

Université de Montréal

**Cartographie automatisée des surfaces boisées en milieu urbanisé
fondée sur la texture d'images IKONOS panchromatiques**

par
Pierre Bugnet

Département de Géographie
Faculté d'Arts et Sciences

Mémoire présenté à la Faculté des études supérieures
en vue de l'obtention du grade de M.Sc.
en géographie
(option recherche)

Novembre 2002

©, Pierre Bugnet, 2002

G

59

U54

2002

v.014

Université de Montréal
Faculté des études supérieures

Ce mémoire intitulé :
Cartographie automatisée des surfaces boisées en milieu urbanisé
fondée sur la texture d'images IKONOS panchromatiques

présenté par :
Pierre Bugnet

a été évalué par un jury composé des personnes suivantes :

Danielle Marceau
président-rapporteur

François Cavayas
directeur de recherche

Langis Gagnon
superviseur en milieu de pratique (CRIM)

Benoît St-Onge
membre du jury



SOMMAIRE

Le suivi des surfaces boisées est d'une importance capitale de nos jours, particulièrement dans les zones urbaines comme la Région Métropolitaine de Montréal. Or, le développement urbain cause généralement la fragmentation des surfaces boisées, ce qui engendre des difficultés quant à leur détection à partir d'images de satellites de résolution spatiale haute à moyenne (>10 m). L'essor de l'imagerie satellitale à très haute résolution pourrait permettre un suivi approprié de ces zones critiques, à condition de disposer de techniques automatisées adéquates pour les en extraire. Nous utilisons ici une image IKONOS panchromatique à une résolution spatiale de 1 mètre. Notre objectif principal est l'élaboration d'une méthode de détection automatisée des surfaces boisées à partir d'images de texture extraites de cette image. La méthode proposée comprend trois étapes principales : a) la création d'images de texture, b) la classification dirigée pixel par pixel à partir de ces images et c) le filtrage post-classification. Les images de texture sont produites par la méthode de Unser, qui permet un calcul accéléré d'une série de mesures de texture d'Haralick à partir des histogrammes des sommes et des différences. Ces opérations exigent la spécification de trois paramètres : la taille de la fenêtre f , le pas p et la direction d'échantillonnage d ; pour cette dernière, nous adoptons systématiquement la moyenne des quatre directions disponibles. Les tests effectués nous ont démontré que les quatre mesures de texture qui permettent la meilleure discrimination inter-classes sont la moyenne, le contraste, la corrélation et l'écart-type et que les combinaisons $f-p$ 17-1, 17-2, 35-1 et 35-2 donnent les meilleures performance de détection. Nous avons opté pour une classification dirigée par maximum de vraisemblance basée sur les signatures texturales de différentes classes (surfaces boisées, îlots urbains, surfaces gazonnées, etc.) et pour un filtrage permettant d'imposer une surface minimale. La performance de notre méthode est dans l'ensemble très acceptable, avec des taux de détection des surfaces boisées de l'ordre de 90 % et des coefficients Kappa d'environ 0.8. Elle connaît cependant quelques difficultés aux abords des frontières entre zones boisées et non-boisées ainsi que lorsque l'image contient des arbres de tailles diverses. Cette recherche a donc démontré le fort potentiel de l'imagerie IKONOS panchromatique pour la détection automatisée des surfaces boisées, ce qui est prometteur quant au développement d'un système de suivi des surfaces boisées à partir de ce nouveau type de données.

