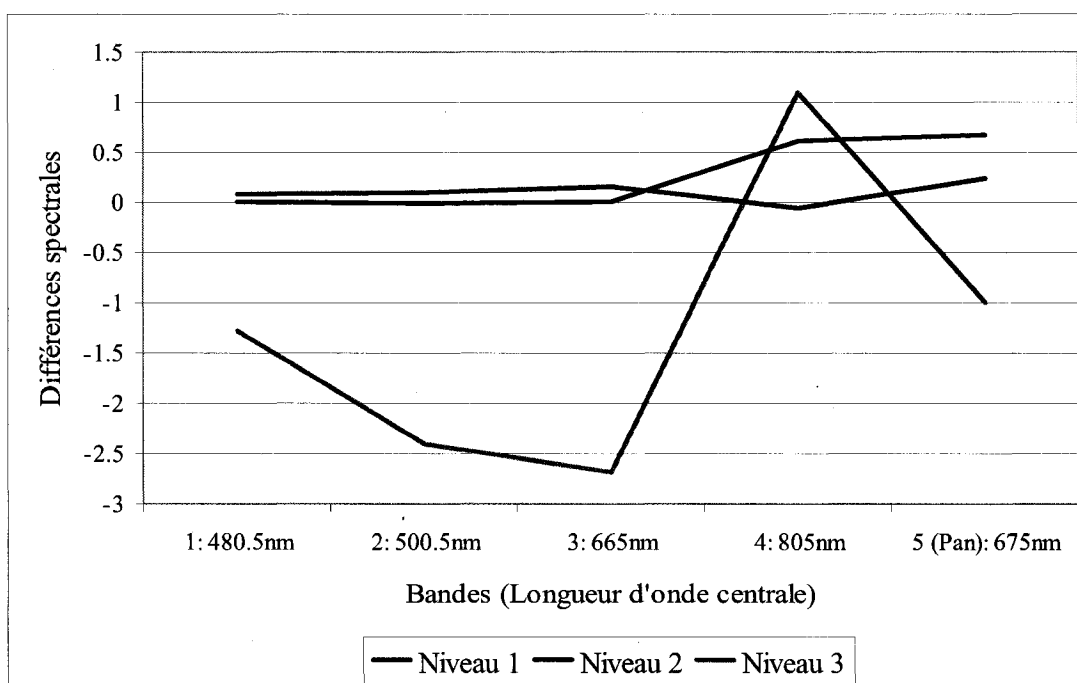


Figure 4.6 : Moyenne des différences spectrales aux objets voisins, IKONOS.

4.3 Analyse selon les méthodes de classifications

Deux procédés de classification ont été appliqués aux images CASI du site de St-Jean-sur-Richelieu : la classification orientée pixel et orientée objet. Comme mentionné dans le chapitre 3, les images, aux résolutions spatiales de 1, 2 et 4 m, ont été traitées dans le logiciel PCI Geomatica v9.1 (PCI Geomatics, 2007) pour obtenir les résultats de classifications orientées pixels et dans le logiciel eCognition v4.1 (Batz *et al.*, 2004) pour les résultats de classifications orientées objets. Dans les prochaines sections, nous allons observer comment ces procédés ont été appliqués, leurs paramètres et leurs résultats, en fonction de ces deux procédés et dans chacune des résolutions spatiales respectives.

4.3.1 Classification orientée pixel

Afin d'exécuter les classifications orientées pixels supervisées du maximum de vraisemblance, diverses classifications non-supervisées du *k-moyen* (ou *k-means*) ont été appliquées pour observer les regroupements spectraux, ou « clusters » de pixels qui forment les différentes classes. Une classification non-supervisée de 30 classes a permis d'observer l'emplacement de différents groupes de pixels qui pourraient se regrouper en classes de cultures. La figure 4.7 illustre les résultats de ces classifications non-supervisées à 1 (4.7A), 2 (4.7B) et 4m (4.7C). Chacune des couleurs représente une classe unique qui est un regroupement spectrale de pixels dans l'espace à n dimensions, soit n le nombre de bandes spectrales utilisées pour la classification.

C'est en se basant sur ces regroupements spectraux que les sites d'entraînements ont été sélectionnés pour les classifications supervisées du maximum de vraisemblance orientée pixels. Nous pouvons bien observer à la figure 4.7 qu'il y a toujours 3 classes dans le champ de maïs (bas), au moins 2 classes dans le champ d'haricots (champ supérieur gauche), au moins 2 classes dans le champ de pois (champ supérieur droit) et souvent 2 classes qui distinguent le sol nu entre les champs supérieurs. Ces classes représentent différentes densités des couverts végétaux. L'algorithme de classification non-supervisée nous informe que pour les trois cultures visibles, il est impossible d'isoler seulement une signature spectrale pour ceux-ci. Nous allons donc classifier nos images en

fonctions des différentes signatures spectrales trouvées, soit les différentes densité de couvert végétal à travers les champs à l'étude (2 classes d'haricots, 2 de pois, 3 de maïs et 1 de sol nu).




Figure 4.7 : Classifications orientées pixels non-supervisées du *k-moyen* (30 classes aléatoires), à 1m (A), 2m (B) et 4m (C).

La figure 4.9 illustre les résultats des 3 images classifiées, selon les deux procédés de classifications. La première observation des résultats orientés pixels est la présence de pixels non-classifiés. Le tableau 4.1 représente le pourcentage de pixels classifiés à l'intérieur de la zone agricole à l'étude.

Tableau 4.1 : Pourcentage des pixels classifiés (Maximum de vraisemblance)

Résolutions	Pourcentage des pixels classifiés
1m	78%
2m	77%
4m	72%

La diminution de la résolution spatiale augmente significativement la mixture spectrale à l'intérieur des pixels. Ceci résulte donc à une plus grande confusion dans la classification et, dans le cas du maximum de vraisemblance, à une augmentation des pixels non-classifiés qui sont ceux qui pourraient se retrouver dans plusieurs classes différentes. Ils sont donc assignés à aucune classe.

4.3.2 Classification orientée objet

Comme mentionné dans la section 4.2, la segmentation des images a permis la création d'objets qui sont des regroupements de pixels ayant des caractéristiques d'homogénéité similaires. En se basant sur les statistiques des classifications orientées pixels (supervisées et non-supervisées), divers objets ont été sélectionnés pour être considérés comme objets, ou sites d'entraînements. Les statistiques spectrales ont été observées pour maintenir une distribution normale des objets d'entraînements dans chacune des bandes spectrales à l'étude.




Figure 4.8 : Stabilité des classifications orientées objets des données images CASI à 1 m (A), 2m (B) et 4m (C).

Comme nous en avons discuté à la section précédente (4.3.1), la classification orientée pixel du maximum de vraisemblance ne permet pas une classification totale des pixels d'une image. Plusieurs pixels se mélangent à plus d'un type de couvert végétal ou

d'un sol sous-jacent. Dans le cas de la classification orientée objet, chacun des objets se voit assigner un degré d'appartenance, ou « membership value » à toutes les classes à l'étude. Un objet est assigné à la classe dont son degré d'appartenance avec celle-ci est le plus haut. La figure 4.8 illustre la répartition de la stabilité des classifications des images CASI à 1 (4.8A), 2 (4.8B) et 4m (4.8C). La stabilité de classification représente les différences entre les premier et deuxième degrés d'appartenance les plus hauts pour chacun des objets. Les valeurs vont du vert au rouge, vert pour un grand écart entre le premier et le deuxième degré d'appartenance et rouge pour une faible différence entre ces valeurs. Par exemple, nous pouvons observer la forte présence de la couleur rouge dans le champ de maïs. Cela signifie que deux classes de maïs se disputent une forte majorité des objets. Il s'avère possible que pour un objet, un degré d'appartenance de 0,9 soit assigné à la classe maïs-1 et 0,8 pour maïs-2. La stabilité de cet objet est donc très faible, car la différence de ces valeurs d'appartenance, soit de 0,1, est très faible, comparativement à un objet qui possède seulement une classe dominante pour son appartenance.

Il est normal que la stabilité soit faible dans le champ de maïs, car nous avons choisi d'utiliser 3 classes de maïs plutôt que 2. Malgré cette confusion entre ces 3 classes de maïs, les figures 4.10, 4.12 et 4.14 révèlent une forte précision de la classification de ces classes. Les coefficients Kappa sont assez élevés dans chacun de leur cas, soit de plus de 80%.

4.4 Analyse selon l'échelle

Cette section traite de l'analyse de la précision des résultats des classifications orientées pixels et objets, en fonction des trois résolutions spatiales des données images CASI. Nous comparerons les coefficients Kappa de chacune des classes à l'étude, toujours en fonction des résolutions et des techniques de classifications. Différents scatterplots sont illustrés pour démontrer la distribution spectrale des classes dans un environnement à deux dimensions. Nous discuterons également de la technique utilisée pour la validation des résultats orientés pixels et objets.

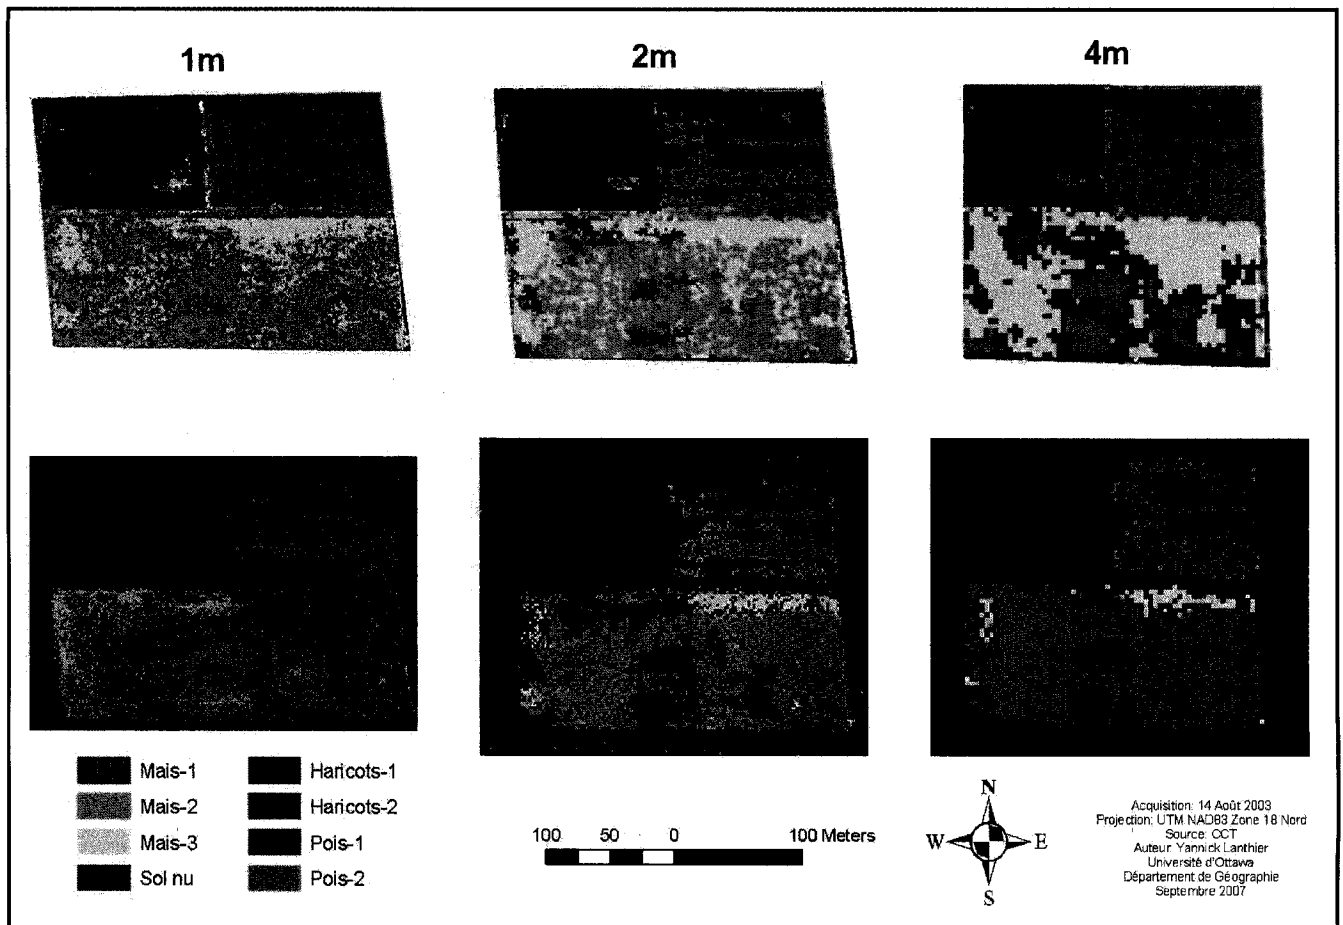


Figure 4.9 : Classifications orientées objets (haut) et pixels (bas) des données images du capteur CASI, à 1, 2 et 4 m.

4.4.1 Image CASI à 1 m

À la figure 4.9, nous pouvons observer qu'il existe une certaine similitude visuelle dans les résultats des classifications orientées objets (en haut à gauche) et pixels (en bas à gauche) à 1 m. Cette similitude, uniquement visuelle et non pas statistique, est surtout présente dans le cas des classes d'haricots (1 et 2), du maïs-2, pois-2 et du sol nu. Nous pouvons voir qu'il existe certaines zones de concentrations communes à ces classes. Dans la classification orientée pixels, la classe du sol nu semble être présente dans le champ des pois. Ceci s'explique par la faible présence de pois qui représente un couvert végétal très faible. La classification orientée objets semble avoir également classifié certains objets comme étant un sol nu dans le champ des pois mais leur présence est beaucoup moins significative. Les trois classes de maïs semblent éprouver des problèmes de

séparabilité dans les deux méthodes de classifications. Celles-ci sont tout de même mieux dispersées dans l'approche orientée objets. À l'aide de cette technique de classification, leur couverture semble plus continue étant donné que ces classes sont de trois différentes concentrations de maïs.

