

Université de Montréal

**Applicabilité de la texture couleur à la différenciation des
classes d'occupation du territoire sur des images
satellitaires multispectrales**

par

André Boyer

Département de Géographie
Faculté des arts et sciences

**Mémoire présenté à la Faculté des études supérieures
en vue de l'obtention du grade de M.sc.
en Géographie**

Août 2010

© André Boyer, 2010

Université de Montréal
Faculté des études supérieures

Ce mémoire intitulé :

**Applicabilité de la texture couleur à la différentiation des
classes d'occupation du territoire sur des images
satellitales multispectrales**

Présenté par :
André Boyer

A été évalué par un jury composé des personnes suivantes :

M. André Roy, président-rapporteur
M. François Cavayas, directeur de recherche
M. Langis Gagnon, examinateur externe

Résumé

La texture est un élément clé pour l'interprétation des images de télédétection à fine résolution spatiale. L'intégration de l'information texturale dans un processus de classification automatisée des images se fait habituellement via des images de texture, souvent créées par le calcul de matrices de co-occurrences (MCO) des niveaux de gris. Une MCO est un histogramme des fréquences d'occurrence des paires de valeurs de pixels présentes dans les fenêtres locales, associées à tous les pixels de l'image utilisée; une paire de pixels étant définie selon un pas et une orientation donnés. Les MCO permettent le calcul de plus d'une dizaine de paramètres décrivant, de diverses manières, la distribution des fréquences, créant ainsi autant d'images texturales distinctes. L'approche de mesure des textures par MCO a été appliquée principalement sur des images de télédétection monochromes (ex. images panchromatiques, images radar monofréquence et monopolarisation). En imagerie multispectrale, une unique bande spectrale, parmi celles disponibles, est habituellement choisie pour générer des images de texture. La question que nous avons posée dans cette recherche concerne justement cette utilisation restreinte de l'information texturale dans le cas des images multispectrales. En fait, l'effet visuel d'une texture est créé, non seulement par l'agencement particulier d'objets/pixels de brillance différente, mais aussi de couleur différente.

Plusieurs façons sont proposées dans la littérature pour introduire cette idée de la texture à plusieurs dimensions. Parmi celles-ci, deux en particulier nous ont intéressés dans cette recherche. La première façon fait appel aux MCO calculées bande par bande spectrale et la seconde utilise les MCO généralisées impliquant deux bandes spectrales à la fois. Dans ce dernier cas, le procédé consiste en le calcul des fréquences d'occurrence des paires de valeurs dans deux bandes spectrales différentes. Cela permet, en un seul traitement, la prise en compte dans une large mesure de la « couleur » des éléments de texture. Ces deux

approches font partie des techniques dites intégratives. Pour les distinguer, nous les avons appelées dans cet ouvrage respectivement « textures grises » et « textures couleurs ». Notre recherche se présente donc comme une analyse comparative des possibilités offertes par l'application de ces deux types de signatures texturales dans le cas spécifique d'une cartographie automatisée des occupations de sol à partir d'une image multispectrale. Une signature texturale d'un objet ou d'une classe d'objets, par analogie aux signatures spectrales, est constituée d'une série de paramètres de texture mesurés sur une bande spectrale à la fois (textures grises) ou une paire de bandes spectrales à la fois (textures couleurs). Cette recherche visait non seulement à comparer les deux approches intégratives, mais aussi à identifier la composition des signatures texturales des classes d'occupation du sol favorisant leur différenciation : type de paramètres de texture / taille de la fenêtre de calcul / bandes spectrales ou combinaisons de bandes spectrales.

Pour ce faire, nous avons choisi un site à l'intérieur du territoire de la Communauté Métropolitaine de Montréal (Longueuil) composé d'une mosaïque d'occupations du sol, caractéristique d'une zone semi urbaine (résidentiel, industriel/commercial, boisés, agriculture, plans d'eau...). Une image du satellite SPOT-5 (4 bandes spectrales) de 10 m de résolution spatiale a été utilisée dans cette recherche. Puisqu'une infinité d'images de texture peuvent être créées en faisant varier les paramètres de calcul des MCO et afin de mieux circonscrire notre problème nous avons décidé, en tenant compte des études publiées dans ce domaine : a) de faire varier la fenêtre de calcul de 3*3 pixels à 21*21 pixels tout en fixant le pas et l'orientation pour former les paires de pixels à (1,1), c'est-à-dire à un pas d'un pixel et une orientation de 135°; b) de limiter les analyses des MCO à huit paramètres de texture (contraste, corrélation, écart-type, énergie, entropie, homogénéité, moyenne, probabilité maximale), qui sont tous calculables par la méthode rapide de Unser, une approximation des matrices de co-occurrences, c) de former les deux signatures texturales par le même nombre d'éléments choisis d'après une analyse de la séparabilité (distance de Bhattacharya) des classes d'occupation du sol; et d) d'analyser les résultats de classification (matrices de confusion, exactitudes, coefficients Kappa) par maximum de vraisemblance

pour conclure sur le potentiel des deux approches intégratives; les classes d'occupation du sol à reconnaître étaient : résidentielle basse et haute densité, commerciale/industrielle, agricole, boisés, surfaces gazonnées (incluant les golfs) et plans d'eau.

Nos principales conclusions sont les suivantes a) à l'exception de la probabilité maximale, tous les autres paramètres de texture sont utiles dans la formation des signatures texturales; moyenne et écart type sont les plus utiles dans la formation des textures grises tandis que contraste et corrélation, dans le cas des textures couleurs, b) l'exactitude globale de la classification atteint un score acceptable (85%) seulement dans le cas des signatures texturales couleurs; c'est une amélioration importante par rapport aux classifications basées uniquement sur les signatures spectrales des classes d'occupation du sol dont le score est souvent situé aux alentours de 75%; ce score est atteint avec des fenêtres de calcul aux alentours de 11*11 à 15*15 pixels; c) Les signatures texturales couleurs offrant des scores supérieurs à ceux obtenus avec les signatures grises de 5% à 10%; et ce avec des petites fenêtres de calcul (5*5, 7*7 et occasionnellement 9*9) d) Pour plusieurs classes d'occupation du sol prises individuellement, l'exactitude dépasse les 90% pour les deux types de signatures texturales; e) une seule classe est mieux séparable du reste par les textures grises, celle de l'agricole; f) les classes créant beaucoup de confusions, ce qui explique en grande partie le score global de la classification de 85%, sont les deux classes du résidentiel (haute et basse densité).

En conclusion, nous pouvons dire que l'approche intégrative par textures couleurs d'une image multispectrale de 10 m de résolution spatiale offre un plus grand potentiel pour la cartographie des occupations du sol que l'approche intégrative par textures grises. Pour plusieurs classes d'occupations du sol un gain appréciable en temps de calcul des paramètres de texture peut être obtenu par l'utilisation des petites fenêtres de traitement. Des améliorations importantes sont escomptées pour atteindre des exactitudes de classification de 90% et plus par l'utilisation des fenêtres de calcul de taille variable adaptées à chaque type d'occupation du sol. Une méthode de classification hiérarchique

pourrait être alors utilisée afin de séparer les classes recherchées une à la fois par rapport au reste au lieu d'une classification globale où l'intégration des paramètres calculés avec des fenêtres de taille variable conduirait inévitablement à des confusions entre classes.

Mots-clés : Texture couleur, matrices de co-occurrences, classification de l'occupation du sol, imagerie multispectrale, signature texturale.

Abstract

Texture is a key element in interpreting remotely sensed images of fine spatial resolution. The integration of textural information in an automatic image-classification process is usually done via textural images, which are often created by calculating gray levels co-occurrences matrices (COM). A COM is a histogram of frequencies of pairs of pixel values present in local windows associated with all pixels in the used image; each pixel pair being formed using a given orientation and spacing. COM allows calculation for more than a dozen of parameters describing in various ways the frequency distribution, creating thus as many different textural images. Texture measurements approach based on COMs had been mainly applied on monochrome images (e.g. panchromatic, single polarisation and frequency radar images). In the case of multispectral images, a single spectral band, among those available, is usually chosen to generate texture images. The question we asked in this research concerns precisely this limited use of textural information in the case of multispectral images. In fact, the visual effect of a texture is created, not only by the spatial arrangement of variable objects/pixels brightness, but also of different colors.

Several ways are suggested in the literature to introduce this concept of multi-dimensional texture. In this research, two of them were of particularly interested us. In the first way COMs are calculated spectral band by band and in the second one, generalized COMs are applied involving the joint use of two spectral bands. In the latter case, the pairs of pixel values are defined in two different spectral bands. This allows, in a single treatment, for a broad accounting of the "color" element composing a texture. These two approaches are called integrative techniques. To distinguish them, we call them respectively "gray textures" and "color textures". Our research concerns the comparative analysis of the opportunities offered by applying these two types of textural signatures in the specific case of an automated land cover mapping using multispectral images. A

textural signature of an object or class of objects, by analogy to spectral signatures, consists in a set of texture parameters measured; band by band (grey textures), or by pairs of bands (color textures). This research was designed not only to compare the two integrative approaches, but also to identify the components of textural signatures favouring the differentiation of land cover classes: texture parameters, window sizes and bands selection.

To do this, a site within the territory of the Montreal Metropolitan Community (Longueuil) was chosen with a diversity of land covers representative of a semi-urban area. (residential, industrial / commercial, woodlots, agriculture, water bodies...). A SPOT-5 (4 spectral bands) image of 10m spatial resolution was used in this research. Since an infinite number of texture images can be created by varying the design parameters of COM, and to better define our problem, we have decided, taking into account studies published in this field: a) to vary the computation window from 3*3 to 21*21 pixels while setting the pixel spacing and direction to (1,1); that is to say, an spacing of 1 and an orientation of 135 ° between pairs of pixels. b) limit the COM analysis to eight texture parameters (contrast, correlation, standard deviation, energy, entropy, homogeneity, average, maximum probability), all of which are computable by the Unser's fast-COM-approximation method, c) form the two textural signatures by the same number of elements chosen from a separability analysis (Bhattacharya distance) between land cover classes, and d) analyse the results (confusion matrices, accuracies, kappa) obtained using a maximum likelihood classification algorithm to conclude on the potential of both integrative approaches; classes to be recognized included: low and high density residential, commercial / industrial, agricultural, woodlots, turf (including golf) water bodies, clouds and their shadows.

Our main conclusions are as follows a) except maximum probability, all other textural parameters are useful in the formation of textural signatures; mean and standard deviation are most useful in the formation of gray textures while contrast and correlation, are the best in the case of color textures b) the overall classification accuracy achieved an acceptable score (85%), only in the case of color textural signatures. This is a significant

improvement compared to classifications based solely on spectral signatures, whose accuracies are often situated around 75%. This score is reached with windows size from about 11*11 to 15 * 15 pixels, c) Textural colors signatures offer higher scores, ranging from 5% to 10%, than those obtained by gray signatures. This is true while using the smaller process windows (5*5, 7*7, and occasionally 9*9) d) For several land cover classes examined individually, the accuracy is above 90% regardless of the used textural signatures e) Only one class is better separated from the rest by gray textures, the agricultural one; f) Classes creating a lot of confusion, which largely explains the overall classification score of 85 %, are the two residential classes (high and low density).

As a final conclusion, we can say that the integrative approach by color textures provides a greater potential for mapping land covers using multispectral images than the integrative approach by gray textures. For several land cover classes an appreciable gain computing time of textural parameters may be obtained using smaller size windows. Significant improvements of the classification results (even better than 90%) are expected using calculation windows with sizes better adapted to each classes particular texture characteristics, A hierarchical classification method could then be used to separate each class at a time from all others, instead of a broad classification where the integration of parameters calculated with varying size windows, would inevitably lead to confusion between classes.

Keywords: Color texture, co-occurrences matrix, landcover classification, multispectral imaging, textural signature.

Table des matières

Liste des tableaux.....	xii
Liste des figures.....	xiii-xiv
 Introduction.....	 1
 1-Matrices de co-occurrences et signature texturales, théorie et problématique.....	 7
1.1- Les matrices de co-occurrences : bref rappel.....	10
1.2- Les matrices de co-occurrences généralisées.....	16
1.3- Formation des signatures texturales.....	18
1.4- Objectifs-Hypothèse.....	20
 2-Méthodologie.....	 21
2.1- Site à l'étude et données.....	21
2.2- Méthode	25
2.3- Étapes de la démarche.....	26
2.4- Outils d'analyse.....	32
2.4.1- Texel : algorithme de création des images de texture.....	32
2.4.2- Analyse de séparabilité.....	33
2.4.3- Classificateur.....	34
2.4.4- Analyses d'exactitude des classifications.....	36
2.4.5- Semi-variogramme et taille de fenêtre de calcul.....	38

3-Résultats et analyses.....	40
3.1- Présentation des images texturales grises vs couleur.....	40
3.2- Analyse de la séparabilité des signatures texturales.....	47
3.2.1-Signatures texturales grises.....	48
3.2.2-Signatures texturales couleurs.....	50
3.2.3- Meilleure séparabilité : gris ou couleur?.....	53
3.2.4- Formation des signatures texturales.....	54
3.3-Résultats des tests de classification.....	57
3.3.1- Qualité de classification dans son ensemble.....	57
3.3.2- Qualité de classification par classe.....	62
3.3.3- Semi-variogrammes et taille des fenêtres de calcul.....	69
3.4- Exemples de classification et observations.....	71
3.5- Comparaison avec des classifications standards.....	78
3.6- Discussion générale des résultats.....	79
Conclusion.....	81
Bibliographie.....	85-91
Annexe 1	I-VII

Liste des tableaux

Tableau 1.1 : Récapitulatif des principales techniques d'utilisation des textures et articles de référence associés.....	9
Tableau 1.2 : Huit mesures de texture extractibles des MCO regroupées selon leur ressemblance mathématique (Haralick, 1973).....	11
Tableau 1.3 : Calcul des paramètres de texture selon la méthode d'Unser (1986).....	16
Tableau 2.1 : Matériel.....	23
Tableau 2.2 - Matrice de confusion.....	37
Tableau 3.1 : Matrices de séparabilité des signatures de classes selon les 8 textures grises, en utilisant les 4 bandes spectrales	49
Tableau 3.2 : Matrices de séparabilité des signatures de classes selon les 4 bandes spectrales, en utilisant les 8 textures grises.....	50
Tableau 3.3 : Matrices de séparabilité des signatures de classes selon les 8 textures couleurs, en utilisant les toutes les paires de bandes possibles.....	51
Tableau 3.4 : Matrices de séparabilité des signatures de classes selon chacune des combinaisons de bandes spectrales possibles, en utilisant les 8 types de textures...	52
Tableau 3.5 : Séparabilité des classes avec textures variables et utilisations de toutes les Bandes.....	53
Tableau 3.6 : Séparabilité des classes avec bandes variables et utilisations de toutes les textures.....	53
Tableau 3.7 : Signatures texturales optimisées, gris et couleur.....	56
Tableau 3.8 : Différence d'exactitude moyenne selon l'orientation pour les (couleur - gris).....	59
Tableau 3.9 : Test de Z pour la séparabilité des classifications originale et Vérification.....	62
Tableau 3.10 : Tests de Student en fonction de la taille de fenêtre texturale.....	68
Tableau 3.11 : Position (en pixels) du point d'inflexion des semi-variogrammes.....	71
Tableau 3.12 : Matrices de confusions.....	76-77

Liste des figures

Fig. 1.1 : Fonctionnement des matrices de co-occurrences (MCO).....	10
Fig. 1.2 : Combinaison de bandes pour une MCO généralisée.....	17
Fig. 2.1 : Territoire de la Communauté Métropolitaine de Montréal et le site à l'étude.....	21
Fig. 2.2 : Courbes de réflectances des matériaux typiques de surface et bandes spectrales de SPOT-5.....	22
Fig. 2.3 : Image SPOT-5 utilisée avec ses bandes spectrales.....	24
Fig. 2.4 : Vérité terrain obtenue par photo-interprétation.....	25
Fig. 2.5 : Histogramme des valeurs numériques des bandes spectrales.....	28
Fig. 2.6 : Schéma Méthodologique.....	31
Fig. 2.7 : Interface de l'algorithme Texel.....	33
Fig. 2.8 : Étapes des calculs du classificateur par maximum de vraisemblance.....	35
Fig. 2.9 : Paramètres types d'un semi-variogramme.....	39
Fig. 3.1 : Image SPOT-5 utilisée avec ses bandes spectrales.....	42
Fig. 3.2 : Corrélation et Écart-type.....	43
Fig. 3.3 : Homogénéité et Contraste.....	44
Fig. 3.4 : Moyenne et Probabilité maximale (Pmax).....	45
Fig. 3.5: Entropie et Énergie.....	46
Fig. 3.6: Pour chaque type de classe on trouve les meilleures combinaisons possibles.....	48
Fig. 3.7 : Exactitudes de classification en fonction de l'orientation et du pas.....	58
Fig. 3.8 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre Texturale.....	60
Fig. 3.9 : Variations du coefficient Kappa des classifications en fonction de la taille de la Fenêtre.....	61
Fig. 3.10 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre de calcul, classes (a) eau, (b) ombre et (c) nuage.....	63
Fig. 3.11 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre de calcul, classes (a) commerciale/industrielle (b) résidentielle haute densité (HD) et (c) résidentielle basse densité (BD)	65
Fig. 3.12 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre de calcul, classes (a) agricole, (b) golf/gazon et (c) forêt.....	67

Fig. 3.13 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre de calcul, pour toutes les classes.....68

Fig. 3.14 : Semi-variogrammes des profils diagonaux pour; toute l'image, agricole et forêt pour les 4 bandes SPOT-5.....70

Fig.3.15 : Classification par les textures grises avec une fenêtre 5*5 orientation 1,1.....72

Fig.3.16 : Classification par les textures couleurs avec une fenêtre 5*5 orientation 1,1.....72

Fig.3.17 : Classification par textures grises avec fenêtre de 11*11 orientation 1,1.....73

Fig. 3.18 : Classification par textures couleurs avec fenêtre de 11*11 orientation 1,1.....73

Fig. 3.19: Vérité terrain obtenue par photo-interprétation74

Fig. 3.20 : Classification non supervisée, par Fuzzy K-means, des signatures texturales grise (gauche) et couleur (droite) selon fenêtre de 5*5, 9 classes et 10 itérations....78

Fig. 3.21 : Classification supervisée des 4 bandes de SPOT multispectrale, sans textures..79

Remerciements :

Merci à mon directeur, M. Cavayas, ainsi qu'à mes collègues du laboratoire de télédétection, pour leur excellent support moral, technique et académique.

Introduction

Les recherches sur la classification automatisée et la cartographie des occupations du sol à partir d'images satellitales multispectrales datent d'aussi longtemps que l'ère satellitale elle-même. Les techniques de classification ont été largement diversifiées au fil des ans par l'introduction des nouveaux concepts d'analyse de données (réseaux de neurones, classificateurs flous, etc.) provenant des disciplines autres que la reconnaissance des formes pratiquée aux débuts de la télédétection numérique. L'évolution de la capacité des ordinateurs à gérer des quantités de données de plus en plus considérables est un facteur important à la base de cette diversification. Pourtant, il y a encore et toujours place à des nouveaux concepts et techniques. En effet, avec le raffinement des résolutions spatiales, les images multispectrales nous donnent accès à des informations de plus en plus détaillées, mais, incidemment, de plus en plus complexes à extraire par voie automatique. Cela se traduit concrètement par une demande élevée pour des procédés de classification capables de bien fonctionner, malgré cette hausse de la complexité, tout en fournissant une information thématique appropriée (Jensen, 2007)

Les méthodes de classification standard mises de l'avant dans les années 1970 et 1980 font appel, en premier lieu, aux signatures spectrales des objets (la couleur des objets dans un sens large). Cependant, il est bien connu que plus la résolution spatiale au sol devient fine, plus la texture des objets devient un élément important pour leur différenciation/classification. Ainsi, depuis maintenant plusieurs années, des études prônent l'usage de l'information texturale conjointement ou non avec l'information spectrale pour améliorer les résultats de classification des images multispectrales de résolution moyenne à grande (entre 20 m et 1m).

Pour extraire cette information d'une image multispectrale, plusieurs méthodes ont été proposées. Nous pouvons les regrouper en deux catégories générales : celles où la texture est « mesurée » dans chaque bande individuelle et celles où la texture est « mesurée » sur deux ou plusieurs bandes conjointement. La comparaison de ces deux méthodes sera omniprésente tout au long de cet ouvrage. Nous parlerons alors des *textures*

grises pour signifier celles extraites d'une seule ou plusieurs bandes considérées individuellement et des *textures couleurs* pour signifier celles extraites du traitement conjoint de deux ou plusieurs bandes d'une image multispectrale.

Les recherches en télédétection

L'extraction des textures grises, de par sa faible demande en ressources informatiques, représente encore aujourd'hui l'approche privilégiée en télédétection, et ce malgré le fait que plusieurs auteurs (Rosenfeld et Kak, 1982; Estes *et al.*, 1983; entre autres) parlaient déjà dans les années 1980 de l'intérêt d'une analyse conjointe 'couleur' des multiples bandes. Il est à noter que les techniques d'extraction de l'information texturale sont extrêmement nombreuses. Tuceryan et Jain (1998), Petrou et Sevilla (2006) ainsi que Mihrmendi *et al.* (2008) en présentent une revue exhaustive. Ces techniques vont des très simples comme celles fondées sur les statistiques de 1^{er} ordre (variance, asymétrie, entropie,...) calculées à partir des valeurs numériques dans le voisinage d'un pixel quelconque de l'image aux plus sophistiquées impliquant des analyses des fréquences spatiales (Fourier, Gabor, ondelettes) ou des modèles de texture (champs aléatoires, fractales). Cependant, parmi cette pléiade de méthodes, les plus populaires sont celles fondées sur la description statistique des variations conjointes des valeurs des pixels avoisinants (statistiques de 2^e ordre) et parmi celles-ci la plus employée est la méthode basée sur les matrices de co-occurrences (MCO) des niveaux de gris proposée par Haralick (1973).

Afin d'introduire l'information texturale dans une procédure de classification d'images, le plus souvent, une seule bande spectrale parmi celles disponibles est choisie pour son contraste élevé. Une des techniques d'extraction des textures grises est alors employée afin de générer une ou plusieurs images (paramètres) de texture. Ces images sont par la suite introduites dans la procédure de classification au même titre que les bandes spectrales d'origine. L'utilité de l'ajout de la dimension spatiale, par le biais des textures

grises, pour la segmentation du territoire par imagerie multispectrale, a été démontrée par de nombreuses études. Parmi les premières études dans ce domaine on peut noter celle de Gong et Howarth (1990). Les auteurs utilisent une mesure de densité locale d'arrêtes appliquée à la bande spectrale verte (SPOT 20m) pour générer une image de texture. Cette image ainsi que les bandes spectrales d'origine sont alors introduites dans un classificateur. Ils démontrent que l'ajout de l'image texturale se traduit par une augmentation de l'exactitude de classification d'un milieu périurbain de 77% à 81%. Parmi les études les plus récentes nous pouvons citer celles de Herold *et al.* (2002, 2003). Ces auteurs utilisent le canal du proche infrarouge d'une image IKONOS (4 m de résolution spatiale) pour créer des canaux texturaux en se basant sur un grand nombre de traits caractéristiques issus des matrices de co-occurrences (énergie, entropie, homogénéité,...) ainsi que des métriques spatiales. Ils commencent par une classification grossière, par la signature spectrale, pour ensuite raffiner les résultats par une classification selon les canaux texturaux les plus pertinents (principe que nous appellerons « signature texturale » dans cet ouvrage). Ces nouveaux résultats sont alors soumis à des analyses spatiales. Leur but est de cartographier les utilisations du sol (catégories des 2^e et 3^e niveaux de la taxinomie d'Anderson *et al.*, 1976) habituellement inatteignables par classification des signatures spectrales seules. Étant donné le détail thématique recherché, l'exactitude globale de leur carte, évaluée à 76%, est très intéressante. Ils arrivent cependant à la conclusion que les canaux texturaux issus de l'analyse de la bande du proche infrarouge n'apportent qu'une information complémentaire et que ce sont surtout les métriques spatiales qui sont les plus utiles à la classification des utilisations du sol.

Il existe, évidemment, une grande variété d'approches dans l'utilisation des textures grises dont les plus notables sont : a) celles utilisant une ou des images de texture créées à partir d'une image panchromatique de plus fine résolution spatiale que les images multispectrales associées (ou des canaux dérivés des ces dernières tels les indices de végétation) pour une classification (voir par exemple, Ünsalan et Boyer, 2004) et b) celles où l'information texturale est extraite d'une image multispectrale classifiée, une sorte de

« texture thématique ». Par exemple, Fukue *et al.* (1998) utilisent les MCO sur les pixels déjà classifiés comme base pour une classification supplémentaire, par réseau de neurones.

Depuis quelques années, on observe un changement dans la façon d'utiliser l'information texturale en télédétection en introduisant d'une manière ou d'une autre le concept de la texture multidimensionnelle (Petrou et Sevilla, 2006; Mirhmendi *et al.*, 2008). L'amélioration des performances informatiques n'est pas étrangère à ce changement. Parmi les premières études introduisant ce concept de la texture multidimensionnelle nous pouvons citer celle de Hepner *et al.* (1990) qui utilisent des réseaux de neurones pour analyser conjointement l'information spectrale du pixel et de son voisinage local (fenêtre 3*3), pour toutes les bandes spectrales disponibles. Parmi les études les plus récentes nous pouvons mentionner celles de : a) Fiset et Cavayas (1997) qui ont utilisé la méthode de Hepner *et al.* (1990) pour l'extraction du réseau routier d'un secteur péri-urbain, à partir d'images SPOT multispectrales (20m), b) Dony *et al.* (1995) qui ont utilisé des MCO calculées sur des images multitemporelles pour générer des images de texture introduites par la suite à un réseau neuronal pour une classification multitemporelle; et c) Coburn *et al.* (2004) qui ont introduit des images des textures générées avec des dimensions variables de la fenêtre de calcul dans leur classification.

Les recherches en traitement d'images

Parallèlement à ces recherches en télédétection, des recherches dans le domaine du traitement d'images couleurs (imagerie médicale et industrielle, etc.) poursuivent le même objectif que les études en télédétection, c'est-à-dire l'intégration de la texture dans le processus de reconnaissance automatique des objets. Le terme « texture couleur » y est de plus en plus utilisé pour caractériser ces techniques. Palm (2004) les classifie selon trois catégories : parallèles, intégratives et séquentielles. Les approches parallèle et séquentielle s'apparentent d'une manière ou d'une autre aux approches utilisées en télédétection. À titre d'exemple, une approche parallèle consisterait à changer l'espace couleur (par exemple

intensité-nuance-saturation), puis utiliser le canal d'intensité pour créer des canaux texturaux et par la suite classifier les bandes spectrales et ces canaux texturaux. Dans l'approche séquentielle les éléments structurants d'une texture sont considérés des pixels de couleur homogène et l'analyse texturale est appliquée sur ces pixels. Dans l'approche intégrative on cherche à utiliser de façon conjointe les informations spectrales et texturales. Palm sépare l'approche intégrative en deux sous-catégories. La première sous-catégorie comprend des méthodes qui visent à l'extraction de l'information texturale à partir de chacun des trois canaux (RGB) disponibles, séparément. Les images de texture ainsi générées (« signature texturale ») sont par la suite utilisées conjointement comme intrants dans un algorithme de classification. C'est l'approche que nous avons appelée précédemment « textures grises ». La deuxième sous-catégorie de Palm est une autre variante du concept, très large, de la texture multidimensionnelle. Cependant, ce qui est unique ici est que l'extraction de l'information texturale se fait en traitant conjointement deux (ou plusieurs) bandes spectrales. C'est l'approche que nous avons définie précédemment comme « textures couleurs ». Diverses techniques utilisées pour l'extraction de l'information texturale sur une seule bande spectrale peuvent s'adapter à cette analyse conjointe. Par exemple, Arvis *et al.* (2004) utilisent les matrices de co-occurrences dites généralisées pour générer des images de texture par paire de bandes spectrales d'une image couleur (Bleu-vert, bleu-rouge, vert-rouge).

C'est l'approche intégrative avec ses deux sous-catégories, tel que spécifiées par Palm (2004), et la méthode des matrices de co-occurrences (généralisées ou non) qui seront au cœur de cette recherche. D'une part, cette façon de prendre en considération conjointement spectre et texture n'a été que rarement étudiée en télédétection multispectrale, notamment les « textures couleurs ». En effet, la revue de littérature n'a permis d'identifier qu'une seule étude, celle de Vansteenkse *et al.* (2004) utilisant les matrices de co-occurrences généralisées avec une image IKONOS couleur (trois bandes spectrales). D'autre part, le présent projet mettra l'accent sur une analyse plus poussée de ce concept de la signature texturale et cela dans l'optique de la hausse de la densité

d'information dans les images texturales. Ceci est selon nous nécessaire pour répondre adéquatement à la demande formulée par Jensen (2007) et mentionnée au début de cette introduction pour des procédés de classification capables de bien fonctionner, malgré la hausse de la complexité des images, tout en fournissant une information thématique appropriée. La création d'une signature texturale couleur qui sera comparée à une signature texturale grise, constituées toutes deux d'éléments optimisant la séparabilité des diverses classes d'occupation du sol, constitue une approche qui permettra de mettre en lumière l'apport de l'intégration des éléments spectraux et texturaux grâce aux MCO. Cette façon de faire, plutôt unique, avec les images multispectrales contribuera à l'avancement des connaissances dans ce domaine de grand intérêt en télédétection qui est l'extraction de l'information thématique par voie automatisée.

Structure du mémoire :

Ce mémoire se positionne dans le domaine de l'étude des textures couleur par MCO et se divise en trois chapitres :

1) La problématique de la création des signatures texturales par matrices de co-occurrences : Mis à part l'introduction où nous avons présenté une vision très générale de l'évolution des textures, ainsi que la position des textures couleurs dans la nomenclature et la théorie texturale actuelle, ce chapitre se concentrera sur les matrices de co-occurrences, leur généralisation pour extraire les textures couleurs, ainsi que leur utilisation pour la formation des signatures texturales des objets.

2) La méthodologie : Il y sera présenté le site à l'étude, les données utilisées, les étapes et les techniques utilisées pour parvenir à la création des signatures texturales optimisées par classe d'occupations du sol, ainsi que pour la comparaison des classifications.

3) Résultats et discussion : Les résultats obtenus y seront analysés et discutés afin de faire ressortir les éléments clés de cette expérimentation.

1-Matrices de co-occurrences et signatures texturales: théorie et problématique

Introduction aux textures

Depuis l'avènement de l'imagerie numérique en télédétection un des objectifs principaux a toujours été la cartographie automatisée des classes d'occupation / utilisation du sol. À cette fin, des techniques ont été développées, qui pour la plupart tentent d'imiter le procédé d'interprétation de l'œil et du cerveau humain. Les textures qui ont vite été reconnues comme un élément majeur sur lequel un interprète peut s'appuyer lors du procédé de distinction des objets/thématiques (Estes et al, 1983), n'ont cessé d'évoluer depuis et constituent un domaine extrêmement vaste. Voici une définition générale du concept : «La production de groupements similaires est importante dans la perception des textures visuelles. Ce sont des agencements visuels de formes complexes composés d'entités ou de sous-agencements qui ont des caractéristiques telles : la brillance, la couleur, la taille, l'orientation. Une texture est donc un regroupement de similitudes» (traduction de : Rosenfeld et Kak, vol #1, p 65)

En imagerie, une classification plus ou moins précise, selon les détails thématiques recherchés (Caloz et Collet, 2001; p.15), repose sur la séparabilité des valeurs numériques des pixels. Ces valeurs numériques peuvent être issues de traitements associés aux «mesures/intensités» de textures, dont le but général est d'offrir des métriques capables de différencier les objets sur les images, et ce de la façon la plus précise possible. Or, la précision effective dépend de plusieurs facteurs, notamment, les résolutions spectrales et spatiales des images utilisées. Ainsi, une image SPOT-5 multispectrale (10 m) comme celle employée dans notre recherche (chapitre 2) devrait fournir la résolution appropriée à la cartographie des classes d'occupation du sol à un niveau thématique plutôt général :

résidentiel, industriel/commercial, agriculture, etc. (niveau II du système de taxinomie du USGS; Jensen, 2007, p 447).