SUMMARY

Nowadays, forested land monitoring is an issue of great importance, especially in urban areas such as Montreal Metropolitan Region. However, urban development usually results in the fragmentation of forested land, which complicates seriously their detection from high to medium spatial resolution satellite images (>10 m.). The expansion of very high resolution satellite imagery could allow an appropriate monitoring of these critical areas, providing we have access to suitable techniques for their automated extraction. For this study, we are using a panchromatic IKONOS image with a 1-meter resolution. Our main objective is the elaboration of an automated forested land extraction method from texture images based on this image. The proposed method consists of three main steps: a) the creation of texture images, b) the pixel-by-pixel supervised classification using these images and c) the post-classification filtering. Texture images are produced with the Unser method which allows a quick calculation of several Haralick texture features using the sum and difference histograms. These operations demand the specification of three parameters: the window size f , the displacement p and the orientation d . For the latter, we systematically take the mean of all four available orientations. Our tests show that the four texture features yielding the best discrimination between classes are the mean, the contrast, the correlation and the standard deviation, and also that the f - p combinations 17-1, 17-2, 35-1 and 35-2 are those which give us the best detection performance. We have chosen to use a maximum likelihood classifier based on textural signatures of various classes (forested land, urban block, grass land, etc.) and a filtering technique allowing for the use of a minimal region size. The overall accuracy of our method is very acceptable with detection rates of about 90 % for forested land and Kappa coefficients near 0.8. Still, some difficulties occur in the surroundings of frontiers between forested and non-forested land, as well as in the case of images containing trees of various sizes. This study has proven the great potential of panchromatic IKONOS imagery for automated detection of forested land, and provides good hopes for the future development of a monitoring system of these areas using this new data type.

MOTS CLÉS

Texture, IKONOS, surface boisée, cartographie automatisée, haute résolution spatiale, milieu urbanisé, télédétection.

KEYWORDS

Texture, IKONOS, forested land, automated mapping, high spatial resolution, urban area, remote sensing.

TABLE DES MATIÈRES

SOMMAIRE.....	iii
SUMMARY	iv
MOTS CLÉS	v
KEYWORDS.....	v
TABLE DES MATIÈRES.....	vi
LISTE DES FIGURES.....	viii
LISTE DES TABLEAUX.....	xi
CHAPITRE I : INTRODUCTION	1
1.1 - Mise en contexte.....	1
1.2 - Objectifs et hypothèses	5
1.3 - Plan du mémoire.....	6
CHAPITRE II : L'APPROCHE PAR MATRICE DE CO-OCCURRENCE (CONCEPTS ET REVUE DE LITTÉRATURE)	7
2.1 - La matrice de co-occurrence et les images de texture	7
2.2 - La méthode de Unser (1986).....	10
2.3 - Problèmes d'application	11
2.4 - Conclusion	14
CHAPITRE III : DONNÉES, OUTILS ET DÉMARCHE.....	15
3.1 - Données utilisées.....	15
3.2 - Outils	17
3.3 - Démarche	17
3.3.1 <i>Création de sous-images</i>	18
3.3.2 <i>Choix du pré-traitement à appliquer</i>	25
3.3.3 <i>Création des images de texture</i>	26
3.3.4 <i>Choix de la méthode de segmentation</i>	31
CHAPITRE IV : APPLICATION ET RÉSULTATS	33

4.1 - Entraînement du classificateur et validation des résultats	33
4.2 - Classification dirigée à partir des huit mesures de texture	39
4.3 - Choix des mesures de texture.....	43
4.4 - Classification dirigée à partir des quatre mesures de texture retenues.....	44
4.5 - Post-traitements.....	54
CHAPITRE V : DISCUSSION.....	64
5.1 - Pré-traitement des images.....	64
5.2 - Mesures et paramètres optimaux.....	68
5.3 - Efficacité de détection des surfaces boisées	70
CHAPITRE VI : CONCLUSION.....	72
RÉFÉRENCES.....	75
ANNEXE A.....	xiii
ANNEXE B.....	xx
REMERCIEMENTS.....	xxvii