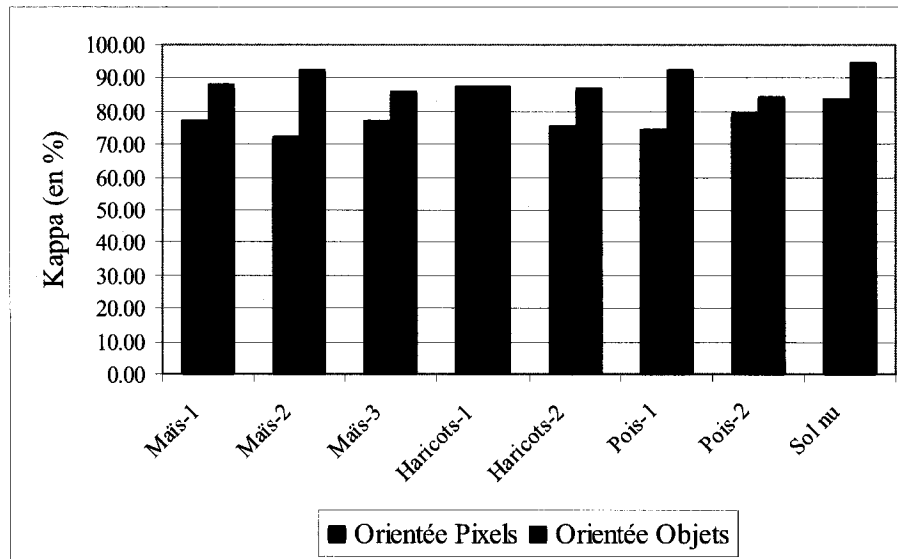


Figure 4.10 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (CASI : 1m)

La figure 4.10 représente les coefficients Kappa en fonction des classes et des deux méthodes de classifications. La classe la plus dominante est la classe du sol nu. Elle possède la plus haute précision dans la classification orientée objets et donne le deuxième meilleur résultat dans la classification orientée pixels. Comme nous allons le voir dans la prochaine section lors des comparaisons au deuxième site d'étude, cette classe possède une forte séparabilité envers les autres classes de cultures à l'étude. Elle possède une signature très distincte, plus spécifiquement dans le proche infrarouge, comparativement à un couvert végétal qui possède un signal beaucoup plus fort dans cette région du spectre électromagnétique. Nous pouvons également voir à la figure 4.11 comment la classe du sol nu se sépare significativement des autres classes dans un environnement à deux dimensions, soit la bande 7 (799,86 nm; axe des X) et la bande 4 (699,76nm; axe des Y). La figure 4.10 révèle donc que les résultats orientés objets sont très représentatifs. Ils sont en moyenne 10,57% supérieurs aux résultats orientés pixels.

En somme, les classes de maïs possèdent une moyenne supérieure de 13,20%, les classes de pois une moyenne de 11,55% et les classes d'haricots une moyenne de 5,57% supérieure aux résultats orientés pixels. La meilleure augmentation de la précision des résultats est reconnue par la classe de maïs-2, soit une augmentation de 19,69%, et la plus faible augmentation est la classe d'haricots-1 de 0,08%. Nous pouvons observer à la figure 4.9 que la classe de maïs-2 est significativement mieux représentée dans la classification orientée objets, c'est-à-dire qu'elle est beaucoup plus présente et continue, tandis que la classe d'haricots-1 est sensiblement représentée à part égale, soit qu'elle semble être distribuée spatialement égale entre les deux résultats, ce qui explique la faible augmentation. Nous allons observer dans les prochaines sections si cette tendance se maintient lorsque nous considérons les deux autres résolutions spatiales.

La figure 4.11 représente la distribution spectrale des objets classifiés (pixels de couleurs) ainsi que les points utilisés dans la validation des données. Ces données sont représentées dans ce scatterplotte en fonction de la bande 7 (799,86 nm; axe des X) et la bande 4 (699,7 nm; axe des Y). Nous pouvons très bien observer la faible séparabilité entre les trois classes de maïs (jaune, bleu et vert). Cette représentation en deux dimensions est en étroite relation avec la figure 4.8 de la section 4.3.2 qui illustre la stabilité des classes à l'étude. Nous pouvons observer certains points de validations qui sont situés dans, ou même très près, des autres classes, ce qui représente les erreurs de commissions et d'omissions. Pour plus d'information sur les résultats de validation, l'annexe I résume les différentes matrices de confusions analysées et représentées graphiquement pour observer les précisions des résultats des méthodes de classifications.

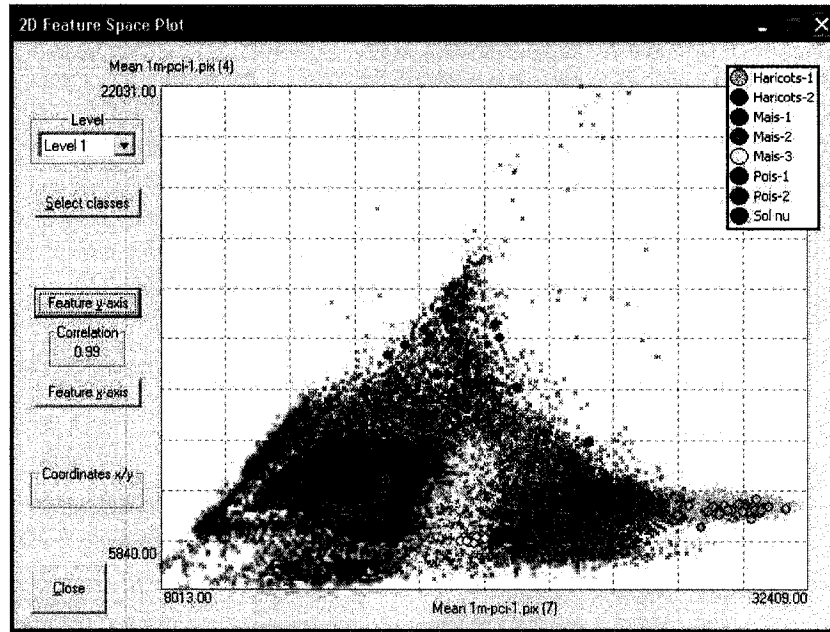


Figure 4.11 : Distribution spectrale des objets classifiés avec les points de validation (CASI : 1 m, axe des X: Moyenne spectrale de la bande 7 - 799,86 nm; axe des Y: Moyenne spectrale de la bande 4 – 699,76 nm)

4.4.2 Image CASI à 2 m

Les images centrales de la figure 4.9 représentent les résultats des classifications orientées objets (haut) et orientées pixels (bas) pour l'image CASI à une résolution de 2 m. Nous pouvons observer une grande ressemblance entre les résultats orientés objets à 1 m et 2 m au niveau des classifications orientées objets. Plus spécifiquement, les deux classes d'haricots, les deux classes de pois, la classe du sol nu et la classe de maïs-3 semblent avoir une similitude dans leur étendue spatiale des objets classifiés. Par contre, les classes de maïs-1 et 2 semblent révéler une confusion dans leur distribution spatiale. La technique orientée pixel semble effectuer une sur-classification de la classe du sol nu. Elle se mélange énormément avec les pois, comme pour l'image à 1 m. Également, la classe d'haricots-1 est la classe qui semble posséder une grande similitude spatiale pour les deux techniques de classifications. La figure 4.12 prouve ce fait en illustrant la faible augmentation des coefficients Kappa de la classe haricots-1 lorsque nous passons de la classification orientée pixels (75,50%) à orientée objets (81,14%). La classe qui possède la plus forte augmentation de sa précision (25,30%), tout comme dans le cas des résultats à 1 m, est la classe maïs-2. La figure 4.13 illustre bien cette augmentation pour la

classification orientée objets. Nous pouvons observer que la classe de maïs-2 se dissocie beaucoup plus dans le scatterplotte des objets classifiés à 2 m (figure 4.13, classe vert pâle) que dans le scatterplotte à 1 m (figure 4.11, classe vert pâle). Cette forte séparabilité spectrale fait en sorte que la classification orientée objets a réussi à maintenir une haute précision de la classe de maïs-2.

La figure 4.13 représente donc les objets sélectionnés comme site de validation pour les données à 2 m (points foncés dans le scatterplotte). Ils ont été sélectionnés en fonction de leur emplacement spatial qui est similaire aux objets de validation à 1 m et en fonction de leurs caractéristiques spectrales qui sont très similaires aux objets d'entraînements des classes à l'étude. Dans ce scatterplotte, nous pouvons à nouveau observer la forte dissociation de la classe du sol nu (rouge) qui, tout comme à la résolution de 1 m, possède la plus haute précision des résultats (figures 4.10 et 4.12). La seule différence est qu'ici, la classe du sol nu, dans le cas de la classification orientée pixels, est la classe possédant la plus haute précision. Ceci prouve donc son fort pouvoir de discrimination par rapport aux autres classes qui perdent beaucoup de précision lorsque nous réduisons la résolution spatiale.

La validation orientée pixels est effectuée au même moment que l'application de l'algorithme de classification orientée pixels du maximum de vraisemblance. Une matrice de confusion est générée pour observer la précision de chacune des classes ainsi que la précision globale. Pour permettre une validation acceptable et comparative entre les deux procédés de classification, la matrice de confusion de la précision des résultats orientés pixels est convertie en coefficient Kappa (grâce à l'équation 3.2 décrite au chapitre 3) par classe pour être par la suite comparée aux coefficients Kappa des classifications orientées objets. L'annexe I présente les informations sur les matrices de confusion au sujet de cette analyse.

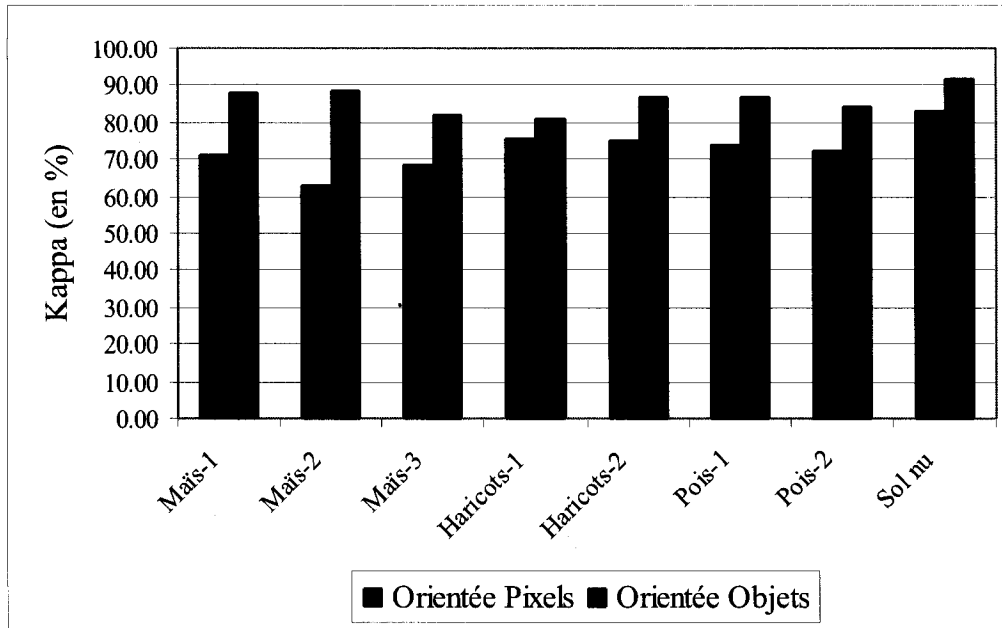


Figure 4.12 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (CASI : 2 m)




Figure 4.13 : Distribution spectrale des objets classifiés avec les points de validation (CASI : 2 m, axe des X: Moyenne spectrale de la bande 7 - 799,86 nm; axe des Y: Moyenne spectrale de la bande 4 - 699,76 nm)

4.4.3 Image CASI à 4 m

Les images de droite de la figure 4.9 illustrent les résultats des classifications orientées objets (haut) et pixels (bas) pour l'image CASI à une résolution de 4 m. Nous pouvons observer une forte diminution de la résolution spatiale. Les objets segmentés sont nettement plus grossiers, par conséquent ils sont formés par beaucoup moins de pixels. À une résolution de 4 m, il est plus difficile d'avoir des objets significatifs, car ils regroupent moins de pixels purs et il y a beaucoup plus de mixture spectrale à l'intérieur des pixels. Nous pouvons tout de même observer quelques similitudes visuelles qui se répètent de résolutions en résolutions. Les classes de sol nu, d'haricots, de pois et de maïs-3 sont certainement plus grossières mais leurs distributions à travers les différents champs semblent être constantes. La classe du sol nu est toujours légèrement infiltrée à l'intérieur des champs de pois et d'haricots. Dans le cas des résultats orientés objets, la délimitation des classes d'haricots-1 et haricots-2 semble être toujours aux mêmes endroits. Il est de même pour la classe des pois. Pour le maïs, la classe de maïs-3 semble avoir dominé le champ en obtenant beaucoup plus d'objets que les classes de maïs-1 et 2. Nous pouvons conclure que les résultats orientés pixels à une résolution de 4 m sont les plus faibles. Ils possèdent beaucoup de pixels non-classifiés. Ceci est un indicateur de la faible séparabilité des classes qui ne peut tout simplement pas identifier les pixels à une classe bien précise. Peu importe la précision des sites d'entraînements, l'algorithme de classification ne peut tout simplement pas classifier des pixels ayant un aussi fort mélange d'entités au sol. À une résolution de 4 m par 4 m, il faut imaginer comment plusieurs couverts végétaux, résidus de cultures et sol nu se mélangent pour former l'information spectrale enregistrée par le capteur. La segmentation permet l'agrégation de plusieurs pixels qui vont former de nouvelles valeurs spectrales, qui seront à leur tour utilisées pour la classification des objets créés. Il est donc bien évident que la stabilité des résultats laisse à désirer mais l'objet est tout simplement classifié à la classe qui lui donne la plus haute valeur d'appartenance. Cette technique se rapproche sensiblement de la classification orientée pixels par analyse de mixture spectrale linéaire (Smith *et al.*, 1990). Un pixel peut être identifié selon une échelle de 0 à 1 à toutes les classes et seulement la classe qui possède la plus forte association réussira à obtenir ce pixel. Il en est donc de même pour la classification orientée objets et ses valeurs d'appartenance.

La figure 4.14 illustre toujours les deux mêmes tendances, soit la forte précision des résultats pour la classe du sol nu selon les deux méthodes de classifications et la faible augmentation des coefficients Kappa pour la classe d'haricots-1. Ceci s'explique par le fort contraste spectral entre le sol et le couvert végétal. L'augmentation de 5,68% est toujours la plus faible différence entre les deux procédés pour une même classe. La classe du sol nu possède toujours un fort pouvoir de séparabilité par rapport aux autres classes et la classification orientée objets semble la départir beaucoup mieux. La figure 4.15 qui représente les objets classifiés ainsi que les points de validation, démontre bien l'étendue de la classe du sol nu dans le scatterplotte des bandes 7 (799,86 nm; axe des X) et 4 (699,76 nm; axe des Y) du capteur CASI. La classe maïs-2 est toujours la classe qui possède la plus forte augmentation des coefficients Kappa entre les deux résultats, soit de 17,42%. Les deux autres classes de maïs sont les deuxième et troisième augmentations significatives, ce qui nous laisse supposer que le champ de maïs se classe très bien à l'aide de la segmentation, car son couvert végétal est le plus dominant en espace comparativement aux haricots et pois. Ces trois classes de maïs, représentant trois densités différentes de cette culture, possèdent un couvert pouvant atteindre plus de 2 m en hauteur et est très dense, le plaçant ainsi comme une culture parfaite pour la segmentation d'image.