Cependant, tel que mentionné en introduction, il existe un très grand nombre d'approches et de types de textures pouvant être associées au concept de la « signature texturale » des objets. Le tableau 1.1 présente un résumé non exhaustif des publications consultées dans le cadre de cette recherche en les classant selon la technique employée et, dans le cas des textures couleurs par matrices de co-occurrences (MCO), selon la classification de Palm (2004) dont il a été fait mention en introduction. Bien que les recherches de la section «Autres que MCO» du tableau 1.1 aient plus ou moins inspiré la méthodologie de cette recherche, seule l'approche fondée sur les MCO sera étudiée. L'approche par MCO est un standard reconnu pour l'extraction des textures en imagerie multispectrale. De plus, sa forte versatilité, permet une adaptation facile au domaine des textures couleurs bi-bandes de ce projet.

Tableau 1.1 : Récapitulatif des principales techniques d'utilisation des textures et articles de référence/auteurs associés

Textures grises par :	Approches classiques		Approches récentes
	Avant 2000		Après 2000
Matrices De Co-occurrences	Haralick (1973 et 1979). Unser (1986) Hepner <i>et al.</i> 1990 Ojala <i>et al.</i> (1996) Dedieu <i>et al.</i> (1997)		Shaban et Dikshit (2001) Zhang Q. <i>et al.</i> (2002, 2003) Arivazhagan et Ganesan (2003). Dell'acqua, Gamba, (2003a,b) Bugnet <i>et al.</i> (2003) Fiset (2006)
Textures couleurs par :	Approches Parallèles	Approches Séquentielles	Approches Intégratives
Matrices De Co-occurrences	Smith et Chang (1996) Ryherd et Woodcock (1996) Dubuisson-Jolly et Gupta (2000) Junqing <i>et al.</i> (2002)	Chen et Chen (2002) Aujol et Kang (2006)	Palm (2004) Arvis <i>et al.</i> (2004) Vansteenkiste <i>et al.</i> (2004)
Autres que MCO	Auteurs		
Image 'tower'	Mirmehdi et Petrou (2000)		
Séparation de texture/couleur	Drimbareanet Whelan (2001), Mäenpää et Pietikäinen (2004)		
Semi-variogramme,	Dekker (2003).		
Écologie du paysage	Frohn (1998)		
Spectre de texture	Wang L. (1994)		
Multi-variogramme	Peijun Li <i>et al.</i> (2009)		
Patrons locaux binaires	Wang A. <i>et al.</i> (2010)		
Dimensions fractales	Ma W.Y. <i>et al.</i> (1997)		
Gabor	Jain et Farrokhnia (1991), Hoang <i>et al.</i> (2005)		
Wavelet (ondelettes)	Laine et Fan (1993), Zhu et Yang (1998), Wouwer <i>et al.</i> (1999)		

1.1-Les matrices de co-occurrences : bref rappel

Les matrices de co-occurrences (MCO) de Haralick (1973,1979) calculées sur des images monobandes sont des histogrammes 2D présentant les fréquences d'occurrence conjointe des paires des valeurs numériques des pixels. La MCO est fonction de la probabilité de co-occurrence des intensités des pixels i,j pour un pas d'échantillonnage (rayon r) ainsi que de l'orientation choisie, soit $P(i,j,r,\theta)$. Le calcul étant basé sur un espace matriciel, le pas est exprimé en pixels et l'orientation est limitée à quatre directions (0° , 45° , 90° et 135°) pour un pas de 1. La figure 1.1 montre un exemple simplifié de calcul d'une matrice de co-occurrences. Habituellement en télédétection, où l'on s'intéresse aux propriétés locales des pixels, une MCO distincte est calculée pour une fenêtre donnée autour de chaque pixel constituant l'image. Des métriques sont alors calculées en tenant compte de la distribution des fréquences de la MCO. Ces métriques sont attribuées aux pixels examinés et des images de 'texture' sont ainsi créées.

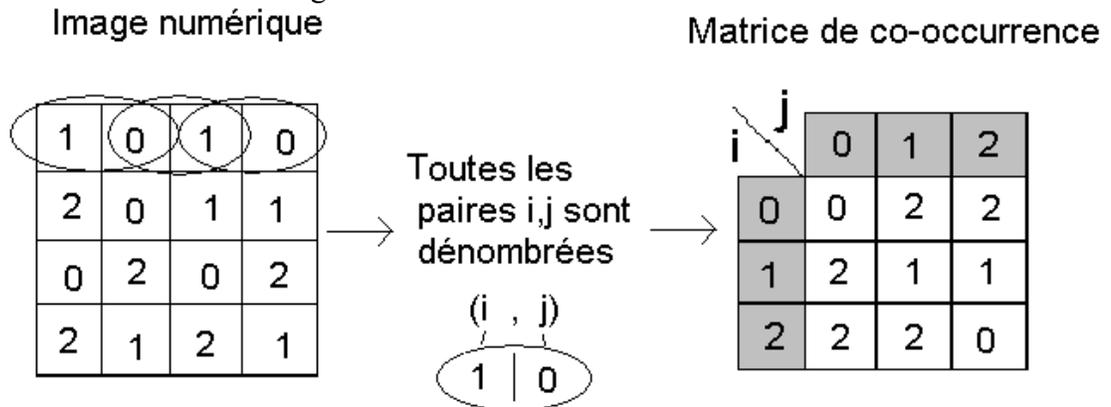


Fig. 1.1 : Fonctionnement des matrices de co-occurrences (MCO)

Note : la MCO varie en fonction de $P(i,j,r,\theta)$.

Le tableau 1.2 présente les métriques (mesures) les plus utilisées parmi les 14, présentées par Haralick (1973) pouvant être calculées à partir de ces MCO. Ce sont en fait des statistiques de 2^e ordre qui sont utilisées comme paramètres/mesures de texture. Dans ce tableau, ces huit mesures sont regroupées avec leur inverse mathématique.

Tableau 1.2 : Huit mesures de texture extractibles des MCO regroupées selon leur ressemblance mathématique (Haralick, 1973).	
Mesure texturale	Description
Contraste = $\sum_i \sum_j (i - j)^2 * \hat{P}(i, j)$ Homogénéité= $\sum_i \sum_j \frac{1}{1+(i-j)^2} * \hat{P}(i, j)$	Le contraste indique la concentration des paires de valeurs autour de la diagonale centrale de la MCO. Le degré d'éloignement est mesuré par le carré des différences des valeurs i et j. Ainsi plus les paires de pixels ont des valeurs dissemblables plus le contraste devient important. L'homogénéité indique avec des fortes valeurs l'inverse du contraste. Plus les valeurs de pixels se ressemblent plus forte est l'homogénéité.
Moyenne= $\sum_i \sum_j i * \hat{P}(i, j)$ Probabilité Maximale= $Max (\hat{P}(i, j))$	La moyenne calcule la probabilité moyenne des co-occurrences de la MCO, tandis que la probabilité maximale (Pmax) identifie uniquement la paire (i, j) la plus probable. Cependant Pmax est désavantagé si la P(i,j) identifiée ne correspond pas à un mode nettement prévalent.
Énergie= $\sum_i \sum_j \hat{P}(i, j)^2$ Entropie= $\sum_i \sum_j -\hat{P}(i, j) * \log(\hat{P}(i, j))$	Ces deux mesures indiquent le degré d'occupation des MCO. Dans un cas extrême où toutes les paires possibles de valeurs se trouvent sur l'image, l'entropie serait maximale tandis que l'énergie serait minimale. Aux antipodes, une image ayant une seule paire de valeurs aurait une énergie maximale tandis que l'entropie serait minimale.
Écart-type= $\sqrt{\sum_i \sum_j (i - \mu)^2 * \hat{P}(i, j)}$ Corrélation= $\sum_i \sum_j (i - \mu) * (j - \mu) * \hat{P}(i, j) / \sigma^2$	L'écart-type est une mesure de l'écart d'une distribution par rapport à la moyenne (se situant, à la diagonale de la MCO) tandis que la corrélation est une mesure du taux de convergence des probabilités, se rapprochant ainsi de la diagonale de la MCO.
i et j représentent les valeurs numériques selon les lignes et les colonnes d'une MCO et P(i,j) la fréquence d'occurrence relative de la paire de valeurs i,j	

Cette méthode, via ses différents types de mesures texturales et sa versatilité (variations du pas, de l'orientation et de la fenêtre), constitue un outil de génération d'images de texture aisément adaptable au contexte de l'image analysée. Comme nous le verrons à la section 1.2, les MCO peuvent aussi être généralisées afin de générer des images de textures couleurs, en intégrant plusieurs bandes. Cependant, leur utilisation avec les images de télédétection a mis en évidence une série de problèmes dont les principaux sont :

- 1) Le choix de r et θ
- 2) La taille de la fenêtre du calcul
- 3) La redondance des mesures proposées par Haralick
- 4) La distribution statistique des paramètres de texture.
- 5) Le volume de données et le temps de calcul

Ces problèmes referont surface tout au long de cette étude. Cela est d'autant plus vrai lorsqu'on augmente le nombre de dimensions d'informations, augmentant grandement le volume des données à traiter et le temps de traitement, comme c'est le cas pour les textures couleurs.

Définition du pas et de l'orientation d'échantillonnage

Le pas d'échantillonnage est un élément crucial car son choix approprié peut bien révéler l'échelle de texture des objets (fine ou grossière). Il y a bien sûr une limite inférieure qui est celle de 1 pixel ainsi qu'une limite supérieure fonction de la taille de la fenêtre choisie. Avec des images multispectrales de résolution spatiale entre 10 m et 20 m, un pas de 1 à 2 pixels est souvent choisi. Quant à l'orientation, plusieurs auteurs font l'hypothèse d'une texture isotrope (indépendante de l'orientation) et utilisent comme paramètre de texture, la moyenne des paramètres calculés dans les quatre directions. Ceci diminue ainsi d'un facteur de 4 le nombre d'images de texture à analyser (Vansdteenkiste *et al.*, 2004). Dans le cas des images à analyser avec des objets créant des ombres (e.g. arbres,

bâtiments) une solution qui peut maximiser la sensibilité des paramètres aux variations de texture est de choisir l'orientation qui est la plus rapprochée de celle de la source d'éclairage (Bugnet 2002; Fiset 2006). Dans le cas des images multispectrales satellitaires, elles sont acquises pour la plupart entre 10h et 11h heure locale. Dans l'hémisphère nord et à des latitudes moyennes à cette heure le soleil se trouve au Sud-Est, ainsi une orientation d'échantillonnage de 135^0 (1,1) est tout à fait indiquée.

Taille de la fenêtre de calcul

La taille de la fenêtre utilisée est un autre élément crucial. Le bon choix exige de bien connaître la taille des objets recherchés et même si cela était possible, comme Coburn *et al.* (2004) l'ont démontré, une seule taille est rarement suffisante pour capter les subtilités des textures de tous les objets. Ainsi, ce projet présentera des analyses s'étendant sur de multiples tailles de fenêtres texturales.

Redondance des mesures

Bien que chaque mesure de texture fasse ressortir des caractéristiques particulières des objets, elles sont souvent corrélées entre elles. Cependant, il est difficile de connaître *a priori* l'utilité de chacune car cette utilité est fortement dépendante du contexte (type d'images analysées et caractéristiques des objets présents). De plus, d'une bande spectrale à l'autre, l'utilité d'une mesure peut ne pas être la même. De ces faits, il a été décidé de tester les huit mesures figurant au tableau 1.2 qui sont les plus souvent mentionnées dans la littérature (Unser 1986, Parker 1997, Bugnet 2002, Fiset 2006).

Distribution statistique des paramètres

Les méthodes de classification d'images sont nombreuses. Celles qui sont les plus utilisées à l'heure actuelle sont celles du type dirigée et paramétrique. Pour appliquer ces méthodes dans le cas d'une classification d'une image multidimensionnelle la distribution de probabilité associée à chaque classe est la multinormale. Cependant la question de la distribution statistique de ces mesures de texture n'est pas souvent abordée dans la littérature. Dans cette recherche cette question demeurera ouverte.

Volume de données et temps de calcul

Les images multispectrales, tel SPOT-5, sont souvent quantifiées en 8 bits (256 niveaux de gris), bien que la tendance actuelle soit vers les 12 bits (exemple images IKONOS). Or, l'utilisation des MCO 2D sur le l'imagerie 8bits requiert la création des matrices par pixel de dimension 256 x 256. En ajoutant la création des huit images texturales, on obtient un traitement relativement lourd. La principale source d'économie consiste donc à modifier le nombre de bits de gris associés à chaque bande spectrale. Il y a aussi un autre problème lié aux matrices de grande taille. Plus la taille est élevée, plus grande est la probabilité que la fréquence d'occurrence d'une paire quelconque de valeurs soit très faible voir même nulle. On obtiendrait ainsi une MCO avec des fréquences d'occurrence ne dépassant quelques dixièmes voir centièmes de 1%. Pour ces raisons les matrices de co-occurrences sont souvent calculées en compressant l'échelle de gris à 6, 5 et même 4 bits (Vansteenskiste *et al.* 2004, Wang A. *et al.* 2010). Cependant, bien que cette compression allège le traitement, le danger est de détruire l'information spectrale. Dans le cas présent, comme on le verra dans le chapitre 2, les images ont été traitées directement en 8 bits.

Quant au temps de calcul, certaines solutions informatiques ont été proposées dont la plus utilisée est l'algorithme d'Unser (1986), présenté par Parker (1997) sous la forme d'un algorithme programmé en langage C. Compte tenu du nombre élevé d'images à produire (chapitre 2), c'est cette approche qui a été jugée la plus efficace, en terme de temps, quant aux besoins de ce projet. À cet effet, voici les bases de l'approche d'Unser (1986).

Il s'agit d'une méthode d'approximation des matrices de co-occurrences par deux « vecteurs » : l'histogramme des fréquences de la somme des paires des valeurs et l'histogramme des fréquences des différences de ces mêmes paires. Selon Bugnet *et al.* (2003, p.758) : « Ces histogrammes définissent les fonctions de probabilité de premier ordre suivant les axes principaux de la MCO. Utilisés conjointement, ils possèdent une capacité presque identique à la MCO pour discriminer les différentes textures d'une image. Pour une image de 256 niveaux de gris, les sommes peuvent prendre une valeur allant de 0 à 510, tandis que les différences peuvent prendre une valeur allant de -255 à +255. »

Le mode de fonctionnement est similaire à celui des matrices de co-occurrences puisque il est toujours fonction de i, j, r, θ et ce pour une fenêtre mobile appliquée à tous les pixels. Cependant, c'est la somme et la différence de leurs valeurs qui sont calculées et comptabilisées pour former les deux histogrammes unidimensionnels. L'analyse de ces histogrammes, comme Unser (1986) l'a démontré, permet de bien s'approcher des valeurs de plusieurs des paramètres de texture proposés par Haralick. Le tableau 1.3 présente les formules de calcul selon cette méthode des huit paramètres de texture retenus au tableau 1.2.

Tableau 1.3 : Calcul des paramètres de texture selon la méthode d'Unser (1986)

$\text{Homogénéité} = \sum_{j=1}^{2N-1} \frac{1}{1+j^2} \cdot f_d(j)$	$\text{Contraste} = \sum_{j=1}^{2N-1} (j^2 \cdot f_d(j))$
$\text{Énergie} = \sum_{i=1}^{2N-1} (f_s(i) \cdot f_s(i)) \cdot \sum_{j=1}^{2N-1} (f_d(j) \cdot f_d(j))$	$\text{Moyenne} = \frac{1}{2} \sum_{i=1}^{2N-1} i \cdot f_s(i)$
$\text{Corrélation} = \frac{1}{2} \left(\sum_{i=1}^{2N-1} (i - 2\mu)^2 \cdot f_s(i) - \sum_{j=1}^{2N-1} j^2 \cdot f_d(j) \right)$	$P_{\max} = \text{Max} (f_s(i))$
$\text{Entropie} = - \sum_{i=1}^{2N-1} (\log(f_s(i)) \cdot f_s(i)) - \sum_{j=1}^{2N-1} (\log(f_d(j)) \cdot f_d(j))$	
$\text{Écart - type} = \sqrt{\frac{1}{2} \left(\sum_{i=1}^{2N-1} ((i - 2\mu)^2 \cdot f_s(i)) + \sum_{j=1}^{2N-1} (j^2 \cdot f_d(j)) \right)}$	
<p>N est le nombre de niveau de gris des images examinées, f_s et f_d sont les vecteurs des fréquences d'occurrence des sommes et des différences des niveaux de gris, i et j sont les indices de ces vecteurs et μ est la moyenne des indices associés.</p>	

1.2-Les matrices de co-occurrences généralisées

La généralisation des matrices de co-occurrences pour mesurer les textures couleurs se fait habituellement en traitant simultanément deux bandes spectrales d'une image multidimensionnelle (voir par exemple Arvis *et al.* 2004). Ainsi, une paire de pixels est toujours définie selon un pas et une orientation spécifique, non pas dans une seule bande spectrale mais dans deux bandes spectrales différentes. À titre d'exemple, avec une image couleur (RGB) trois matrices de co-occurrences généralisées peuvent être formées : RG, RB, GB. Nous pouvons étendre ce concept à des images multispectrales en tenant compte

de toutes les combinaisons possibles. La figure 1.2 schématise cette technique avec une image multispectrale à n bandes spectrales en mettant l'accent sur le cas d'une image SPOT-5, comme celle utilisée dans cette étude, avec quatre bandes spectrales : vert (V), rouge (R), proche infrarouge (PIR) et moyen infrarouge (MIR). Les paires de bandes spectrales le long de la diagonale principale de ce tableau représentent évidemment les textures grises extraites des matrices de co-occurrences standard.

	V	R	PIR	MIR	...	n
V	VV	VR	VPIR	VMIR	V...	Vn
R		RR	RPIR	RMIR	R...	Rn
PIR			PIRPIR	PIRMIR	PIR...	PIRn
MIR				MIRMIR	MIR...	MIRn
...				n
n						nn

Bandes de SPOT5
 Symétrique à

Fig. 1.2 : Combinaison de bandes pour une MCO généralisée.

Tel que mentionné en introduction, rares sont les recherches avec des MCO généralisées. Dans le cas d'images multispectrales de télédétection, l'étude de Vansteenkiste *et al.* (2004) avec des images IKONOS à trois bandes (bleu, vert, rouge) est la seule que nous avons pu repérer dans la littérature. Vansteenkiste *et al.* (2004) présentent des résultats préliminaires à partir d'une méthode par MCO. Ces résultats ne permettent pas de conclure sur l'utilité des textures couleurs par MCO généralisées pour une classification plus précise que celle obtenue par l'approche traditionnelle. Toutefois, les auteurs signalent qu'avec des recherches plus poussées pour trouver les bons paramètres de calculs des MCO généralisées, des hauts taux de succès des classifications sont attendus. Ainsi, la recherche d'une optimisation des paramètres $P(i,j,r,\theta)$, présentés en section 1.1, nécessite un travail supplémentaire qui est abordé dans ce mémoire.

1.3- Formation des signatures texturales

Une signature texturale représente l'équivalent d'une signature spectrale typique de l'imagerie multispectrale, mais intégrant la dimension spatiale par le biais de la texture. À l'encontre d'une signature spectrale formée par des mesures selon un seul axe, celui du spectre, la signature texturale pourrait être constituée d'un nombre quasi infini de combinaisons : bandes spectrales/ mesures texturales.

Signature texturale: $\mathbf{m}_1(\text{texture } 1), \mathbf{m}_2(\text{tex. } 2), \dots, \mathbf{m}_n(\text{tex. } n)$

Où- $\mathbf{m}(\text{texture})$ est une matrice image résultante d'une texture donnée.

- texture n est grise ou couleur et optimise la classe n

Dans ce projet, l'approche des matrices de co-occurrences par leur approximation selon les vecteurs d'Unser a été choisie pour la formation des signatures texturales. La figure 1.2 montre les deux utilisations possibles des MCO. À titre d'exemple, si on maintient tout les paramètres de calcul des vecteurs d'Unser constants (pas, orientation, fenêtre) et en utilisant les 4 bandes de SPOT-5 on aura :

a) Textures grises : les signatures texturales auront jusqu'à 32 dimensions :

8 mesures de texture x 4 bandes spectrales

b) Textures couleurs : les signatures texturales auront jusqu'à 48 dimensions :

8 mesures x 6 paires de bandes spectrales.

Or, les textures sont fonction de $P(i,j,r,\theta)$ et varient aussi selon la taille de fenêtre de calcul utilisée. Cela ajoute une dimensionnalité quasi illimitée. Par exemple, l'utilisation d'une fenêtre de calcul allant de 3 à 15 pixels (soit sept tailles de fenêtres) ainsi que d'un θ et d'un r totalisant 12 nouvelles avenues de calculs (fig. 3.8), on arrive, pour la texture couleur, à $48*7*12 = 4032$ possibilités.

Il s'agit d'une quantité de données à produire relativement importante. Or, si on fait varier davantage le pas et/ou l'orientation et/ou la fenêtre de calcul et/ou le type de texture pour un nombre de bandes spectrales n , on peut augmenter à l'infini la dimensionnalité des signatures texturales autant grises que couleurs. Pour maintenir cette dimensionnalité à un niveau acceptable pour cette recherche nous avons décidé de garder le pas et l'orientation fixe pour des raisons expliquées précédemment et de ne faire varier que la taille de la fenêtre de calcul qui, selon Coburn *et al.* (2004), a un impact très important sur la sensibilité des mesures de texture. Cependant, un essai sur l'effet de l'orientation et un pas de maximum 2, sera tout de même présenté, en considérant uniquement l'exactitude générale, afin de déterminer si la texture couleur est affectée différemment par r et θ .

La question que nous posons dans cette recherche est si cette augmentation de la densité de l'information texturale apportée par les textures couleurs a un impact important sur la qualité des classifications. Puisque cette augmentation de la densité est accompagnée par une augmentation substantielle de la dimensionnalité des signatures texturales, la question peut se poser autrement : est-ce les gains en précision des classifications par rapport aux textures grises valent l'augmentation du volume des données et des calculs? La méthodologie mise de l'avant pour examiner cette question, qui consiste en la comparaison de deux signatures texturales (grise et couleur) est décrite en détail dans le chapitre 2.

1.4-Objectifs et hypothèses

Cette recherche comporte deux objectifs intimement liés. Le premier consistera à évaluer/quantifier l'intérêt de l'utilisation des textures couleurs, par rapport aux textures grises, quant à l'amélioration de la qualité d'une classification d'images multispectrales, et de là, tirer des conclusions quant à sa pertinence dans le cas de la cartographie des occupations des sols. Le second objectif consiste en l'élaboration d'une méthodologie permettant la combinaison des textures grises ou couleurs, et ce, sous la forme de deux signatures texturales optimisées (l'une composée uniquement de textures grises et l'autre de textures couleurs). Cela permettra de répondre au premier objectif tout en visant un pourcentage d'exactitude des classifications intéressant.

Pour atteindre ces objectifs, les étapes clés sont les suivantes :

- Isoler les meilleures textures et paramètres propres à chaque classe d'occupation du sol pour les approches par textures grises et couleurs. La méthodologie développée à cette fin devra être facilement adaptable à d'autres situations semblables par la création d'une « signature texturale » optimisée et analogue à la signature spectrale des objets;
- Comparer les résultats des deux approches intégratives (textures grises et couleurs) et conclure sur leurs avantages et désavantages en fonction de leur comportement selon les catégories d'occupation du sol et selon la classification générale.

Ainsi, l'hypothèse que nous voulons valider est que les textures couleurs, malgré la prise en considération de l'existence d'une certaine corrélation entre les bandes spectrales, ont un meilleur potentiel discriminatoire des classes d'occupation du sol que les textures grises. Cette hypothèse est confortée par les résultats des études dans le domaine des images couleurs. Cependant, sa validité avec les images multispectrales de télédétection, reste à confirmer.

2-Méthodologie

2.1- Site à l'étude et données

Le site à l'étude est situé dans le territoire de la Communauté Métropolitaine de Montréal (Figure 2.1). Il est situé aux abords de l'autoroute 20 et se trouve dans la municipalité de Longueuil. Il a été choisi pour la diversité de son occupation du sol comprenant à la fois du bâti (résidentiel à faible et haute densité, commercial/industriel), des espaces non construits (boisés, champs agricoles et eau) ainsi que des zones mixtes (aéroport, golf).

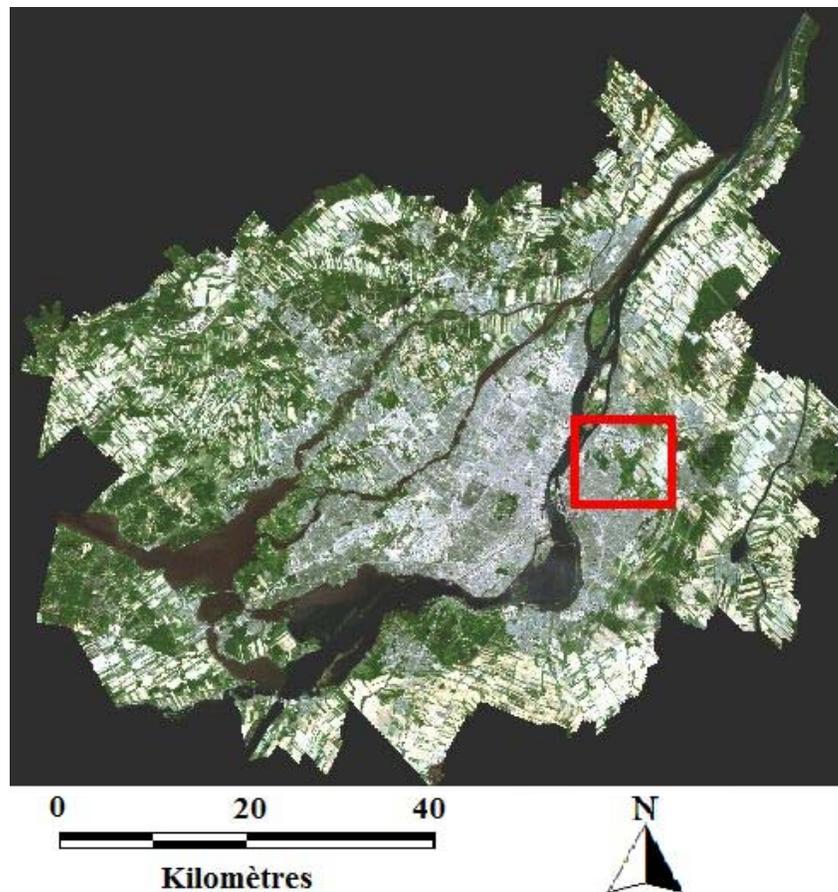


Figure 2.1 : Territoire de la Communauté Métropolitaine de Montréal et le site à l'étude (encadré rouge).

En fonction de la zone de couverture appropriée, l'image satellite SPOT-5 du 29 juillet 2006 a été sélectionnée parmi les diverses images disponibles au laboratoire de télédétection de l'Université de Montréal. Trois raisons motivent ce choix : a) Sa résolution de 10m en mode multispectrale permet de bien discerner les diverses formes de l'environnement urbain et rural à segmenter sans le détail excessif des images multispectrales à des hautes résolutions (par ex. QuickBird, Ikonos); b) Ces quatre bandes spectrales sont bien situées dans le spectre (fig.2.2); c) La disponibilité de diverses données territoriales (photographies, cartes) acquises à la même période que l'image SPOT, ce qui a permis de supporter et de valider l'expérimentation. Le tableau 2.1 donne un aperçu de l'ensemble des données utilisées dans cette étude.

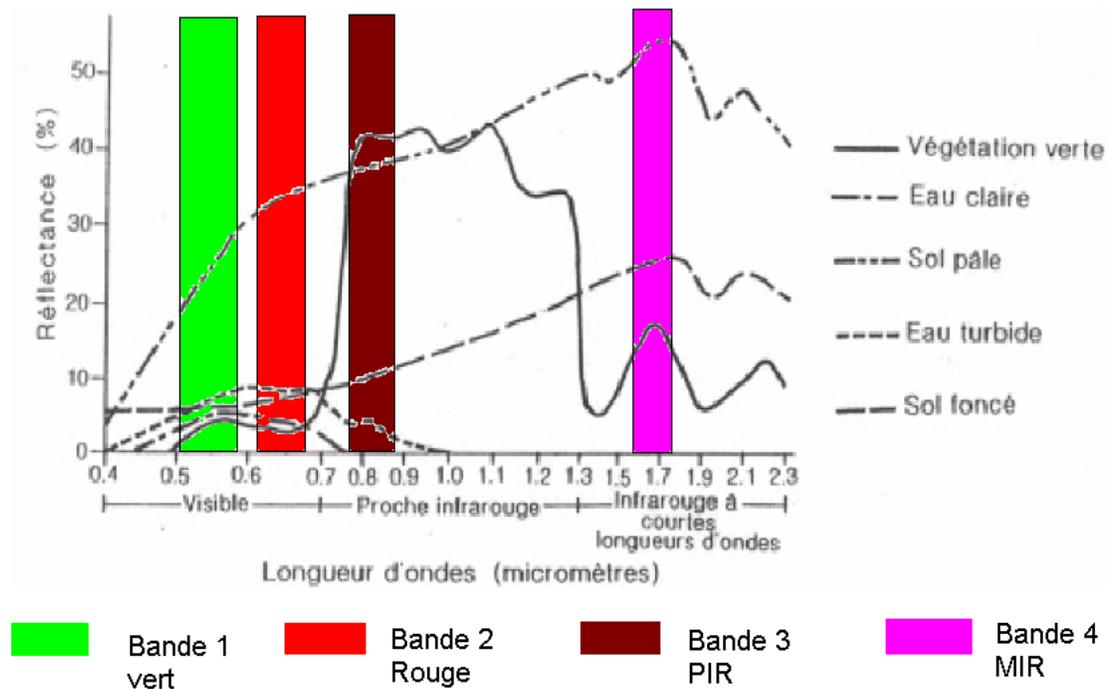


Fig. 2.2 : Courbes de réflectances des matériaux typiques de surface et bandes spectrales de SPOT 5.

Tableau 2.1 : Matériel

<u>Image satellite</u>	<u>Données territoriales</u>
Image SPOT-5 multi spectrale 2006-07-29, 15h55 GMT (10m) (bande 4 rééchantillonnée de 20 à 10 m)	Orthophotographies aériennes 2006 de la CMM (aide à la prise des sites de contrôle)
Image SPOT-5 panchromatique 2006-07-29, 15h55 GMT (5m) Utilisation occasionnelle	Modèle numérique d'altitude (MNA) (pour l'orthorectification des images satellites)
	Carte forestière 2006 (aide à la prise des sites de contrôle)
	Carte vérité terrain (voir texte et figure 2.4)

Cette image SPOT (multispectrale et panchromatique) couvrant partiellement le territoire de la CMM a été orthorectifiée en se servant d'un modèle numérique d'altitude créé à partir des courbes de niveau des feuillets topographiques au 1:20 000 à une résolution spatiale de 10 m. Par la suite, un extrait de 1000*1000 pixels, centré au site à l'étude, a été créé. Cette taille d'image, recouvrant une zone de 100 km² (fig.2.3) et possédant la diversité des classes voulue, a été considérée comme un bon compromis entre la surface occupée par ces classes et le volume de données à générer lors des expérimentations. Pour faciliter les analyses subséquentes cette image a été interprétée visuellement en une carte vérité terrain (fig. 2.4) à partir des photographies aériennes, avec une assistance des cartes de références disponibles lors des cas douteux. En plus des classes standard d'occupation des sols, nous en avons deux autres pour tenir compte de la présence des nuages ainsi que de leur ombre bien visibles sur l'image utilisée (Figure 2.3). À noter que le réseau routier et les maisons isolées sur les routes de campagne n'ont pas été pris en compte, mis à part les autoroutes qui ont une taille relativement importante.