LISTE DES FIGURES

<u>Figure 1</u> : Agrandissement d'une image IKONOS panchromatique montrant de petits arbres isolés.....	3
<u>Figure 2a</u> : Exemple de matrice de co-occurrence ($f=5, p=1, d=0$).....	8
<u>Figure 2b</u> : Autre exemple de matrice de co-occurrence ($f=5, p=1, d=0^\circ$).....	9
<u>Figure 3</u> : MCO standardisées et mesures de texture.....	10
<u>Figure 4</u> : Région Métropolitaine de Montréal (Image Landsat-7 ETM4).....	15
<u>Figure 5</u> : Image IKONOS panchromatique du mois d'août.....	16
<u>Figure 6</u> : Organigramme de la démarche suivie.....	18
<u>Figure 7a</u> : Sous-image A.....	20
<u>Figure 7b</u> : Sous-image B.....	21
<u>Figure 7c</u> : Sous-image C.....	22
<u>Figure 7d</u> : Sous-image D.....	23
<u>Figure 7e</u> : Sous-image E.....	24
<u>Figure 8a</u> : Sous-image A initiale (à gauche) et égalisée localement (à droite).....	25
<u>Figure 8b</u> : Sous-image B initiale (à gauche) et égalisée localement (à droite).....	26
<u>Figure 9a</u> : Images moyennes de texture normalisées pour la sous-image A (combinaison 5-1).....	29

<u>Figure 9b</u> : Images moyennes de texture normalisées pour la sous-image B (combinaison 5-1).....	30
<u>Figure 10a</u> : Sites d'entraînement et de validation sur la sous-image A.....	34
<u>Figure 10b</u> : Sites d'entraînement et de validation sur la sous-image B.....	35
<u>Figure 11a</u> : Masque de vérité-terrain pour les surfaces boisées (sous-image A).....	37
<u>Figure 11b</u> : Masque de vérité-terrain pour les surfaces boisées (sous-image B).....	38
<u>Figure 12a</u> : Classification dirigée à partir des 8 images de texture et contour du masque VT (sous-image A).....	40
<u>Figure 12b</u> : Classification dirigée à partir des 8 images de texture et contour du masque VT (sous-image B).....	41
<u>Figure 13</u> : Classification dirigée à partir des 4 textures optimales pour la combinaison 17-1 et contour du masque VT.....	48
<u>Figure 14</u> : Classification dirigée à partir des 4 textures optimales pour la combinaison 17-2 et contour du masque VT	49
<u>Figure 15</u> : Classification dirigée à partir des 4 textures optimales pour la combinaison 35-1 et contour du masque VT.....	50
<u>Figure 16</u> : Classification dirigée à partir des 4 textures optimales pour la combinaison 35-2 et contour du masque VT	51
<u>Figure 17</u> : Classification dirigée à partir des 4 textures optimales après filtrage et contour du masque VT (combinaison 17-1).....	56
<u>Figure 18</u> : Classification dirigée à partir des 4 textures optimales après filtrage et contour du masque VT (combinaison 17-2).....	57
<u>Figure 19</u> : Classification dirigée à partir des 4 textures optimales après filtrage et contour du masque VT (combinaison 35-1).....	58

Figure 20: Classification dirigée à partir des 4 textures optimales après filtrage et contour du masque VT (combinaison 35-2)..... 59