Figure 4.14 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (CASI : 4 m) Classes

En comparant les scatterplots des trois résolutions spatiales (figures 4.11, 4.13 et 4.15), nous pouvons observer principalement la diminution du nombre d'objets à classifier, l'étendue spectrale des classes dans cet espace à deux dimensions et la distribution des sites de validation. Les classes de maïs sont toujours très rapprochées, car il est à noter qu'elles ont été les plus difficiles à séparer spectralement.

La figure 4.16 illustre la distribution des objets d'entraînement pour la classe de maïs-3 (noir) et maïs-2 (bleu). Seulement dans les bandes 5, 6 et 7 (750,19 nm, 774,05 nm et 799,86 nm respectivement) ont pu être séparées statistiquement. Ces bandes sont situées dans le proche infrarouge et c'est dans cette zone du spectre électromagnétique que la végétation se distingue le plus. Comme pour les autres résolutions, la validation des résultats orientés pixels a été effectuée à l'aide des sites d'entraînements, et calculée pendant l'application de l'algorithme de classification par maximum de vraisemblance. Pour des informations sur les matrices de confusion utilisées dans l'analyse des résultats, veuillez consulter l'annexe I.




Figure 4.15 : Distribution spectrale des objets classifiés avec les points de validation (CASI : 4 m, axe X: Moyenne spectrale de la bande 7 - 799,86 nm; axe Y: Moyenne spectrale de la bande 4 – 699,76 nm)

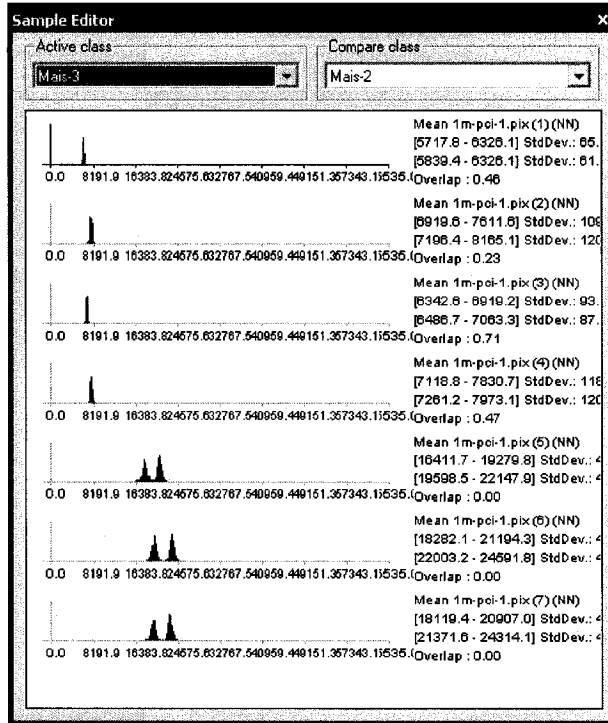


Figure 4.16 : Discrimination entre les objets d'entraînements pour les classes de maïs-3 (noir) et maïs-2 (bleu). (Bandes 1 à 7, CASI 1 m)

En observant la figure 4.9, représentant tous les résultats des classifications orientées objets et pixels aux différentes résolutions spatiales, nous pouvons conclure par observation visuelle et analyse statistique que le résultat de la classification orientée objets à 4 m est supérieur à la classification orientée pixels à 1 m. La figure 4.17 représente les coefficients Kappa globaux selon les différentes résolutions et les différents procédés de classifications. Statistiquement, la classification orientée objet à 4 m possède un coefficient Kappa global de 82,68%, comparativement à 77,30% pour la classification orientée pixels de 1 m. Il est donc évident de conclure que la segmentation de l'image permet l'utilisation d'une image à résolution plus grossière pour la création de carte d'occupation du sol avec une meilleure précision. L'information spectrale et spatiale a bien été conservée après la segmentation et la classification peut s'effectuer en utilisant les diverses caractéristiques des objets segmentés.

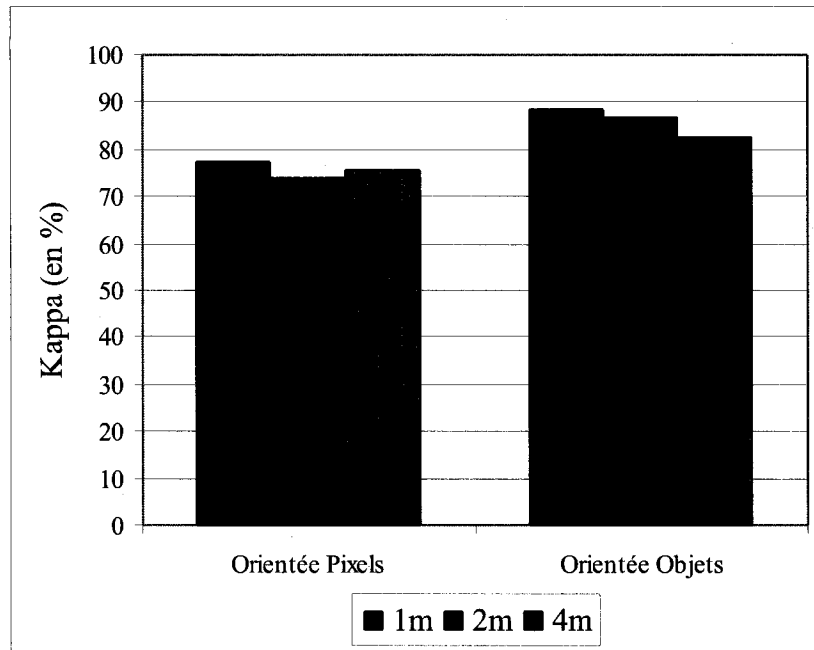


Figure 4.17 : Exactitude des classifications en fonction des résolutions (CASI)

4.5 Validation sur les données Probe-1

Pour valider les résultats du site de St-Jean-sur-Richelieu, le deuxième site d'Indian Head en Saskatchewan, a été utilisé pour y effectuer les mêmes procédés. Comme mentionné dans le chapitre précédent, deux types de données images ont été utilisées, soit une image hyperspectrale du capteur Probe-1 et une image multispectrale du capteur IKONOS. Les classes à l'étude étaient les mêmes pour les deux images, soit le blé, les pois, le canola, les résidus de culture et le sol nu. Les seules classes qui sont communes aux deux sites, Indian Head et St-Jean-sur-Richelieu, sont les pois et le sol nu. Les traitements ont été appliqués à l'aide des mêmes logiciels de traitement d'images, soit PCI Geomatica 9.1 et eCognition 4.0. Les sites d'entraînements sont basés sur des données prises lors d'une campagne de terrain dirigée au même moment que l'acquisition des images. La validation de la classification orientée pixel a été effectuée statistiquement par rapport aux pixels sélectionnés comme site d'entraînement. Pour la classification orientée objet, elle était effectuée en relation à d'autres objets sélectionnés qui ont les mêmes propriétés statistiques des objets sélectionnés comme site d'entraînement (voir l'annexe I pour les matrices de confusions). Cette technique est souvent utilisée dans des

cas de manque de données de validation (Owojori et Xie, 2004; Carleer et Wolff, 2006). La figure 4.18 illustre les résultats pour les classifications orientées objets (haut) et pixels (bas).

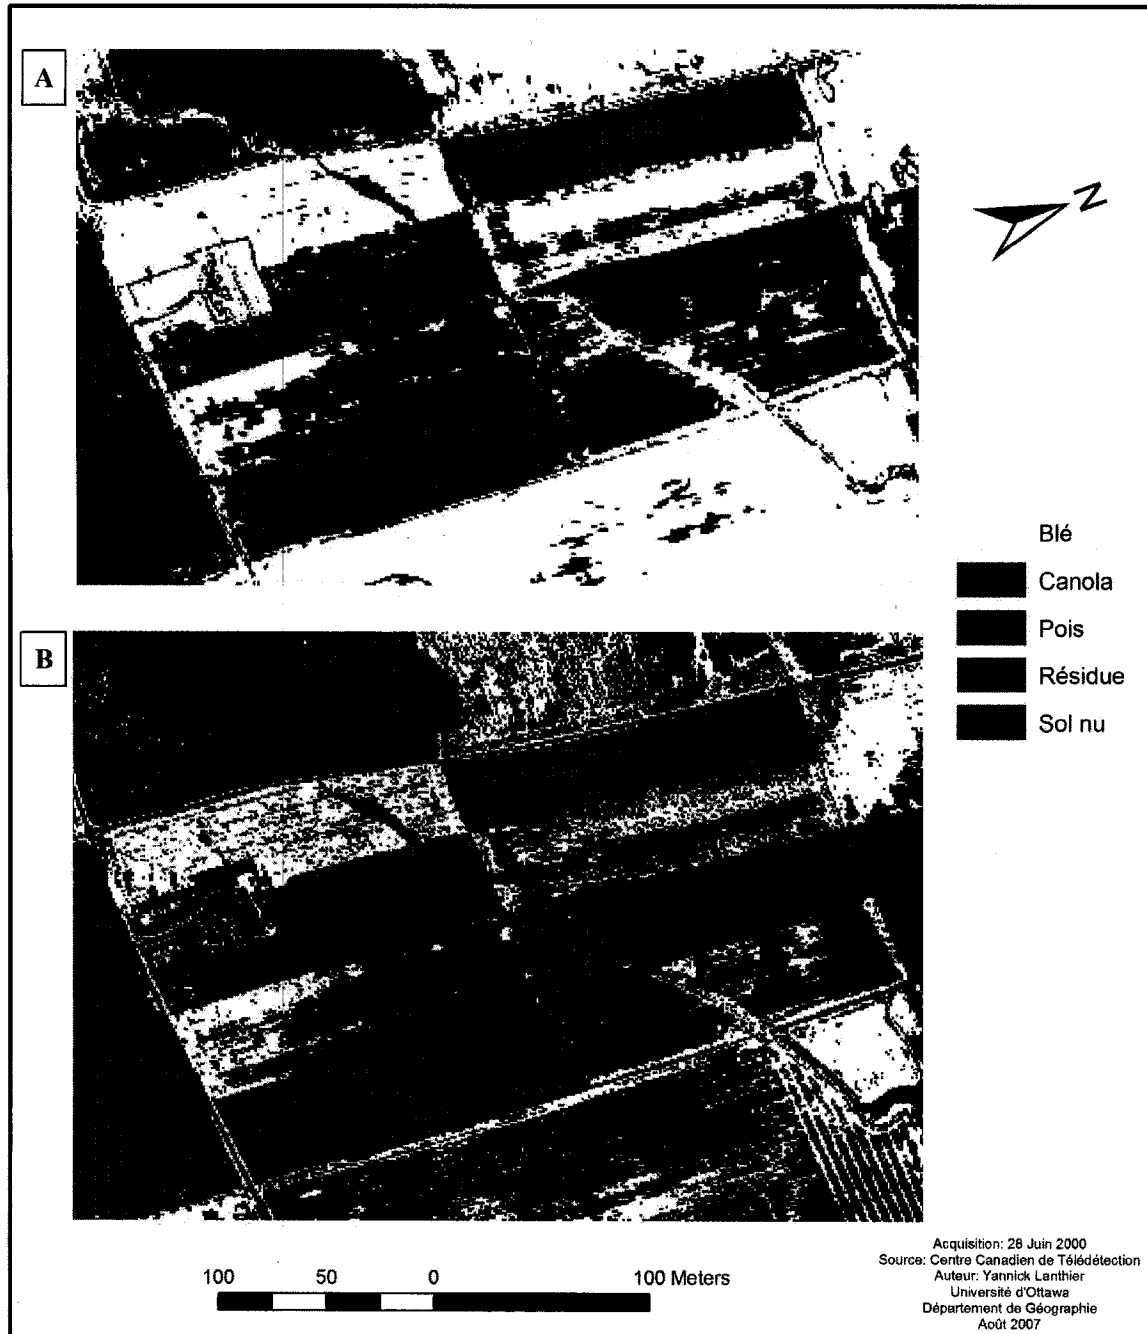


Figure 4.18 : Classifications orientées objets (A) et pixels (B) de l'image Probe-1

Visuellement, les résultats sont spatialement similaires. Comme mentionné dans la revue littéraire, la classification orientée pixel souffre du problème de mixture, c'est-à-dire que certaines classes sont très parsemées à l'intérieur d'autres classes. Par exemple, le sol nu possède une surface très continue dans deux champs, par contre les classes de pois et de blé se mélangent énormément à l'intérieur de leur champs respectifs et se sont même retrouvées dans d'autres champs voisins. Dans le cas de la classification orientée objet, ces classes sont limitées à leurs propres étendue spatiales et ne se retrouvent qu'en faible proportion dans les parcelles voisines.




Figure 4.19 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (Probe-1)

La figure 4.19 représente les coefficients Kappa pour chacune des classes à l'étude lors des classifications orientées pixels et objets sur l'image Probe-1. Pour les trois classes de cultures, les classifications orientées objets sont, en moyenne, supérieures de 7,6%. Pour les classes de résidus de cultures et de sol nu, les résultats ne sont pas aussi significatifs, car ces classes sont, tout comme le premier site, plus distinctes spectralement. Il est donc très facile pour un classificateur, que ce soit par méthode orientée pixel ou objet, d'effectuer une classification précise de ces deux classes. C'est pourquoi nous observons une faible amélioration entre les deux procédés. Également, ces deux classes sont souvent en confusion en raison de leur faible signal dans le proche

infrarouge. Elles sont pourtant bien distinctes et possèdent des coefficients Kappa très élevés (95 à 97%). La figure 4.20 représente l'histogramme de la distribution des sites ou objets d'entraînements pour les classes de résidus et le sol nu. Nous pouvons observer la distinction des deux classes (résidus et sol nu) dans les bandes du proche infrarouge (37 à 59 ou 958,9 à 1286,2 nm). Aucun objet sélectionné pour la classe de résidus ne se retrouve dans les limites de la classe du sol nu, et vice versa.