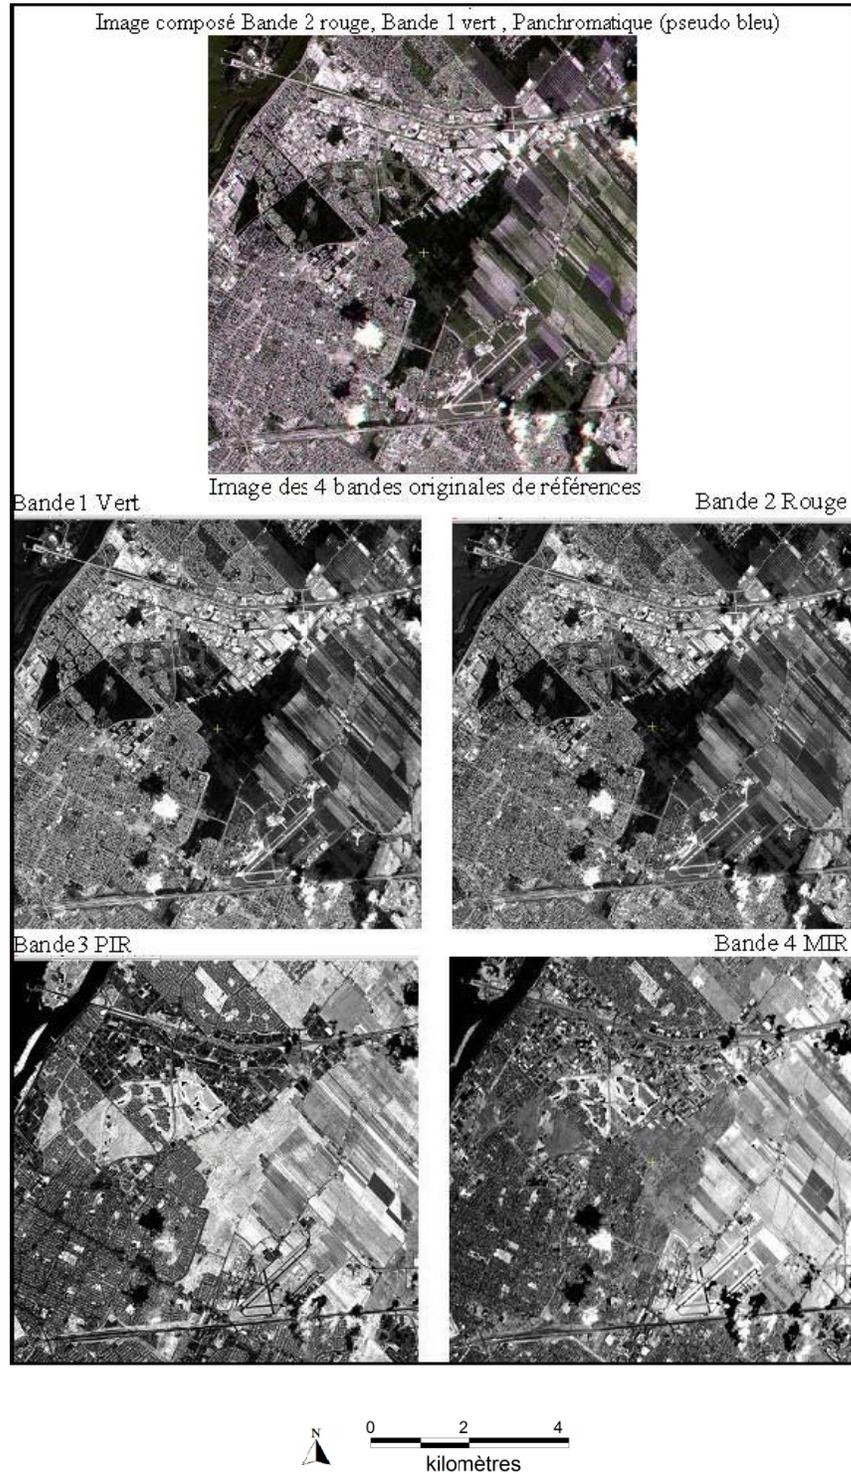


Figure 2.3 : Image SPOT-5 utilisée avec ses bandes spectrales.

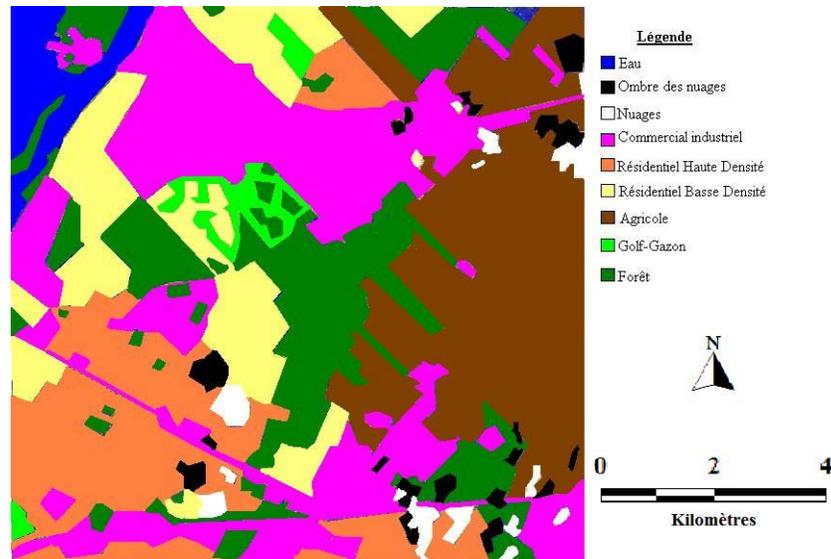


Figure 2.4 : Vérité terrain obtenue par photo-interprétation.

2.2-Méthode

La méthodologie employée lors de cette recherche se veut une extension de la méthodologie employée lors d'études effectuées dans notre laboratoire avec des images monochromes radar (Fiset, 2006) ou panchromatiques (Bugnet *et al.*, 2003). Cette méthodologie préconise l'utilisation des vecteurs d'Unser tel qu'expliqué au chapitre 1. La principale différence est la modification du logiciel de base pour réaliser la généralisation des matrices de co-occurrences. Les détails sur le fonctionnement du logiciel sont présentés dans la section 2.4.

L'utilisation des textures couleurs et leur comparaison aux textures grises, posent deux problèmes majeurs. D'abord, il y a l'énorme quantité de données pouvant être générée par l'utilisation de toutes les combinaisons [textures, bandes spectrales, taille de fenêtre texturale, orientation, pas]. Deuxièmement, on fait face à l'impossibilité de comparer directement les résultats de chaque approche sur une base globale. Par exemple, il est facile de dire que telle combinaison pour une texture grise est bonne pour isoler la classe x, mais

avec quelle combinaison la comparer pour les textures couleurs puisque la texture couleur provient d'une combinaison de deux bandes. Ces problèmes ont été résolus grâce au développement d'une méthodologie appropriée, associée au concept de signature texturale traité au chapitre 1. En effet, la vérification de l'hypothèse principale sera effectuée grâce à la comparaison de l'exactitude des classifications, grise et couleur, issues de signatures texturales comportant un nombre égal d'images texturales. La sélection des images texturales utilisées dans chaque signature sera effectuée en analysant la séparabilité des signatures pour chaque type de classe. Ainsi, la signature texturale utilisée dans chaque approche sera également composée d'images texturales optimisant la séparabilité de chaque classe d'occupation. Le résultat final ainsi obtenu permet une comparaison globale et optimisée (nombre réduit d'images texturales), entre deux entités comparables, de l'efficacité des deux méthodes lors de la classification du territoire. L'explication détaillée des étapes de cette méthodologie est présentée dans la section suivante.

2.3-Étapes de la démarche

Afin d'atteindre notre objectif, qui est d'étudier le potentiel des textures couleurs comparativement aux textures grises traditionnelles, la méthodologie suivante, à été utilisée (figure 2.6). Hormis la création de la base de données et le choix des classes d'occupation du sol, les étapes méthodologiques peuvent être regroupées en deux parties. La première partie (étapes 3 et 4) vise à isoler les meilleures combinaisons texturales nécessaires pour adapter la signature texturale au terrain d'étude. Cette partie nécessite une sélection manuelle (pouvant éventuellement être automatisée) des textures en fonction des analyses de séparabilité. Une fois la bonne signature texturale créée pour un type de terrain et de classes d'occupation donnés, elle n'aura théoriquement pas besoin d'être recalculée (sauf changements majeurs du territoire). La seconde partie consiste en la classification du territoire et la production des statistiques d'exactitude. Ainsi, les différentes étapes de la méthodologie sont les suivantes :

- 1) **Création d'une base de données** : Corrections géométriques et intégration des diverses couches de données utilisées sous une même projection cartographique.
- 2) **Choix des classes d'occupation des sols**: Ce choix a été fait en interprétant visuellement les images SPOT tout en tenant compte des classes d'occupation du sol habituellement représentées sur des cartes à l'échelle 1 :50 000. La figure 2.4 montre les classes retenues. Nous avons préféré procéder ainsi afin d'éviter des problèmes souvent rencontrés en classification d'images lorsque les sites d'entraînement et les sites de validation sont choisis directement sur une carte d'occupation des sols existante, en faisant abstraction de la résolution des images utilisées. Il est évident que si, par exemple, la carte d'occupation indique un terrain commercial, mais que la photo aérienne montre un petit bâtiment dans un pâté de maisons, il est impossible de faire cette différence par le biais de l'imagerie satellitale avec 10m de résolution spatiale.

Partie 1 : Formation de la signature texturale adaptée au terrain d'étude

- 3) **Génération des images de texture** : Après la création des polygones de vérité terrain, nous procédons à la création des images de textures grises et couleurs. Dans le cas actuel, les textures grises seront calculées en fonction des quatre bandes spectrales de SPOT-5 tandis que les textures couleurs, le seront à partir des six combinaisons possibles (paires de bandes spectrales, fig. 1.2). Puisqu'il est pratiquement impossible, sans l'aide d'algorithmes dépassant le cadre de cette recherche, de tester toutes les combinaisons de textures et de paramètres texturaux possibles (orientations, pas, tailles de fenêtres, paires de bandes spectrales...). Le nombre d'images texturales générées, à ce stade-ci de la recherche, a donc été limité en fixant les paramètres de calcul comme suit : a) le pas a été fixé à 1 pixel tandis que l'orientation à 135^0 (1,1) b) la taille de la fenêtre de calcul a été fixée à $9*9$.

Cette taille de fenêtre, qui semble visuellement correspondre à la taille moyenne des objets sera validée selon la variation des exactitudes et les semi-variogrammes dans la partie 2. À ce stade, la taille de la fenêtre représente assez bien la morphologie moyenne d'occupation du territoire d'une image 10m;c) Les niveaux de gris des bandes spectrales ont été maintenus à 256. Les histogrammes des bandes spectrales (figure 2.5) montrent que même si la masse de pixels ont des valeurs plutôt basses, il y en a quand même un bon nombre (des centaines) avec des fortes valeurs. Une compression des niveaux de gris risquerait ainsi de diminuer la sensibilité des paramètres calculés à la brillance des textures. De plus, les nuages ayant de très fortes valeurs dans toutes les bandes risqueraient d'être confondus avec des objets d'une texture brillante.

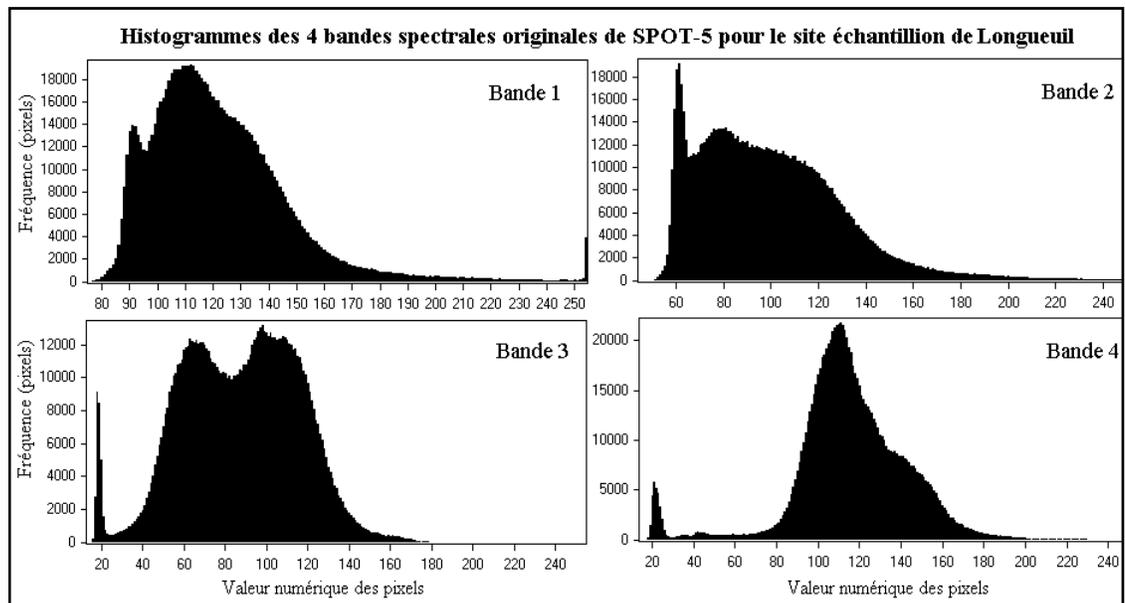


Figure 2.5 : Histogrammes des valeurs numériques des bandes spectrales

- 4) **Sélection des images texturales optimisant la séparabilité des classes** : Basé sur une série de sites de contrôle, les statistiques (moyennes, matrices de variance-covariance) par classe pour l'ensemble des images texturales seront générées et soumises à des analyses de séparabilité selon la distance (entre paires de classes) de

Bhattacharyya (section 2.4.2). Les images texturales seront alors triées pour ne retenir que celles offrant une séparabilité optimale (meilleurs résultats pondérés vs toutes les paires de classes). Tel que mentionné plutôt, pour bien comparer les résultats de classification par textures grises et textures couleurs, le nombre d'images de texture choisies par type de classe pour le gris et la couleur doit être le même. Ceci permet de garder la même dimensionnalité des signatures texturales grises et couleurs. Notez que par dimensionnalité des signatures, on entend le nombre de textures uniques, selon les paramètres (type, pas, orientation, taille de fenêtre, bande(s) spectrale(s) utilisée(s)) composant cette signature.

Cependant, puisque le but de ce projet n'est pas la création des signatures texturales parfaites, mais bien l'obtention de deux signatures comparables, les résultats obtenus n'ont pas besoin d'être raffinés davantage. Ainsi, si la recherche de la classification parfaite était le but, la répétition des étapes 3 et 4 en faisant varier paramètres texturaux, particulièrement la taille de la fenêtre, et ce pour chaque type de classe, serait nécessaire pour mieux caractériser chaque classe d'occupation par les signatures texturales. Par exemple, une fenêtre de 3*3 ou 5*5 serait meilleure pour la classe d'occupation résidentielle alors que du 7*7 ou 9*9 serait plus approprié pour les plus grands bâtiments associés au secteur commercial et finalement 11*11 et plus pour les classes agricole, eau, etc. Des tests en faisant varier ces paramètres seront effectués dans les étapes subséquentes pour examiner leur impact sur les résultats de la classification.

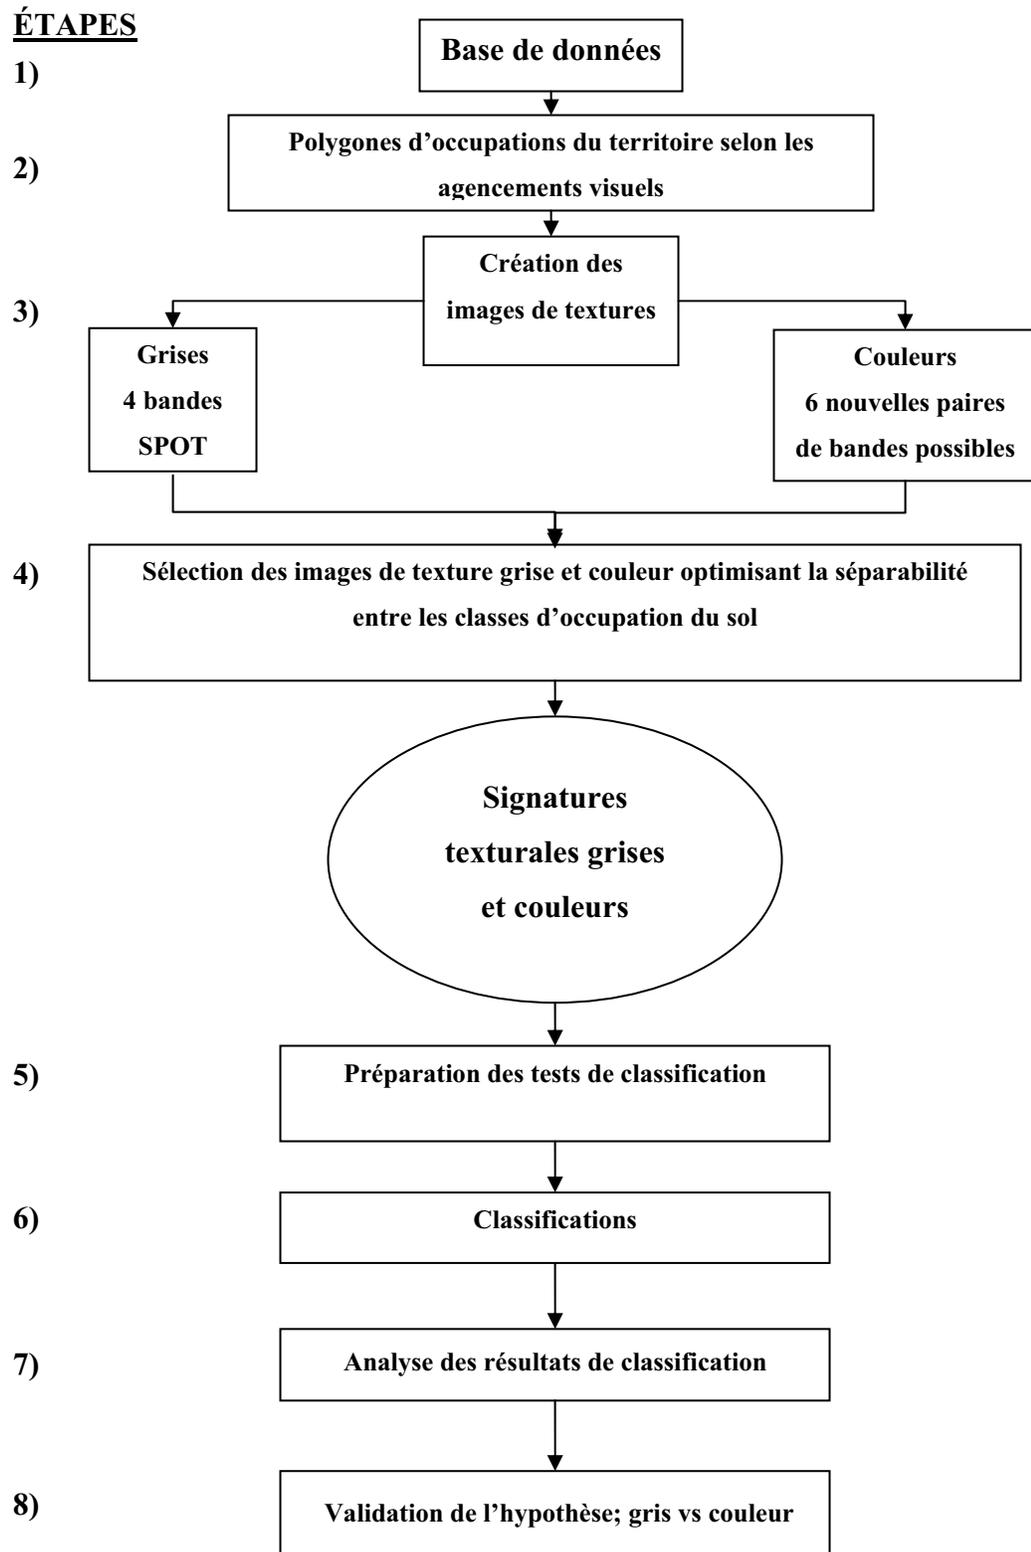
Partie 2 : Classification et statistiques d'exactitude :

- 5) **Préparation des tests de classification :** Maintenant qu'une sélection des images texturales offrant le meilleur potentiel pour des classifications de l'occupation du sol a été effectuée, nous passons aux tests de classification. Une série de sites de contrôle sera utilisée, afin d'obtenir les statistiques de base par classe d'occupation,

pour diriger un algorithme de classification. Pour tester l'impact des différents paramètres de calcul, de nouvelles images de texture seront générées en faisant varier ces paramètres, pour les mêmes mesures de texture choisies à l'étape 4, et leurs statistiques seront estimées.

- 6) **Classifications** : Les statistiques des images de texture composant les signatures texturales grises et couleurs selon les différents paramètres de calcul (fenêtre et pas/orientation) seront introduites dans le classificateur standard par maximum de vraisemblance (section 2.4.3) pour obtenir des cartes d'occupation du sol selon les classes : Eau; Nuages et leurs ombres; Forêt; Agricole; Commercial/Industriel; Résidentiel Haute densité; Résidentiel Basse Densité; Golf/Gazon
- 7) **Analyse des résultats de classification** : En plus des sites d'entraînement originaux, une série différente de sites de contrôle de classification seront choisis, et les cartes obtenues à l'étape 6 seront analysées pour former des matrices de confusion. L'analyse de ces matrices (exactitudes, test kappa, graphiques de variation de l'exactitude), fournira les outils nécessaires pour comparer les différentes classifications. De plus, afin de vérifier la pertinence de l'utilisation de la fenêtre 9*9 à l'étape 4, ainsi que pour extraire des informations quant à l'optimisation de la taille de la fenêtre vs le gain/perte d'exactitude des résultats obtenus, nous analyserons les semi-variogrammes (section 2.4.5) des valeurs des pixels de l'image entière ainsi que dans les polygones des diverses classes.
- 8) **Vérification de l'hypothèse de recherche** : Les résultats de l'étape précédente nous permettront de conclure quant à la validité de notre hypothèse, à savoir, que les textures couleurs permettent de mieux identifier les différentes classes d'occupation du sol.

Figure 2.6 : Étapes méthodologiques



2.4-Outils d'analyse

La majeure partie des traitements et des analyses a été effectuée à partir du logiciel Géomatica (version 9.1) de PCI, ou plus précisément par la création de fichiers de commandes EASI, nécessaires vu la quantité de données créées, pour les applications Xpace appropriées. Les principaux outils d'analyse sont décrits ici.

2.4.1 Texel : algorithme de création des images de texture

L'algorithme Texel permet d'obtenir les vecteurs d'Unser selon les paramètres de base (pas, orientation, fenêtre) spécifiés par l'utilisateur et de là, les différentes images de texture (voir Tableau 1.3). Texel a été développé par M. Fiset (2006) dans le cadre de son projet de doctorat à notre laboratoire de télédétection. L'algorithme a été programmé en C et implanté via le ToolBox de PCI dans l'environnement Xpace de Géomatica. L'algorithme peut calculer la texture à l'intérieur d'un polygone irrégulier ou l'image entière. Dans le premier cas, seules les paires de pixels entièrement à l'intérieur du polygone sont utilisées dans les vecteurs d'Unser. Dans sa version originale Texel était adapté aux images monochromes. M. Fiset a bien voulu modifier son algorithme pour nous permettre de calculer les vecteurs d'Unser généralisés en tenant compte d'une paire d'images. La figure 2.7 montre le menu principal de Texel ainsi que la description des différents paramètres de fonctionnement de l'algorithme. Il est à noter que Texel utilise les vecteurs d'Unser adaptés à des images exprimées en 256 niveaux de gris.

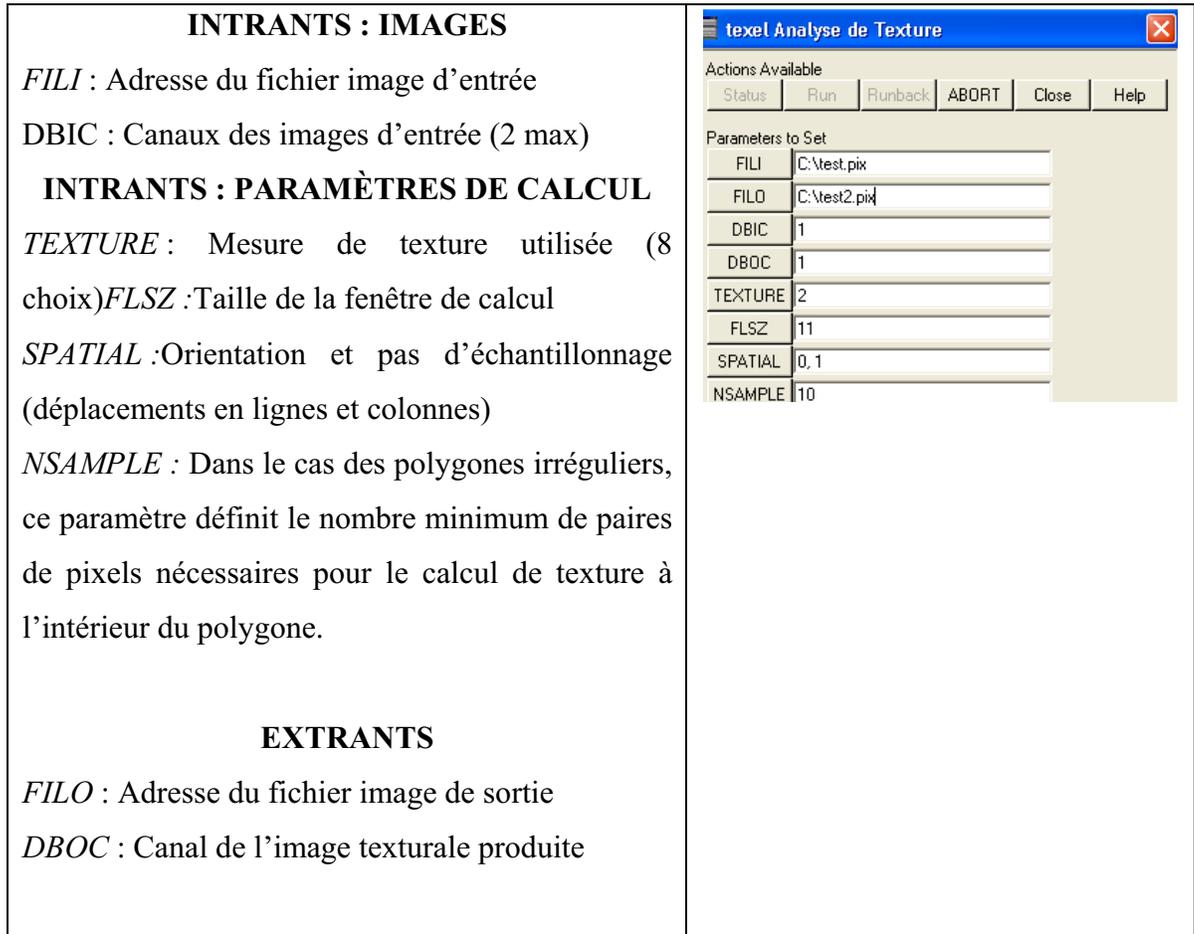


Figure 2.7 : Interface de l'algorithme Texel

2.4.2 Analyse de séparabilité

Pour les analyses de séparabilité entre les signatures des classes, nous avons utilisé l'algorithme SIGSEP de Xpace après avoir utilisé CSG pour la génération des signatures par classe. L'algorithme propose comme mesure de séparabilité la divergence ou la distance de Bhattacharyya. C'est la deuxième mesure qui est utilisée dans cette recherche. Pour ces calculs, on utilise les statistiques par classe (vecteur des moyennes, matrices de variance-covariance) fournies par CSG. Mathématiquement, le programme CSG crée un hyperellipsoïde en fonction des paramètres de la distribution, supposée multinormale, des pixels par type de classe pour générer les paramètres requis. Par la suite, SIGSEP calculera

la séparabilité de chacune des paires d'hyperellipsoïdes possibles en mesurant la distance de Bhattacharyya, i.e. la distance de chevauchement des paires de distributions. Cela formera une matrice semblable, par ses dimensions, à celle de variance-covariance. Cette distance est, de par les limites mathématiques de la formulation utilisée par PCI, limitée entre 0 et 2. Une paire de classes y est considérée : confondue si la distance est inférieure à 1; relativement séparable de 1 à 1,9; et certainement séparable de 1,9 à 2. Ces valeurs arbitraires de PCI seront utilisées pour classer les résultats dans les matrices de séparabilité au prochain chapitre. Landgrebe (2002) les a utilisées avec succès pour une classification hyperspectrale, similaire à l'approche par signatures. Voici la formule, utilisée par PCI et Landgrebe (2002), qui calcule la distance selon les 2 premiers moments des distributions :

$$B(S_1, S_2) = \frac{1}{8}(\mathbf{u}_1 - \mathbf{u}_2)^T \left(\frac{\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2}{2} \right)^{-1} (\mathbf{u}_1 - \mathbf{u}_2) + \frac{1}{2} \ln \left\{ \frac{\frac{1}{2} |\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2|}{|\boldsymbol{\Sigma}_1|^{1/2} |\boldsymbol{\Sigma}_2|^{1/2}} \right\} \quad (1)$$

S_1 et S_2 sont les distributions/signatures des 2 classes comparées

\mathbf{u}_1 et \mathbf{u}_2 sont les vecteurs moyenne des classes d'occupation

$\boldsymbol{\Sigma}_1$ and $\boldsymbol{\Sigma}_2$ sont leurs matrices de variances-covariances.

2.4.3 Classificateur

L'algorithme de classification utilisé est celui de maximum de vraisemblance (classes d'occupation du sol équiprobables) version dirigée et paramétrique (classes multinormales). Dans sa version Xspace, cet algorithme (MLC) peut être appliqué sans ou avec classe nulle. Une telle classe inclue tout pixel non classifié par l'algorithme. Dans le cas sans classe nulle, l'algorithme force l'attribution des pixels non classifiés à une des classes utilisées en se servant directement de la distance de Mahalanobis (voir plus loin). La classification s'effectue sur chaque série d'images composant la signature texturale de chaque approche. La figure 2.8 résume les étapes de calcul de cet algorithme tel que décrit par Atkinson et Lewis (2000).