Figure 21: Organigramme de la méthode proposée..... 65

LISTE DES TABLEAUX

<u>Tableau I:</u> Formules de Haralick pour les huit mesures de texture retenues.....	8
<u>Tableau II:</u> Formules de Unser pour les huit mesures de texture retenues.....	11
<u>Tableau III:</u> Récapitulatif des études antérieures utilisant l'approche par matrice de co-occurrence.....	13
<u>Tableau IV:</u> Description des sous-images choisies.....	19
<u>Tableau V:</u> Paramètres utilisés pour la création des images de texture.....	27
<u>Tableau VI:</u> Classes présentes sur chacune des sous-images.....	33
<u>Tableau VIIa:</u> Résultats de la classification dirigée à partir des 8 textures (sous-image A).....	42
<u>Tableau VIIb:</u> Résultats de la classification dirigée à partir des 8 textures (sous-image B).....	42
<u>Tableau VIII:</u> Présence de chaque mesure de texture dans la combinaison optimale.....	44
<u>Tableau IX:</u> NC sur les classifications dirigées à partir des quatre textures optimales.....	45
<u>Tableau X:</u> Résultats de la classification dirigée à partir des quatre textures optimales (TD / FA selon le masque VT).....	46
<u>Tableau XIa:</u> Matrice de confusion (combinaison 35-2, sous-image A).....	52
<u>Tableau XIb:</u> Matrice de confusion (combinaison 35-2, sous-image B).....	52
<u>Tableau XII:</u> TD* pour la classification dirigée à partir des quatre textures optimales (selon les sites de validation).....	53

<u>Tableau XIII:</u> Coefficients Kappa pour la classification dirigée à partir des quatre textures optimales (selon les sites de validation).....	54
<u>Tableau XIV:</u> NC sur les classifications dirigées à partir des quatre textures optimales après filtrage.....	60
<u>Tableau XV:</u> Résultats de la classification dirigée à partir des quatre textures optimales après filtrage (TD / FA).....	60
<u>Tableau XVIa:</u> Matrice de confusion après filtrage (combinaison 35-2, sous-image A).....	61
<u>Tableau XVIb:</u> Matrice de confusion après filtrage (combinaison 35-2, sous-image B).....	61
<u>Tableau XVII:</u> TD* pour la classification dirigée à partir des quatre textures optimales après filtrage.....	62
<u>Tableau XVIII:</u> Coefficients Kappa pour la classification dirigée à partir des quatre textures optimales après filtrage.....	62
<u>Tableau XIX:</u> Différence inter-pixel sur la sous-image B (sans et avec égalisation d'histogramme).....	66

CHAPITRE I : INTRODUCTION

1.1 - Mise en contexte

Depuis quelques années, le suivi des surfaces boisées constitue l'une des préoccupations majeures des organismes chargés de l'environnement dans la Région Métropolitaine de Montréal (R.M.M.). Leur rôle dans l'équilibre écologique des zones urbaines est en effet d'une importance capitale et on peut d'ailleurs les comparer à des poumons sans lesquels les villes étoufferaient inévitablement. Elles permettent également le maintien d'une réelle biodiversité, d'autant plus qu'elles constituent un habitat potentiel pour de nombreuses espèces animales. Avec l'urbanisation incessante que connaît la Région Métropolitaine de Montréal (R.M.M.), les surfaces boisées subissent une fragmentation de plus en plus inquiétante et se voient restreintes, dans bien des cas, à de très petits territoires. La santé, mais également le bien-être des résidents s'en trouvent sérieusement menacés, particulièrement au centre-ville où les boisés sont pratiquement absents. Un inventaire précis et un suivi rigoureux de ces surfaces sont donc indispensables et doivent absolument bénéficier des données et des techniques les plus performantes.

La cartographie de précision est depuis longtemps réalisée par interprétation visuelle de photographies aériennes mais pour combien de temps encore? Les développements récents dans le domaine de la télédétection remettent en question cette méthode qui est affectée par plusieurs contraintes: les coûts associés au processus d'acquisition des photographies aériennes, la durée des traitements (recalage des images et interprétation) et les problèmes de compatibilité entre les jugements des différents interprètes. En comparaison, une détection automatisée à partir d'images satellitales pourrait s'avérer moins subjective, plus rapide et plus simple, et améliorerait certainement la fréquence du suivi des boisés, alors que le prix de ces images devrait se faire de plus en plus abordable. C'est dans une telle optique que plusieurs études ont été réalisées quant aux possibilités qu'offre la télédétection par satellite comme source de données de nature environnementale. Il en ressort que l'imagerie satellitale possède un réel potentiel dans ce domaine et que la résolution spatiale est un facteur crucial, surtout en milieu urbanisé, pour obtenir des données valables sur le couvert végétal, en particulier sur les boisés. D'après Neville (1992), cette imagerie doit nécessairement être de