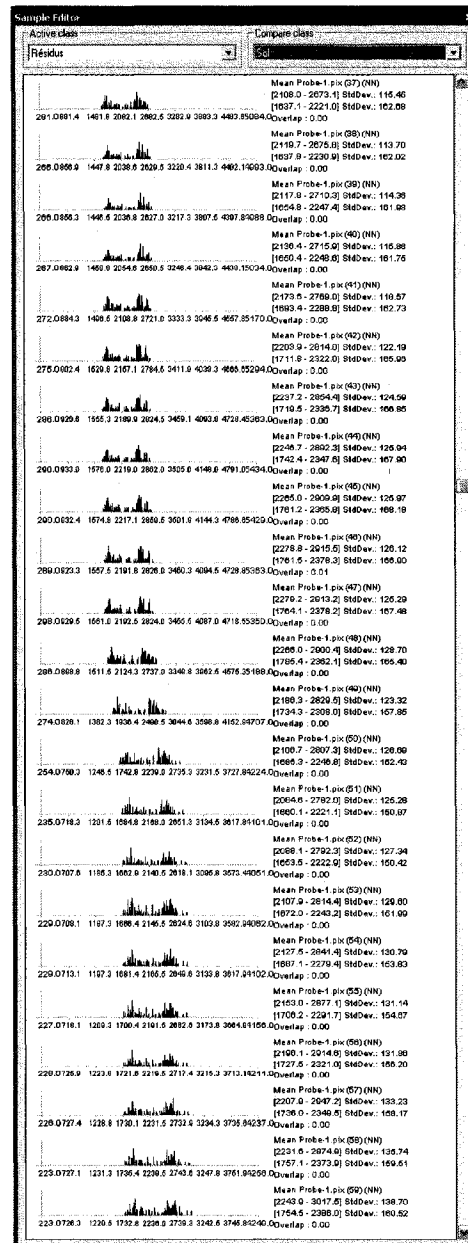


Figure 4.20 : Discrimination entre les objets d'entraînements pour les classes de résidus (noir) et sol nu (bleu). (Bandes 37 à 59 - 958,9 nm à 1286,2 nm de l'image Probe-1)

La figure 4.21 représente l'exactitude des classifications (en coefficient Kappa) en fonction des données images et du procédé de classification. La technique de classification orientée objet semble améliorer les résultats de 4,11% pour l'image Probe-1, et de 4,45% pour IKONOS. Cette amélioration est significative et constante dans le cas des deux types d'images. Nous discuterons plus en détails de la relation des résultats des classifications des deux images (Probe-1 et IKONOS) du site d'Indian Head dans la section 4.6.




Figure 4.21 : Exactitude des classifications en fonction des méthodes de classification en considérant les deux capteurs : Probe-1 et IKONOS.

4.6 Validation sur les données IKONOS

Comme mentionné dans la section précédente, une campagne de terrain fut dirigée lors de l'acquisition des images Probe-1 et IKONOS. Ces informations ont été utilisées pour la sélection des sites d'entraînements des classes à l'étude. Les endroits de fortes densités de cultures agricoles ont donc été utilisés comme objets et pixels d'entraînements. Les mêmes classes de cultures agricoles ont été utilisées, soit le blé, les pois, le canola, les résidus de cultures et le sol nu.

La figure 4.22 illustre les résultats des classifications orientées objets (4.22A) et pixel (4.22B). Comme dans le cas de l'image Probe-1, les résultats sont comparables. Nous pouvons observer une grande mixture des classes dans le cas de la classification orientée pixel. La classe des pois se mélange beaucoup à l'intérieur des champs de blé et de canola, et il semble avoir confusion entre la classe du sol nu et des résidus de cultures. Ces dernières sont surtout sous-classifiées dans la classification orientée pixels. Cette technique orientée pixels a permis la classification de 86% des pixels, ou 14% non-classifiés, et ce, à l'intérieur des champs à l'étude, comparativement à 12% de pixels non-classifiés pour l'image Probe-1. Le manque d'informations spectrales pourrait être à la source de ces pixels non-classifiés, car les classifications dirigées sur l'image Probe-1 ont été appliquées sur les 118 bandes spectrales disponibles, comparativement à seulement 4 bandes (visibles et proche infrarouge, vous référez au chapitre 3 sur les longueurs d'onde) pour les données IKONOS.

La classification orientée objet a permis une bonne isolation des classes à l'intérieur de leurs parcelles respectives, comme dans le cas de l'image Probe-1. Il semblerait qu'il y ait une surclassification du sol nu, car le manque d'une classe pour objets non-classifiés, soit les objets qui sont trop loin de la moyenne spectrales des segments d'entraînements, résulte en une appartenance par défaut à la classe la plus proche, soit le sol nu. Également, la technique de classification du plus proche voisin, appliquée à l'image segmentée, permet une bonne classification de la classe de la culture du canola, plus spécifiquement dans le champ du sud. Pour le même champ, les classifications orientées pixels du Probe-1 et d'IKONOS ont sous-estimés la présence de cette culture. Les classes des pois et du blé sont très similaires spatialement, pour les deux procédés, mais la technique orientée objets offre une excellent représentation continue des cultures à travers leurs parcelles.




Figure 4.22 : Classifications orientées objets (A) et pixels (B) de l'image IKONOS

La figure 4.23 représente les coefficients Kappa pour chacune des classes à l'étude, en fonction des méthodes de classifications. Pour les trois cultures, encore une fois, les classifications orientées objets sont, en moyenne, supérieures de 7%. Le canola est toujours la classe qui se distingue la plus entre les deux procédés de classification et les pois sont la classe la plus dominante dans l'exactitude des résultats. Leurs signatures spectrales sont considérées très fortes et uniques, ce qui permet une classification très précise, maximisant la séparabilité. En moyenne, les résultats des classifications orientées objets dirigés sur l'image Probe-1 sont 2,47% supérieurs aux résultats orientés objets de l'image IKONOS, toutes classes confondues. Dans le cas de la classification orientée

pixels, la moyenne d'augmentation des coefficients Kappa est de 2,49% pour l'image Probe-1, comparativement à l'image IKONOS.




Figure 4.23 : Coefficient Kappa de chaque classe pour les deux méthodes de classification (IKONOS)

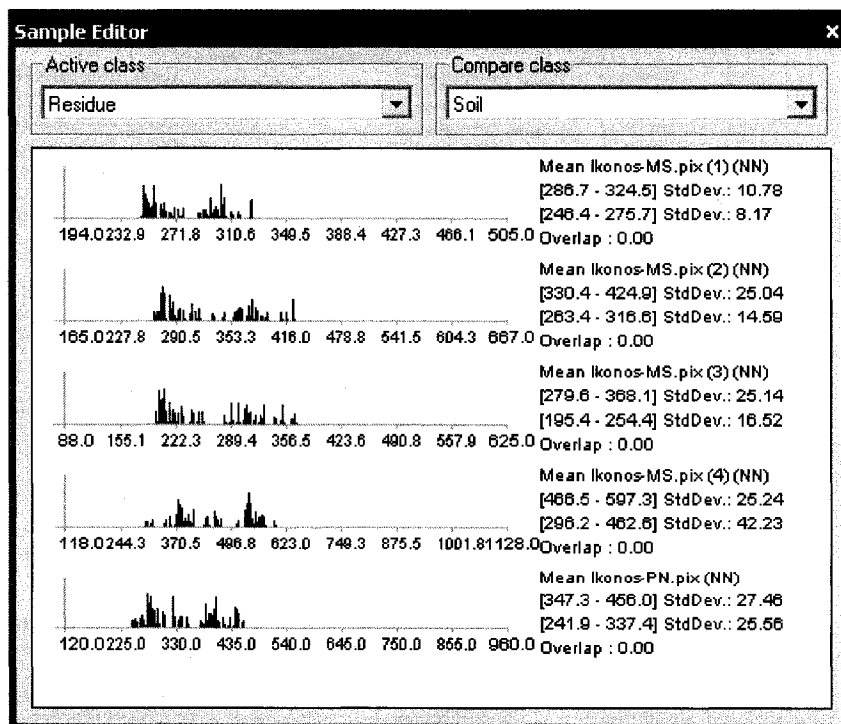


Figure 4.24 : Discrimination entre les objets d'entraînements pour les classes de résidus (noir) et sol nu (bleu). (5 bandes IKONOS, incluant le panchromatique)

Ces résultats, qui sont presque constants, démontrent clairement l'importance de l'apport de l'information hyperspectrale lors de la classification de cultures en milieux agricoles. De plus, les résultats entre les classes de résidus et de sol nu sont toujours très rapprochés. La similarité spectrale de ces classes est toujours présente dans le multispectrale. La figure 4.24 représente l'histogramme de la distribution des sites ou objets d'entraînements pour les classes de résidus et le sol nu. Nous pouvons observer la distinction des deux classes (résidus et sol nu) dans les 5 bandes du capteur IKONOS. Aucun objet sélectionné pour la classe de résidus ne se retrouve dans les limites de la classe du sol nu et vice versa.

En ce qui a trait aux résultats de validation du site d'Indian Head, il est concluant d'affirmer que la classification orientée objets est significativement avantageuse sur la classification conventionnelle orientée pixels. De plus, l'apport de l'information hyperspectrale améliore considérablement les résultats, surtout dans la classification des cultures agricoles. Les résidus et le sol nu sont des classes qui possèdent une forte séparabilité spectrale comparativement aux cultures croissantes et ceci est distinctement représenté dans les deux types de données images, dans le multispectrale comme dans l'hyperspectrale. En effet, la classe commune aux deux sites, le sol nu, semble toujours obtenir une forte exactitude de classification. Cette séparabilité spectrale semble donc y permettre une bonne classification dans les deux sites. Autre constatation des deux sites; la classification orientée objets permet l'apport de règles pour l'isolation des classes à l'intérieur de leurs parcelles respectives. Aucun objet attribué à une culture ne peut se retrouver à l'intérieur d'une parcelle d'une autre culture. Il est normal qu'il y ait une faible séparabilité entre certaines classes et que des objets se voient être assignés à une mauvaise classe, mais si une règle de classification vient limiter spatialement l'étendue des parcelles, ces mélanges sont réduits considérablement.

Le site d'Indian Head confirme donc les résultats obtenus sur le site de St-Jean-sur-Richelieu. La classification orientée objets favorise les résultats sur des classes de cultures en milieux agricoles, et ce sur deux sites différents et à l'aide de trois types de données images à différentes résolutions spatiales.

4.7 Conclusions

Ce chapitre résume les résultats obtenus sur nos deux sites à l'étude en considérant différentes images acquises à différentes résolutions spatiales et par différents capteurs. D'une part, les résultats du site de St-Jean-sur-Richelieu sont comparés et analysés en fonction des procédés de classification et en considérant différentes résolutions spatiales. Par la suite, les résultats du second site, Indian Head, sont comparés au premier site pour en observer les similarités, consistances et différences.

En somme, le site de St-Jean-sur-Richelieu révèle que la classification orientée objets peut s'effectuer à une résolution plus grossière que la classification orientée pixels, tout en obtenant des résultats significativement améliorés (augmentation de 5,38% entre 1 m orientée objets et 4 m orientée pixels). Également, indépendamment de la résolution spatiale, la classe du sol nu est spectralement différente des autres classes à l'étude. Cette classe possède un fort pouvoir discriminatoire, elle s'isole bien des signatures spectrales des cultures et des résidus et montre une forte précision de classification dans les deux procédés de classification. Le site d'Indian Head vient appuyer cette conclusion sur la classe du sol nu et ce site semble également prouver que la classe des résidus de cultures est également très distincte des classes de végétation. Le manque de chlorophylle dans ces deux classes est la raison de cette forte séparabilité spectrale. Les autres classes du site d'Indian Head sont également soumises à la mixture. Les classifications orientées objets de ces classes de cultures agricoles ont toutefois permis une amélioration significative comparativement aux résultats orientés pixels (une augmentation moyenne de 8,25% pour l'image Probe-1 et 7,08% pour l'image IKONOS). Notamment pour la précision des résultats de la classe de canola qui augmenta de 81,77% (orienté pixels) à 95,32% (orienté objets) sur l'image Probe-1, ainsi que de 80,22% (orienté pixels) à 94,04% (orienté objets) sur l'image IKONOS.

Le site d'Indian Head prouve également que l'information hyperspectrale possède un fort pouvoir discriminatoire lors de la classification des classes agricoles. La haute résolution spectrale s'avère être un fort atout lors de la sélection des sites d'entraînements, car elle permet la création d'une signature spectrale unique qui se

distingue statistiquement des autres classes de végétations. Par contre, la haute résolution spatiale des données hyperspectrales et multispectrales est également à la source d'une bonne segmentation, ce qui permet la création d'objets qui délimite adéquatement les entités au sol.

En somme, dans le domaine de l'agriculture de précision, une classification appliquée après une segmentation d'images est significativement plus avantageuse que la classification conventionnelle orientée pixels. Les deux sites ont démontré statistiquement cette affirmation d'abord sur des images hyperspectrales à différentes échelles et aussi sur une image multispectrale.

CHAPITRE 5 : CONCLUSIONS ET RECOMMANDATIONS

5.1 Conclusions

Des classifications orientées pixels d'images hyperspectrales ont été comparées aux résultats de classifications orientées objets après segmentation, dans le contexte de l'agriculture de précision. Les résultats ont par la suite été comparés sur un second site en utilisant une image hyperspectrale et une autre image multispectrale. Après évaluation, l'algorithme de classification orientée pixels sélectionné fut l'algorithme du maximum de vraisemblance et la technique de segmentation choisie fut par croissances des régions avec notion de hiérarchie. Les classifications orientées objets hyperspectrales des images acquises à différentes résolutions spatiales (1, 2 et 4 m) au-dessus d'un premier site, ont permis de conclure que la segmentation d'images permet d'atteindre une meilleure précision des résultats que la classification orientée pixels. De plus, une image à faible résolution spatiale (4 m) peut être utilisée conjointement avec le procédé de classification orientée objets pour surpasser les résultats de classifications orientées pixels à une image de plus haute résolution spatiale (1 m). En somme, le procédé de la segmentation qui utilise l'information contextuelle des pixels pour les regrouper en objets significatifs, peut utiliser une image moins coûteuse pour atteindre les mêmes résultats d'une classification par pixels à l'aide d'une image à plus haute résolution spatiale, donc plus coûteuse.

Notre méthodologie a été validée sur un second site et en utilisant d'autres données hyperspectrales et multispectrales de résolutions spatiales de 5 et 4 m respectivement. L'apport de la segmentation permet également d'obtenir de meilleurs résultats et ce, significativement supérieurs, notamment pour l'image hyperspectrale.

Grâce à ces résultats, nous pouvons donc affirmer que nous avons atteint notre objectif de recherche. Nous avons prouvé qu'une image hyperspectrale à faible résolution spatiale peut être utilisée conjointement avec la technique de classification d'objets, dérivés d'une segmentation, pour obtenir des résultats significativement supérieurs à un procédé de classification par pixels sur une image à haute résolution, et ce, en milieu agricole. Cette combinaison optimale, qui vise en un compromis entre la résolution

spatiale de l'image et la précision de la dérivation de cartes d'occupation du sol en milieu agricoles, assure une diminution des coûts d'investissements.