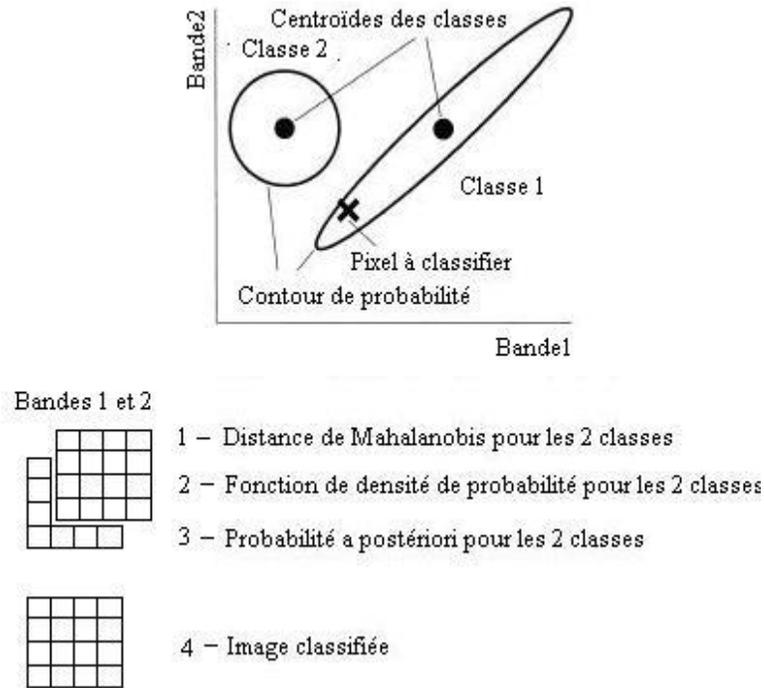


Figure. 2.8 : Étapes des calculs du classificateur par maximum de vraisemblance

Dans l'espace de représentation (dans le schéma précédent à deux dimensions) le domaine de chaque classe est défini en termes probabilistes. Dans sa version dirigée et paramétrique avec des classes supposées multinormales, les vecteurs des moyennes et la matrice de variance-covariance de chaque classe sont suffisantes pour décrire son domaine (les ellipses du schéma précédent). La probabilité d'un pixel quelconque d'appartenir à une des classes en présence est calculée essentiellement en se servant de la distance de Mahalanobis :

$$M_{ci} = (\mathbf{z}_k(\mathbf{x}_i) - \mathbf{u}_{kc})^T \mathbf{V}_c^{-1} (\mathbf{z}_k(\mathbf{x}_i) - \mathbf{u}_{kc}) \quad (\text{Atkinson, 2000}) \quad (2)$$

M_{ci} = distance de Mahalanobis; \mathbf{u}_{kc} = vecteur des moyennes des centroïdes; \mathbf{x}_i = pixels ;

\mathbf{V}_c^{-1} = matrice de variance-covariance ; $\mathbf{z}_k(\mathbf{x}_i)$ = vecteur des valeurs de bande $\{k=1 \dots K\}$

À partir de M_{ci} il est possible de calculer la fonction de densité de la probabilité pour chaque classe. Pour prendre une décision finale selon le principe Bayésien nous pouvons

pondérer la probabilité conditionnelle par la probabilité *a priori* d'occurrence d'une classe et calculer ainsi la probabilité *à posteriori* d'appartenance à une classe. Le pixel est alors attribué à la classe qui maximise la probabilité *a posteriori*. Dans la plupart des cas la probabilité *a priori* n'est pas connue, ainsi on suppose des classes équiprobables ce qui revient essentiellement à ne tenir compte que de la distance de Mahalanobis comme critère de classification. Par la suite, une série prédéterminée d'itérations raffineront/optimiseront la probabilité *a posteriori*.

Fonction de densité de probabilité conditionnelle :

$$p(z(\mathbf{x}_i) | c) = \frac{1}{(2\pi)^{K/2} |\mathbf{V}_c|^{1/2}} \exp[-1/2M_{ci}] \quad (3)$$

(Atkinson 2000)

Probabilité *a posteriori* :

$$L(c | z(\mathbf{x}_i)) = \frac{P_c \cdot p(z(\mathbf{x}_i) | c)}{\sum_{r=1}^t P_r \cdot p(z(\mathbf{x}_i) | r)} \quad (4)$$

Dans sa version Xspace, nous pouvons limiter l'étendue du domaine de chaque classe en imposant un seuil en termes d'écart-types par rapport à la moyenne par canal utilisé pour la classification. Plus ce seuil est faible, plus il y a le risque qu'un nombre important des pixels soient non classifiés.

2.4.4 Analyses d'exactitude des classifications

L'analyse quantitative de la qualité des classifications passe habituellement par les matrices de confusion où l'on compare les résultats du classificateur pour un certain nombre de pixels dont l'identité est connue (sites de validation ou de référence). Le tableau 2.2 présente la forme générique d'une Matrice de confusion.

Tableau 2.2 - Matrice de confusion					
		unité 1	unité i	unité n	Total lignes
Référence	unité 1	x_{11}	x_{1j}	x_{1n}	N_1
	unité i	x_{1+}	x_{ij}	x_{+i}	N_j
	unité n	x_{n1}	x_{ni}	x_{nn}	N_n
Total colonnes		M_1	M_2	M_n	N

Girard 2004, p332

Une fois une telle matrice compilée, il est possible de calculer l'exactitude globale ou l'exactitude par classe (erreurs d'omission et de commission). Nous pouvons aussi calculer la statistique Kappa qui permet de vérifier si la matrice de confusion n'est pas due au hasard. Plus cette statistique est faible plus la classification est considérée inexacte :

$$\hat{K} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i.} \cdot n_{.i}}{n^2 - \sum_{i=1}^k n_{i.} \cdot n_{.i}} \quad (5)$$

Girard 2004, p331

Finalement, une fois que toutes les classifications des images texturales retenues auront leur indicateur de qualité, un test statistique (généralement, la cote Z est associée à ce test) sera effectué pour départager la qualité des classifications faites à partir des deux sets de textures grises ou couleurs. La combinaison des deux avenues d'analyse de la qualité des classifications permettra d'avoir un portrait global de la situation conduisant à une réponse significative à l'hypothèse de cette recherche. Un test de Z sera effectué sur la précision des Kappa (séparabilité des classifications) et un test de Student permettra de démontrer la séparabilité des groupes d'exactitudes associés aux diverses classes, selon les textures grises et couleurs

2.4.5- Semi-variogramme et taille de fenêtre de calcul

Afin d'adapter la méthodologie à la nature de l'information terrain, il reste à optimiser la taille de la fenêtre texturale utilisée. Pour ce faire, il faut identifier le seuil à partir duquel l'information spatiale atteint son point optimum, c'est-à-dire que les formes texturales n'ont plus de réel intérêt face à la variabilité de l'information locale. Le variogramme ou plus particulièrement dans ce projet le semi-variogramme, est un outil extrêmement efficace et utilisé dans la littérature (Cohen *et al.* 1990, Berberoglu *et al.* 2000, Bugnet *et al.* 2003) afin de monter/modéliser graphiquement la hausse de cette variabilité spatiale dans un profil d'image (figure 2.8). Ainsi, nous avons programmé, avec Matlab, le calcul du semi-variogramme pour analyser des profils de pixels des bandes spectrales.

$$\gamma(h) = \frac{1}{2(n-h)} \sum_{i=1}^{n-h} [Z(x_i) - Z(x_i + h)]^2 \quad \text{Cohen (1990)} \quad (6)$$

En théorie, l'identification du seuil d'information est associée à la détection de la portée, assimilable au point d'inflexion, représenté dans la figure 2.9, c'est-à-dire le point précédent la zone d'horizontalité de la courbe de variance. Cependant, dans la réalité, avec des petits échantillons, ce point est souvent diffus et la détection d'un point d'inflexion est nécessaire. En pratique, Bugnet *et al.* (2003), obtiennent généralement une portée de 13 pixels et plus, pour un milieu semi-urbain avec des images de résolution spatiale de l'ordre de 10 m. Évidemment, cela dépend d'une multitude de facteurs influençant la précision des semi-variogrammes produits.

- Le type de classe d'occupation du sol.
- Les formes et patrons dominants dans une classe donnée.
- La taille de l'échantillon permettant de calculer le semi-variogramme.
- La pureté de la classe analysée ou l'absence d'erratiques

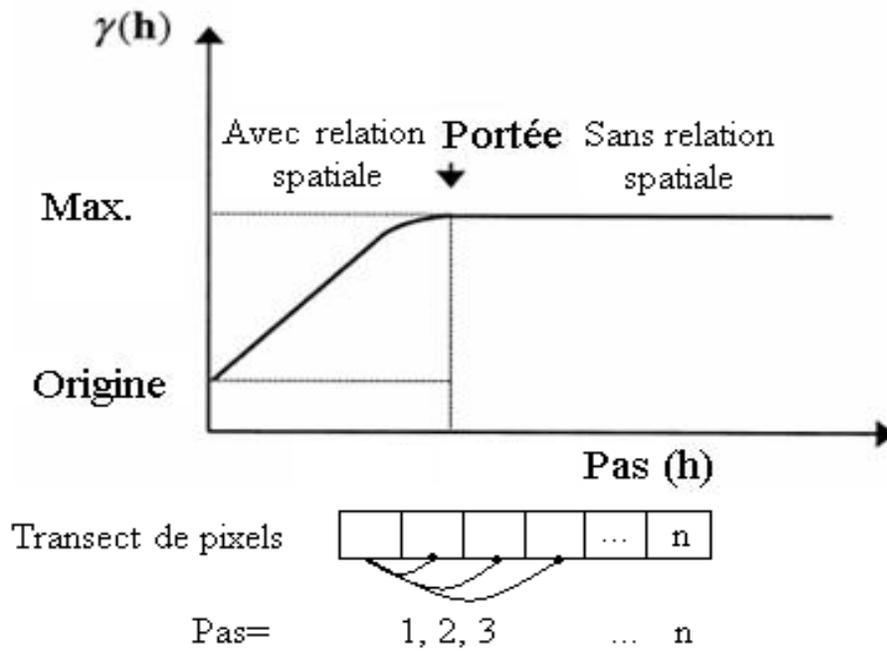


Fig. 2.9 : Paramètres types d'un semi-variogramme

Finalement, il est important de retenir que les facteurs influençant la forme d'un semi-variogramme peuvent aussi affecter les exactitudes des classifications texturales. Par exemple, un patron dominant peut, en théorie, avoir un effet spécifiquement à une taille de fenêtre de calcul proportionnelle à la taille des constituants de ce patron.

3-Résultats et analyses

3.1- Présentation des images texturales grises vs couleur

Précédemment, il a souvent été question de la distinction entre les textures grises et textures couleurs. Avant de passer à l'analyse des résultats quantitatifs, nous présentons une revue plus visuelle et qualitative du concept de la texture couleur par rapport à la texture grise. À cette fin et pour chaque type de texture, trois images texturales ont été produites, soit : bande 1, bande 3 et combiné bande 1-3. Afin de bien cerner les différentes propriétés entre ces deux types de texture, le lecteur devra se référer, si nécessaire, à la carte vérité terrain (fig. 2.4) et porter une attention particulière aux effets suivants dans les figures 3.1 à 3.5:

-Les textures couleurs, comparées aux images de textures grises (monobandes), offrent au premier coup d'œil, une amélioration notable du réalisme ou de la richesse des textures. Cela représente très certainement une bonne prémisse à une meilleure classification. (entre autres, fig. 3.2 et 3.3)

-Les textures couleurs offrent parfois des résultats complètement différents de leurs homologues gris (entre autres, corrélation et écart-type fig. 3.2, et contraste fig. 3.3)

-L'utilisation de bandes spectrales différentes de façon séparée ou combinée permet d'isoler visuellement diverses classes d'occupation. Cela est notamment évident pour la distinction entre les classes commerciale et résidentielle par contraste et corrélation (fig. 3.2 et 3.3)

-L'utilisation de différents types de textures permet la mise en valeur de diverses formes. Par exemple, la corrélation couleur (fig.3.3) met nettement en évidence les zones commerciales (en blanc), tandis que l'homogénéité couleur accentue nettement les divers types de terrains agricoles (les textures grises offraient uniquement du gris pâle, tandis que la texture couleur présente une forte variabilité, de noir à blanc).

Par souci d'économie d'espace, il est impossible de mettre un exemple imagé de tous les composés (textures couleur, bandes, tailles de fenêtres étudiées), mais il est toutefois important de connaître les principes suivants :

-L'utilisation de tailles de fenêtres différentes permet d'adapter les textures à la taille des formes associées aux classes d'occupation à isoler. Entre autres, les centres commerciaux semblent bien répondre à une fenêtre plus grande étant donné la grande taille des bâtiments. Ce point sera discuté plus loin.

-Finalement, probablement l'élément important à connaître est le fait que si deux classes ont une texture grise identique, mais que leur brillance diffère dans une bande spectrale, il est possible de différencier ces deux classes uniquement en utilisant un composé textural des deux bandes, chose impossible dans une texture grise. Observez, entre autres, le secteur industriel en haut des imageries (fig.3.2), qui est peu différenciable du résidentiel par l'approche grise, mais qui est nettement apparent par l'approche couleur.

La corrélation, le contraste et dans une moindre mesure l'écart-type, offrent les changements les plus saillants entre la méthode grise et couleur. On remarque principalement que les sites commerciaux et industriels (ainsi que les nuages) apparaissent de façon *très* nette (en noir) dans l'image de texture couleur ce qui est logique puisque contrairement aux textures grises qui se basent uniquement sur le changement de teinte d'un pixel à l'autre (selon le pas), la texture couleur optimise la forte corrélation négative entre les sites commerciaux plus pâles en bande 1 et plus foncés en bande 3. De plus la fenêtre 11*11 permet d'homogénéiser les zones, ce qui est intéressant pour la segmentation uniforme de l'occupation du territoire (entre autres, les zones commerciales)

La moyenne et l'homogénéité couleur montrent des différences un peu moins prononcées par rapport aux textures grises. Par contre, ces paramètres présentent une certaine hausse de la variabilité interne de certaines classes, par exemple : homogénéité et la classe agricole, ou moyenne et la classe commerciale. La probabilité maximale (Pmax), l'entropie et l'énergie (fig.

3.4 et 3.5), ne semblent pas offrir, visuellement, d'amélioration marquée de la séparabilité. Seules les classes primaires (eau, bâti et végétalisé) sont nettement séparables.

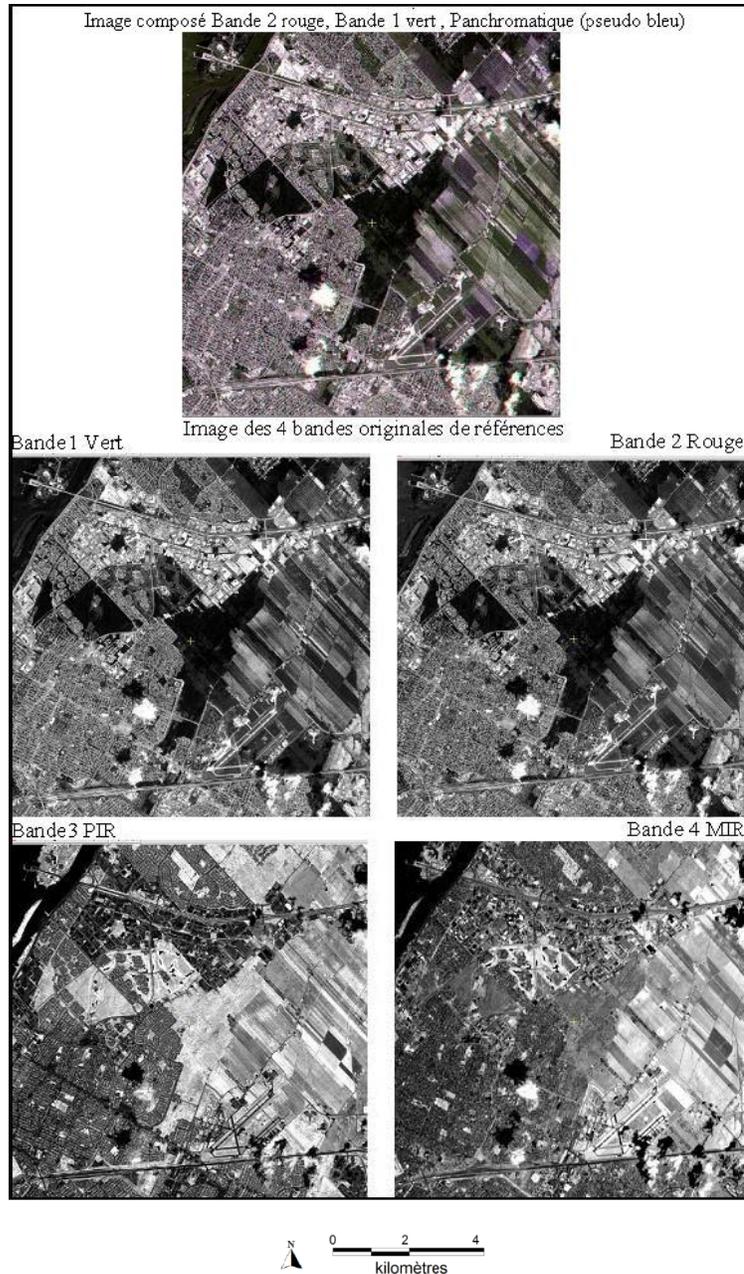


Figure 3.1 : Image SPOT-5 utilisée avec ses bandes spectrales

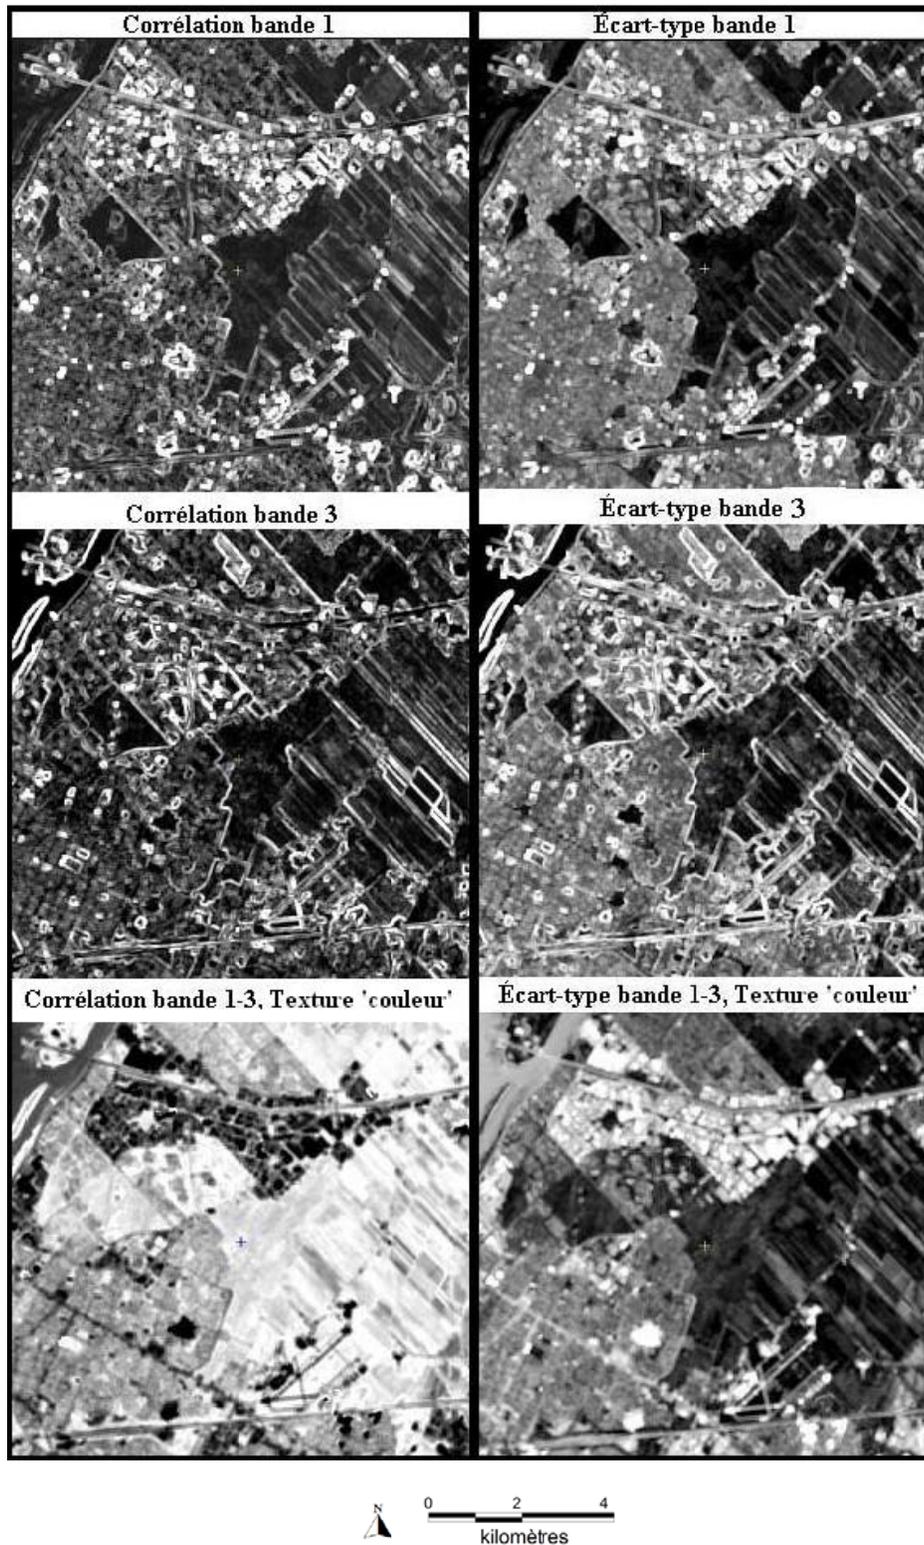


Figure 3.2 : Corrélation et Écart-type

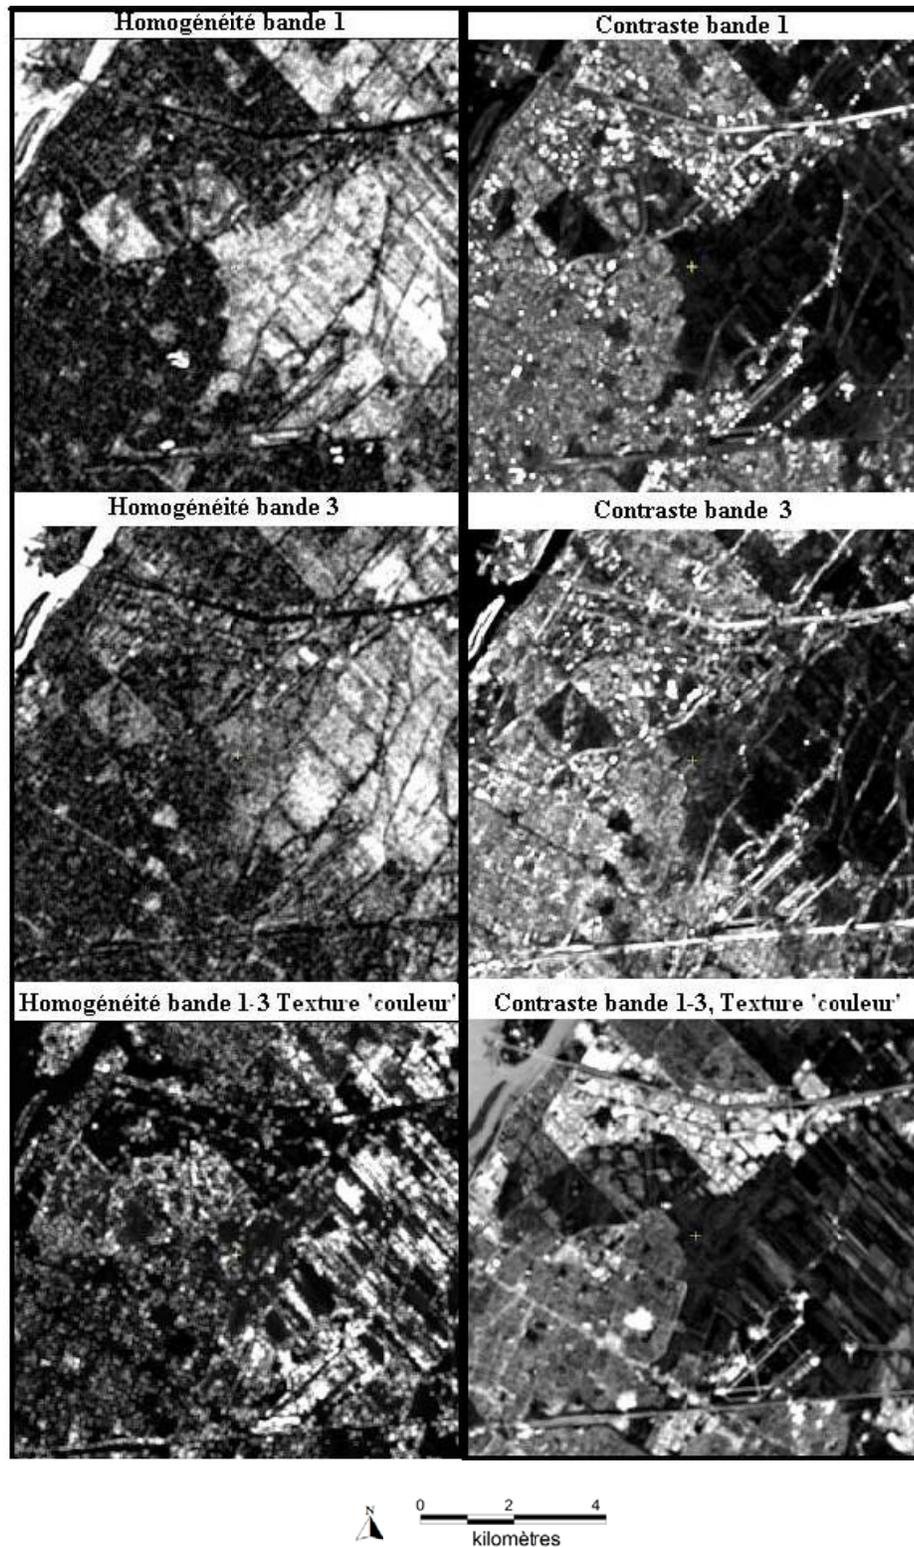


Figure 3.3 : Homogénéité et Contraste

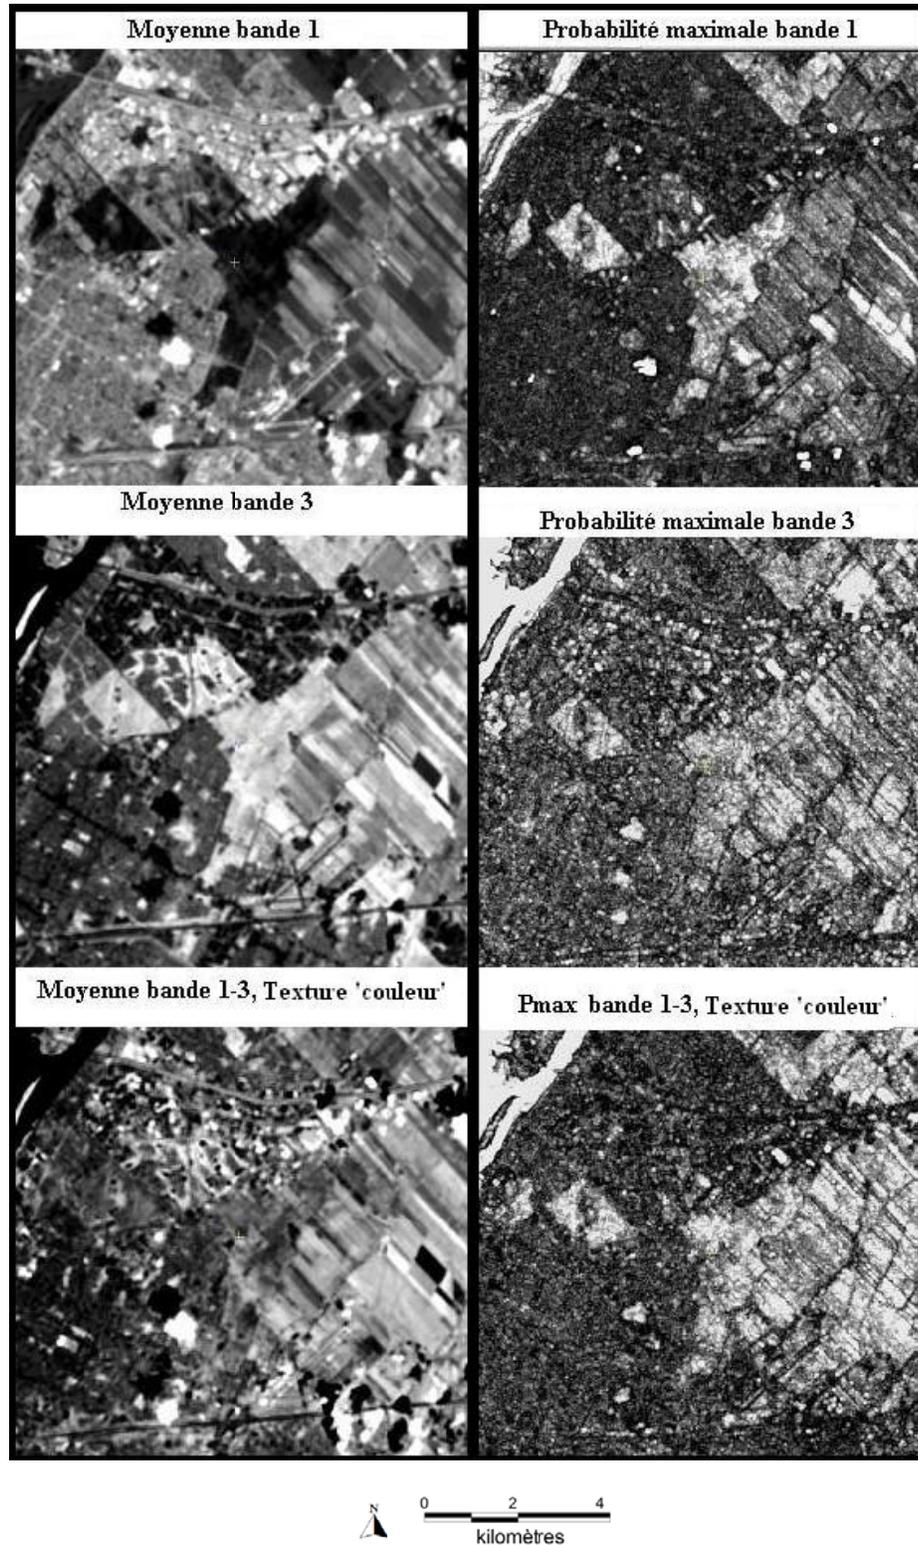


Figure 3.4 : Moyenne et Probabilité maximale (Pmax)

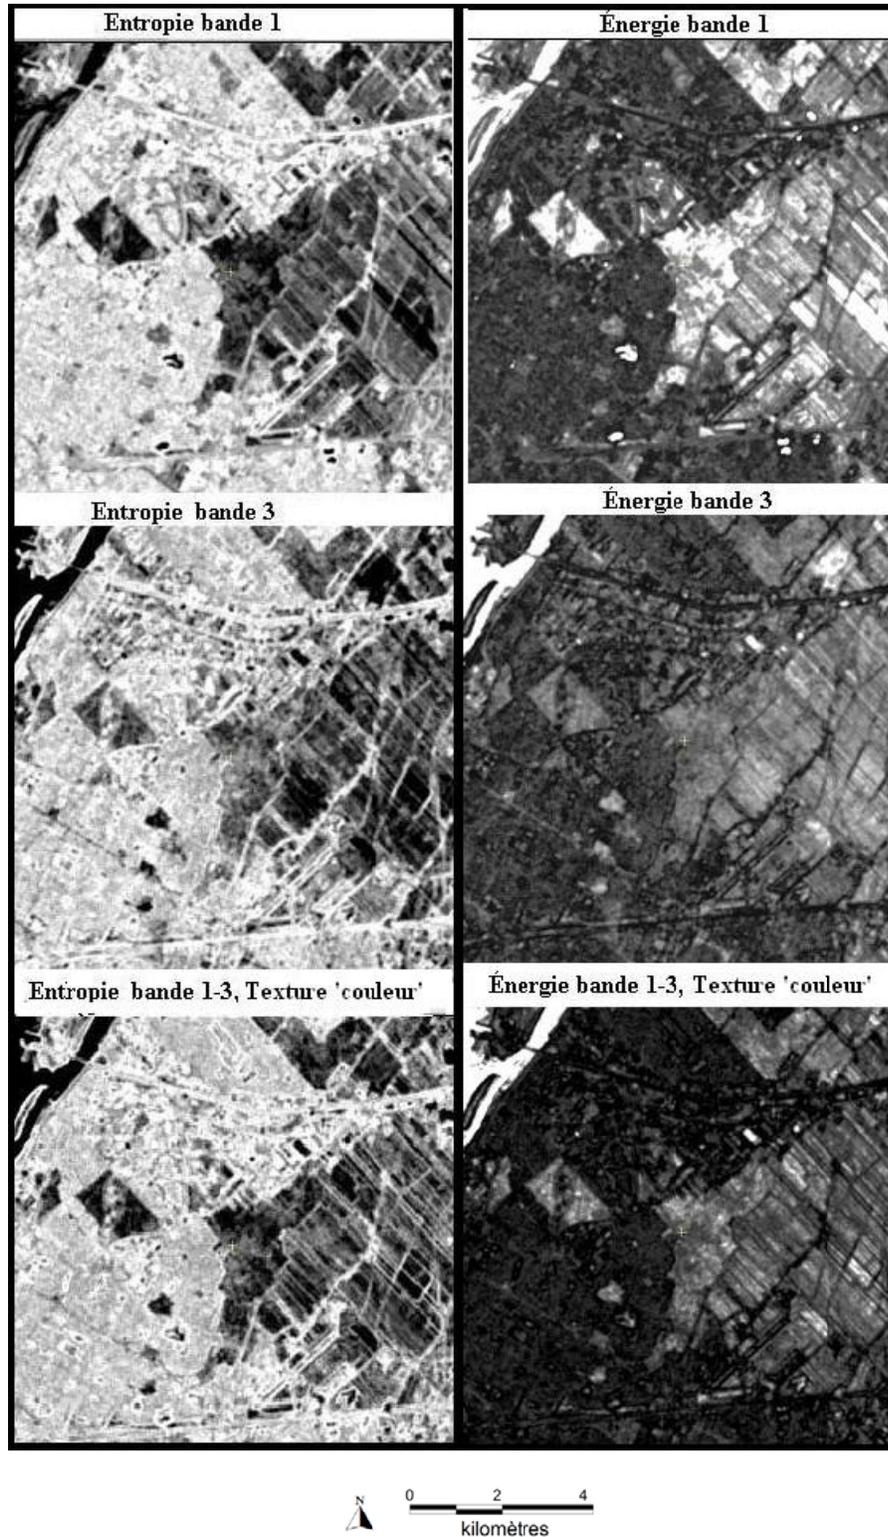


Figure 3.5 : Entropie et Énergie

Bien que ces combinaisons particulières offrent souvent des améliorations marquées ainsi que des traits distinctifs, il existe des milliers d'autres possibilités à explorer, et les tests de séparabilité entre les diverses classes permettront, éventuellement, d'isoler les meilleures combinaisons de textures associées à des classes spécifiques (par le biais du calcul des matrices de séparabilité ainsi que des pourcentages d'exactitude pour chaque type de classes d'occupation), ou pour une classification plus généralisée (matrice de confusion et kappa, permettant de comparer directement diverses images segmentées)

3.2- Analyse de la séparabilité des signatures texturales

Les textures et les bandes spectrales n'étant pas analysables séparément dans la méthode intégrative, et l'objectif de cette étape étant d'isoler les meilleurs composés texture/bande par classe d'occupation, les analyses de séparabilité ont été effectuées comme suit.