très haute résolution (inférieure à cinq mètres) afin de répondre aux exigences d'un inventaire forestier. Or, on assiste ces dernières années à un raffinement considérable de cette résolution avec l'avènement des images acquises par les satellites IKONOS (1999), Eros (2000) et Quickbird (2001). Une telle résolution spatiale sera particulièrement appréciée dans les régions métropolitaines, où la délimitation précise des surfaces boisées s'avère tout aussi importante que la distinction entre les divers peuplements qui sont présents. C'est sur cette délimitation que nous concentrerons nos recherches dans le cadre de cette étude.

Les images ayant la meilleure résolution spatiale sont celles qui sont acquises en mode panchromatique. On peut dire que ce sont les plus pauvres au niveau spectral étant donné qu'une seule bande est utilisée. Par contre, la précision spatiale atteinte est de l'ordre du mètre (pour IKONOS), ce qui permet d'obtenir un niveau de détail très intéressant. À la différence des images SPOT-4 panchromatiques où le pixel était de taille comparable à celle d'un arbre, une image IKONOS décompose l'arbre en plusieurs dizaines de pixels. La figure 1 montre de petits arbres isolés représentés par une quarantaine de pixels mais ce chiffre peut facilement atteindre la centaine pour de gros individus. Ainsi, on ne peut classifier efficacement un tel type d'image selon le seul niveau de gris de ses pixels pris individuellement et il nous faudra absolument employer une méthode qui tienne compte de leur voisinage. En ce sens, la texture s'avère une mesure prometteuse pour y distinguer les boisés des autres occupations du sol; elle est d'ailleurs utilisée depuis longtemps en cartographie forestière puisque c'est l'un des critères fondamentaux dans l'interprétation des photographies aériennes. Cette texture est en quelque sorte un indicateur de la distribution spatiale des valeurs de gris dans une image et elle nous permet d'évaluer et de décrire les variations de celles-ci dans le voisinage d'un pixel choisi. Il existe plusieurs mesures pour quantifier la texture d'une image et elles peuvent être appliquées de façon simple et rapide grâce à la puissance des outils informatiques actuels. Dans certains cas, les mesures quantitatives ainsi calculées seraient même plus aptes que l'œil humain à discriminer différentes textures.




Figure 1: Agrandissement d'une image IKONOS panchromatique montrant de petits arbres isolés.

Lorsque l'on parle de techniques servant à mesurer la texture d'une image, le nom de Robert M. Haralick est sans conteste le plus cité. Dès 1973, Haralick *et al.* proposaient plusieurs mesures permettant de décrire efficacement les divers types de texture d'une image à partir de la matrice de co-occurrence des niveaux de gris (MCO). Cette matrice renseigne sur la variabilité spatiale des valeurs de brillance dans une fenêtre d'échantillonnage parcourant toute l'image, en y effectuant une série de calculs comparatifs entre des paires de pixels. Pour chaque mesure, on peut alors créer une nouvelle image où chaque pixel prendra une valeur de texture calculée à partir de son propre voisinage. D'autres méthodes d'analyse texturale ont été aussi élaborées et mises à l'épreuve lors des trente dernières années, dont celles du variogramme (Atkinson et Danson, 1988; St-Onge et Cavayas, 1995; Lévesque et King, 1999), de la densité locale des arêtes (Hlavka, 1987) et du spectre de Fourier (Weszka *et al.*, 1976; Connors et Harlow, 1980). Cependant, la méthode de Haralick demeure encore aujourd'hui prédominante.