De plus, nos hypothèses en ce qui a trait aux images hyperspectrales ont été validées. En effet, les images hyperspectrales CASI et Probe-1 possèdent un fort pouvoir discriminatoire des différentes classes d'occupation du sol. Malgré certaines difficultés de séparabilité entre les diverses densités de classes agricoles du site de St-Jean-sur-Richelieu, la majorité des classes a pu être dissociée spectralement avec beaucoup plus de facilité dans le cas des images hyperspectrales. La richesse spectrale permet une distinction très précise des signatures spectrales de chacune des classes à l'étude. En conséquence, les images hyperspectrales acquises au-dessus des deux sites ont permis de produire des cartes d'occupation du sol en milieu agricole avec précision. Quant à la segmentation des images hyperspectrales, elle a permis d'atteindre une plus haute précision des résultats, comparativement aux classifications orientées pixels et ce, indépendamment de la résolution spatiale. Finalement, la classification appliquée après la segmentation de l'image multispectrale a définitivement amélioré les résultats sur la globalité des classes comparativement aux résultats orientés pixels.

Les conclusions tirées de cette thèse soutiennent les résultats de divers chercheurs, tel Yan (2003). Les résultats de sa recherche ont démontré que l'apport de la segmentation par croissance des régions réussit à améliorer la précision de 10%, comparativement à la classification orientée pixels, dans la recherche de charbon de bois, en Chine. Nous appuyons donc fortement de telles conclusions pour le domaine de l'agriculture de précision.

5.2 Recommandations

Une des limites de cette recherche est le manque de données de terrain qui doivent être acquises sur différents champs agricoles en même temps que les images pour la validation des résultats.

Suite à l'accessibilité des données de validation, il serait possible que la précision des résultats des deux procédés de classifications augmente. Comme décrit au chapitre 4, la validation des résultats orientés objets fut effectuée en sélectionnant d'autres objets qui ont les mêmes caractéristiques spectrales que les objets d'entraînements. Cette source d'erreur pourrait donc être corrigée en possédant des informations sur les zones de concentrations des couverts végétaux. Il est de même pour les classifications orientées pixels.

Finalement, une étude plus approfondie pourrait être effectuée sur les différentes techniques de segmentation. Malgré les publications retrouvées dans la littérature sur ces procédés, aucune analyse ne mentionne convenablement des impacts sur les effets d'échelle en fonction de différentes résolutions spatiales. La segmentation effectue le regroupement de pixels pour mieux comprendre son contexte, mais ceci au détriment de l'agglomération de l'information spectrale de tous ces pixels qui sont différents. Il est bien évident que les pixels regroupés sont très homogènes mais si certaines applications de télédétection requièrent la localisation de zones minuscules à l'échelle spatiale et spectrale, le regroupement des pixels en objets significatifs n'est pas nécessairement la meilleure approche. Cependant, la majorité des applications de la télédétection s'intéresse aux surfaces continues d'occupation du sol et la segmentation d'images est définitivement une technique à considérer dans ces domaines d'applications.

BIBLIOGRAPHIE

1. ADAMS, R. et L. BISCHOF, 1994. Seeded Region Growing, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 16, No. 6, pp. 641-647.
2. AIT BELAID., M. 1990. Cartographie de l'utilisation des sols par analyse numérique d'image SPOT cas du Maroc, Thèse de doctorat, Université Laval, Québec, Canada, 133 pages.
3. APLIN, P., P.M. ATKINSON et P.J. CURRAN, 1999. Fine spatial resolution simulated satellite sensor imagery for land cover mapping in the united kingdom, *Remote Sensing of Environment*, Vol. 68, pp. 206-216.
4. BAATZ, M. et A. SCHÄPE, 1999. Object-oriented and multi-scale image analysis in semantic networks, *2nd International Symposium: Operationalization of Remote Sensing*, Aug. 16-20, ITC, NL, 7 pages.
5. BAATZ, M. et A. SCHÄPE, 2000. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation, *Angewandte Geographische Informationsverarbeitung XII, Beiträge zum AGIT-Symposium*, Salzburg, 12 pages.
6. BAATZ, M., U. BENZ, S. DEHGHANI, M. HEYNEN, A. HOLTJE, P. HOFMANN, I. LINGENFELDER, M. MIMLER, M. SOHLBACH, M. WEBER, et G. WILLHAUCK, 2004, eCognition User's Guide, Site web: <http://www2.definiens.com/central/default.asp> (Accédez le 15 Septembre, 2006).
7. BABEY, S.K. et C.D. ANGER, 1993. Compact airborne spectrographic imager (*casi*) : A progress review, In *Proceedings of SPIE : Imaging Spectrometry of the Terrestrial Environment*, Vol. 1937, pp.152-163.
8. BALLARD, D.H. et C.M. BROWN, 1982, *Computer Vision*, Englewood Cliffs, NJ, Prentice-Hall.
9. BANNARI, A., D. MORIN, G.B. BÉNIÉ et F. BONN, 1995. A Theoretical Review of Different Mathematical Models of Geometric Corrections Applied to Remote Sensing Images. *Remote Sensing Reviews*, Vol. 13, pp.27-47.
10. BANNARI, A., J.R. GIBSON et D. MORIN, 1997. The Necessity of Exterior Orientation Parameters for the Rigorous Geometric Correction of the MEIS-II Airborne Digital Image. *Remote Sensing Reviews*, Vol. 16, p. 135-156.
11. BANNARI, A., P.M. TEILLET et G. RICHARDSON, 1999. Nécessité de l'étalonnage radiométrique et standardisation des données de télédétection. *Journal Canadien de Télédétection*, Vol. 25, No 1, pp. 45-59.

12. BANNARI, A., A. PACHECO, K. STAENZ, H. MCNAIRN et K. OMARI, 2006. Estimating and mapping crop residues cover on agricultural lands using hyperspectral and IKONOS data, *Remote Sensing of Environment*, Vol. 104, pp. 447-459.
13. BANNARI, A., K. S. KHURSHID, K. STAENZ et J. W. SCHWARTZ, 2007. A comparison of hyperspectral chlorophyll indices for wheat crop chlorophyll content estimation using laboratory reflectance measurements, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 45, No. 10, pp. 3063-3074.
14. BANNARI, A., K. S. KHURSHID, K. STAENZ et J. W. SCHWARTZ, 2008. Potential of Hyperion EO-1 Hyperspectral Data for Wheat Crop Chlorophyll Content Estimation. *Canadian Journal of Remote Sensing*, Vol. 34 (In press)
15. BARLOW, J., Y. MARTIN et S.E. FRANKLIN, 2003. Detecting translational landslide scars using segmentation of Landsat ETM+ and DEM data in the northern Cascade Mountains, British Columbia. In: *Canadian Journal of Remote Sensing*, Vol. 29, No. 4, pp. 510-517.
16. BASNYAT, P., B. MCCONKEY, G.P. LAFOND, A. MOULIN et Y. PELCAT, 2004. Optimal time for remote sensing to relate to crop grain yield on the Canadian prairies, *Canadian Journal of Plant Science*, Vol. 84, No.1, pp 97-103.
17. BEAULIEU, J.M., 1984. Hierarchical picture segmentation by step-wise optimization, Thèse de Doctorat, Université d'Ottawa, Canada, 220 pages.
18. BÉNIÉ, G. B. 1987. Segmentation d'images de hautes limites de résolution pour fin d'inventaire agricole au Canada adaptation et développement d'algorithmes, Thèse de Doctorat, Université Laval, Québec, Canada, 182 pages.
19. BÉNIÉ, G. B., K.P.B. THOMSON et M. GOLDBERG, 1989. A comparison of four segmentation algorithms in the context of agricultural remote sensing, *I.S.P.R.S. Journal of Photogrammetry and Remote Sensing*, Vol. 44, pp. 1-13.
20. BENZ, U.C., P. HOFMANN, G. WILLHAUCK, I. LINGENFELDER et M. HEYNEN, 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS Journal of Photogrammetry & Remote Sensing*, Vol. 58, pp. 239-258.
21. BERK, A., L.S. BERSTEIN et D.C. ROBERTSON, 1989. MODTRAN: A moderate resolution model for LOWTRAN7. Final Report, GL-TR-0122, AFGL, Hanscom AFB, Maryland, 42 pages.

22. BLASCHKE, T., S. LANG, E. LORUP, J. STROBL et P. ZEIL, 2000. Object-oriented image processing in an integrated GIS/Remote sensing environment and perspectives for environmental applications, In: Cremers, A. and Greve, K. (eds.): *Environmental Information for Planning, Politics and the Public*. Metropolis Verlag, Marburg, Vol. 2, pp. 555-570.
23. BLASCHKE, T. et J. STROBL, 2001. What's Wrong with Pixels? Some Recent Developments Interfacing Remote Sensing and GIS, *Geo-Information-Systeme*, pp. 12-17.
24. BOLSTAD, P.V. et T.M. LILLESAND, 1991. Rapid maximum likelihood classification. *Photogrammetric Engineering and Remote Sensing*, Vol. 57, pp. 67-74.
25. BOWEN, H., 2002. Absolute radiometric calibration of the IKONOS sensor. *Proceedings of ISPRS commission I mid-term symposium*, Denver, Colorado, USA, November 10-15.
26. BRESCI, E., 1992. Land-use classification from remotely-sensed data. Unpublished Report of Institute for hydrology, Water Resources and Environmental Engineering, Ruhr University Bochum, Bochum.
27. BROOKS, C.N., D.L. SCHAUB, R.B. POWELL, N.H.F. FRENCH et R.A. SHUCHMAN, 2006. Multi-temporal and multi-platform agricultural land cover classification in southeastern Michigan, *ASPRS 2006 Annual Conference*, Reno, Nevada, May 1-5, 12 pages.
28. BUNTING, P., et R.M. LUCAS, 2006. The Delineation of Tree Crowns in Australian Mixed Species Forests using Hyperspectral CASI Data, *Remote Sensing of Environment*, Vol. 101, pp.230-248.
29. BURNETT, C. et T. BLASCHKE, 2003. A multi-scale segmentation/object relationship modelling methodology for landscape analysis, *Ecological Modelling*, Vol. 168, pp. 233-249.
30. CALOZ, R., et C. COLLET, 2001. Précis de télédétection : Traitements numériques d'images de télédétection, Volume 3, Presse de l'Université du Québec, Québec, 386 pages.
31. CAMPBELL, J.B., 1996. *Introduction to Remote Sensing*, The Guilford Press, New York, 622 pages.
32. CANNY, J.F., 1986. A computation approach to edge detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 8, pp. 679-698.

33. CARLEER, A.P., O. DEBEIR et E. WOLFF, 2005. Assessment of very high spatial resolution satellite image segmentations, *Photogrammetric Engineering and Remote Sensing*, Vol. 71, No. 11, pp. 1285-1294.
34. CARLEER, A.P. et E. WOLFF, 2006. Urban land cover multi-level region-based classification of VHR data by selecting relevant features, *International Journal of Remote Sensing*, Vol. 27, No. 6, pp 1035-1051.
35. CARRANZA, E.J.M., et M. HALE, 2001. Remote detection of vegetation stress for mineral exploration. Proceedings of the 1999 IEEE International Geoscience and Remote Sensing Symposium, Sydney, Australia, 9-13 July 2001. CD-ROM.
36. CASALS-CARRASCO, P., S. KUBO, et B. BABU MADHAVAN, 2000. Application of spectral mixture analysis for terrain evaluation studies. *International Journal of Remote Sensing*, Vol. 21, pp.3039–3055.
37. CHAMPAGNE C. M., K. STAENZ, A. BANNARI, H. MCNAIM, J.-C., et DEGUISE, 2003. Validation of a hyperspectral curve-fitting model for the estimation of plant water content of agricultural canopies, *Remote sensing of environment*, Vol. 87, No. 2-3, pp.148-160.
38. CHEN, J.M., S.G. LEBLANC, J.R. MILLER, S.E. J. FREEMANTLE, C.L. LOECHEL, K.A. WALTHALL, H. INNANEN et P. WHITE, 1999. Compact Airborne Spectrographic Imager (CASI) used for Mapping Biophysical Parameters of Boreal Forests. *Journal of Geophysical Research-Atmosphere*, Vol.104, No. D22, pp. 27,945-27,948.
39. COCQUEREZ, J.P. et S. PHILIPP, 1995. Analyse d'images : filtrage et segmentation, Masson, Paris, 457 pages.
40. CONGALTON, R.G., 1983. The use of discrete multivariate techniques for assessment of Landsat Classification accuracy, Thèse de Maîtrise, Blacksburg, VA: Virginia Polytechnic Institute and State University, 111 pages.
41. COOK, M. K., B.A. PETERSON, D. G. DIAL, L. GIBSON, F. GERLACH, K. HUTCHINS, R. KUDOLA et H.S. BOWEN, 2001. IKONOS technical performance assessment, *Algorithms for multispectral, hyperspectral and ultraspectral imagery Conference No. 7*, Orlando, Florida, USA. 15 pages.
42. CRDH, 2007. Centre de recherche et de développement en horticulture, <http://sci.agr.ca/stjean/> (site web consulté le 4 mars 2007)
43. CRAWFORD, T. W., J.A., COMMITO, et A.B. BOROWIK, 2006. Fractal characterization of *Mytilus edulis* L. spatial structure in intertidal landscapes using GIS methods. *Landscape Ecology*, Vol. 21, pp. 1033-1044.

44. DEBEIR, O., 2001. Segmentation Supervisée d'Images, Ph.D., Faculté des Sciences Appliquées, Université Libre de Bruxelles.
45. DEMIRCI, S., B. YAZGAN et O. ERSOY, 2005. Multispectral target detection by statistical methods, *Proceedings of 2nd International Conference on Recent Advances in Space Technologies*, 9-11 June, pp. 653-659.
46. DERAVID, F. et S.K. PAL, 1983. Grey level thresholding using second-order statistics, *Pattern Recognition Letters*, Vol. 1, pp. 417-422.
47. EL-MAGD, I.A. et T.W. TANTON, 2003. Improvements in land use mapping for irrigated agriculture from satellite sensor data using a multi-stage maximum likelihood classification, *International Journal of Remote Sensing*, Vol. 24, No. 21, pp. 4197-4206.
48. ESSI Inc, 2001. About Probe-1, Kalispell, MT, <http://www.earthsearch.com>
49. FERNANDES, R.A., J.R. MILLER, B. HU et I.G. RUBINSTEIN, 2002, A Multi-Scale Approach to Mapping Effective Leaf Area Index in Boreal *Picea mariana* Stands using High Spatial Resolution CASI Imagery, in press *International Journal of Remote Sensing*, Vol. 23, No 18, pp. 3547-3568.
50. FREUDER, E.C., 1976, Affinity: A relative approach to region finding, *Computer Graphics & Image Processing*, Vol. 5, pp. 254-264.
51. FREUND, J.E., 1962. *Mathematical Statistics*, Prentice-Hall, 390 pages.
52. FU, K. et J. MUI, 1981. A survey on image segmentation. *Pattern Recognition*, Vol.13, No.1, pp.3-16.
53. GREIWE, A. et M. EHLERS, 2005. Combined analysis of hyperspectral and high resolution image data in an object oriented classification approach. In: *Proceedings of the ISPRS WG VII/1 "Human Settlements and Impact Analysis" 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas and 5th International Symposium Remote Sensing of Urban Areas*, Tempe, AZ, USA.
54. GUPTA, J.N. et P.A. WINTZ, 1975. A boundary finding algorithm and its applications, *IEEE Transactions on Circuits and Systems*, Vol. 22, No.4, pp. 351-362.
55. HABOUDANE, D., J.R. MILLER, N. TREMBLAY, P.J. ZARCO-TEJADA, et L. DEXTRAZE, 2002. Integrated narrow-band vegetation indices for a prediction of crop chlorophyll content for application to precision agriculture, *Remote Sensing of Environment*, Vol. 81, pp.416-426.