L'étude de séparabilité d'un ensemble (ex, la séparabilité des classes selon les 8 textures) a été calculée grâce à l'utilisation d'une texture pour toutes les bandes (ex. : un SIGSEP basé sur : moyenne bande 1, ..., moyenne bande 4). Cette méthode a l'avantage, pour des analyses de classes semblables, de produire des résultats réutilisables, éliminant ainsi l'étude des séparabilités individuelles ou la création des espaces orthogonaux pour ainsi devenir une approche d'ensembles (fig.3.6).

Ainsi, le but de cette étape est d'isoler les meilleures textures/classes, peu importe les bandes, puis les meilleures bande/classes, peu importe les textures, pour ensuite déterminer et conserver les combinaisons considérées optimales.

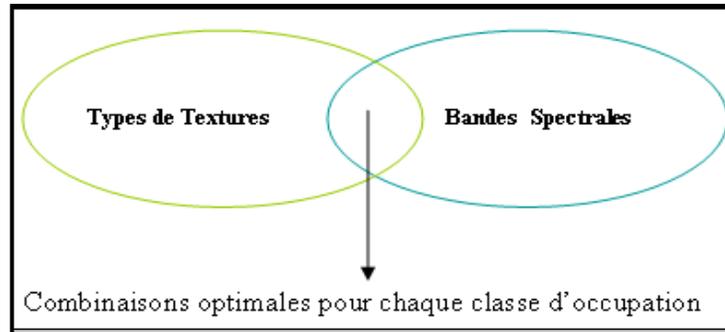


Fig. 3.6 : Pour chaque type de classe, on trouve les meilleures combinaisons possibles

À cette fin, les sections 3.2.1 à 3.2.3 présenteront, dans cet ordre, les matrices de séparabilité grises, couleur, et leur comparaison. Notons que par souci d'allègement du texte, les matrices de séparabilité en 3.2.1 et 3.2.2 ne tiennent compte que des classes d'occupation principales, les matrices totales (avec eau, nuage, ombre) sont disponibles en annexe 1.

3.2.1 Signatures texturales grises

Le tableau 3.1 montre les matrices de séparabilité calculées en se servant comme intrants des images de texture d'une même mesure (moyenne, entropie, etc.) calculée sur les quatre bandes spectrales (fenêtre de 9*9 pixels). En règle générale, toutes les mesures, sauf le Pmax et l'énergie, réussissent à séparer plus ou moins bien les classes du bâti du reste, tout particulièrement le contraste et la moyenne. Cependant, on notera que la classe agricole se confond souvent avec la classe gazon, tandis qu'aucune mesure n'arrive à départager les classes du bâti entre elles, comme en témoigne le maximum absolu de séparabilité, toutes textures confondues, de 0,5337 (dans texture de moyenne, en jaune). Ce dernier résultat n'est pas surprenant, il était même désiré pour permettre de tester le potentiel des textures couleur dans le cas d'une situation à forte confusion. En effet, les classes résidentielles haute et basse densité (HD et BD dans les tableaux subséquents) de Longueuil ne sont pas aussi séparables que dans un cas comme Montréal. Alors que les classes HD de Montréal sont généralement constituées de quartiers d'immeuble mitoyens peu ou pas végétalisés, la présente classe HD se fonde sur une végétation légèrement moins importante que pour BD et des bâtiments plus gros ou plus collés. Logiquement, ces classes devaient présenter une forte confusion.

Tableau 3.1 : Matrices de séparabilité des signatures de classes selon les huit textures grises, en utilisant les quatre bandes spectrales

Pmax						Énergie					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	0,8396					ResHD	0,9703				
ResBD	0,7347	0,0488				ResBD	1,0636	0,1236			
Agricole	0,8802	1,4965	1,4353			Agricole	1,6897	1,7822	1,8220		
Golf-gaz.	0,8607	1,3084	1,2046	0,8443		Golf-gaz.	1,3074	1,0257	1,1601	1,5190	
Forêt	1,4881	1,7169	1,6749	0,9210	0,9516	Forêt	1,8561	1,7731	1,8157	1,4229	1,4095

Moyenne						Écart-type					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	1,5032					ResHD	1,1714				
ResBD	1,6868	0,5337				ResBD	1,2249	0,0535			
Agricole	1,7175	1,9168	1,8546			Agricole	1,4256	1,6984	1,7781		
Golf-gaz.	1,9576	1,9973	1,9679	0,8499		Golf	1,3959	1,6388	1,7159	0,9047	
Forêt	1,9988	1,9998	1,9853	1,6642	1,5836	Forêt	1,8010	1,9603	1,9583	1,2757	1,3952

Homogénéité						Corrélation					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	1,1368					ResHD	1,5572				
ResBD	1,0684	0,1084				ResBD	1,6319	0,1172			
Agricole	1,6677	1,9515	1,9362			Agricole	1,7381	0,5755	0,5786		
Golf-gaz.	1,3336	1,6958	1,5761	1,3415		Golf-gaz.	1,6014	1,1987	1,3084	1,0250	
Forêt	1,8993	1,9776	1,9601	1,4779	1,0878	Forêt	1,9165	1,4032	1,4118	1,0544	1,5732

Entropie						Contraste					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	1,1093					ResHD	1,2178				
ResBD	1,0025	0,3676				ResBD	1,2527	0,0228			
Agricole	1,6766	1,9263	1,8034			Agricole	1,9412	1,9735	1,9758		
Golf-gaz.	1,6490	1,8778	1,8174	1,0425		Golf-gaz.	1,5646	1,7195	1,7609	1,6888	
Forêt	1,9543	1,9845	1,9547	1,6504	1,1892	Forêt	1,9206	1,9543	1,9575	0,7898	1,5782

i \ j	Le meilleur résultat entre 2 classes (i,j)				
ResHD					
ResBD					
Agricole					
Golf-gaz.					
Forêt					

i \ j	Tout résultat (i, j) supérieur à 1,9 (max 2)				
ResHD					
ResBD					
Agricole					
Golf-gaz.					
Forêt					

Le tableau 3.2 montre que si l'on utilise les huit mesures de texture ensemble calculées sur chaque bande individuellement, les bandes 1 à 3 offrent un potentiel équivalent pour séparer la forêt du reste et les bandes 1, 2 (vert et rouge) offrent des bons résultats en ce qui à trait à la séparation des classes non-bâti entre elles et entre bâti et non-bâti. Pour ce qui est de la séparabilité des classes du bâti entre elles, aucune bande individuelle n'offre un potentiel intéressant, à l'exception peut-être de la bande 1 (vert) et de la bande 3 (PIR). Mais, comme

dans le cas du tableau 3.1 la séparation entre les deux classes résidentielles demeure très problématique et dans une moindre mesure celle des classes agricole et gazon.

Tableau 3.2 : Matrices de séparabilité des signatures de classes selon les quatre bandes spectrales, en utilisant les huit textures grises

Bande 1						Bande 3					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	1,3285					ResHD	0,6851				
ResBD	1,4292	0,7284				ResBD	0,4765	0,4523			
Agricole	1,8716	1,9685	1,9742			Agricole	1,8793	1,9741	1,9015		
Golf-gaz.	1,6699	1,7088	1,6176	1,0118		Golf-gaz.	1,8758	1,9693	1,8918	1,3058	
Forêt	1,9853	1,9966	1,9469	1,3401	1,0309	Forêt	1,9768	1,9883	1,9482	0,7858	1,127

Bande 2						Bande 4					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	1,3238					ResHD	1,0921				
ResBD	1,4288	0,7111				ResBD	1,0150	0,1607			
Agricole	1,8084	1,9101	1,8711			Agricole	1,8632	1,9166	1,9145		
Golf-gaz.	1,7981	1,7306	1,3368	0,9642		Golf-gaz.	0,9950	1,819	1,8146	1,3978	
Forêt	1,9960	1,9996	1,9735	1,4239	1,2422	Forêt	1,5380	1,3197	1,3454	1,1315	1,447

i \ j	Le meilleur résultat entre 2 classes (i, j)				
ResHD	1,3238				
ResBD	1,4288	0,7111			
Agricole	1,8084	1,9101	1,8711		
Golf-gaz.	1,7981	1,7306	1,3368	0,9642	
Forêt	1,9960	1,9996	1,9735	1,4239	1,2422

i \ j	Tout résultat (i, j) supérieur à 1,9 (max 2)				
ResHD	1,0921				
ResBD	1,0150	0,1607			
Agricole	1,8632	1,9166	1,9145		
Golf-gaz.	0,9950	1,819	1,8146	1,3978	
Forêt	1,5380	1,3197	1,3454	1,1315	1,447

Pour résumer cet exercice sur les séparabilités des classes traitées par des textures grises on peut dire que moyenne et contraste sont les mesures qui ressortent un peu plus que les autres mesures et que les bandes 2 et 3 (rouge et PIR) offrent le meilleur potentiel pour distinguer entre classes du bâti et non-bâti. Quant aux classes du bâti, elles ne sont que faiblement dissociables, tout comme la classe agricole est difficilement séparable de la classe gazon/golf.

3.2.2 Signatures texturales couleurs

Des analyses similaires ont été effectuées avec les textures couleurs sauf qu'ici on parle des paires de bandes spectrales au lieu des bandes spectrales individuelles. On note des améliorations substantielles surtout dans la séparation des classes du résidentiel (confondues) et l'industriel/commercial. Il en va de même quant à la séparabilité gazon/agricole. On note une légère hausse comparative au tableau 3.1, mais la confusion demeure élevée. Quant à l'utilité d'une paire de bandes prise individuellement (tableau 3.4) il n'y en a pas une qui ressort de

façon nette, mais 2.4 semble être la plus polyvalente et 3.4 est la bande idéale pour la séparation de la classe forêt des autres.

Tableau 3.3 : Matrices de séparabilité des signatures de classes selon les huit textures couleurs, en utilisant toutes les paires de bandes possibles

Pmax						Énergie					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	Res BD	Agricole	Golf-gaz.
ResHD	0,6162					ResHD	1,2155				
ResBD	0,5855	0,0372				ResBD	1,1136	0,0972			
Agricole	1,2428	1,7031	1,6935			Agricole	1,7388	1,469	1,5620		
Golf-gaz.	0,6343	1,2131	1,1653	0,9794		Golf-gaz.	1,1874	1,1972	1,2126	1,3662	
Forêt	1,4560	1,7563	1,7418	0,6281	0,8629	Forêt	1,8703	1,7086	1,7593	1,1479	1,5062
Moyenne						Écart-type					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	Res BD	Agricole	Golf-gaz.
ResHD	1,5622					ResHD	1,7296				
ResBD	1,9329	0,7283				ResBD	1,8691	0,6711			
Agricole	1,9550	1,9684	1,9741			Agricole	1,9733	1,9959	1,987		
Golf-gaz.	1,9772	1,7087	1,6176	1,0118		Golf-gaz.	1,9953	1,9990	1,9940	1,1449	
Forêt	1,9993	1,9965	1,9468	1,3401	1,6314	Forêt	2	2	1,9999	1,7779	1,7289
Homogénéité						Corrélation					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	Res BD	Agricole	Golf-gaz.
ResHD	0,9629					ResHD	1,8792				
ResBD	1,2346	0,4753				ResBD	1,9352	0,6325			
Agricole	1,6771	1,7692	1,604			Agricole	1,9490	1,9825	1,9718		
Golf-gaz.	1,838	1,9738	1,9421	1,5324		Golf-gaz.	1,9920	1,9956	1,9839	1,0775	
Forêt	1,9802	1,9979	1,9924	1,9496	1,7002	Forêt	1,9999	1,9999	1,9988	1,8535	1,8315
Entropie						Contraste					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	Res BD	Agricole	Golf-gaz.
ResHD	0,8671					ResHD	1,8351				
ResBD	0,6837	0,3616				ResBD	1,9350	0,7451			
Agricole	1,646	1,8813	1,7626			Agricole	1,9383	1,9904	1,9828		
Golf-gaz.	1,6767	1,9024	1,8157	0,8575		Golf-gaz.	1,9897	1,9953	1,9808	1,1737	
Forêt	1,9538	1,9857	1,9551	1,3329	1,1370	Forêt	1,9998	1,9999	1,9965	1,9077	1,8716

i \ j Le meilleur résultat entre 2 classes (i, j)

i \ j Tout résultat (i, j) supérieur à 1,9 (max 2)

Tableau 3.4 : Matrices de séparabilité des signatures de classes selon chacune des combinaisons de bandes spectrales possibles, en utilisant les huit types de textures

Bande 1.2						Bande 2.3					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	1,5574					ResHD	1,8116				
ResBD	1,4841	0,1743				ResBD	1,8771	0,4483			
Agricole	1,836	1,7017	1,5740			Agricole	1,7389	1,7039	1,5609		
Golf	1,8268	1,6639	1,4601	0,7731		Golf	1,3648	1,2832	1,3091	1,1653	
Forêt	1,9926	1,9929	1,9794	1,7575	1,6746	Forêt	1,7842	1,9610	1,9614	1,6320	1,3975

Bande 1.3						Bande 2.4					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	1,6578					ResHD	1,7047				
ResBD	1,8089	0,4581				ResBD	1,6089	0,1766			
Agricole	1,9677	1,8198	1,5571			Agricole	1,2723	1,7125	1,5819		
Golf-gaz.	1,9101	1,8542	1,6520	1,1801		Golf-gaz.	1,5941	1,9778	1,9582	1,2627	
Forêt	1,9984	1,9720	1,8631	1,4794	1,5608	Forêt	1,9448	1,9997	1,9947	1,7430	1,7324

Bande 1.4						Bande 3.4					
i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.	i \ j	Com-Indus	ResHD	ResBD	Agricole	Golf-gaz.
ResHD	1,7993					ResHD	1,6573				
ResBD	1,8149	0,2988				ResBD	1,8447	0,7629			
Agricole	1,7461	1,6131	1,4346			Agricole	1,3676	1,2797	1,1417		
Golf-gaz.	1,4281	1,6626	1,6957	1,3873		Golf-gaz.	1,4810	1,4936	1,3287	1,0471	
Forêt	1,9427	1,8832	1,8696	1,2584	1,7043	Forêt	1,9988	1,9919	1,9068	1,7965	1,8791

i \ j	Le meilleur résultat entre 2 classes (i, j)				
ResHD					
ResBD					
Agricole					
Golf-gaz.					
Forêt					

i \ j	Tout résultat (i, j) supérieur à 1,9 (max 2)				
ResHD					
ResBD					
Agricole					
Golf-gaz.					
Forêt					

Pour clore cet exercice, nous pouvons dire que les résultats du tableau 3.3 montrent nettement, par rapport aux résultats du tableau 3.1, que la texture couleur offre le meilleur pouvoir séparateur entre les classes. Parallèlement, les paires de bandes (tableau 3.4) offrent des meilleurs résultats que pour le tableau 3.2. Cependant, cette démarcation est plus difficile à observer de par le nombre différent de composants de ces tableaux. De plus, un fait intéressant à signaler est que le « jumelage » d'une bande du visible (ex. vert) avec une bande de l'infrarouge (ex. MIR) offre des meilleurs résultats comparativement à un jumelage entre deux bandes du visible ou deux bandes dans l'infrarouge. La corrélation plus forte entre deux bandes dans la même partie du spectre pourrait expliquer ces résultats.

3.2.3 : Meilleure séparabilité : gris ou couleur?

Afin de déterminer si l'utilisation de l'approche grise ou couleur influence la séparabilité, la différence entre les meilleurs résultats (couleur – gris) de chaque combinaison de classe a été effectuée pour les textures et les bandes (respectivement tableau 3.5 = maxima de tableaux (3.3 - 3.1) et 3.6= maxima des tableaux (3.4 - 3.2)). Les données pour les classes eau, ombre et nuage proviennent de l'annexe 1.

Tableau 3.5 : Séparabilité des classes avec textures variables et utilisations de toutes les bandes.

Comparaison des meilleures séparabilités par paires de classes (les cases jaunes des tableaux 3.1 et 3.3)								
textures	eau	om.	nuag.	c.i.	res.hd.	res.ld.	agricole	g.g.
ombre	++							
nuage	++	++						
com.ind.	++	++	++					
res.hd.	++	++	++	+				
res.ld.	++	++	++	+	-			
agricole	++	++	++	++	++	++		
golf/gaz.	++	++	++	++	++	++	+	
forêt	++	++	++	++	++	++	+	+
La meilleure séparabilité entre les classes ligne/colonne est:						++ : [1.9, 2]	+: [1, 1.9[- : [0, 1[
Couleur est:		mieux	pire	bien mieux	bien pire	égale	que gris	

Tableau 3.6 : Séparabilité des classes avec bandes variables et utilisations de toutes les textures.

Comparaison des meilleures séparabilités par paires de classes (les cases jaunes des tableaux 3.2 et 3.4)								
bandes	eau	om.	nuag.	c.i.	res.hd.	res.ld.	agricole	g.g.
ombre	++							
nuage	++	++						
com.ind.	++	++	++					
res.hd.	++	++	++	+				
res.ld.	++	++	++	+	-			
agricole	++	++	++	+	++	++		
golf/gaz.	++	++	++	+	++	+	+	
forêt	++	++	++	++	++	++	+	+
La meilleure séparabilité entre les classes ligne/colonne est:						++ : [1.9, 2]	+: [1, 1.9[- : [0, 1[
Couleur est:		mieux	pire	bien mieux	bien pire	égale	que gris	

Pour les tableaux 3.5 et 3.6, la distinction entre ++, + et – est effectuée selon la suggestion du logiciel PCI lors du calcul des distances de Bhattacharyya par SIGSEP. De plus, les distinctions entre les méthodes couleur et grise pour eau, ombre, nuage, peuvent être négligées, car elles sont de l'ordre de la 2^e voir 3^e décimale. De plus, la distinction entre «bien mieux, bien pire» et «mieux, pire» consiste en une différence absolue, et arbitraire, de 0,1 et plus, comparativement à 0,1 et moins, entre les distances de Bhattacharyya des deux approches.

Au tableau 3.5, on remarque immédiatement que la texture couleur offre des résultats nettement supérieurs, en fait seule la séparabilité agricole/golf-gazon subi un effet nettement négatif. Par contre, au tableau 3.6, quand on observe le comportement des bandes seules vs des paires de bandes, le résultat est plus mitigé. On observe une nette amélioration pour les classes primaires étudiées aux tableaux 3.1 à 3.4 (sauf agricole/résidentiel), mais un résultat généralement légèrement négatif pour toutes les combinaisons utilisant eau, ombre, nuage (sauf pour commercial/nuage qui est extrêmement négatif).

En conclusion, nous pouvons dire, que l'utilisation des huit mesures de texture calculées sur une seule bande (ou paires de bandes) offre de moins bons résultats que l'utilisation d'une seule mesure calculée sur l'ensemble des bandes (ou paires de bandes). Cela montre, selon nous, l'intérêt d'étendre les mesures de texture sur l'ensemble des bandes et, donc, de l'approche intégrative de Palm (2004) par rapport aux autres approches.

3.2.4-Formation des signatures texturales

Comme on l'a vu au chapitre 1, une signature texturale, telle que vue dans le présent ouvrage, est constituée d'une série de minimum 1 image par classe (ou plus si désiré, tableau 3.7) et optimisant n classes. Chacune des n textures n'optimise qu'une seule des n classes. Ainsi, le choix final des mesures de texture constituant les signatures texturales grises et couleurs qui seront utilisées pour la classification a été effectué sur la base des résultats de séparabilité montrés aux tableaux 3.1 à 3.4. Le résultat de cet exercice est présenté au tableau 3.7. Comme on peut le constater, les deux signatures sont composées de 14 mesures de texture différentes. Ces mesures sont celles qui permettent la meilleure séparabilité entre une classe donnée et le reste selon *l'union* (fig. 3.6) des deux tests de séparabilité soit des tableaux 3.1 \cup 3.2 et 3.3 \cup 3.4

lorsque la séparabilité est optimale. Par exemple, pour la classe commerciale-industrielle, au tableau 3.3, la corrélation optimise presque toutes les classes et au tableau 3.4, la paire de bande 2.3 est optimale, ainsi on obtient une corrélation sur la bande 2.3. De plus, pour ombre nuage et golf, puisque les meilleures séparabilités sont redondantes avec plusieurs mesures déjà utilisées pour d'autres classes, il n'a pas été jugé nécessaire d'augmenter davantage la dimensionnalité de la signature. Plus particulièrement, le choix des éléments des signatures texturales par classe, pour texture (tableaux 3.1 ou 3.3) et bande (tableaux 3.2 et 3.4), s'est fait en tenant compte (sans ordre particulier, pour autant que ce soit un élément optimal) :1) du nombre de cases jaunes (meilleurs résultats) dans une même ligne/colonne; 2) du nombre de cases avec >1.9 dans une même ligne/colonne; 3) de la séparabilité moyenne, si plusieurs mesures de texture/bandes donnent des résultats comparables.

Ainsi, le tableau 3.7 présente deux signatures texturales optimisées selon leurs composantes grises et couleurs. Diverses observations sont possibles :

- 1-) Bien que l'énergie et l'entropie soit fréquemment présente dans la signature grise, elles sont absentes de la signature couleur. De plus, moyenne semble moins utile pour la signature couleur. Cela démontre une différence fondamentale entre les deux approches.
- 2-) Les bandes présentes dans la signature grise, pour une classe donnée, reviennent dans la signature couleur, pour ces mêmes classes. Cependant, de nouvelles bandes font leur apparition dans l'approche couleur. Par exemple, pour les classes bâti, en gris on a exclusivement 1 et 3 tandis qu'en couleur on note une abondance de bande 2 en plus de 1 et 3. Cela semble démontrer un usage plus dense de l'information disponible, ce qui, hypothétiquement, permettrait une hausse de l'exactitude des classifications.
- 3-) De plus, certaines textures semblent unilatéralement appropriées à certaines classe, notamment agricole qui répond bien à l'homogénéité utilisée sur les bandes 1 et 3.
- 4-) Finalement, on note que la signature couleur met fortement l'accent sur corrélation, contraste et écart-type.

Tableau 3.7 : Signatures texturales optimisées, gris et couleur

	Utilisation pour classifications GRISES		Utilisation pour classifications COULEURS
Eau	entropie bande 4	Eau	contraste bandes 3.4
	énergie bande 4		écart-type bandes 3.4
Ombre	moyenne bande 4	Ombre	moyenne bandes 3.4
Nuage	contraste bande 4	Nuage	contraste bandes 2.4
Com.ind.	corrélation bande 3	Com.ind.	corrélation bandes 2.3
	contraste bande 1		contraste bandes 1.3
Res.HD	moyenne bande 3	Res.HD	écart-type bandes 1.2
	entropie bande 1		contraste bandes 1.2
Res. BD.	contraste bande 3	Res. BD.	corrélation bandes 1.2
	entropie bande 3		écart-type bandes 2.4
Agricole	homogénéité bande 3	Agricole	homogénéité bandes 1.3
	homogénéité bande 1		homogénéité bandes 3.4
Golf /	énergie bande 3	Golf /	homogénéité bandes 2.4
Gazon		Gazon	
Forêt	contraste bande 2	Forêt	écart-type bandes 1.3
	entropie bande 2		corrélation bandes 2.4

NB si une combinaison est déjà utilisée pour une classe précédente ex : écart-type 2.4 pour forêt en couleur, le meilleur résultat suivant a été considéré.

3.3- Résultats des tests de classification

Les signatures texturales du tableau 3.7 ont servi de base pour une série de tests de classification (par maximum de vraisemblance). Par ces tests nous avons voulu étudier les impacts sur les résultats de classification de :

- 1) l'orientation et le pas pour le calcul des vecteurs d'Unser ;
- 2) la taille de fenêtre du calcul des vecteurs d'Unser.

Les résultats de ces tests sont présentés par la suite, en premier pour l'orientation et la classification dans son ensemble, et en deuxième, au niveau de chaque classe d'occupation du sol. Le tout sera complété par les résultats d'un test de Student établissant la signification des différences entre les séries couleur et les séries grises (site de contrôle et vérification).

3.3.1 Qualité de la classification dans son ensemble

En fixant la taille de la fenêtre de calcul à 11×11 nous avons voulu examiner l'effet de la variation pas/orientation sur la classification. Cette taille représente la taille moyenne des fenêtres de calcul dont les effets seront examinés plus loin. Le graphique de la figure 3.7 montre les variations de l'exactitude globale de la classification calculée sur la base des sites d'entraînement du classificateur ainsi que des sites de vérification. Il est évident, par les graphiques, que ces deux paramètres de calcul influencent davantage les résultats de classification dans le cas des textures grises. En effet, on remarque un intervalle des valeurs d'exactitude qui tourne autour de 3% pour les classifications avec des textures grises comparativement aux textures couleurs où cet intervalle tourne autour de 1,5%. La source de cette différence n'est pas vraiment claire, mais on peut supposer que l'utilisation de multiples bandes normalise les disparités ou l'anisotropie associées à l'orientation que ce soit par les propriétés spectrales différentes ou possiblement les légères erreurs lors de la correction géométrique. Quoiqu'il en soit, cette observation n'influence en rien les conclusions de ce projet, mais pourrait être sujet à une analyse intéressante dans le futur. Une autre conclusion importante que l'on peut tirer de cette figure est que la classification par signature des textures

couleurs offre un rendement de classification qui tourne autour du seuil acceptable d'une bonne classification (85%) validée avec des sites de vérification, ce qui n'est pas le cas avec les textures grises. Concernant notre choix de départ de considérer un pas de 1 et une orientation parallèle à celle de l'orientation du soleil lors de l'acquisition de données (combinaison 1,1 dans la figure 3.7), nous pouvons dire qu'il est justifié. En effet, même si ce n'est pas la meilleure combinaison absolue (ce serait plutôt 0,1, de par sa meilleure moyenne globale), on est toujours dans la direction générale produisant les meilleures améliorations (voir tableau 3.8). Or, la meilleure amélioration ne voulant pas forcément dire meilleure exactitude, par exemple, l'orientation 1,2 (selon le tableau 3.8) offre la meilleure amélioration, mais la pire exactitude (figure 3.7, point de vérif.gris). Ainsi, il restera encore à l'utilisateur à adapter l'orientation à ses besoins.

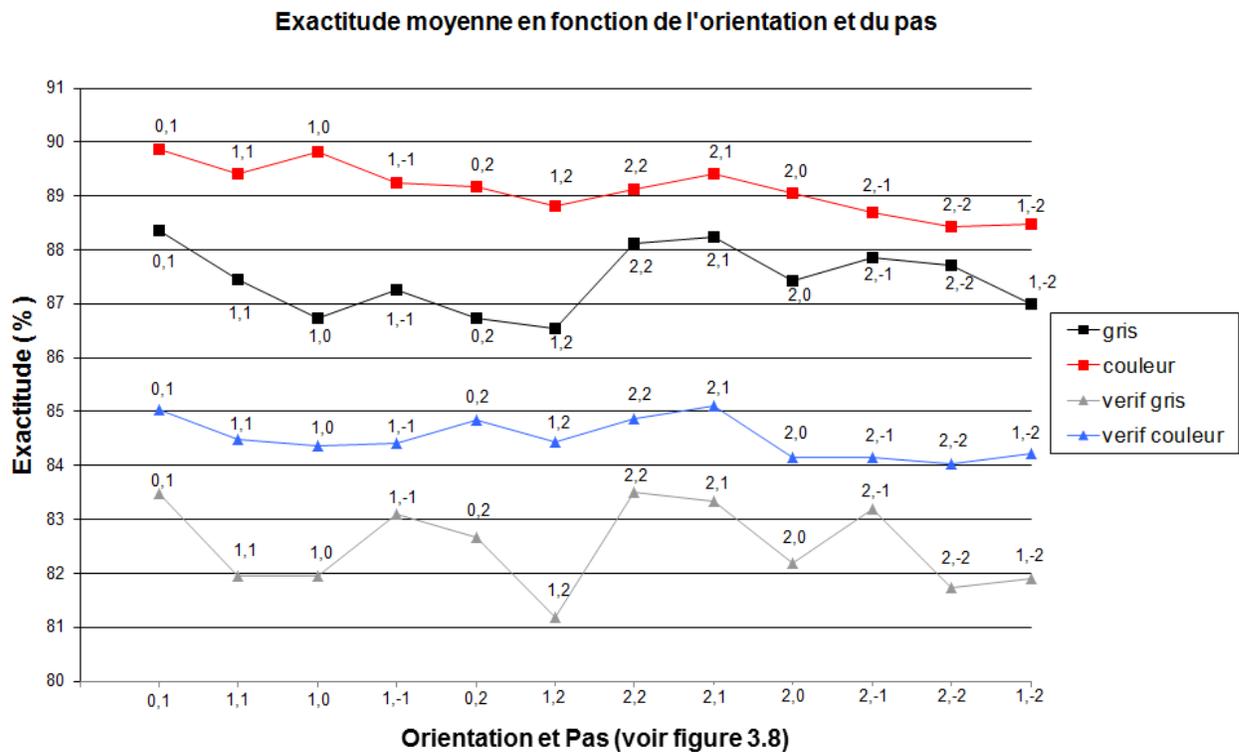


Figure 3.7 : Exactitudes de classification en fonction de l'orientation et du pas.