Les mesures de Haralick (ou d'autres qui s'y apparentent) furent appliquées sur des images satellitales ou aéroportées à des résolutions variables et dans divers domaines d'application. Généralement les études portant sur des images à des résolutions spatiales de 10 à 100 mètres ont montré que les mesures de texture basées sur les statistiques de distribution des valeurs de pixels (de premier, deuxième et même troisième ordre) ont un fort potentiel pour la classification des surfaces. Ainsi, en milieu forestier, Logan et Strahler (1979) ont appliqué avec succès une mesure d'écart-type à des images Landsat MSS à partir d'une fenêtre de 3×3 pixels pour distinguer plusieurs classes de densité du couvert forestier. Cette même expérience a d'ailleurs été reprise par Laporte (1983) sur des images SPOT-HRV simulées, avec cette fois une mesure de variance. De leur côté, Teillet *et al.* (1981) ont cherché à quantifier l'apport de la texture lorsque incorporée à une simple classification multispectrale de la forêt, en appliquant deux mesures calculées sur une fenêtre de convolution de 3×3 pixels sur une image à 20 mètres de résolution. Les études sur des images radar ont également fourni plusieurs résultats probants. Par exemple, les chercheurs Podest et Saatchi ont récemment travaillé sur la classification d'une forêt tropicale à partir d'une image SAR du satellite JERS-1, en sélectionnant trois mesures de texture et leurs résultats atteignaient une efficacité globale de 85 % (Podest et Saatchi, 1999). Plusieurs études réalisées dans le domaine de la glaciologie marine ont aussi donné des résultats intéressants en appliquant diverses mesures de texture à des images RSO (Holmes *et al.*, 1984; Barber et LeDrew, 1991; Clausi, 2002). Cependant, dans le domaine qui nous préoccupe pour cette recherche (i.e. la distinction entre classes d'occupation du sol), relativement peu d'études ont été réalisées. À titre d'exemple, citons Marceau *et al.* (1990) qui ont pu améliorer nettement leurs résultats de classification multispectrale pour l'ensemble des occupations du sol avec l'ajout de mesures de texture, et ce à partir d'images SPOT à 20 mètres de résolution.

En ce qui concerne l'imagerie à résolution plus fine (inférieure à 10 mètres), la plupart des résultats proviennent de simulation d'images satellitales ou de photographies aériennes scannées. Ces études démontrent que la prise en compte de la texture y est indispensable pour la cartographie des milieux et qu'elle constitue, pour certains types d'images (panchromatiques et radar), la seule option pour arriver à une classification des matériaux de surface. Ici encore, la plupart des études ont fait appel aux mesures de Haralick. Nagao et Matsuyama (1980) sont parmi les premiers chercheurs qui ont appliqué ces mesures à des photographies aériennes afin de montrer combien la texture est intéressante pour la caractérisation et la discrimination des diverses occupations du sol. De très bons résultats ont

également été obtenus par Vlcek *et al.* (1987) avec quatre mesures de texture sur des images aéroportées à 2 mètres de résolution. Plus récemment, Solberg *et al.* (1996) ont procédé la simulation d'images à partir de photographies aériennes pour obtenir des résolutions allant de 0.5 à 15 mètres. Le but de leurs recherches était d'évaluer l'amélioration éventuelle d'un inventaire forestier avec l'affinement de la résolution spatiale des images utilisées. Là encore, la texture était au centre des opérations de segmentation, sous la forme de cinq différentes mesures. Pour cette étude, le taux d'erreur global de la classification, visant à distinguer cinq classes de couverture forestière, passait de 46 % pour des résolutions de 15 et 10 mètres à 37 % pour une résolution de 5 mètres, à 30 % pour 1 mètre et enfin à 24 % pour 0.5 mètre.