56. HABOUDANE, D., J.R. MILLER, E. PATTEY, P.J. ZARCO-TEJADA, et I. STRACHAN, 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, Vol. 90, pp.337–352.
57. HARALICK, R.M., K. SHANMUGAM et I. DINSTEN, 1973. Textural features for image classification, *IEEE Transactions on System, Man and Cybernetics*, SMC-3, pp.610-621.
58. HARALICK, R.H., et L.G. SHAPIRO, 1985. Image Segmentation Techniques, *Computer Vision, Graphics, and Image Processing*, Vol. 29, pp.100-132.
59. HILL, R.A., G.M. SMITH, R.M. FULLER et N. VEITCH, 2002. Landscape modeling using integrated airborne multi-spectral and laser scanning data, *International Journal of Remote Sensing*, Vol. 23, No. 11, pp. 2327-2334.
60. HODGSON, M.E., 1988. Reducing the Computational Requirements of the Minimum-Distance Classifier, *Remote Sensing of Environment*, Vol. 25, pp. 117-128.
61. HOROWITZ, S.L. et T. PAVLIDIS, 1974. Picture segmentation by directed split and merge procedure, *Proceedings of 2nd International Joint Conference on Pattern Recognition*, pp. 424-433.
62. HOSSEIN, S. Z., S.J. KHAJEDDIN, H. AZARNIVAD, S.A. KHALILPOUR, 2004, Land Use Mapping Using Etm+ Data (case Study: Chamestan Area, Iran), XXth ISPRS Congress, 12-23 July 2004 Istanbul, Turkey.
63. JAGO RA, MEJ. CUTLER et P.J. CURRAN, 1999. Estimating canopy chlorophyll concentration from field and airborne spectra. *Remote Sensing of Environ.* Vol. 68 pp. 217-224.
64. JANSSEN, L., 1993. Methodology for updating terrain object data from remote sensing data. The application of Landsat TM data with respect to agricultural fields, Thèse de Doctorat, Agricultural University, Wageningen, NL.
65. JOYCE, A.T. 1978. Procedures for gathering ground truth information for a supervised approach to computer-implemented land cover classification of Landsat-Acquired Multispectral Scanner Data, NASA Reference Publication 1015, Houston, TX: National Aeronautics and Space Administration, 43 pages.
66. KARANTZALOS, K.G. et D.P. ARGIALAS, 2003. Evaluation of selected edge detection techniques in remotely sensing images, *Proceedings of SPIE Image and Signal Processing for Remote Sensing VIII*, Vol. 4885, pp.102-110.

67. LACAR, F.M., M.M. LEWIS et I.T. GRIERSON, 2001. Use of Hyperspectral Imagery for Mapping Grape Varieties in the Barossa Valley, *Geoscience and Remote Sensing Symposium*, Vol. 6, pp. 2875-2877.
68. LHOMME, S., C. WEBER, D-C. HE, D. MORIN et A. PUISSANT, 2004. Building extraction from very high spatial resolution image, *XXth ISPRS Congress*, July 12-23, Istanbul, Turkey, 5 pages.
69. LILLESAND, T.M. et R.W. KIEFER, 2004. Remote Sensing and Image Interpretation, 5th edition. Wiley, New York, 726 pages.
70. LIU, J., J.R. MILLER, D. HABOUDANE, E. PATTEY et M.C. NOLIN, 2005. Variability of seasonal CASI image data products and potential application for management zone delineation for precision agriculture, *Can. Journal of Rem. Sens.*, Vol 31, No 5, pp. 400-411.
71. LUCIEER, A., 2004. Uncertainties in Segmentation and their visualization, Ph.D. Thesis Utrecht University, ITC Dissertation 113, Enschede, 174 pages.
72. MANSOR, S., W.T. HONG, et A.R.M. SHARIFF, 2002. Object oriented classification for land cover mapping. *Proceedings of Map Asia 2002*, Bangkok: GISDevelopment.
73. MASSALABI, A., 2006. Détection et exploitation d'ombre de bâti sur les images de très haute résolution spatiale (IKONOS) : Application au milieu urbain (Sherbrooke), Thèse de Doctorat, Département de géomatique appliqué, Université de Sherbrooke, 134 pages.
74. MATHER, P.M. 1987. Computer Processing of Remotely-Sensed Images Chichester: Wiley.
75. MEINEL, G. et M. NEUBERT, 2004. A comparison of segmentation programs for high resolution remote sensing data, In *Proceedings of the ISPRS 2004 Annual Conference*, Istanbul, Turkey, July 19-23, 6 pages.
76. MILNE, B.T., 1992. Spatial aggregations and neutral models in fractal landscapes, *American Nature*, Vol. 139, pp. 32-57.
77. MOORTHY, I., J.R. MILLER, T.L. NOLAND, U. NIELSEN, et P.J. ZARCO-TEJADA, 2003. Needle chlorophyll content estimation of boreal conifers using hyperspectral remote sensing. *International Geoscience and Remote Sensing Symposium*, IGARSS'03, Toulouse, France

78. NEUBERT, M. et G. MEINEL, 2003. Evaluation of segmentation programs for high resolution remote sensing applications. In: *Proceedings of the ISPRS Joint Workshop High Resolution Mapping from Space 2003*. 6-8 October 2003. Hannover, Germany
79. NEUBERT, M., H. HEROLD et G. MEINEL, 2006. Evaluation of remote sensing image segmentation quality - further results and concepts, First International Conference on Object-based Image Analysis. Salzburg, Austria, 6 pages.
80. O'NEILL, N.T., F. ZAGOLSKI, M. BERGERON, A. ROYER, J.R. MILLER, et J. FREEMANTLE, 1997. Atmospheric correction validation of casi images acquired over the BOREAS southern study area, *Canadian Journal of Remote Sensing*, Vol. 23, pp.143-162.
81. OWOJORI, A. et H. XIE, 2004, Landsat image-based LULC changes of San Antonio, Texas using advanced atmospheric correction and object-oriented image analysis approaches, *Proceedings of the 5th International Symposium on Remote Sensing of Urban Areas (URS2005)*, March 14-16, Tempe, Arizona. 4 pages.
82. PACHECO, A. 2004. Contribution of hyperspectral remote sensing to the estimation of leaf area index in the context of precision agriculture, Thèse de Maîtrise, Université d'Ottawa, Canada, 156 pages
83. PAL, N.R. et S.K. PAL, 1993. A review on image segmentation techniques. *Pattern Recognition*, Vol. 26, pp.1277-1294.
84. PCI GEOMATICS, 2007. Site web: www.pcigeomatics.com (Accédez le 20 mars 2007)
85. PETERSON, B., 2001. IKONOS Relative Spectral Response and Radiometric Calibration Coefficients, *Space Imaging Internal ISO-9001 Reference Document SE-REF-016*, <http://www.geoeye.com>
86. RADOUX, J. et P. DEFOURNY, 2006. Influence of image segmentation parameters on positional and spectral quality of the derived objects, *1st International Conference on Object-based Image Analysis (OBIA 2006)*, Salzburg University, Austria, July 4-5, 5 pages.
87. REPAKA, S. R. 2004. Comparing spectral-object-based approaches for extracting and classifying transportation features using high-resolution multi-spectral satellite imagery, Master thesis, Mississippi State University, 162 pages
88. REPAKA, S.R., D.D. TRUAX, E. KOLSTAD, et C.G. O'HARA, 2004. Comparing spectral and object based approaches for classification and transportation feature extraction from high resolution multispectral imagery. *Proceedings of the ASPRS 2004 Annual Conference*, Denver, USA. 11 pages

89. RICHARDS, J.A., 1993. Remote Sensing Digital Image Analysis, Edition Springer-Verlag, Germany, 340 pages.
90. ROBINSON, G.S., 1977, Detection and coding of edges using directional masks, *Optical Engineering*, Vol. 16, No. 6, pp. 580-585.
91. SAMPSON, P.H., P.J. ZARCO-TEJADA, G.H. MOHAMMED, J.R. MILLER, et T.L. NOLAND. 2003. Hyperspectral remote sensing of forest condition: Estimating chlorophyll content in tolerant hardwoods. *Forest Science*, (Bethesda, MD), Vol. 49, pp. 381–391.
92. SANTOS, T., J. A. TENEDÓRIO, S. ENCARNAÇÃO et J. ROCHA, 2006. Comparing pixel vs. Object based classifiers for land cover mapping with Envisat-MERIS data, *26th EARSeL Symposium*, Maio, Varsóvia, 9 pages.
93. SCHIEWE, J., L. TUFTE et M. EHLERS, 2001. Potential and problems of multi-scale segmentation methods in remote sensing, *GIS-Zeitschrift für Geoinformationssysteme*, Vol. 6, pp. 34-39.
94. SHAFRI, H.Z.M., A. SUHAILI et S. MANSOR, 2007. The performance of maximum likelihood, spectral angle mapper, neural network and decision tree classifiers in hyperspectral image analysis, *Journal of Computer Sciences*, Vol. 3, No. 6, pp. 419-423.
95. SHETTIGARA, V. K., 1991. Robustness of Gaussian maximum likelihood and linear discriminant classifiers. *Proceedings of the International Geoscience and Remote Sensing Symposium, IGARSS'91*. Remote Sensing Global Monitoring for Earth Management, Helsinki University of Technology, Espoo, Finland, New York: IEEE, Vol. 3, pp.1830–1842.
96. SMITH, G.M. et R.M. FULLER, 2001. An integrated approach to land cover classification: an example in the Island of Jersey, *International Journal of Remote Sensing*, Vol. 22, No. 16, pp. 3123-3142.
97. SMITH, M.O., S.L. USTIN, J.B. ADAMS et A.R. GILLESPIE, 1990. Vegetation in Deserts: I. A Regional Measure of Abundance from Multispectral Images, *Remote Sensing of Environment*, Vol. 31, pp.1-26.
98. SPACE IMAGING, 2002. IKONOS relative spectral response and radiometric calibration coefficients, <http://www.geoeye.com>
99. STAENZ K., et D. WILLIAMS, 1997. Retrieval of Surface Reflectance From Hyperspectral Data Using a Look-up Table Approach, *Canadian Journal of Remote Sensing*, Vol.23, No.4, pp.354-368.

100. STAENZ, K., T. SZEREDI et J.W. SCHWARTZ, 1998. ISDAS A system for processing and analyzing hyperspectral data. *Canadian Journal of Remote Sensing*, Vol. 42, No. 2, pp. 99-113.
101. STRASTERS, K. et J. GERBRANDS, 1991. Three-dimensional segmentation using a split, merge and group approach, *Pattern Recognition Letters*, Vol. 12, pp. 307-325.
102. SU, Z., 2000. Remote sensing of land use and vegetation for mesoscale hydrological studies. *International journal of remote sensing*, Vol. 21, No. 2, pp. 213-233.
103. TANRÉ D., C. DEROO, P. DUHAUT, M. HERMAN, J.J. MORCETTE, J. PERBOS et P.Y. DESCHAMPS, 1986, Simulation of the Satellite Signal in the Solar Spectrum (5S), Logiciel et documentation, LOA, Lille, France.
104. TILTON, J.C., 1989. Image segmentation by iterative parallel region growing and splitting, *Geoscience and Remote Sensing Symposium*, Vancouver, Canada, Vol. 4, pp. 2420-2423.
105. TILTON, J.C., 1998. Image segmentation by region growing and spectral clustering with a natural convergence criterion, *Proceedings of the 1998 International Geoscience and Remote Sensing Symposium*, Seattle, Washington, July 6-10.
106. THOMSON, A.G., R.M. FULLER et J.A. EASTWOOD, 1998. Supervised versus unsupervised methods for classification of coasts and river corridors from airborne remote sensing. *International Journal of Remote Sensing*, Vol. 19, No.17, pp. 3423-3431.
107. TURKER, M. et M. ARIKAN, 2004. Field-based crop mapping through sequential masking classification of multi-temporal Landsat-7 ETM+ images in Karacabey, Turkey, *XXth ISPRS Congress, Komisyon 7*, Istanbul, Turkey.
108. VAN COILLIE, F.M.B., L.P.C. VERBEKE et R.R. DE WULF, 2007. Feature selection by genetic algorithms in object-based classification of IKONOS imagery for forest mapping in Flanders, Belgium, *Remote Sensing of Environment*, Vol. 110, pp. 476-487.
109. VAN DER SANDE, C.J., S.M. DE JONG et A.P.J. DE ROO, 2003. A segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist flood risk and flood damage assessment, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 4, pp. 217-229.
110. VIETTI-VIOLI, C., 2007. Exploitation de données LIDAR à haute resolution pour la foresterie, Thèse de Maîtrise, École Polytechnique Fédérale de Lausanne, Laboratoire de systèmes d'information géographique, 74 pages.

111. VINCENT, L. et P. SOILLE, 1991. Watershed in digital spaces: An efficient algorithm based on immersion simulations, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 13, No. 6, pp. 583-598.
112. WANG, Z. et R. BOESCH, 2007. Color and Texture based image segmentation for improved forest delineation, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 45, No. 10, pp.3055-3062.
113. WEI, W., X. CHEN et A. MA, 2005. Object-oriented Information Extraction and Application in High-resolution Remote Sensing Image, *Proceedings of Geoscience and Remote Sensing Symposium*, July 25-29 2005, Vol. 6, pp.3803-3806.
114. WULDER, M.A., et D. SEEMAN, 2003. Forest inventory height update through the integration of lidar data with segmented Landsat imagery. *Canadian Journal of Remote Sensing*, Vol.29, No.5, pp.536-543.
115. XU, W., B. WU, J. HUANG, Y. ZHANG et Y. TIAN, 2004. A segmentation and classification approach of land cover mapping using quickbird image, *International Geoscience and Remote Sensing Symposium (IGARSS)*, Anchorage, AK, United States, pp. 162-171.
116. YAN, G., 2003. Pixel based and object oriented image analysis for coal fire research, Thèse de Maîtrise, International Institute for Geo-Information Science and Earth Observation, Enschede, The Netherlands, 82 pages.
117. YAN, G., J.F. MAS, B.H.P. MAATHUIS, Z. XIANGMIN, et P.M. VAN DIJK, 2006. Comparison of pixel-based and object-oriented image classification approaches - a case study in a coal fire area, Wuda, Inner Mongolia, China. *International Journal of Remote Sensing*. Vol. 27, No. 18, pp. 4039 – 4055.
118. YANG, L., F. ALBREGTSEN, T. LONNESTAD et P. GROTTUM, 1995. A supervised approach to the evaluation of image segmentation methods, *Computer Analysis of Image Pattern*, Vol. 970, pp. 759-765.
119. ZARCO-TEJADA, P.J., J.R. MILLER, G.H. MOHAMMED, T.L. NOLAND et P.H. SAMPSON, 2001. *Scaling-up and Model Inversion* methods with narrow-band Optical Indices for Chlorophyll Content Estimation in closed Forest Canopies with Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 39 No 7, pp. 1491-1507.
120. ZHANG, Y.J., 1997. Evaluation and comparison of different segmentation algorithms, *Pattern Recognition Letters*, Vol. 18, pp. 963-974.
121. ZHANG, Q., J. WANG, P. GONG, et P. SHI, 2003. Study of Urban Spatial Patterns from SPOT Panchromatic Imagery Using Textural Analysis. *International Journal of Remote Sensing*, Vol. 24, No. 21, pp. 4137-4160.