Tableau 3.8 : Différence d'exactitude moyenne selon l'orientation pour les couleur-gris

Orientation (ligne-colonne) Voir fig. 3.7					Différence moyenne Couleurs - Gris(%) et orientation(°)					
							0°		45°	
	Symétrique					Symétrique				Classes
		pixel i	0,1	0,2			pixel i	1,5	2,1 90°	[0 à 1% [
1,-2	1,-1	1,0	1,1	1,2	1,75	1,75	2,5	2,25	2,75	[1 à 2% [
2,-2	1,-2	2,0	2,1	2,2	1,4	0,8	1,75	1,5	1,2 135°	[2 à 3% [
pixel i= pixel de la co-occurrence(i,j),j dépend de l'orientation et du pas										

Les tests faisant varier la fenêtre de calcul ont révélé divers faits intéressants dont certains mériteraient un approfondissement particulier dans le futur. Au départ nous avions prévu de faire nos tests en progressant jusqu'à une fenêtre maximale de 21*21 pixels. Or, comme le montre la figure 3.8, aux alentours d'une fenêtre de 15*15, les exactitudes de classification varient d'une façon « étrange » particulièrement dans le cas des textures grises où l'on note une baisse de l'ordre de 40%. Quant aux textures couleurs, les exactitudes reviennent vers une valeur plafond qui tourne aux alentours de 90%, mais seulement après un « creux » en 15*15. Nous pouvons avancer comme cause possible la trop grande diffusion de l'information spatiale, causant peut-être une grande redondance/corrélation des mesures de texture. La différenciation des classes par l'algorithme du maximum de vraisemblance atteint donc un « seuil d'instabilité » après une fenêtre de 15*15 approximativement. Des tests effectués avec d'autres classificateurs (parallélépipède et distance minimum) ont présenté des problèmes similaires. Notez que cette instabilité semble provenir principalement des classes forêt, golf ainsi que résidentielle haute et basse densité dont la différenciation est la plus problématique. Cependant, bien que cette explication soit adéquate pour l'approche par textures grises, elle n'explique pas le comportement ponctuel de l'erreur par les textures couleurs. Théoriquement, on peut supposer qu'un effet du patron des classes principalement affectées (résidentielles), combiné à l'effet de diffusion et à la meilleure séparabilité générale des textures couleurs, est à la base de l'erratique en 15*15. En somme, si cela ne dépassait pas le cadre de ce mémoire, c'est une question qui mériterait un examen approfondi, surtout quant à la relation qu'entretiennent

les diverses mesures de texture lorsque la fenêtre de calcul devient grande (par rapport à la résolution spatiale de l'image utilisée). Pour le reste des tests nous avons décidé de considérer la fenêtre de 15*15 pixels comme la limite supérieure. De plus, l'unique point erratique des courbes couleur, en 15*15 étant suivi de trois points successivement corrects, il a été jugé intéressant de procéder à une interpolation, entre les exactitudes en 13*13 et 17*17, dans tous les graphiques qui suivront. Quant aux courbes des textures grises, les résultats supérieurs à 15*15 sont considérés erratiques et exclus. Finalement, notez que les points associés à la taille 1*1 des graphiques subséquents, ne sont pas des textures, mais une classification directe, à titre comparatif, des bandes originales, soit panchromatique (rééchantillonnée à 10m) en gris et les quatre bandes multispectrales en couleur.

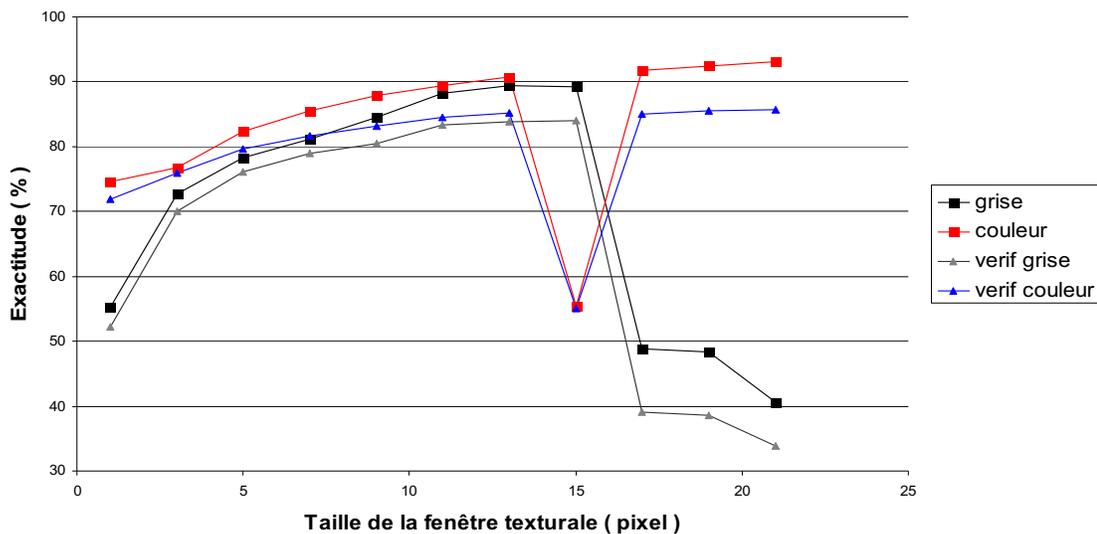


Figure 3.8 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre texturale

Si l'on se limite aux résultats jusqu'à la fenêtre de 15*15 nous pouvons faire les constats suivants : 1) les deux types de signature donnent des exactitudes qui augmentent d'une façon régulière avec l'accroissement de la taille de la fenêtre jusqu'à une taille de 11*11. À partir de cette taille les changements de l'exactitude semble vouloir plafonner. 2) Que ce soit avec les sites d'entraînement ou les sites test, les classifications avec les textures couleurs offrent une exactitude significativement supérieure (tableau 3.9) de quelques pourcentages jusqu'à une

fenêtre de 9*9 (résultat partiel en 9*9), à partir de laquelle textures grises et couleurs se rejoignent à toutes fins pratiques.

La figure 3.9 montre d'une autre façon la variation de la qualité des classifications en fonction de la taille de la fenêtre. Ici, on emploie le coefficient Kappa calculé à partir des différentes matrices de confusion. Le tableau 3.9 montre la comparaison statistique entre les Kappa gris et couleur pour la même taille de fenêtre. Ce test a été effectué en suivant les recommandations de Skidmore (1989). C'est un score Z qu'on estime à l'aide des valeurs Kappa et de leur variance calculés par matrice de confusion. Il permet de se prononcer s'il y a une différence significative entre les deux matrices de confusion. :

$$Z = (\text{Kappa}_{\text{couleur}} - \text{Kappa}_{\text{gris}}) / \sqrt{(\text{Variance}_{\text{Kappa}_{\text{couleur}}} + \text{Variance}_{\text{Kappa}_{\text{gris}}})}$$

Le test statistique (tableau 3.9) montre que les matrices de confusion sont significativement différentes à l'exception de 9*9 pour les courbes vérifications. L'effet de pic de la texture grise, observé en 7*7 est explicable par un effet de la géométrie des quartiers des classes résidentielles sur l'anisotropie de la texture mieux captée par les textures grises.

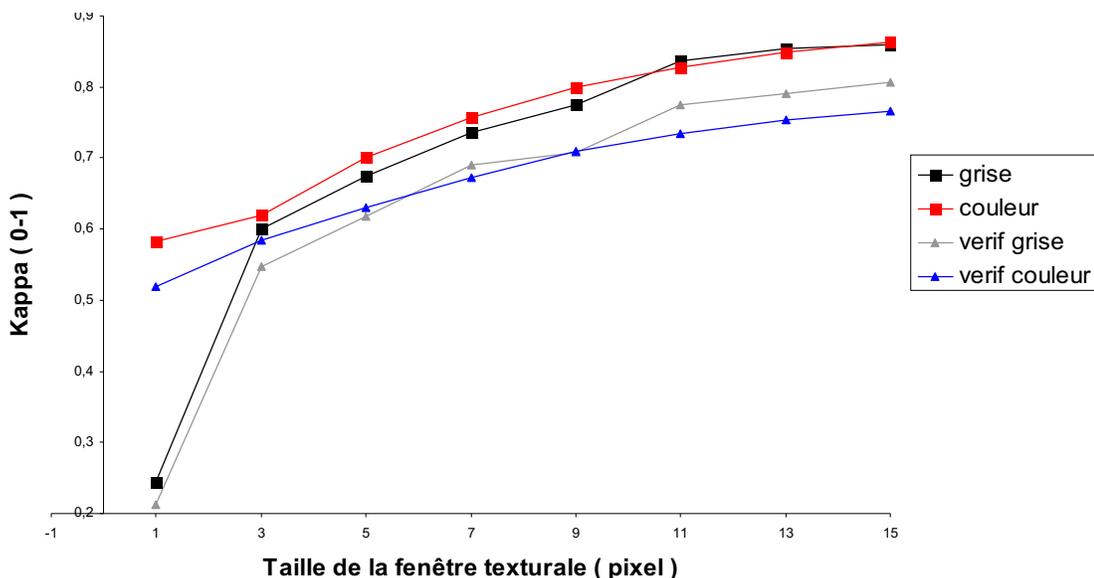


Figure 3.9 : Variations du coefficient Kappa des classifications en fonction de la taille de la fenêtre

Tableau 3.9 : Test de Z pour la séparabilité des classifications originale et vérification

Fenêtre	1*1	3*3	5*5	7*7	9*9	11*11	13*13	15*15
Z	186,11	10,71	15,5	12,31	15,98	-5,96	-3,5	2,09
Z vérification	138,61	18,25	6,63	-9,74	0,41	-22,77	-22,85	-16,51
Normalité $\alpha=0,05$ Ssi valeur $x > 1,96$	Oui	Oui	Oui	Oui	Non	Oui	Oui	Oui

3.3.2-Qualité de classification par classe

Passons maintenant à l'étude des exactitudes par classe d'occupation du sol. Pour présenter les résultats, nous les avons regroupés selon leur texture visuelle en trois catégories : 1) les classes de faible texture (eau, ombre, nuage); elles sont des classes relativement faciles à séparer du reste même avec un simple seuillage d'histogramme; 2) les classes du bâti, (commerciale-industrielle, résidentiel HD, résidentiel BD) présentant beaucoup de surfaces pâles et une texture plus ou moins régulière et 3) les classes les plus végétalisées (agricole, golf-gazon, forêt) présentant une texture plus au moins fine. Seulement les effets de la taille de la fenêtre ont été analysés ici.

1) Eau, ombre, nuage :

La figure 3.10 montre les variations de l'exactitude de classification en faisant varier la taille de la fenêtre. Pour les trois classes, tel qu'attendu, la taille de la fenêtre de calcul ne joue pas un rôle important, de par le plafonnement apparent des exactitudes de leurs classifications qui demeurent de très bonnes (ombre, nuages) à excellentes (eau).

Pour la classe eau (Figure 3.10a), mise à part une nette amélioration apportée par l'utilisation de multiples bandes pour la taille 1*1, donc sans traitement textural, la méthode couleur semble légèrement supérieure à la grise. Cependant étant donné que la seule texture potentiellement présente est une certaine turbidité de l'eau dans certaines bandes, on peut penser que seul l'élément spectral influence l'exactitude.

Il en va de même pour la classe ombre et nuage (Figure 3.10b et c respectivement). La différence observée à 3*3 pour nuage serait potentiellement explicable par un effet de bordure (nuage/sol) des nuages moins bien définis de la bande 3 (fig. 3.1), sur les polygones de contrôle. Cet effet est atténué par la combinaison (couleur) de bandes ou les nuages sont plus clairs.

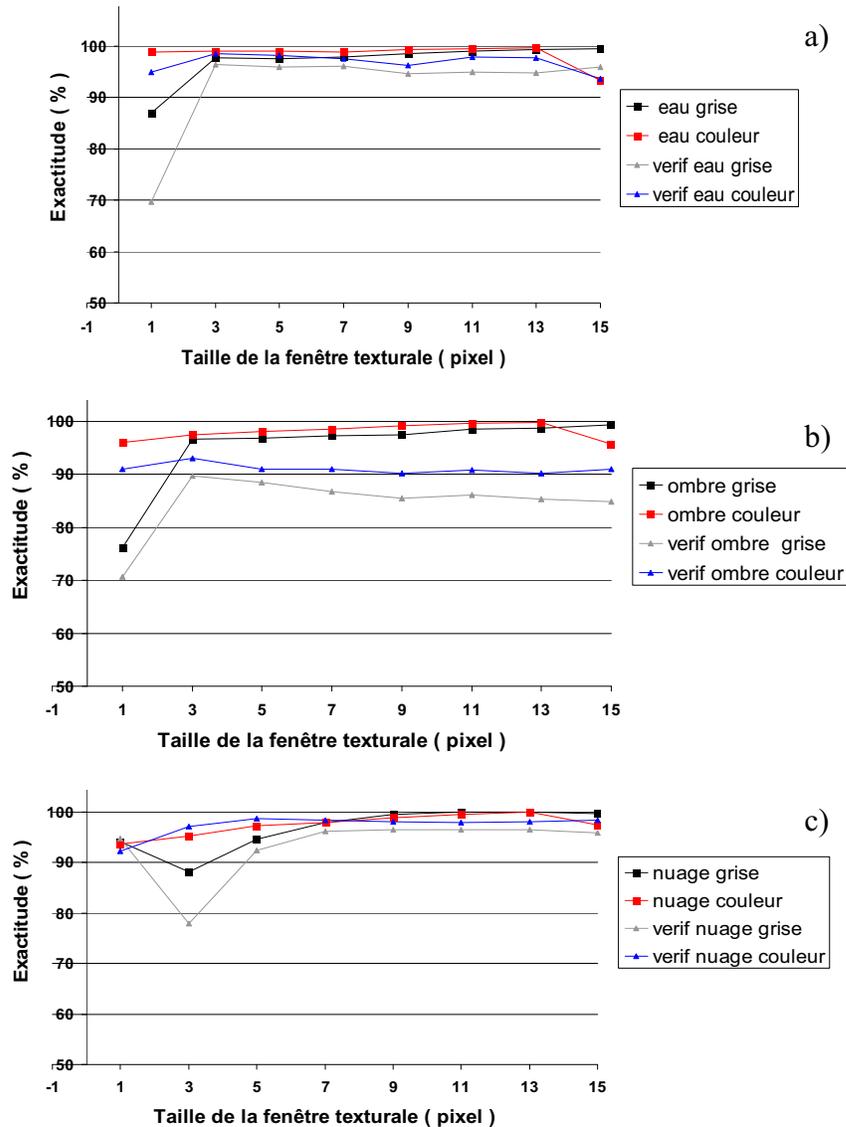


Fig. 3.10 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre de calcul, classes (a) eau, (b) ombre et (c) nuage.

2) *Les classes du bâti :*

La figure 3.11 présente les variations de l'exactitude de classification en faisant varier la taille de la fenêtre. Parmi les classes du bâti seule la classe commerciale/industrielle (Figure 3.11a) atteint des exactitudes de 85% ou plus. Les classifications par textures couleurs atteignent cette exactitude plus rapidement à une fenêtre de 9*9. À partir de cette taille de fenêtre, les exactitudes selon les deux signatures sont comparables avec un léger avantage des textures grises.

Tel que montré par les analyses de séparabilité, les classes résidentielles basse et haute densité sont problématiques, que ce soit avec des textures grises ou couleurs. Le comportement des textures couleurs demeure tout de même avantageux, par rapport aux textures grises, pour la classe résidentielle haute densité, où, à partir d'une fenêtre 7*7, une exactitude de presque 80% est atteinte. La seule différence entre le résidentiel HD et BD est la différence dans la taille de bâtiments ainsi que la densité du couvert végétal. Possiblement, la résolution spatiale de 10 m de l'image n'est pas sensible à la texture créée par l'agencement « petits bâtiments-points de végétation ». De plus on observe (b,c) que la texture couleur pour les zones résidentielles est plus stable et régulière que la texture grise, ce qui laisse croire que la texture couleur est effectivement plus appropriée lors d'une problématique de haute confusion entre classes.

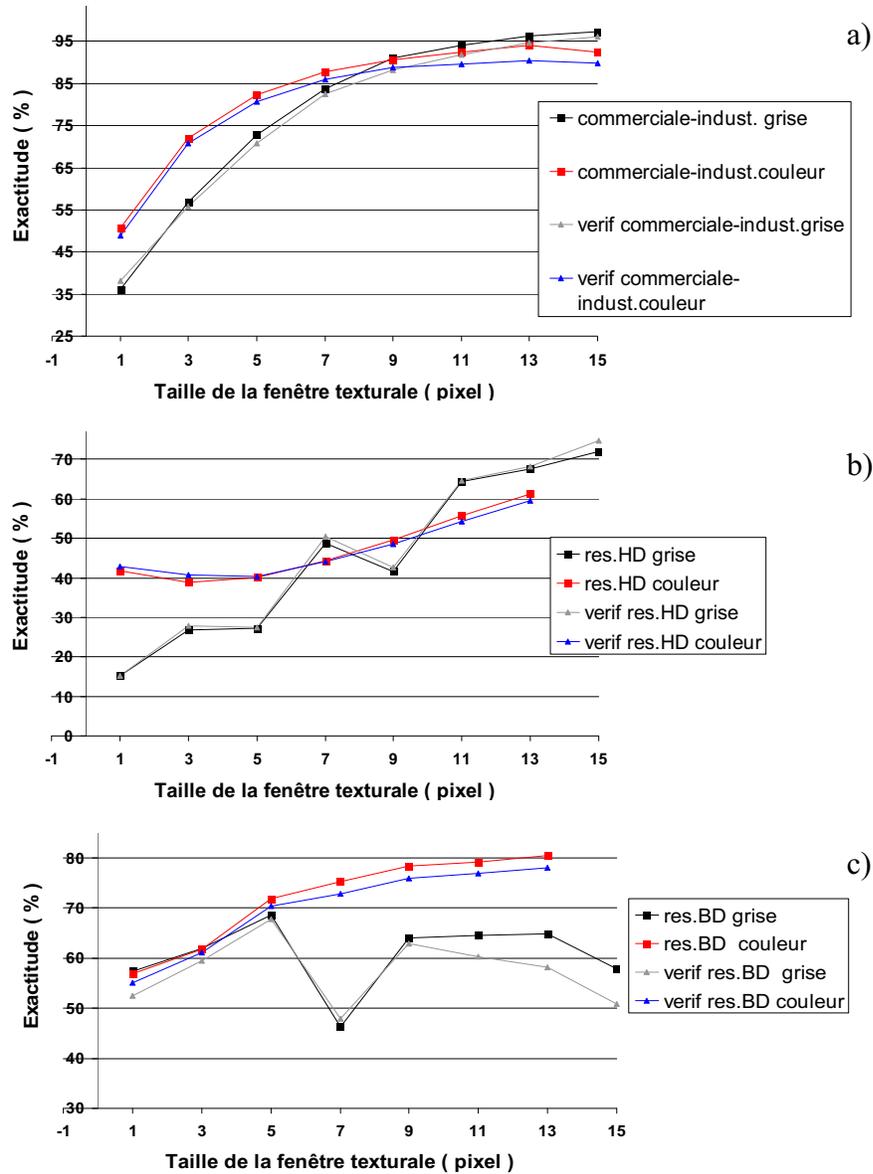


Fig. 3.11 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre de calcul, classes (a) commerciale/industrielle (b) résidentielle haute densité (HD) et (c) résidentielle basse densité (BD).

3) Classes végétalisées :

La figure 3.12 présente les variations de l'exactitude de classification en faisant varier la taille de la fenêtre. Parmi les trois classes, la forêt présente les meilleures exactitudes qui demeurent, pour la plupart des fenêtres, de 90% et même plus, particulièrement pour les textures couleurs. Viennent par la suite la classe agricole pour les textures grises et la classe golf/gazon, particulièrement pour les textures couleurs. Fait marquant à signaler pour les deux classes où la texture couleur domine (forêt, golf/gazon), des fortes exactitudes sont atteintes à partir des petites fenêtres (5*5).

En ce qui concerne la classe golf-gazon, elle est définitivement le résultat le plus marquant de la texture couleur. Elle affiche une amélioration de l'exactitude de 20%, et par extension, une forte hausse de la séparabilité des classes nécessitant des faibles fenêtres étant donné la finesse de la texture de cette classe (voir tableau 3.10). La classe de golf/gazon étant généralement très peu différente de la classe forêt ou agricole, et un parcours de golf étant étroit (rarement plus de 5-6 pixels de large, coïncidant avec le pic des courbes couleurs), il est important d'avoir une fenêtre de cette taille ainsi qu'une méthode adaptée à cette fin. On voit nettement que c'est exactement le cas pour la texture couleur, le pic des exactitudes est situé à 5*5 suivi par un plafonnement / déclin pour les fenêtres plus grandes.

Quant à la classe agricole, elle semble constituer la faiblesse de l'approche par textures couleurs. En effet, bien que les exactitudes dépassent partiellement les 85%, il s'agit de la seule classe où les textures grises sont systématiquement supérieures. Afin d'expliquer ce phénomène, la grande hétérogénéité de la classe pourrait être mis en cause, comme on pourra le voir lors de l'analyse des matrices de confusions.

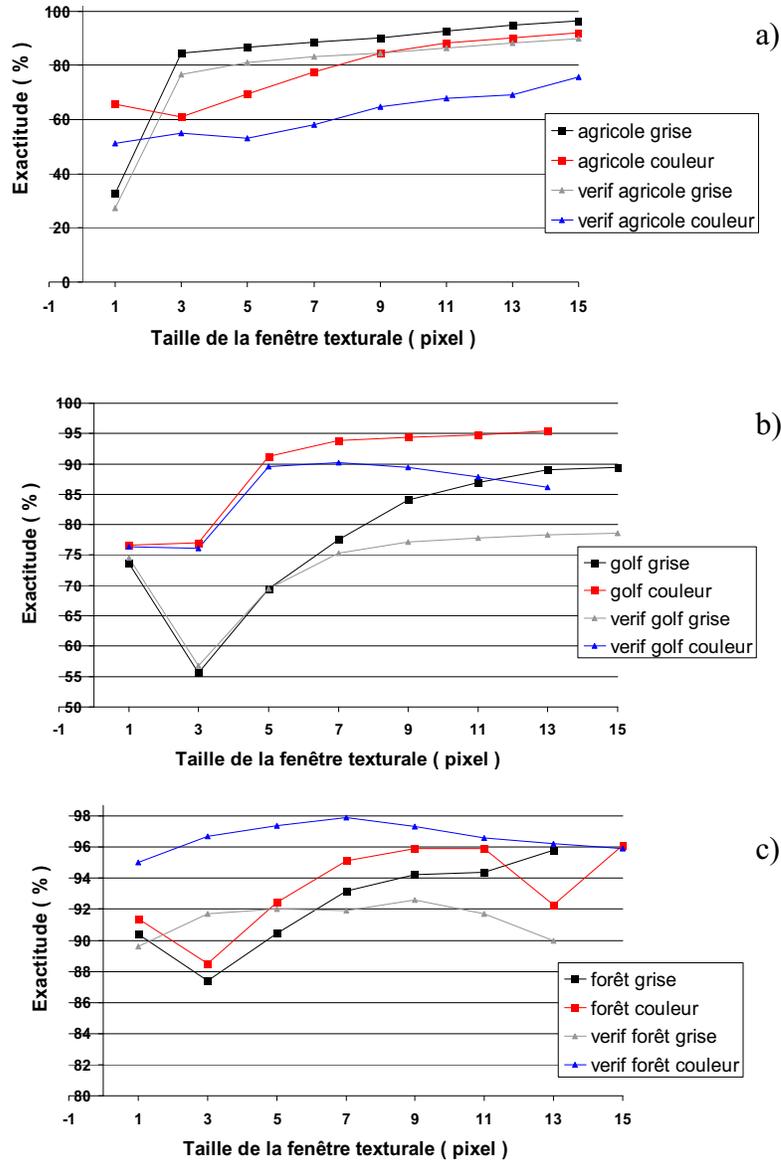


Fig. 3.12 : Variation de l'exactitude des classifications en fonction de la taille de la fenêtre de calcul, classes (a) agricole, (b) golf/gazon et (c) forêt.

Pour conclure cette section sur les exactitudes des classifications en fonction des tailles de fenêtres, une analyse de la signification des différences (test de Student) a été effectuée entre les exactitudes couleur et grises, pour chaque taille de fenêtre. Ces différences ont été calculées en tenant compte de toutes les exactitudes montrées dans les figures 3.10 à 3.13. Ainsi, le tableau 3.10 montre les résultats de ces test pour $n=20$ et $\alpha=0,05$.

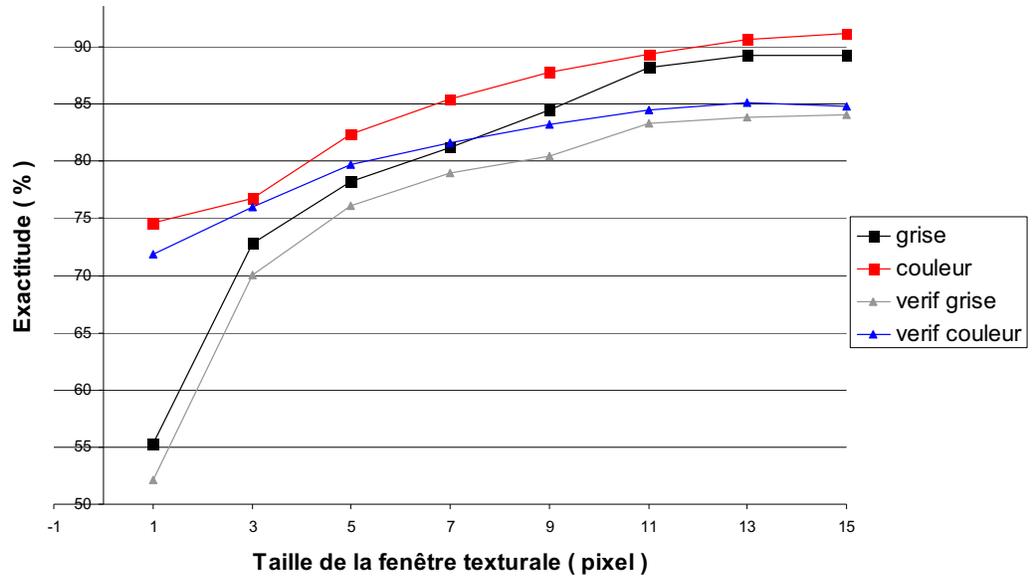


Fig 3.13: Variation de l'exactitude des classifications en fonction de la taille de la fenêtre de calcul, pour toutes les classes

Tableau 3.10 : Tests de Student en fonction de la taille de fenêtre texturale

taille de fenêtre	1*1	3*3	5*5	7*7	9*9	11*11	13*13	15*15
test Student significatif à $\alpha=0,05$	2,554	2,626	2,465	2,638	1,668	1,819	1,883	2,338
oui: la différence est significative ssi $x > 2,093$	oui	oui	oui	oui	non	non	non	oui

Ces résultats, vont dans le sens des résultats précédents et démontrent la signification des différences d'exactitude pour les petites tailles de fenêtres.

3.3.3- Semi-variogrammes et taille des fenêtres de calcul

Afin de valider les résultats des analyses précédentes sur l'effet de la taille des fenêtres selon les type de classes (ex. : le cas 7*7 pour résidentiel), ainsi que de déterminer les tailles de fenêtres les plus pertinentes à analyser (si les formes d'une classe ont une taille de 7 pixels, il est inutile d'utiliser des textures 15*15) une analyse des semi-variogrammes pour chaque type de classes a été effectuée. En plus des trois exemples présentés à la figure 3.14, le tableau 3.11 présente les points d'inflexion indiquant la taille maximale des textures principales constituant une classe donnée. On remarque que la taille maximale moyenne estimée est d'environ 9 pixels pour la classe eau (normalement l'eau pure et profonde n'a pas de limite étant lisse, mais la turbidité et la présence de hauts fonds a certainement influencé ce résultat). Pour le cas problématique du pic 7*7 de la figure 3.11b de la classe résidentielle (ainsi qu'une certaine périodicité de 3 pixels dans les courbes grises), on remarque un point d'inflexion moyen de 3. Le semi-variogramme étant estimé dans une seule direction et la fenêtre texturale étant calculée dans un rayon de 3,5 pixels du point central (donc 3 pixels à gauche, 1 central et 3 à droite) on peut conclure que cela explique le phénomène. Finalement, on note qu'en combinant les zones ayant une texture plus grossière, voire homogène, qui tendent à avoir un point d'inflexion plus élevé (commercial, grands bâtiments, agricole...), avec les classes fines (résidentiel golf-gazon), le profil général aura une moyenne légèrement inférieure à 6. Ainsi, si l'on se base sur la relation du point d'inflexion d'un semi-variogramme vs la taille de fenêtre texturale, on obtient une taille optimale d'environ 11*11. Ce qui n'est pas loin de la fenêtre 9*9 utilisée lors des calculs de séparabilité pour la création des signatures. Étant donné que la classe résidentielle occupe plus de la moitié de la carte et que sa texture est plus fine on peut conclure que le choix de la fenêtre 9*9 est justifié.

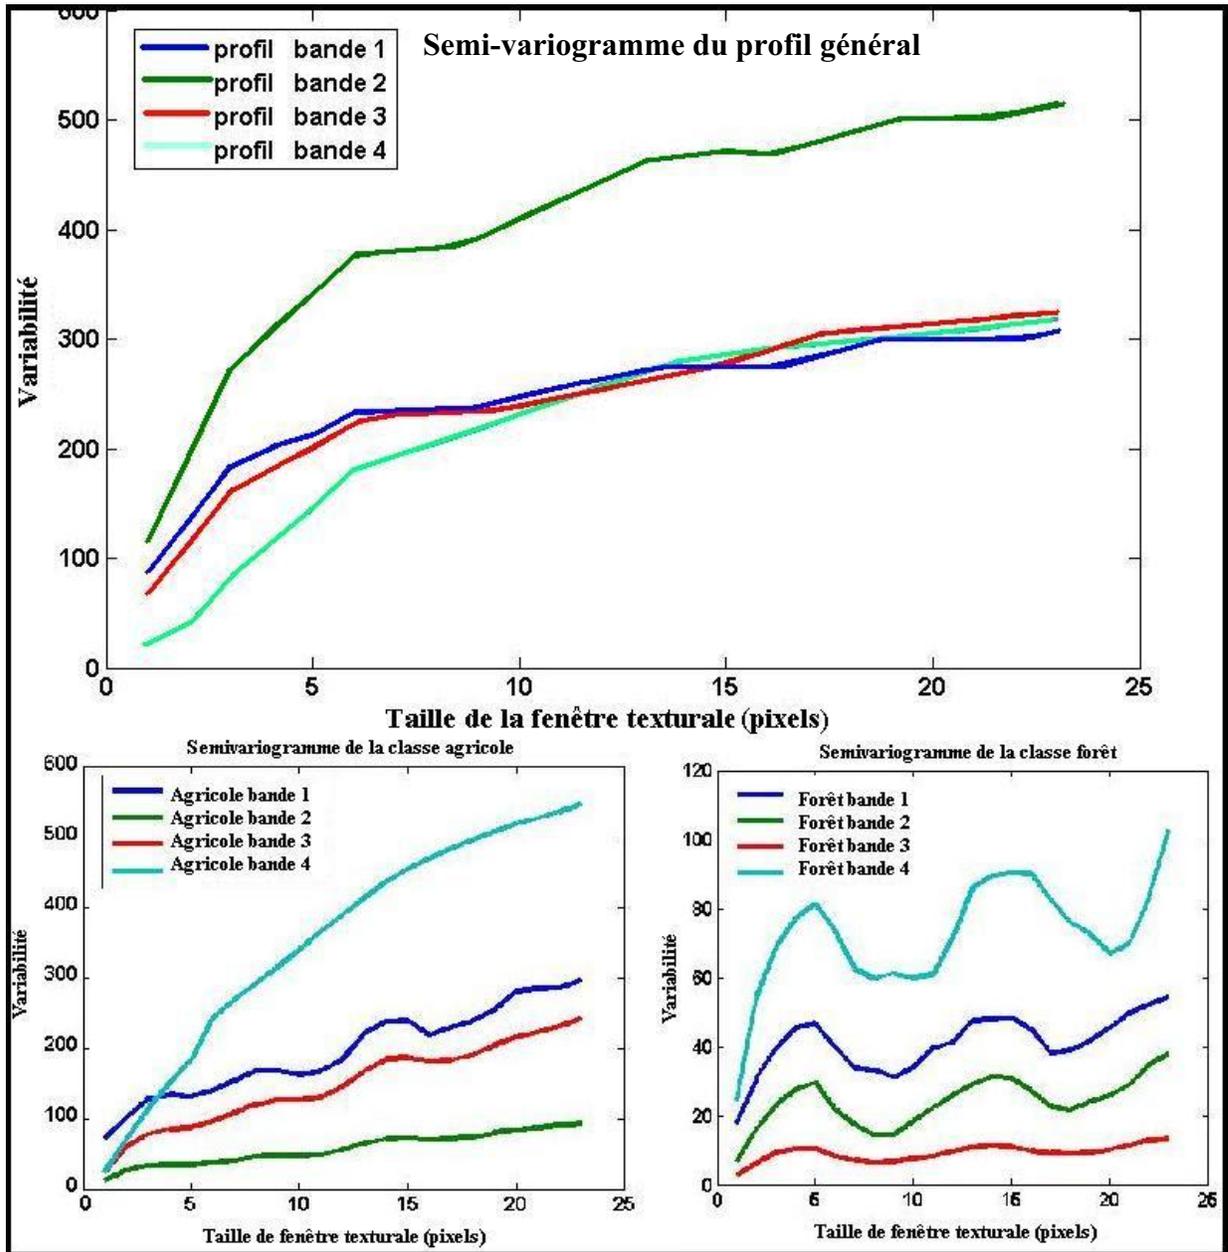


Fig. 3.14 : Semi-variogrammes des profils diagonaux pour : toute l'image, agricole et forêt pour les 4 bandes SPOT-5.

Tableau 3.11 :Position (en pixels) du point d'inflexion des semi-variogrammes				
Classedirection	horizontale	verticale	diagonale	moyenne
eau	6	10	11	9
oombre nuage	échantillon trop petit			
nuage	échantillon trop petit			
comm-ind	7	9	5	7
res.haut. dens.	2	3	4	3
res.bas. dens.	5	4	7	5
agricole	5	7	5	6
golf gazon	3	4	3	3
forêt	4	4	6	5
Profil général	5	6	6	6

NB. : Par le faible nombre de points utilisé pour les calculs dans chaque classe (sauf pour profil général qui a 1000pixels) les résultats sont extrêmement instables, particulièrement pour des classes avec des profils hétérogènes comme pour résidentiel HD et BD.

Finalement, il est intéressant de noter la différence des points d'inflexion pour les deux classes de résidentiel. Selon nous, cette différence s'explique par la densité du bâti. Ainsi, pour la classe haute densité le point d'inflexion moyen est de 3 vs 5 (bâtiments collés vs distants).

3.4- Exemples de classification et observations

La présente section montre des exemples visuels des améliorations apportées par les textures couleurs pour les tailles de fenêtre 5*5 et 11*11. De plus, le lecteur devra effectuer un lien entre les matrices de confusions (tableau 3.12), les principaux changements identifiés (cercles rouges sur les fig. 3.15 à 3.18) et la carte de vérité terrain (fig. 3.19).

De façon plus globale on remarque immédiatement (figures 3.15 à 3.18) la différence entre les deux tailles de fenêtres. En effet, les zones d'occupation sont beaucoup plus homogénéisées lorsqu'on applique une fenêtre de plus grande taille. Cet effet est certainement à l'origine de l'augmentation des qualités de classification avec l'augmentation de la taille de fenêtre. Puisque les sites d'entraînement pour certaines classes, tel que résidentiel, incluent nécessairement des éléments de classe forestière et gazon, voir même commercial, la seule façon d'homogénéiser la zone est d'augmenter la taille de fenêtre afin de diminuer la proportion des « erratiques ».

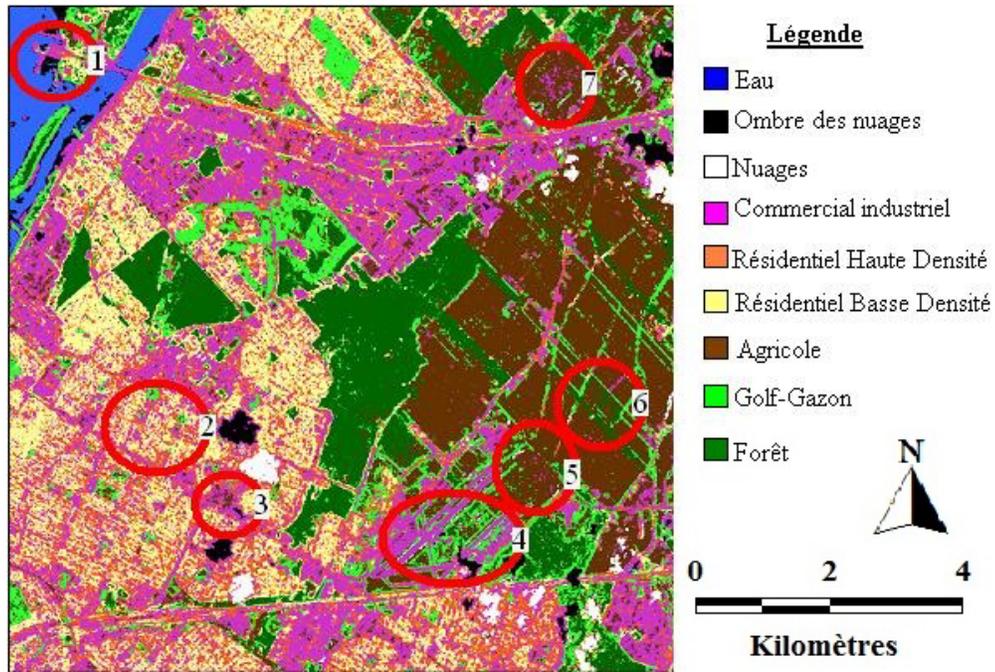


Fig. 3.15 : Classification par les textures grises avec une fenêtre 5*5 orientation 1,1

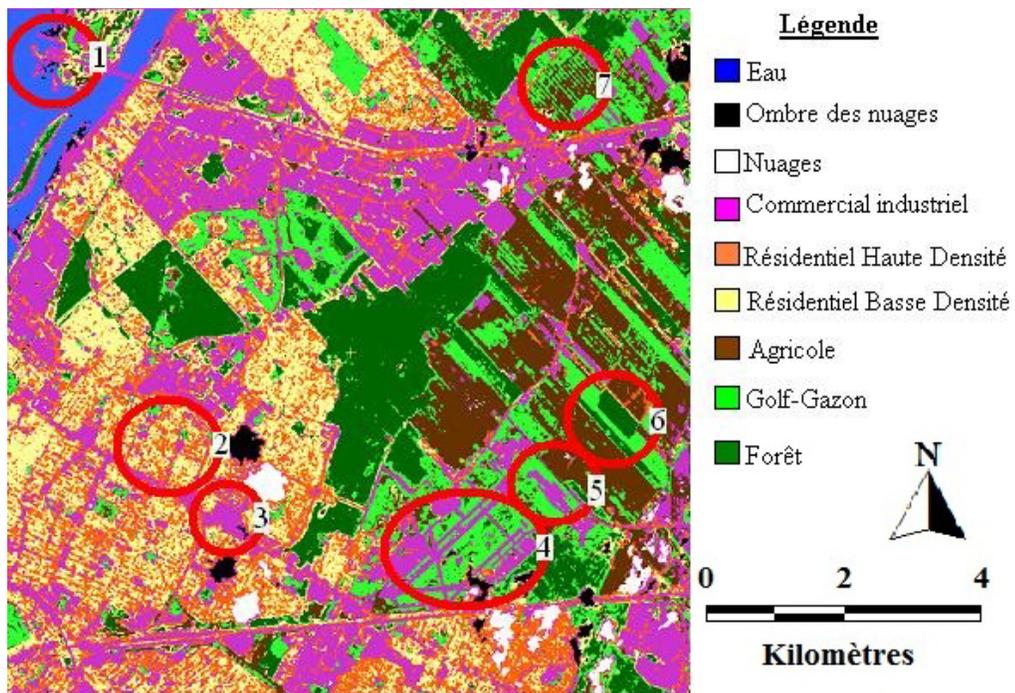


Fig. 3.16 : Classification par les textures couleurs avec une fenêtre 5*5 orientation 1,1

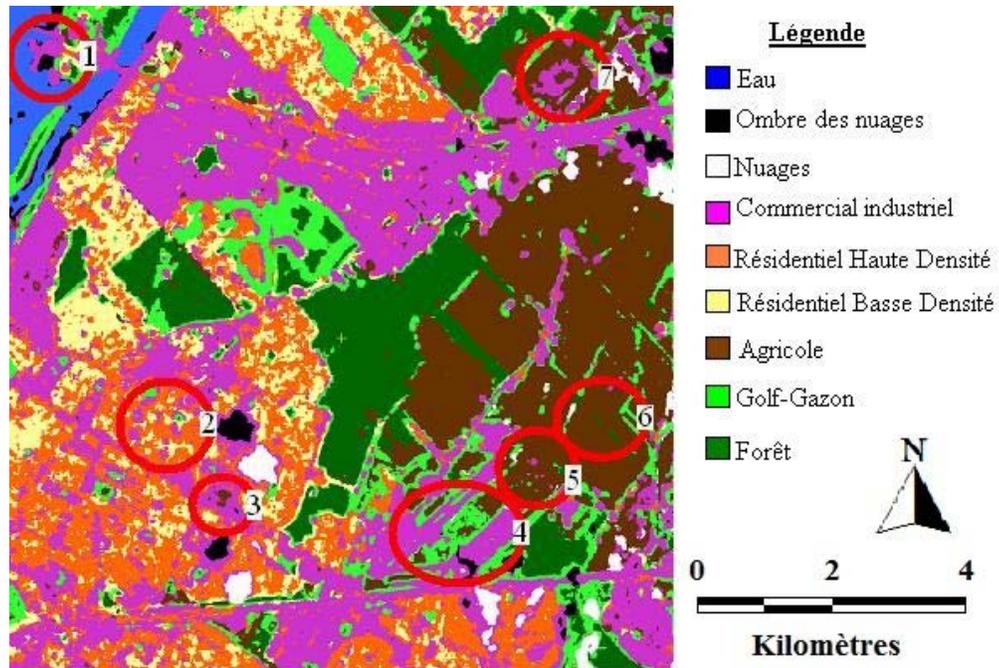


Fig. 3.17 : Classification par textures grises avec fenêtre de 11*11 orientation 1,1

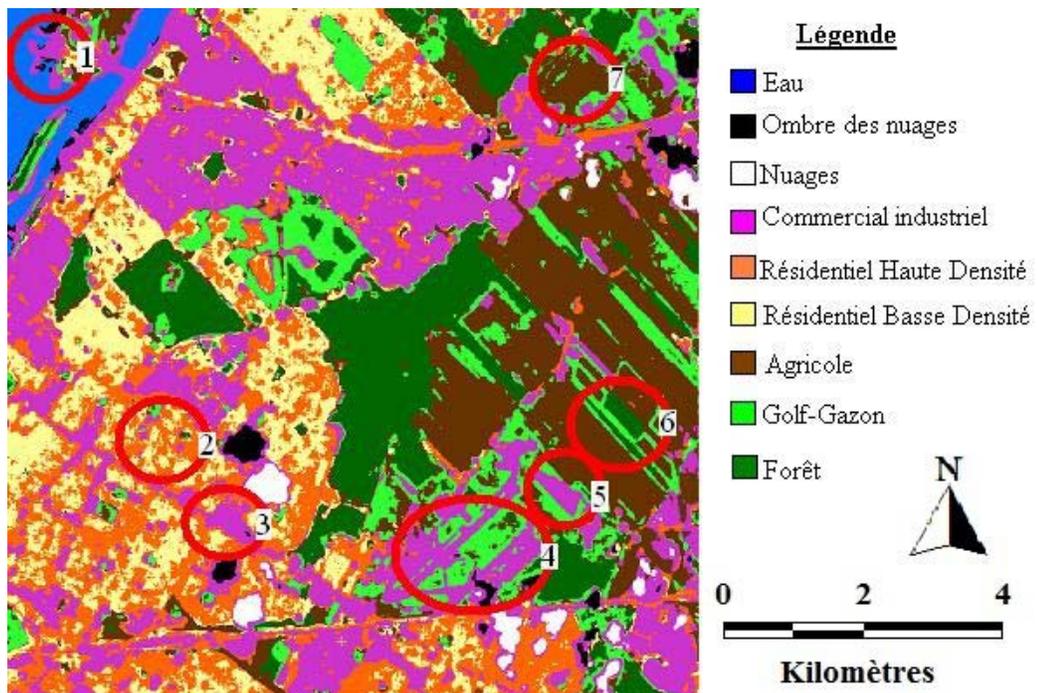


Fig. 3.18 : Classification par textures couleurs avec fenêtre de 11*11 orientation 1,1

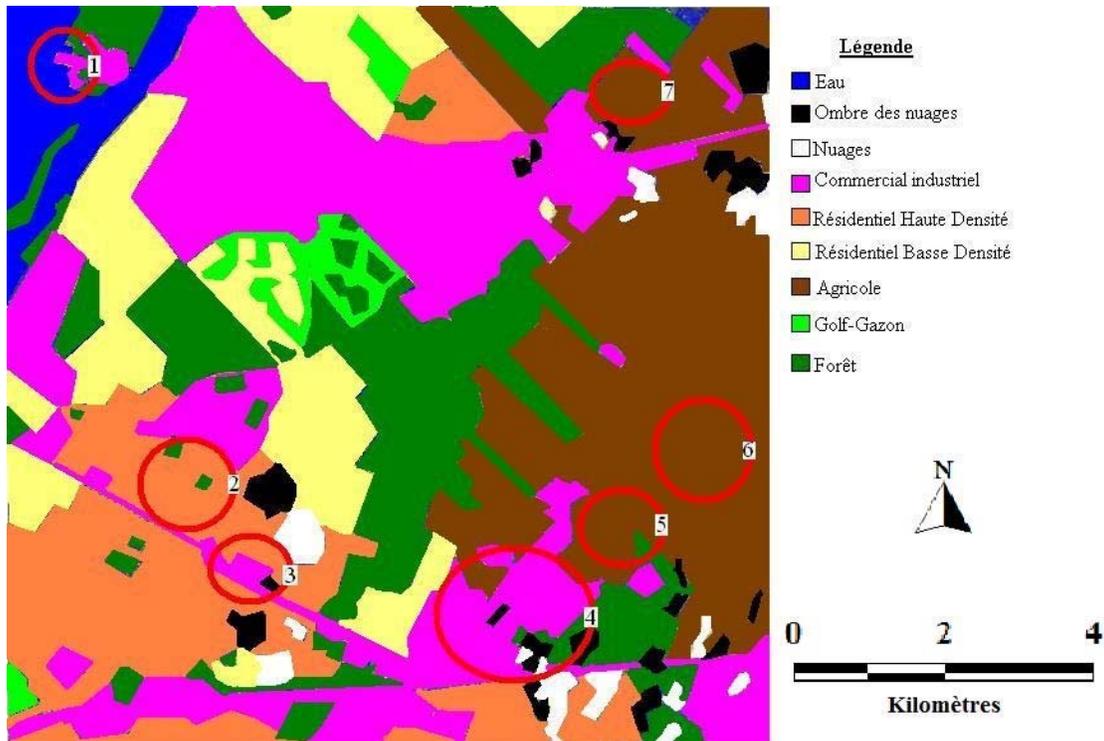


Fig. 3.19: Vérité terrain obtenue par photo-interprétation

Les figures 3.15 à 3.19 possèdent des cercles rouges numérotés qui correspondent aux observations suivantes :

1) À ce point on peut observer, conformément aux résultats du tableau 3.12, une légère diminution de la confusion entre les classes eau (plus précisément les zones de berges peu profondes) et ombre de nuage.

2) Ici, pour les images 5*5 on observe que les classes résidentielles HD et BD semblent être légèrement plus distinctes et présentent moins de confusions avec la classe commerciale/industrielle. La classe HD est mieux définie, cependant pour la 11*11 le taux de confusion pour le résidentiel HD va en croissant pendant que le BD diminue. C'est un exemple montrant l'utilité des textures couleurs pour des classes idéalement associées à de petites fenêtres texturales, l'usage d'une grande fenêtre fait perdre une bonne partie de l'information sur le HD.

3) et 7) À ces points, on remarque que la confusion entre les classes commerciale/agricole (3), et agricole/commerciale (7), est nettement inférieure pour les classifications des textures couleurs, et ce, peu importe la taille de fenêtre utilisée.

4) Entre les pistes de l'aéroport de Saint-Hubert, on remarque que les méthodes grises ont identifié plus de la moitié de l'espace comme étant agricole. Il s'agit d'une mauvaise attribution qui est presque parfaitement corrigée par les classifications selon la méthode couleur.

5) et 6) Cependant, les améliorations au point 3, 4 et 7 se font au grand détriment de la classe agricole qui est respectivement confondue avec la classe commerciale/industrielle (5) et les classes forêt et gazon (6) aux points 5 et 6.

Après ces quelques appréciations qualitatives, on peut transposer ces mêmes analyses au tableau 3.12, représentant les matrices de confusion et leurs différences selon l'approche.

Tableau 3.12 : Matrices de confusions

	bonne classification
	aucune confusion
	moins de 1% de confusion
	1% à 5% de confusion
	5% à 10% de confusion
	10% et + de confusion

Matrice de confusion pour fenêtre 5*5 de texture grise (en %)

	nbr. de pixels	eau	ombre nuage	Nuage	com.-ind.	res.haut. dens.	res.bas. dens.	agricole	golf gazon	forêt
eau	5165	97,48	0,5		0,74				1,28	
ombre nuage	2320	0,04	96,81		1,94				1,21	
nuage	2822			94,51	3,9	0,39		1,17	0,04	
com.-ind.	38054		0,19	0,4	72,85	12,21	2,35	7,3	4,2	0,49
res.haut. dens.	25964				24,95	27,32	45,16	0,8	1,76	0,01
res.bas. dens.	14490				13,75	14,4	68,55	0,6	2,37	0,32
agricole	38174		0,01	0,1	1,56	0,91	0,18	86,55	6,61	4,08
golf gazon	7468			0,36	1,35	0,52	0,25	22,98	69,44	5,09
forêt	29562		0,07	0,01	0,15	0,05	0,68	3,35	5,24	90,45

78,22 moyenne de la diagonale

72,96 moyenne pondérée selon le nombre de pixel par classe

Matrice de confusion pour fenêtre 5*5 de texture couleur (en %)

	nbr. de pixels	eau	ombre nuage	nuage	com.-ind.	res.haut. dens.	res.bas. dens.	agricole	golf gazon	forêt
eau	5165	99,01			0,91	0,04			0,04	
ombre nuage	2320		98,02		0,82	0,47	0,69			
nuage	2822			97,2	1,88	0,6		0,32		
com.-ind.	38054			0,43	82,26	9,43	2,46	0,61	4,36	0,45
res.haut. dens.	25964			0,03	15,12	40,01	42,85	0,42	1,52	0,06
res.bas. dens.	14490				4,84	20,14	71,86	0,4	2,24	0,51
agricole	38174			0,25	1,82	1,97	0,76	69,31	22,15	3,73
golf gazon	7468				2,37	0,27	0,25	3,47	91,26	2,36
forêt	29562		0,05		0,24	0,26	0,8	0,18	6,03	92,43

82,38 moyenne de la diagonale

74,89 moyenne pondérée selon le nombre. de pixel par classe

Différence d'exactitude et de confusion Couleur-Gris pour une fenêtre 5*5 (en %)

	nbr. de pixels	eau	ombre nuage	nuage	com.-ind.	res.haut. dens.	res.bas. dens.	agricole	golf gazon	forêt
eau	5165	1,53	-0,5		0,17	0,04			-1,24	
ombre nuage	2320	-0,04	1,21		-1,12	0,47	0,69		-1,21	
nuage	2822			2,69	-2,02	0,21		-0,85	-0,04	
com.-ind.	38054		-0,19	0,03	9,41	-2,78	0,11	-6,69	0,16	
res.haut. dens.	25964			0,03	-9,83	12,69	-2,31	-0,38	-0,24	0,05
res.bas. dens.	14490				-8,91	5,74	3,31	-0,2	-0,13	0,19
agricole	38174		-0,01	0,15	0,26	1,06	0,58	-17,2	15,54	-0,35
golf gazon	7468			-0,36	1,02	-0,25		-19,5	21,84	-2,73
forêt	29562		-0,02	-0,01	0,09	0,21	0,12	-3,17	0,79	1,98

Δmoyenne diagonale +4,161

Différence d'exactitude et de confusion Couleur-Gris pour une fenêtre 11*11 (en %)

	nbr. de pixels	eau	ombre nuage	nuage	com.-ind.	res.haut. dens.	res.bas. dens.	agricole	golf gazon	forêt
eau	5165	0,54			-0,18				-0,37	
ombre nuage	2320		1,08		-0,99				-0,09	
nuage	2822			-0,39	0,25			0,14		
com.-ind.	38054			0,06	-1,63	1,93	0,05	-1,21	0,78	0,03
res.haut. dens.	25964				-7,84	-8,74	15,95	0,37	0,26	0,01
res.bas. dens.	14490				-3,45	-11,6	14,57	1,21	-0,76	0,07
agricole	38174			-0,04	-0,38	0,19	-0,01	-4,27	4,62	-0,12
golf gazon	7468			-0,04	-0,13	-0,15		-6,53	7,83	-0,97
forêt	29562				0,03	0,12	0,24	-0,33	-1,56	1,51

Δmoyenne diagonale +1,167



Changement positif pour texture couleur (diagonale + , reste du tableau -)

Changement négatif pour texture couleur (diagonale - , reste du tableau +)

Nb : L'accent étant porté sur les différences couleur - gris, il n'a pas été jugé nécessaire d'inclure les matrices de confusions pour les figures 3.17 et 3.18

Après une analyse des résultats obtenus par les matrices de confusions, on conclut que, similairement à l'analyse des matrices de séparabilité, la confusion a généralement une tendance à la baisse entre les méthodes grises et couleur. Ainsi, l'exactitude moyenne/absolue de la diagonale des textures couleurs augmente par rapport à la diagonale de la texture grise. Cependant, tel qu'observé par les figures d'exactitude (fig.3.10 à 3.13) et révélé par le test de Student, cette distinction devient moins importante quand on dépasse la taille de fenêtre 9*9.

3.5 : Comparaison avec des classifications standards

À titre comparatif, nous avons effectué d'autres tests de classification. La figure 3.20 présente une comparaison de classification non dirigée par la signature grise vs couleur. Il est fort intéressant de noter l'importante amélioration en faveur de l'approche couleur. Cela implique que les images des textures couleurs sont mieux classifiables. Quant à la figure 3.21, elle présente les résultats d'une classification purement multispectrale. Comme prévu (puisque on a les mêmes sites d'entraînement) on observe une forte ressemblance avec les classifications texturales, mais avec moins de précision (e.g. classes commerciales avec du résidentiel, golfs plus 'picotté', résidentiel en plein champs et faible distinction entre le résidentiel HD et BD...). Cela va de pair avec les exactitudes observées pour les fenêtres 1*1 (sans texture) des figures d'exactitudes présentées précédemment.

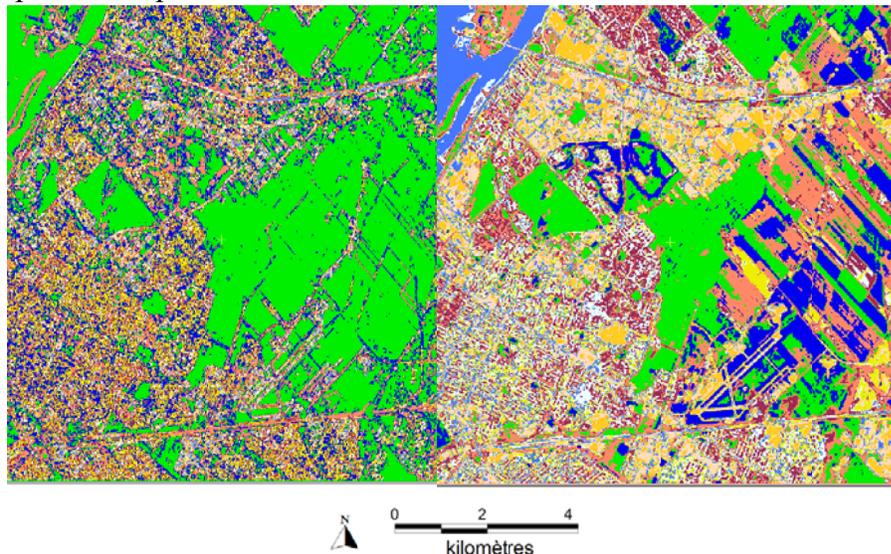


Fig. 3.20 :Classification non supervisée, par Fuzzy K-means, des signatures texturales grise (gauche) et couleur (droite) selon fenêtre de 5*5, 9 classes et 10 itérations.

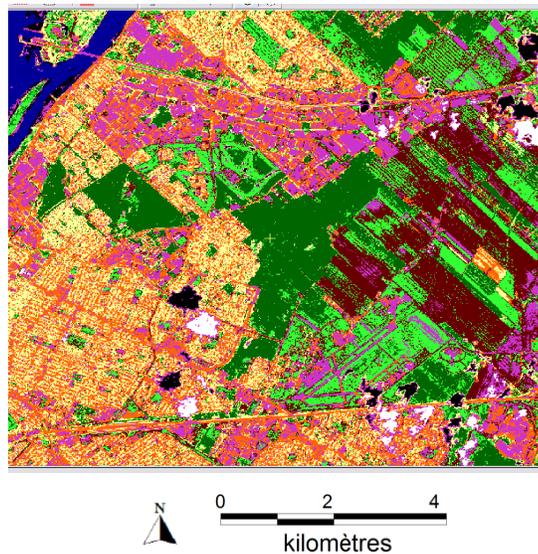


Fig. 3.21 : Classification supervisée des 4 bandes de SPOT multispectrale, sans textures.

3.6 Discussion générale des résultats

Ces résultats montrent d'abord l'amélioration générale, souvent significative, de la vitesse de plafonnement des exactitudes de classification avec des fenêtres de taille relativement petite. Marceau *et al.* (1990) ont établi que l'exactitude d'une classification des paramètres de texture d'une image multispectrale de 20 m de résolution spatiale atteint un plafond avec une fenêtre de 15*15 tandis que Messier *et al.* (2001), avancent un plafond ayant lieu à 25*25 pixels pour des images panchromatiques 5m de résolution. Donc, si l'on transpose ces résultats à une image de 10m de résolution comme la nôtre, une fenêtre de 30*30 est optimale selon Marceau *et al.* et une fenêtre de 13*13 selon Messier *et al.* Or, la technique actuelle, selon toutes les figures d'exactitude, semble débiter son plafonnement à 11*11, autant pour l'approche couleur que grise. Cependant, l'approche couleur tend vers le plafond plus rapidement que la méthode grise. En conséquence, on peut supposer que la création d'une signature texturale couleur est un élément clé pour la réduction de la taille de fenêtre optimale et que la texture couleur augmente la séparabilité pour les plus petites tailles de fenêtres. Ces deux points montrent qu'un gain appréciable peut être obtenu pour les applications actuellement trop lourdes en volume de données/temps de calcul à réaliser dans la pratique. (e.g. les applications n'utilisant pas la méthode rapide d'Unser)

De plus, dans une optique d'optimisation des traitements, on remarque que les fenêtres texturales 3*3 ne sont généralement que marginalement meilleures que l'utilisation 1*1, soit sans texture. Cela s'explique par le fait que peu de classes étudiées possèdent un grain textural de cette taille (voir fig.3.11). Ainsi, le gain pour l'effet textural, par l'intégration de multiples bandes, est obtenu entre 5*5 et 9*9 (11*11 dans certains cas). De ce fait, si le gain de vitesse de traitement est l'objectif, une fenêtre de 5*5 ou 7*7 serait optimale, inversement si seule la qualité de classification importe, le plafonnement des deux approches se situe vers 11*11.

Enfin, on note le rapprochement de l'efficacité des deux méthodes pour les grandes tailles de fenêtre. Ceci pourrait s'expliquer par une certaine dilution de l'information apportée par la texture-couleur à partir d'une fenêtre, qui selon nos résultats, se situe à 11*11. Cela expliquerait aussi l'effet de plafonnement plus rapide des exactitudes par textures couleurs. Cette conclusion est aussi confirmée par les analyses de semi-variogrammes. Le fait que cet effet prenne place dans l'intervalle des tailles de fenêtre correspondant aux seuils établis par les semi-variogrammes des classes, (tableau 3.11) vient montrer l'intérêt de la texture couleur.

D'un point de vue plus général, on constate que la présente méthode permet l'utilisation de l'algorithme de calcul rapide d'Unser (1986) à l'approche couleur d'Arvis *et al.* (2004), de Palm (2004) et, dans une moindre mesure, Vansteenkiste *et al.* (2004), en utilisant une méthodologie permettant une synthèse/optimisation des paramètres d'une signature texturale couleur. Or, bien que les résultats soient concluants et que la supériorité de l'approche couleur ait été démontrée, cette méthode n'est pas parfaite. En effet, cette recherche présente une vaste palette des comportements de la taille de fenêtre, de r et de θ pour les textures grises et couleur, la signature texturale parfaite devrait être composée d'éléments possédant eux même une certaine optimisation, tout en répondant entièrement aux problématiques énoncées au chapitre 1.1, ce qui n'est actuellement pas le cas. Entre autre, rappelons que Coburn *et al.* (2004) ont démontré l'importance d'une taille de fenêtre optimisée à la classe traitée. Éventuellement, l'utilisation de réseaux de neurones, tel que présenté par Hepner *et al.* (1990), mais appliqué à une méthodologie couleur découlant de l'approche présentée dans ce mémoire, pourrait améliorer d'avantage les résultats actuels.

Conclusions

Le but de cette recherche était d'étudier le potentiel des méthodes des textures couleurs pour améliorer les résultats de classification d'images multispectrales. Nous avons décidé d'évaluer ce potentiel en comparant les résultats d'une classification des textures couleurs à ceux d'une classification par textures grises. La différence fondamentale entre ces deux types de texture réside dans le fait que les mesures des textures, dans le cas couleur, se font en analysant conjointement les valeurs numériques des pixels voisins dans deux bandes spectrales différentes, tandis que dans le cas gris, les mesures sont effectuées sur une seule bande spectrale à la fois. Pour ce faire, nous avons analysé une image spectrale SPOT-5 couvrant un territoire semi-urbain de la Communauté Métropolitaine de Montréal. Les principales conclusions tirées de cette expérience sont présentées en détail en ce qui suit.