122. ZHANG, X., M. PAZNER et N. DUKE, 2007. Lithologic and mineral information extraction for gold exploration using ASTER data in the south Chocolate Mountains (California), *ISPRS Journal of Photogrammetry & Remote Sensing*, Vol. 62, pp. 271-282.

ANNEXE I

Matrices de confusion

CASI 1 m - Matrice de confusion des résultats orientés pixels

	Mais-1	Mais-2	Mais-3	Haricots-1	Haricots-2	Pois-1	Pois-2	Sol nu	Total des rangées	Kappa par classe
Mais-1	177	0	0	0	0	0	0	0	177	0.7704
Mais-2	1	207	0	0	0	0	0	0	208	0.7243
Mais-3	1	1	117	0	0	0	0	0	119	0.7690
Haricots-1	0	0	0	125	3	0	0	2	130	0.8737
Haricots-2	0	0	0	0	376	0	0	0	376	0.7550
Pois-1	0	0	0	0	0	306	0	0	306	0.7455
Pois-2	0	0	0	0	0	0	150	0	150	0.7941
Sol nu	0	0	0	0	0	1	1	547	549	0.8383
Non-Classifiés	46	69	33	17	119	87	35	77	483	
Total des colonnes	225	277	150	142	498	394	186	626	2498	

CASI 1 m - Matrice de confusion des résultats orientés objets

	Mais-1	Mais-2	Mais-3	Haricots-1	Haricots-2	Pois-1	Pois-2	Sol nu	Total des rangées	Kappa par classe
Mais-1	17	1	1	0	0	0	0	0	19	0.8807
Mais-2	0	13	2	0	0	0	0	0	15	0.9212
Mais-3	2	0	22	0	0	0	1	0	25	0.8579
Haricots-1	0	0	0	26	2	0	0	0	28	0.8748
Haricots-2	0	0	0	3	15	0	0	1	19	0.8675
Pois-1	0	0	0	0	0	14	2	0	16	0.9260
Pois-2	0	0	0	0	0	1	19	0	20	0.8443
Sol nu	0	0	0	0	0	0	0	19	19	0.9433
Total des colonnes	19	14	25	29	17	15	22	20	161	

CASI 2 m - Matrice de confusion des résultats orientés pixels

	Mais-1	Mais-2	Mais-3	Haricots-1	Haricots-2	Pois-1	Pois-2	Sol nu	Total des rangées	Kappa par classe
Mais-1	108	0	0	0	0	0	0	0	106	0.7144
Mais-2	0	354	0	0	0	0	0	0	354	0.6315
Mais-3	0	1	101	0	0	0	0	0	102	0.6867
Haricots-1	0	0	0	64	3	0	0	0	67	0.7550
Haricots-2	0	0	0	1	50	0	0	0	51	0.7478
Pois-1	0	0	0	0	0	63	0	5	68	0.7388
Pois-2	0	0	0	0	0	0	116	3	119	0.7249
Sol nu	0	0	0	0	0	0	0	115	115	0.8343
Non-Classifiés	36	108	38	16	15	15	34	20	282	
Total des colonnes	142	463	139	81	68	78	150	143	1264	

CASI 2 m - Matrice de confusion des résultats orientés objets

	Mais-1	Mais-2	Mais-3	Haricots-1	Haricots-2	Pois-1	Pois-2	Sol nu	Total des rangées	Kappa par classe
Mais-1	16	0	2	0	1	0	0	0	19	0.8790
Mais-2	1	17	1	0	0	0	0	0	19	0.8853
Mais-3	1	2	15	0	0	0	0	0	18	0.8193
Haricots-1	0	0	0	38	3	0	0	0	41	0.8111
Haricots-2	0	0	0	6	33	0	0	2	41	0.8687
Pois-1	0	0	0	0	0	31	1	0	32	0.8674
Pois-2	0	0	0	0	0	3	12	1	16	0.8466
Sol nu	0	0	0	1	0	1	1	43	46	0.9187
Total des colonnes	18	19	18	45	37	35	14	46	232	

CASI 4 m - Matrice de confusion des résultats orientés pixels

	Mais-1	Mais-2	Mais-3	Haricots-1	Haricots-2	Pois-1	Pois-2	Sol nu	Total des rangées	Kappa par classe
Mais-1	37	0	0	0	0	0	0	0	37	0.7120
Mais-2	0	48	0	0	0	0	0	0	48	0.6300
Mais-3	0	1	41	0	0	0	0	0	42	0.6860
Haricots-1	0	0	0	28	4	0	0	0	32	0.7591
Haricots-2	0	0	0	0	56	0	0	1	57	0.7460
Pois-1	0	0	0	0	0	82	1	4	87	0.6861
Pois-2	0	0	0	0	0	1	46	0	47	0.7168
Sol nu	0	0	0	0	0	0	0	29	29	0.8320
Non-Classifiés	7	22	15	4	14	21	14	5	103	
Total des colonnes	44	71	56	32	74	104	61	39	481	

CASI 4 m - Matrice de confusion des résultats orientés objets

	Mais-1	Mais-2	Mais-3	Haricots-1	Haricots-2	Pois-1	Pois-2	Sol nu	Total des rangées	Kappa par classe
Mais-1	13	1	2	0	0	0	0	0	16	0.8495
Mais-2	1	9	0	0	0	0	0	0	10	0.8042
Mais-3	1	1	9	0	0	0	0	0	11	0.8027
Haricots-1	0	0	0	22	1	0	0	0	23	0.8159
Haricots-2	0	0	0	4	14	0	0	2	20	0.8542
Pois-1	0	0	0	0	0	19	3	0	22	0.7937
Pois-2	0	0	0	0	0	2	5	0	7	0.8103
Sol nu	0	0	0	0	1	2	0	18	21	0.8824
Total des colonnes	15	11	11	26	16	23	8	20	130	

Probe-1 - Matrice de confusion des résultats orientés objets

	Blé	Pois	Canola	Résidus	Sol nu	Total des rangées	Kappa par classe
Blé	216	0	15	0	0	231	0.9190
Pois	5	159	0	9	0	173	0.9066
Canola	35	1	238	4	0	278	0.8177
Résidus	0	2	1	301	7	311	0.9583
Sol nu	0	0	0	9	215	224	0.9525
Non-Classifiés	7	3	6	2	0	18	
Total des colonnes	263	165	260	325	222	1234	

Probe-1 - Matrice de confusion des résultats orientés objets

	Blé	Pois	Canola	Résidus	Sol nu	Total des rangées	Kappa par classe
Blé	33	1	0	1	0	35	0.9655
Pois	0	43	0	0	0	43	0.9722
Canola	0	0	53	0	0	53	0.9532
Résidus	0	0	2	44	2	48	0.9721
Sol nu	1	0	0	0	57	58	0.9551
Total des colonnes	34	44	55	45	59	237	

IKONOS - Matrice de confusion des résultats orientés pixels

	Blé	Pois	Canola	Résidus	Sol nu	Total des rangées	Kappa par classe
Blé	504	0	13	0	0	517	0.8807
Pois	4	194	37	1	0	236	0.9284
Canola	0	4	1318	17	0	1339	0.8022
Résidus	1	3	47	825	2	878	0.8762
Sol nu	1	0	0	5	288	294	0.9422
Non-Classifiés	50	7	71	60	14	202	
Total des colonnes	560	208	1486	908	304	3466	

IKONOS - Matrice de confusion des résultats orientés objets

	Blé	Pois	Canola	Résidus	Sol nu	Total des rangées	Kappa par classe
Blé	55	0	0	0	1	56	0.9169
Pois	0	33	0	4	0	37	0.9665
Canola	1	0	60	0	0	61	0.9404
Résidus	0	1	2	58	2	63	0.9196
Sol nu	3	0	1	0	83	87	0.9514
Total des colonnes	59	34	63	62	86	304	

ANNEXE II

LANTHIER, Y., A. BANNARI, D. HABOUDANE, J.R. MILLER et N. TREMBLAY. 2008, Hyperspectral Data Segmentation and Classification in Precision Agriculture: A Multi-Scale Analysis, IGARSS: International Geoscience and Remote Sensing Symposium. 6-11 Juillet 2008, Boston, États-Unis.

HYPERSPECTRAL DATA SEGMENTATION AND CLASSIFICATION IN PRECISION AGRICULTURE: A MULTI-SCALE ANALYSIS

Y. Lanthier¹, A. Bannari¹, D. Haboudane², J. R. Miller³ and N. Tremblay⁴

¹ Department of Geography, University of Ottawa, Ottawa (Ontario) K1N 6N5 CANADA

Phone (613) 562-5800 Ext: 1042 ; Email: ylant031@uottawa.ca; abannari@uottawa.ca

² Laboratoire d'expertise et de recherche en télédétection et géomatique (LERTG), Université du Québec à Chicoutimi, 555 Boulevard de l'Université, Chicoutimi, Québec, G7H 2B1 Canada, E-mail: driss_haboudane@uqac.ca

³ Department of Earth and Space Science & Engineering, York University, Toronto, Ontario, M3J 1P3, Canada; Email: jrmiller@yorku.ca

⁴ Agriculture and Agri-Food Canada, 430 Boul. Gouin, St-Jean-sur-Richelieu, Quebec, J3B 3E6, Canada; Email: tremblayna@agr.gc.ca

Abstract - The conventional pixel-oriented classification is the most commonly used approach in remote sensing for land use product extraction. The object-oriented classification based on the image segmentation is an alternative, which uses the pixel context, texture and shapes, in addition to their spectral characteristics. This paper reports on a comparative study between supervised pixel-oriented and object-oriented classifications in a precision agriculture context using three hyperspectral images. The images were acquired with the *Compact Airborne Spectrographic Imager (CASI)* sensor at three different altitudes, providing three different spatial resolutions: 1, 2 and 4 m. Pixel-oriented classifications were carried out using the maximum likelihood algorithm, and object-oriented classifications with a hierarchical segmentation and nearest neighbor classifier. The raw CASI data were transformed to absolute ground reflectance using calibration coefficients determined in the laboratory and the CAM5S radiative transfer code for atmospheric corrections. After segmentation, statistical comparison on the mean difference to neighbor objects confirmed that the segments had minimum mixing effects in respect to other segmentation levels and neighboring ground entities. After accuracy analysis on the classifications, the segmentation process allowed for the use of a spatially coarser hyperspectral image (4 m with kappa of 0.8268) to achieve better results than pixel oriented classification of spatially finer hyperspectral image (1 m with kappa of 0.7730), in the task of delineating agricultural classes.

Keywords: Object-Oriented; segmentation; precision agriculture; hyperspectral imagery, CASI, Probe-1, IKONOS.

I. INTRODUCTION

The pixel-oriented classification technique is the most commonly used in remote sensing to create land use land cover products. The imagery is represented by thousands or millions of pixels in multiple spectral channels who are being assigned to diverse classes [1]. The pixel-oriented classification algorithms assign a given class to all pixels, based entirely on their spectral reflectance and derived statistics. A commonly used algorithm is the maximum likelihood, who assigns these classes based on a Gaussian distribution of the derived statistics of trained pixels [2, 3, 4]. This technique, and all supervised classification algorithms, is

limited by the user-selected trained pixels who are defining the statistics of the classes of interest; a crucial step which will have a direct impact on the results' accuracy [5].

Multiple techniques can increase the precision of classification results: texture analysis [6], fractals [7] and image segmentation. The latter allows for the extraction of spatial and spectral components of any multispectral or hyperspectral imagery. The classification on segmented objects has the advantage of exploiting shape and spatial relationships between neighboring pixels or segments. There are two main groups of segmentation algorithms: Boundary-based and Region-based [8]. The boundary, or edge detection, segmentation is based on pixel discontinuity across the image to create the segmented objects. This type of segmentation includes the "optimal edge detector" algorithm and the watershed segmentation technique. The region-based algorithms group the multilevel thresholding technique and region-growing algorithm. The latter is a process that regroups pixels in meaningful objects, based on homogeneity criteria. Compared to pixel-oriented classification, this process is only a few decades old and has now been implemented in many remote sensing software [9, 10, 11]. It also allows for the creation of multiple characteristics, describing the segmented objects, based on shape, texture, color and, in some cases, hierarchy, which can then be used as trained statistics for the classification [12, 9, 13, 14]. All these algorithms have been used and compared for multiple uses [9, 15, 12, 16, 17].

The region-growing algorithm has been used successfully in precision agriculture. In [18], they mention that this technique is commonly used for per-plot or per-field classification [19, 20, 21]. It allows for an accurate delineation of agricultural fields because of their spatial stability (distinct shapes) even if they have a spatially diverse vegetation cover. Other researchers are frequently comparing the object-oriented classification with the pixel-oriented maximum likelihood classifier, in diverse applications. Using SPOT HRV (High Resolution in Visible), the study in [1] achieved a 90% accuracy using object-oriented classification over a 68% accuracy for pixel oriented, in the task of delineating and classifying agricultural plots in northern Africa. In a general land use land cover application, [22] obtained a 83% accuracy for object-oriented classification as compared to 46% for maximum likelihood pixel-oriented, using ASTER data in northern China. In [23] the authors used the hyperspectral

CASI sensor to achieve 88% accuracy for agricultural vegetation classification.

This study focuses on an analysis of a combination of images and processes to achieve optimum results to delineate agricultural classes.

II. MATERIAL AND METHODS

A. Study Site

The images data were acquired in an agricultural region near St-Jean-sur-Richelieu, in South-West Quebec. The site is located at the L'Acadie research station (45° 17' 40"N, 73° 20' 10"W) of the Horticulture Research and Development centre of Agriculture and Agri-food Canada. This site has been used in many other studies on remote sensing and has an area of 84 hectares of crop land. Located in the Saint-Laurent plains, the topography is very flat with an average elevation of 41 m above sea level and a humid continental climate extending the crop season from May to September. For our study, we have chosen 3 fields with 3 different crops: corn, peas and beans.

B. Images Data

On August 14, 2003, 3 images were acquired over the study site using the CASI sensor, resulting in three hyperspectral images at different spatial resolutions: 1, 2 and 4 m. This pushbroom imager allowed for hyperspectral acquisition in 72 spectral bands, ranging from 430 to 870 nm. For this study, only 7 spectral bands were used: (Table 1).

Table 1 : CASI Hyperspectral Bands Used

Band #	Wavelength (nm)	Bandwidth (nm)
1	490.74	6.17
2	549.68	5.25
3	671.30	4.34
4	699.76	4.35
5	750.19	3.41
6	774.05	4.37
7	799.86	5.33

C. Images Pre-processing

All 3 images were pre-processed in three steps. First, radiometric corrections were applied, to normalize the information recorded by the multiple sensors, using the *Imaging Spectrometer Data Analysis System* (ISDAS) [24]. Relative calibration coefficients were calculated to minimize the effect of misalignment, offsetting and banding [25]. The absolute calibration coefficients were also estimated to allow a conversion from digital numbers to at-sensor radiance. These coefficients were calculated in laboratory after the acquisitions, on the sensor, at Earth Observations Laboratory, York University. Second, atmospheric corrections were applied to correct the effects of absorption and scattering. The CAM5S (Canadian Advanced Modified – Simulation du Signal Satellitaire dans le Spectre Solaire), adapted from [26], was used to achieve ground reflectance. This model, based on the 5S [27], is the most commonly used atmospheric correction model on CASI imagery [28]. Finally, the images were geometrically corrected from distortions caused by the aircraft's movements (pitch, yaw, roll and speed variation) during the acquisitions. These parameters were recorded

using an inertial navigation system (INS) [29]. A second order polynomial equation was applied to geo-reference the imagery in the UTM projection, using the NAD 83. This process resulted in a root mean square error (RMSE) of less than a pixel, which is quite acceptable for thematic applications [30].

D. Segmentation

The hierarchical region-growing segmentation algorithm was used in this research. The use of the eCognition software and this segmentation technique is documented in [14]. All the images considered were subjected to the same segmentation process. The software allowed the use of a different scale parameter, which is a heterogeneity threshold, spectral, shape, compactness smoothness parameters and weight for each spectral band to be used in the segmentation process. A segmentation analysis tool is also available to observe the spectral differences between neighboring objects so that the segmentation can be adjusted for optimum results in the delineation of ground entities. Furthermore, we have used a segmentation-derived characteristic, called mean spectral difference to neighbors, to evaluate and quantify the different segmentation levels for each image. Based on those statistics, levels with highest or best spectral separability (especially in the SWIR) were chosen for the classification process.

E. Classifications

The pixel oriented classifications were done with the maximum likelihood classifier using PCI Geomatica 9. Eight classes were trained based on their spectral characteristics and statistics: Corn-1, Corn-2, Corn-3, Peas-1, Peas-2, Beans-1, Beans-2 and Bare Ground. Different crop classes represent a different level of density. The object-oriented classification was performed on the best segmentation results for each image. The same eight classes were created and trained based on same spectral statistics. eCognition's nearest neighbor classifier, which is based on minimum distance, was used as well as a Gaussian membership function created for each characteristic used in the classification process. This allows the algorithm to use the trained objects as a Gaussian distribution throughout the available characteristics. Statistics of both results were then derived. Confusion matrices, overall and per class Kappa coefficients were then compared.

III. ANALYSIS AND DISCUSSION

Since no fieldwork was available to train the classes, unsupervised k-means classifications were performed to find cores of pixel with similar spectral characteristics and statistics. Different pixels of these cores were used in the training and validation processes. Figure 1 represents the pixel-oriented results and Figure 2 the classification results conducted after segmentations. There is a reasonable pattern similarity between both results at the 1 m resolution. Mainly for bean classes, we can identify common zones and patterns. Although, statistically, pixel oriented results seems to create confusion between bare soil and some of the peas and beans. These covers are very sparse and are mainly surrounded by bare ground, which is increasing the spectral mixing of these two covers.




Figure 1 : Pixel Oriented Classifications

Also, the unclassified pixels at 1 m (22%) are clearly present for all classes. The object-oriented classification at 1 m gave strong membership values to the peas classes (>0.600) allowing a great distinction with the bare ground.

At 2 m, the unclassified pixels (23%) are increasing and the bare ground class is dominating the field of peas. We are suggesting that the pixels at 2m are inducing a lot of spectral mixing, which shows in the decreasing overall kappa coefficient from 1 m (Figure 3). Statistically and visually, the object-oriented results at 2 m are very similar to those at 1 m using the same classification process. They only got coarser but the very same patterns of classification are clearly present. At 4m, spectral mixing is affecting all results. The pixel-oriented result is very sparse and unclassified pixels (28%) are a good indicator of the weakness of the classifier. Again, the object-oriented patterns are present, but at a very coarser scale.

According to the per class kappa coefficient of the object oriented results, the corn classes are very strong (>0.80). Out of all 3 crops, corn is the one with the greatest canopy extent. It is therefore minimizing the spectral mixing with the underlying ground. The bare ground class is also very strong in kappa coefficient (>0.83), independent of the resolution and method of classification. This class is spectrally unique as compared to the crop classes, although spectral mixing with bare ground is very present with other weak canopy crops such as peas and beans. Figure 3 also reveals that object-

oriented results, at a coarser spatial resolution (2 or 4m), show greater accuracy than pixel-oriented results at higher resolution (1 m).




Figure 2 : Object Oriented Classifications

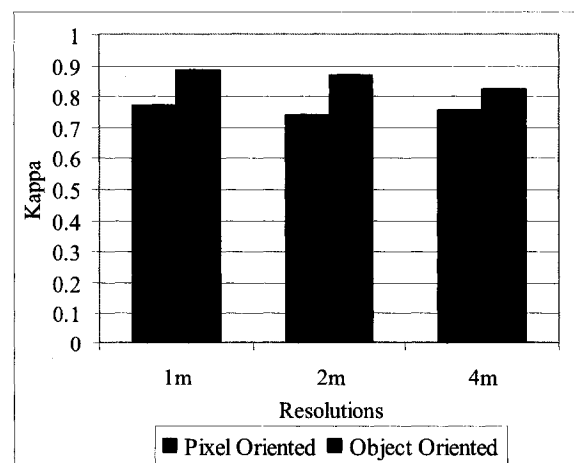


Figure 3 : Classification accuracy

IV. CONCLUSION

The main issue encountered with pixel-oriented classification is the weak canopy cover of peas and beans. Strong spectral mixing with underlying soil induces errors in the classification process which cannot achieve the 95% certainty classification threshold. Object-oriented results, based on segments that are delineating core ground entities, achieved better results. Assigned membership values are allowing a full classification of the scene and a classification accuracy tool that allows a good visualization of problematic areas. We conclude that a coarser spatial resolution image (4m) can be used with an advanced classification technique, such as object-oriented, to achieve better results (kappa of 0.8268) than a pixel-oriented classification on even higher spatial resolution imagery (1 m, kappa of 0.7730), in the task of delineating and classifying agricultural classes. Further research would be required for extreme cases (5 m vs. 10 m using multispectral sensor data) to support precision agriculture applications.

ACKNOWLEDGMENTS

The authors would like to thank the National Science and Engineering Research Council (NSERC) for the financial support.

REFERENCES

- [1] AIT BELAID, M. 1990. Cartographie de l'utilisation des sols par analyse numérique d'image SPOT cas du Maroc, Thèse de doctorat, Université Laval, Québec, Canada, 133 pages.
- [2] MATHER, P.M. 1987. Computer Processing of Remotely-Sensed Images Chichester: Wiley.
- [3] BOLSTAD, P.V. and T.M. LILLESAND, 1991. Rapid maximum likelihood classification. *Photogrammetric Engineering and Remote Sensing*, Vol. 57, pp. 67-74.
- [4] SHETTIGARA, V. K., 1991. Robustness of Gaussian maximum likelihood and linear discriminant classifiers. *Proceedings of the International Geoscience and Remote Sensing Symposium, IGARSS'91*. Remote Sensing Global Monitoring for Earth Management, Helsinki University of Technology, Espoo, Finland, New York: IEEE, Vol. 3, pp.1830-1842.
- [5] LILLESAND, T.M. and R.W. KIEFER, 2004. Remote Sensing and Image Interpretation, 5th edition. Wiley, New York, 726 pages.
- [6] ZHANG, Q., J. WANG, P. GONG, and P. SHI, 2003. Study of Urban Spatial Patterns from SPOT Panchromatic Imagery Using Textural Analysis. *International Journal of Remote Sensing*, Vol. 24, No. 21, pp. 4137-4160.
- [7] CRAWFORD, T. W., J.A., COMMITO, and A.B. BOROWIK, 2006. Fractal characterization of *Mytilus edulis* L. spatial structure in intertidal landscapes using GIS methods. *Landscape Ecology*, Vol. 21, pp. 1033-1044.
- [8] CARLEER, A.P., O. DEBEIR and E. WOLFF, 2004. Comparison of very high spatial resolution satellite image segmentations. *Image and Signal Processing for Remote Sensing IX, Proceedings of SPIE*, Vol. 5238, pp. 532-542.
- [9] HARALICK, R.H., and L.G. SHAPIRO, 1985. Image Segmentation Techniques, *Computer Vision, Graphics, and Image Processing*, Vol. 29, pp.100-132.
- [10] ZHANG, Y.J., 1997. Evaluation and comparison of different segmentation algorithms, *Pattern Recognition Letters*, Vol. 18, pp. 963-974.
- [11] BAATZ, M. and A. SCHÄPE, 2000. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation, *Angewandte Geographische Informationsverarbeitung XII, Beiträge zum AGIT-Symposium*, Salzburg, 12 pages.
- [12] PAL, N.R. and S.K. PAL, 1993. A review on image segmentation techniques. *Pattern Recognition*, Vol. 26, pp.1277-1294.
- [13] BÉNIÉ, G. B. 1987. Segmentation d'images de hautes limites de résolution pour fin d'inventaire agricole au Canada adaptation et développement d'algorithmes, Thèse de Doctorat, Université Laval, Québec, Canada, 182 pages.
- [14] BAATZ, M., U. BENZ, S. DEGHANI, M. HEYNEN, A. HOLTJE, P. HOFMANN, I. LINGENFELDER, M. MIMLER, M. SOHLBACH, M. WEBER, and G. WILLHAUCK, 2004, eCognition User's Guide, Site web: <http://www2.definiens.com/central/default.asp> (Accédez le 15 Septembre, 2006).
- [15] BÉNIÉ, G. B., K.P.B. THOMSON and M. GOLDBERG, 1989. A comparison of four segmentation algorithms in the context of agricultural remote sensing. *I.S.P.R.S. Journal of Photogrammetry and Remote Sensing*, Vol. 44, pp. 1-13.
- [16] NEUBERT, M., G. MEINEL, 2003. Evaluation of segmentation programs for high resolution remote sensing applications. In: *Proceedings of the ISPRS Joint Workshop High Resolution Mapping from Space 2003*. 6-8 October 2003. Hannover, Germany
- [17] CARLEER, A.P., O. DEBEIR and E. WOLFF, 2005. Assessment of very high spatial resolution satellite image segmentations, *Photogrammetric Engineering and Remote Sensing*, Vol. 71, No. 11, pp. 1285-1294.
- [18] BLASCHKE, T. and J. STROBL, 2001. What's Wrong with Pixels? Some Recent Developments Interfacing Remote Sensing and GIS, *Geo-Informations-Systeme*, pp. 12-17.
- [19] JANSSEN, L., 1993. Methodology for updating terrain object data from remote sensing data. The application of Landsat TM data with respect to agricultural fields, Thèse de Doctorat, Agricultural University, Wageningen, NL.
- [20] APLIN, P., P.M. ATKINSON and P.J. CURRAN, 1999. Fine spatial resolution simulated satellite sensor imagery for land cover mapping in the United Kingdom, *Remote Sensing of Environment*, Vol. 68, pp. 206-216.
- [21] SMITH, G.M. and R.M. FULLER, 2001. An integrated approach to land cover classification: an example in the Island of Jersey, *International Journal of Remote Sensing*, Vol. 22, No. 16, pp. 3123-3142.
- [22] YAN, G., J.F. MAS, B.H.P. MAATHUIS, Z. XIANGMIN, and P.M. VAN DIJK, 2006. Comparison of pixel-based and object-oriented image classification approaches - a case study in a coal fire area, Wuda, Inner Mongolia, China. *International Journal of Remote Sensing*. Vol. 27, No. 18, pp. 4039 - 4055.
- [23] HILL, R.A., G.M. SMITH, R.M. FULLER and N. VEITCH, 2002. Landscape modeling using integrated airborne multi-spectral and laser scanning data, *International Journal of Remote Sensing*, Vol. 23, No. 11, pp. 2327-2334.
- [24] STAENZ, K., T. SZEREDI and J.W. SCHWARTZ, 1998. ISDAS A system for processing and analyzing hyperspectral data. *Canadian Journal of Remote Sensing*, Vol. 42, No. 2, pp. 99-113.
- [25] BANNARI, A., P.M. TEILLET and G. RICHARDSON, 1999. Nécessité de l'étalonnage radiométrique et standardisation des données de télédétection. *Journal Canadien de Télédétection*, Vol. 25, No 1, pp. 45-59.
- [26] O'NEILL, N.T., F. ZAGOLSKI, M. BERGERON, A. ROYER, J.R. MILLER, and J. FREEMANTLE, 1997. Atmospheric correction validation of casi images acquired over the BOREAS southern study area, *Canadian Journal of Remote Sensing*, Vol. 23, pp.143-162.
- [27] TANRE D., C. DEROO, P. DUHAUT, M. HERMAN, J.J. MORCETTE, J. PERBOS and P.Y. DESCHAMPS, 1986. Simulation of the Satellite Signal in the Solar Spectrum (5S), Logiciel et documentation, LOA, Lille, France.
- [28] MOORTHY, I., J.R. MILLER, T.L. NOLAND, U. NIELSEN, and P.J. ZARCO-TEJADA, 2003. Needle chlorophyll content estimation of boreal conifers using hyperspectral remote sensing. *International Geoscience and Remote Sensing Symposium, IGARSS'03*, Toulouse, France
- [29] BANNARI, A., J.R. GIBSON and D. MORIN, 1997. The Necessity of Exterior Orientation Parameters for the Rigorous Geometric Correction of the MEIS-II Airborne Digital Image. *Remote Sensing Reviews*, Vol. 16, p. 135-156.
- [30] BANNARI, A., D. MORIN, G.B. BÉNIÉ and F. BONN, 1995. A Theoretical Review of Different Mathematical Models of Geometric Corrections Applied to Remote Sensing Images. *Remote Sensing Reviews*, Vol. 13, pp.27-47.