Signature couleur vs grise :

Les analyses ont montré que les mesures de corrélation, contraste, écart-type, et moyenne, sont les plus performantes pour la classification des occupations du sol en territoire semi-urbain. Ceci va dans la même direction des résultats de Bugnet (2003) qui a étudié l'apport de la texture à la distinction boisé/urbain, en utilisant une image panchromatique à haute résolution, ainsi que de Fiset (2006) avec des images radar pour la distinction entre le bâti et les espaces non construits. Cependant, cette recherche a démontré que la corrélation, le contraste et l'écart-type offrent un meilleur rendement pour les analyses couleurs, tandis que la moyenne et le contraste sont les plus efficaces lorsque calculés sur une seule bande spectrale à la fois. Ces résultats sont intéressants puisqu'on peut faire un parallèle avec les analyses multivariées basées soit sur les variogrammes, directement associés à l'écart-type (Peijun Li *et al.*, 2009), et la corrélation/contraste qui sont naturellement prédisposées à la mise en valeur des différences entre deux bandes d'une image multibande. Cela s'approche du procédé de détection des formes spatiales sur une image couleur par un interprète. Évidemment ces textures ne sont pas universellement les meilleures pour toutes les classes d'occupation du sol (e.g. homogénéité pour la classe agricole), mais elles offrent le meilleur rendement général. Incidemment, cela confirme l'intérêt d'une signature texturale optimisée.

De plus, l'analyse des résultats a permis la validation statistique, de l'hypothèse principale du projet, à savoir l'efficacité accrue de la méthode par textures couleurs. En effet, la séparabilité des classes d'occupation est nettement améliorée par la méthode couleur, ainsi, à quelques exceptions près (notamment la classe agricole) l'exactitude des résultats obtenus lors de la classification du territoire est améliorée de 5 à 10%, voir même 20% dans certains cas (golf). Cependant, observation très intéressante, ces résultats ne sont valides que pour les petites tailles de fenêtre (5 à 9 pixels, parfois 11), car pour les plus grandes tailles, les résultats des textures grises sont équivalents et parfois meilleurs, entre autres pour les classes commerciale/industrielle, résidentielle HD et agricole. Cette observation, mise en relation avec l'analyse des semi-variogrammes des diverses classes étudiées, a révélé des seuils de variabilité spatiale des classes oscillant entre 5 à 9 pixels, ce qui permet de conclure que les textures couleurs offrent aussi des rendements améliorés à des fenêtres appropriées à l'extraction d'information.

Apports du mémoire :

Sommairement, l'utilité principale de la méthode développée dans ce projet se situe dans l'analyse d'une signature texturale composée d'éléments discrets et intégratifs (et non pas uniquement l'usage de n bandes en parallèles) de l'espace image (bandes spectrales, type de textures, classes), permettant une analyse plus adaptée à la variété des classes d'occupation du territoire. Parallèlement, les deux types de signature texturale ayant été créés par une même méthodologie, cela a permis d'établir, sans effets associés aux divers types de classificateur ou de pré-traitements, la pertinence de l'utilisation des textures couleurs pour les tailles de fenêtres plus petites. De plus, cette démonstration d'une tendance vers l'augmentation de l'efficacité des petites tailles de fenêtre augure bien pour les applications futures de la méthode préconisée dans cette recherche et ouvre la voie aux recherches sur l'utilisation optimisée des textures intégrant plus de deux bandes à la fois. Finalement, la méthodologie d'identification des paramètres optimaux d'une signature texturale présentée dans ce mémoire et les résultats obtenus pour les classes d'un milieu péri-urbain, pourront servir de bases à de futures recherches nécessitant la création de signatures texturales optimisées.

Améliorations possibles :

Bien que les résultats de ce projet soient concluants, un certain nombre d'améliorations sont envisageables. En effet, les images classifiées et l'algorithme de classification se voulaient les plus simples possibles afin d'observer la différence entre la méthode grise et couleur sans interférence pré- ou post-classification. Il est envisageable que l'utilisation d'images prétraitées ainsi que l'emploi d'un algorithme de classification plus axé sur l'aspect spatial produiraient de meilleurs résultats. Une autre amélioration majeure possible serait l'usage d'un algorithme de classification plus intelligent (e.g. les réseaux de neurones selon l'approche de Hepner *et al.*, 1990) permettant, à terme, l'utilisation de taille de fenêtre texturale adaptée à la classe segmentée. La méthode actuelle utilise une taille fixe de calcul des mesures texturales qui ne peut que s'apparenter à la taille moyenne requise pour toutes les classes. Finalement, l'utilisation de texture à plus de deux dimensions, en restant dans les limites des capacités informatiques actuelles, permettrait de synthétiser davantage d'informations dans une même image et ainsi d'améliorer la qualité des signatures texturales. Ces améliorations permettraient théoriquement de progresser vers une classification plus précise aux grandes échelles, pour une même taille de fenêtre texturale. Ce qui est l'objectif ultime pour une avancée des méthodes de classification aux fins de gestion des espaces urbains.

Analyse qualitative et perspective future :

L'analyse qualitative des résultats laisse entrevoir une amélioration significative de la séparabilité des classes d'occupation du territoire pour des plus petites tailles de fenêtre texturales. En conséquence, cela ouvre la porte à une panoplie d'avenues pour améliorer les algorithmes de segmentation du territoire existant, du moins, ceux basés sur les analyses texturales. Entre autres, certaines applications des textures, actuellement difficiles à mettre en pratique, seraient théoriquement envisageables puisque les améliorations les plus importantes apportées par la méthode de la texture couleur ont été observées pour les classes requérant la plus grande précision (golf et résidentielle basse densité). Ainsi, la segmentation des diverses

essences d'un boisé, ou la détection de changements plus fins comme la détérioration d'un biome ou l'analyse de évolution d'un espace urbain avec des classes plus précises serait envisageable. Cependant, la méthode dans sa forme actuelle semble peu appropriée aux classes possédant une forte hétérogénéité d'apparences (entre autres, la classe agricole).

En incluant, dans de futurs développements, un certain degré d'intelligence dans la sélection des signatures texturales, les perspectives d'utilisation future de cette méthodologie sont pratiquement illimitées. En effet, la hausse de l'information synthétisée dans une même fenêtre texturale réduit le temps de calcul et permet une utilisation pratique d'une plus grande quantité de bandes spectrales. Le développement d'algorithmes de textures à multiples dimensions, moins gourmands en temps, permettant entre autres des analyses diachroniques, voir même hyperspectrales, est donc théoriquement possible. Cela ouvre la voie à une multitude de possibilités actuellement peu exploitées sous une forme moins axés sur la création d'espaces orthogonaux (contrairement à Gabor, à la machine vectorielle, aux analyse multivariées) et plus sur une synthèse et segmentation de l'information guidée par les besoins de l'utilisateur. Évidemment, l'intégration d'une de ces techniques mathématiques à la méthodologie actuelle pourrait aider à synthétiser davantage la signature texturale, mais cela dépasse largement le cadre de ce projet qui visait, et qui a effectivement démontré, l'intérêt et les particularités de l'utilisation de la texture couleur par rapport aux textures grises.

Bibliographie

Anderson J.R., Hardy E.E., Roach T.J., Witmer E.R., (1976), A land use and land cover classification system for use with remote sensor data, *Geological Survey professional paper 964*, Circular 671

Arivazhagan S., Ganesan L., (2003), Texture classification using wavelet transform, *Pattern Recognition Letters*, 24: 1513-1521

Arvis, V., Debain, C., Berducat, M., Benassi, A., (2004), Generalization of the cooccurrence matrix for colour images: application to colour texture classification, *Image Anal Stereol*, 23: 63-72

Atkinson P.M., Lewis P., (2000), Geostatistical classification for remote sensing: an introduction, *Computer & Geosciences*, 26: 361-371

Aujol J-F., Kang H.S., (2006), Color image decomposition and restoration, *J. Visual Communication & Image Representation*, 17: 916–928

Berberoglu S. Lloyd C.D., Atkinson P.M., Curran P.J.,(2000), The integration of spectral and textural information using neural networks for land cover mapping in the Mediterranean, *Computers & Geosciences*, 26: 385-396

Bugnet P., (2002), *Cartographie automatisée des surfaces boisées en milieu urbanisé fondée sur la texture d'image IKONOS panchromatiques*, Mémoire de maîtrise, Université de Montréal, Département de Géographie, 78 pages

Bugnet P., Cavayas F. Gagnon L., (2003), Vers la cartographie automatisée des surfaces boisées en milieu urbanisé fondée sur la texture d'images IKONOS panchromatiques : le cas de la Région métropolitaine de Montréal, *J. Can. Télédétection*, 29 (6) 755–769

- Caloz R., Collet C.,** (2001), *Précis de télédétection*, Vol. 3, Presses de l'Université du Québec, 386 pages
- Chen, K.-M., Chen, S.-Y.,** (2002), Color texture segmentation using feature distributions. *Pattern Recognition Letters*, 23: 755-771.
- Coburn, C.A., Roberts, A.C.B.,** (2004), A multiscale texture analysis procedure for improved forest stand classification, *Int. J. Remote Sensing*, 25: 4287-4308.
- Cohen Warren B., Spies T.A., Bradshaw G.A.,** (1990), Semivariogramme of digital imagery for analysis of conifer canopy structure, *Remote Sensing of environment*, 34: 167-178
- Dedieu J-P., Kerkache R., Bornicchia F., Pella H.,** (1997), Apport des informations de texture en télédétection pour l'étude de l'occupation des sols, *Revue de Géographie Alpine*, 85 (3): 9-26
- Dekker Rob J.,** (2003), Texture analysis and classification of ERSSAR images for map updating of urban areas, *IEEE Transactions On Geoscience And Remote Sensing*, 41 (9): 1950-1958
- Dell'acqua F., Gamba P.,** (2003a), Texture-based characterization of urban environments on satellite SAR images, *IEEE Transactions On Geoscience And Remote Sensing*, 41 (1): 153-159
- Dell'acqua F., Gamba P.,** (2003b), Discriminating urban environments using multi-scale texture and multiple SAR images, *IEEE Workshop on Advances in Techniques for Analysis of remotely Sensed Data*, 308-314,
- Dony D., Haykin S.,** (1995), Neural networks approach to image compression, *Proceedings of the IEEE*, 83(2): 288-303
- Drimbarean A., Whelan P.F.,** (2001), Experiments in color texture analysis, *Pattern Recognition Letters*, 22: 1161-1167

Dubuisson-Jolly M.-P., Gupta A., (2000), Color and texture fusion: application to aerial image segmentation and GIS updating, *Image And Vision Computing*, 18: 823–832

Estes J.E. Hajic E.J., Tinney L.R., (1983), Fundamentals of image analysis: Analysis of visible and thermal infrared data, *Manual of remote sensing, Second edition* (Robert N. Colwell, editor), American Society of Photogrammetry, 987-1124

Fiset R., Cavayas F., (1997), Automatic comparison of a topographic map with remotely sensed images in a map updating perspective: the road network case, *Int. J. Remote Sensing*, 18 (4): 991-1006

Fiset R., (2006), *Système prototype pour le suivi des changements de l'occupation du sol en milieu urbain fondé sur les images du satellite RADARSAT-1*, Thèse doctorale, Université de Montréal, Département de Géographie, 161pages

Frohn R.C., (1998), *Remote sensing for landscape ecology*, CRC Press, 100pages

Fukue, K., Shimoda, H. & Sakata, T., (1998), Spatial landcover classification using a neural network driven by co-occurrence matrix for landcover elements. *Geoscience and Remote Sensing Symposium Proceedings*, 2: 1137-1139.

Girard M.-C., Girard C.M., (2004), *Traitement des données de télédétection*, Dunod, 529pages

Gong, P., Howarth, P.J. (1990), The use of structural information for improving land-cover classification accuracies at the rural-urban fringe. *Photogrammetric Engineering & Remote Sensing*, 56: 67-73

Haralick R.M., (1973), Textural features for image classification, *IEEE transactions on systems, man, and cybernetics*, 3 (6): 610-621

Haralick, R.M., (1979), Statistical and structural approaches to texture, *Proceedings Of The IEEE*, 67 (5): 786-808

Hepner, G.F., Logan T., Ritter N., BryantN., (1990), Artificial neural network classification using a minimal training set: comparison to conventional supervised classification, *Photogrammetric Engineering & Remote Sensing*,56: 469-473

Herold M.,Scepan J., Clarke K.C., (2002), The use of remote sensing and landscape metrics to describe structures and changes in urban land uses, *Environment And Planning*, 34: 1443- 1458

Herold M., Liu X., Clarke C.K., (2003), Spatial metrics and image texture for mapping urban land use, *Photogrammetric engineering and remote sensing*,69 (9): 991-1001

Hoang, M.A.,Geusebroek J-M., Smeulders W.M.A., (2005), Color texture measurement and segmentation, *Signal Processing*, 85: 265–275

Jain A.K.,Farrokhnia F., (1991), Unsupervised texture segmentation using gabor filters, *Pattern Recognition*, 24 (12): 1167-1186

Jensen J. R., (2007), *Remote sensing of the environment, an earth resource perspective*, second edition, Prentice-Hall, 592 pages

Junqing C., Pappas T.M., Mojsilovic A., Rogowitz B., (2002), Adaptative image segmentation based on color and texture, *IEEE Icip*, 1: 777-780

Kan-Min C.,Chen S-Y., (2002), Color texture segmentation using feature distributions, *Pattern Recognition Letters*, 23: 755–771

- Laine A., Fan J.,** (1993), Texture classification by wavelet packet signatures, *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 15(11):1186-1191
- Landgrebe D.,** (2002), Hyperspectral Image Data Analysis as a High Dimensional Signal Processing Problem, *IEEE Signal processing magazine*, 19(1): 17-28
- Ma W. Y., Deng Y., Manjunath B. S.,** (1997), Tools for texture/color based search of images, SPIE Int. Conf. 3106, *Human Vision and Electronic Imaging II*: 496-507
- Mäenpää T., Pietikäinen M.,** (2004), Classification with color and texture: jointly or separately?, *Pattern Recognition*, 37: 1629-1640
- Marceau D.J., Howarth P.J., Dubois, J.-M.M., Gratton, D.J.,** (1990), Evaluation of the grey-level co-occurrence matrix method for land-cover classification using SPOT imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 28 (4): 513–519
- Messier N., Cavayas F., André P.,** (21–24 août 2001), Cartographie des occupations du sol en milieu urbain, à partir d’images satellites de haute résolution spatiale : le cas de Beijing. *Actes du 23e symposium canadien sur la télédétection*, Ste-Foy, Québec, 829–834.
- Mirmehdi M., Petrou M.,** (2000), Segmentation of color textures, *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 22 (2): 142-158
- Mirmehdi, M., Xie, X. & Suri, J.,** (2008), *Handbook of texture analysis*, Imperial College Press, 413pages
- Ojala T., Pietikainen M., Harwood D.,** (1996), A comparative study of texture measures with classification based on feature distributions, *Pattern Recognition*, 29 (1): 51-59

Palm C., (2004), Color texture classification by integrative co-occurrence matrices, *Pattern Recognition*, 37: 965-976

Parker, J. R., (1997), *Algorithms for image processing and computer vision*, Wiley Computer Publishing, 416pages

Peijun Li, Cheng T., Guo J., (2009), Multivariate image texture by multivariate variogram for multispectral image classification, *Photogrammetric Engineering & remote sensing*, 75(2): 147-157

Petrou, M. & Sevilla, P. G., (2006), *Dealing with texture*, Wiley, 618pages

Rosenfeld A., Kak A. C., (1982), *Digital picture processing, Second Edition*, Vol. 1, Academic Press inc., 435pages

Ryherd S., Woodcock C., (1996), Combining spectral and texture data in the segmentation of remotely sensed images, *Photogrammetric Engineering & remote sensing*, 62 (2):181-194

Shaban M.A., Dikshit O., (2001), Improvement of classification in urban areas by the use of textural features: the case study of Lucknow City, Uttar Pradesh, *Int. J. Remote Sensing*, 22 (4): 565–593

Skidmore K.A., (1989), An expert system classifies eucalypt forest types using thematic mapper data and a digital terrain model, *Photogrammetric Engineering & remote sensing*, 55 (10): 1449-1464

Smith J.R., Chang S-F., (1996), Local color and texture extraction and spatial query, *International Conference on Image Processing, IEEE Proceedings.*, 3:1011-1014

- Tuceryan M., Jain, A.K.**, (1998), *The handbook of pattern recognition and computer vision Texture Analysis*, World scientific publishing co., chapter 2.1: 207-248
- Ünsalan C., Boyer, K.L.**, (2004), Classifying land development in high-resolution panchromatic satellite images using straight-line statistics. *IEEE Transactions On Geosciences And Remote Sensing*, 42: 907-919.
- Unser M.**, (1986), Local linear transforms for texture measurements, *Signal processing*, 11: 61-79
- Vansteenkiste E., Gautama, S., Philips, W.**, (2004), Analysing multispectral textures in very high resolution satellite images. *IEEE Icip.*,5: 3062-3064
- Wang A., Wang S., Lucieer A.**, (2010), Segmentation of multispectral high-resolution satellite imagery based on integrated feature distributions, *Int. J. Remote Sensing*, 31(6), 1471-1483
- Wang L.**, (1994), Un nouvel espace de texture, *Int. J. Remote Sensing*, 15(8) :1713-1723
- Wouwer G. V.D., Scheunders P., Livens S., Van Dyck, D.**, (1999), Wavelet correlation signatures for colour texture characterization, *Pattern Recognition*, 32: 443-451
- Zhang Q., Wang J., Peng X., Gong P. Shi P.**, (2002), Urban Built-up land change detection with road density and spectral information from multi-temporal Landsat TM data, *Int. J. Remote Sensing*, 23 (15): 3057–3078
- Zhang Q., Wang J., Peng X., Gong P. Shi P.**, (2003), Study of urban spatial patterns from SPOT panchromatic imagery using textural analysis, *Int. J. Remote Sensing*, 24 (21): 4137–4160
- Zhu C., Yang X.**, (1998), Study of remote sensing image texture analysis and classification using wavelet, *Int. J. Remote Sensing*, 19 (16):3197-3203

Annexe 1

Matrices de séparabilité: Signature de quatre bandes spectrales appliquée à une texture grise

Matrice de séparabilité PMAX

o	1,6816							
n	1,9224	1,6641						
ci	1,9505	1,4081	1,6745					
rh	1,9841	1,7314	1,8609	0,8396				
rl	1,9821	1,6959	1,8420	0,7347	0,0488			
a	1,8585	0,7346	1,5228	0,8802	1,4965	1,4353		
g	1,9423	1,1988	1,5940	0,8607	1,3084	1,2046	0,8443	
f	1,8860	0,9656	1,4966	1,4881	1,7169	1,6749	0,9210	0,9516
	eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrice de séparabilité Moyenne

o	1,9685							
n	2,0000	2,0000						
ci	1,9999	1,9949	1,9760					
rh	2,0000	1,9999	1,9987	1,5032				
rl	2,0000	1,9999	1,9964	1,6868	0,5337			
a	2,0000	1,9999	1,9983	1,7175	1,9167	1,8546		
g	2,0000	1,9999	1,9997	1,9576	1,9973	1,9679	0,8499	
f	2,0000	2,0000	1,9999	1,9988	1,9998	1,9853	1,6642	1,5836
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrice de séparabilité Homogénéité

o	1,4329							
n	1,9904	1,6717						
ci	1,9830	1,6201	1,3733					
rh	1,9988	1,8411	1,8808	1,1368				
rl	1,9984	1,7960	1,8667	1,0684	0,1086			
a	1,7394	0,5967	1,7173	1,6677	1,9515	1,9362		
g	1,9851	1,2602	1,4577	1,3336	1,6958	1,5761	1,3415	
f	1,9806	1,3071	1,7619	1,8993	1,9776	1,9601	1,4779	1,0878
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrice de séparabilité Entropie

o	1,5865							
n	1,9940	1,7682						
ci	1,9924	1,6701	1,4898					
rh	1,9995	1,8116	1,9683	1,1093				
rl	1,9965	1,6246	1,9654	1,0025	0,3676			
a	1,8331	0,9855	1,7832	1,6766	1,9266	1,8034		
g	1,9433	1,0192	1,7584	1,6490	1,8778	1,8174	1,0425	
f	1,9887	1,3214	1,9303	1,9543	1,9845	1,9547	1,6504	1,1892
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrice de séparabilité Énergie

o	1,9142							
n	1,9870	1,9569						
ci	1,9962	1,8088	1,9612					
rh	1,9978	1,8517	1,9601	0,9703				
rl	1,9982	1,8775	1,9679	1,0636	0,1236			
a	1,9571	1,0146	1,9129	1,6897	1,7822	1,8220		
g	1,9950	1,7330	1,9305	1,3074	1,0257	1,1601	1,5190	
f	1,9776	1,6094	1,8441	1,8561	1,7731	1,8157	1,4229	1,4095
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrice de séparabilité Écart-type

o	1,1914							
n	1,9378	1,7567						
ci	1,9189	1,6434	1,1221					
rh	1,9974	1,9118	1,9386	1,1714				
rl	1,9969	1,9242	1,9415	1,2249	0,0535			
a	1,4980	1,1510	1,7399	1,4256	1,6984	1,7781		
g	1,7614	1,1573	1,8306	1,3959	1,6388	1,7159	0,9047	
f	1,1264	0,7776	1,9101	1,8010	1,9603	1,9583	1,2757	1,3952
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrice de séparabilité Corrélation

o	1,6142							
n	1,9787	1,8064						
ci	1,9711	1,7262	1,0837					
rh	1,7901	1,1331	1,7396	1,5572				
rl	1,7793	1,2273	1,7943	1,6319	0,1172			
a	1,5840	1,0488	1,8539	1,7381	0,5755	0,5786		
g	1,8288	1,1050	1,8403	1,6014	1,1987	1,3084	1,0250	
f	1,0792	1,0048	1,9218	1,9165	1,4032	1,4118	1,0544	1,5732
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrice de séparabilité Contraste

o	1,0253							
n	1,9397	1,7958						
ci	1,9531	1,8340	1,3830					
rh	1,9815	1,9313	1,8764	1,2178				
rl	1,9828	1,9379	1,8817	1,2527	0,0228			
a	0,7883	1,1396	1,8827	1,9412	1,9735	1,9758		
g	1,7418	1,3307	1,8100	1,5646	1,7195	1,7609	1,6888	
f	0,6601	0,8376	1,9202	1,9206	1,9543	1,9575	0,7898	1,5782
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrices de séparabilité : Signature de huit textures grises appliquée à une bande spectrale

bande1								
	eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,7188							
n	2	2						
ci	1,9919	1,9760	1,8640					
rh	1,9972	1,9978	1,9995	1,3285				
rl	1,9920	1,8937	1,9977	1,4292	0,7283			
a	0,9702	1,8550	1,9998	1,8716	1,9684	1,9741		
g	1,4301	1,3086	1,9993	1,6699	1,7087	1,6176	1,0118	
f	1,0740	1,1830	2	1,9853	1,9965	1,9468	1,3401	1,0309
bande2								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,6498							
n	2	2						
ci	1,9989	1,9850	1,7278					
rh	1,9997	1,9990	1,9951	1,3238				
rl	1,9929	1,9326	1,9914	1,4288	0,7110			
a	1,5678	1,6747	1,998	1,8084	1,9100	1,8710		
g	1,5816	1,4048	1,9989	1,7981	1,7305	1,3368	0,9642	
f	0,6119	1,2543	2	1,9960	1,9996	1,9734	1,4239	1,2422
bande3								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,9253							
n	2	1,9997						
ci	1,9991	1,3095	1,9774					
rh	2	1,8146	1,9830	0,6851				
rl	1,9999	1,8197	1,9330	0,4765	0,4523			
a	1,9995	1,9546	0,8227	1,8793	1,9740	1,9014		
g	1,9994	1,9921	1,4783	1,8758	1,9693	1,8918	1,3058	
f	2	1,9999	0,6010	1,9768	1,9882	1,9481	0,7858	1,1270
bande4								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,8670							
n	2	1,9999						
ci	1,9999	1,9794	1,7980					
rh	2	1,9998	1,9679	1,0921				
rl	2	1,9987	1,9712	1,0150	0,1607			
a	2	1,9999	1,9065	1,8632	1,9166	1,9145		
g	1,9999	1,9991	1,4259	0,9950	1,8190	1,8146	1,3978	
f	2	2	1,9807	1,5380	1,3197	1,3454	1,1315	1,4471

**Séparabilité des signatures : Signature de six composés de bandes
appliquée à une texture couleur**

Matrice de séparabilité PMAX

	eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,6719							
n	1,9870	1,8097						
ci	1,9683	1,4434	1,5727					
rh	1,9888	1,7844	1,7395	0,6162				
rl	1,9887	1,7820	1,7312	0,5855	0,0372			
a	1,8616	0,6001	1,7898	1,2428	1,7031	1,6935		
g	1,9634	1,2623	1,5283	0,6346	1,2131	1,1653	0,9794	
f	1,9237	0,9971	1,7109	1,4560	1,7563	1,7418	0,6281	0,8629
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
Matrice de séparabilité Moyenne								
o	1,9253							
n	2	1,9995						
ci	1,9991	1,9961	1,8640					
rh	1,9995	1,9999	1,9995	1,5622				
rl	1,9999	1,9989	1,9777	1,9329	0,7283			
a	2	1,9999	1,9798	1,9550	1,9684	1,9741		
g	1,9994	1,9999	1,9993	1,9772	1,7087	1,6176	1,0118	
f	2	2	2	1,9993	1,9965	1,9468	1,3401	1,6314
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
Matrice de séparabilité Homogénéité								
o	1,9371							
n	1,9994	1,9927						
ci	1,9984	1,9238	1,8155					
rh	1,9999	1,9757	1,9317	0,9629				
rl	1,9998	1,9617	1,9673	1,2346	0,4753			
a	1,9986	1,8931	1,9895	1,6771	1,7692	1,6040		
g	1,9844	1,7930	1,9960	1,8383	1,9738	1,9421	1,5324	
f	1,8175	1,7935	1,9988	1,9802	1,9979	1,9924	1,9496	1,7002
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
Matrice de séparabilité Entropie								
o	1,7023							
n	1,9987	1,6744						
ci	1,9951	1,6763	1,2627					
rh	1,9996	1,8836	1,6659	0,8671				
rl	1,9976	1,7465	1,6147	0,6837	0,3616			
a	1,9589	1,1325	1,7388	1,646	1,8813	1,7626		
g	1,9736	1,1573	1,6761	1,6767	1,9024	1,8157	0,8575	
f	1,9957	1,4070	1,9323	1,9538	1,9857	1,9551	1,3329	1,1370
	eau	Omb.Nuag.	Nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrice de séparabilité Énergie								
o	1,9743							
n	1,9990	1,9114						
ci	1,9997	1,9039	1,9116					
rh	1,9988	1,7299	1,8531	1,2155				
rl	1,9990	1,7733	1,8649	1,1136	0,0972			
a	1,9968	1,5612	1,7464	1,7388	1,469	1,5620		
g	1,9995	1,8417	1,8535	1,1874	1,1972	1,2126	1,3662	
f	1,9976	1,7225	1,8065	1,8703	1,7086	1,7593	1,1479	1,5062
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
Matrice de séparabilité Écart-type								
o	1,9679							
n	2	2						
ci	2	1,9994	1,3472					
rh	2	1,9999	1,9864	1,7296				
rl	2	1,9999	1,9914	1,8691	0,6711			
a	2	2	1,9997	1,9733	1,9959	1,9874		
g	2	2	1,9999	1,9953	1,9990	1,9940	1,1449	
f	2	2	2	2	2	1,9999	1,7779	1,7289
	Eau	Omb.Nuag.	Nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
Matrice de séparabilité Corrélation								
o	1,9925							
n	2	2						
ci	2	1,9990	1,5133					
rh	2	1,9990	1,9995	1,8792				
rl	2	1,9983	1,9999	1,9352	0,6325			
a	2	1,9999	1,9983	1,9490	1,9825	1,9718		
g	2	1,9999	1,9999	1,9920	1,9956	1,9839	1,0775	
f	2	2	2	1,9999	1,9999	1,9988	1,8535	1,8315
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
Matrice de séparabilité Contraste								
o	1,9906							
n	2	2						
ci	2	1,9999	1,6272					
rh	2	1,9995	1,9928	1,8351				
rl	2	1,9976	1,9986	1,9350	0,7451			
a	2	2	1,9942	1,9383	1,9904	1,9828		
g	2	2	1,9999	1,9897	1,9953	1,9808	1,1737	
f	2	2	2	1,9998	1,9999	1,9965	1,9077	1,8716
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.

Matrices de séparabilité : Signature de huit textures couleurs appliquée à un composé de bandes

bande3.4								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,0837							
n	2	1,9998						
ci	1,9999	1,9953	1,3311					
rh	2	1,993	1,9763	1,6573				
rl	1,9994	1,9351	1,9938	1,8447	0,7629			
a	1,9758	1,8505	1,8866	1,3676	1,2797	1,1417		
g	1,9822	1,8354	1,9424	1,4810	1,4936	1,3287	1,0471	
f	1,2546	0,4997	1,9999	1,9988	1,9919	1,9068	1,7965	1,8791
bande 2.4								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,9876							
n	1,9660	1,8546						
ci	1,9296	1,7722	1,0092					
rh	1,9952	1,2877	1,7693	1,7047				
rl	1,9841	1,3443	1,7021	1,6089	0,1766			
a	1,8984	1,8442	1,7206	1,2723	1,7125	1,5819		
g	1,9169	1,9795	1,9327	1,5941	1,9778	1,9582	1,2627	
f	1,9978	1,9998	1,9931	1,9448	1,9997	1,9947	1,7430	1,7324
bande2.3								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,9590							
n	1,9980	1,9964						
ci	1,9907	1,9699	0,7821					
rh	1,8865	1,6145	1,9685	1,8116				
rl	1,9052	1,2853	1,9855	1,8771	0,4483			
a	1,9015	1,4266	1,9717	1,7389	1,7039	1,5609		
g	1,8710	1,6358	1,8754	1,3648	1,2832	1,3091	1,1653	
f	1,9493	1,9920	1,9584	1,7842	1,9610	1,9614	1,6320	1,3975
bande1.4								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,9924							
n	1,9954	1,7137						
ci	1,9253	1,5761	0,8080					
rh	1,9999	1,6477	1,8629	1,7993				
rl	1,9999	1,8197	1,8612	1,8149	0,2988			
a	1,9999	1,8767	1,8305	1,7461	1,6131	1,4346		
g	1,9998	1,6065	1,6964	1,4281	1,6626	1,6957	1,3873	
f	1,9999	1,9224	1,9770	1,9427	1,8832	1,8696	1,2584	1,7043

bande1.3								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,9802							
n	1,9062	1,9900						
ci	1,7539	1,9209	1,1289					
rh	1,9203	1,1534	1,9611	1,6578				
rl	1,9902	1,0506	1,9863	1,8089	0,4581			
a	1,9996	1,6853	1,9992	1,9677	1,8198	1,5571		
g	1,9999	1,8468	1,9934	1,9101	1,8542	1,6520	1,1801	
f	2	1,8808	1,9999	1,9984	1,9720	1,8631	1,4794	1,5608
bande1.2								
	Eau	Omb.Nuag.	nuage	com.Ind.	rés. HD	Rés. Bd	agricole	golf-gaz.
o	1,9214							
n	1,9994	1,9906						
ci	1,9927	1,9234	1,4046					
rh	1,9973	1,8713	1,9288	1,5574				
rl	1,9927	1,7494	1,9121	1,4841	0,1743			
a	1,849	1,1155	1,9801	1,8369	1,7017	1,5740		
g	1,7977	0,6997	1,9788	1,8268	1,6639	1,4601	0,7731	
f	1,5905	1,6554	1,9992	1,9926	1,9929	1,9794	1,7575	1,6746