Dans la plupart des études sur des images satellitaires réelles à résolution fine (inférieure à 10 mètres), les chercheurs ont opté pour des images de milieux naturels, alors que très peu d'exemples existent dans le contexte qui nous préoccupe, soit celui des milieux urbanisés. Citons toutefois Messier *et al.* (2000) qui ont analysé des images panchromatiques IRS dans un contexte de cartographie des occupations du sol en milieu densément urbanisé. Leurs résultats montrent qu'il est possible de distinguer, par une combinaison de l'image panchromatique et d'images de texture, de quatre à cinq classes d'occupation du sol.

1.2 - Objectifs et hypothèses

L'objectif principal de cette recherche est donc l'élaboration d'une méthode d'extraction automatisée des surfaces boisées à partir d'une seule image IKONOS panchromatique, dans la Région Métropolitaine de Montréal. Contrairement à la plupart des études récentes, aucune autre source de données n'interviendra dans le processus de détection: un utilisateur n'aurait à fournir qu'une image panchromatique pour obtenir au bout du compte une image classifiée délimitant les surfaces boisées.

L'une des hypothèses de ce travail est que la texture permet de caractériser et d'extraire les surfaces boisées d'une image IKONOS panchromatique avec un taux de confiance acceptable. Comme nous le verrons, les résultats d'une telle opération dépendent fortement des paramètres nécessaires au calcul des mesures de texture. Nous chercherons donc également à vérifier l'hypothèse qu'il existe une combinaison de ces paramètres pour laquelle la détection des surfaces boisées de notre image est optimale.

1.3 - Plan du mémoire

Ce mémoire se divise en quatre parties. La première présente l'approche par matrice de co-occurrence ainsi que les résultats d'études antérieures concernant les paramètres d'application de cette approche. Ces résultats pourraient nous permettre de mieux circonscrire notre démarche d'analyse (Chapitre II). Une deuxième partie décrit les données et outils disponibles pour cette recherche et la démarche suivie pour l'élaboration de notre méthode de détection des surfaces boisées (Chapitre III). La troisième partie montre l'application et l'optimisation de cette méthode, en présentant des résultats visuels (images classifiées) ainsi que quantitatifs (validation) sur plusieurs sous-images (Chapitre IV). En terminant, une quatrième partie sera constituée d'une discussion portant sur certaines étapes critiques de notre méthode et sur les résultats atteints, sans oublier d'énoncer les limites de son application à d'autres images (Chapitre V).

CHAPITRE II : L'APPROCHE PAR MATRICE DE CO-OCCURRENCE (CONCEPTS ET REVUE DE LITTÉRATURE)

2.1 - La matrice de co-occurrence et les images de texture

Les mesures de texture proposées par Haralick *et al.* (1973) reposent sur la matrice de co-occurrence des niveaux de gris (MCO) qui consiste en un tableau de $N \times N$ éléments, où N est le nombre de niveaux de gris de l'image. Chaque élément (i,j) de cette matrice représente la fréquence d'occurrence conjointe des valeurs i et j dans les paires de pixels séparés par un vecteur de translation déterminé. Une telle matrice est donc caractérisée par les trois paramètres f , p et d , désignant respectivement la taille de la fenêtre, le pas et la direction d'échantillonnage. En effet, pour attribuer à chaque pixel de l'image une valeur de texture basée sur son voisinage, on utilise une fenêtre de calcul de $f \times f$ pixels centrée sur le pixel en question; le même processus de calcul de la MCO est ensuite répété pour chacun des pixels de l'image. Le pas p est la distance entre les pixels constituant les paires à dénombrer tandis que la direction d fixe l'orientation de ces paires. Notons que f est forcément impaire (et supérieur à 3) pour qu'il puisse y avoir un pixel central, que p est toujours inférieur à f pour que l'on puisse former des paires, et que d peut prendre quatre valeurs, soit 0 (horizontale), 1 (45°), 2 (verticale), ou 3 (135°). De nombreuses combinaisons de ces trois paramètres sont envisageables et nous verrons au chapitre IV que leur choix est déterminant quant à l'efficacité de la détection des surfaces boisées.

La figure 2a explique la création d'une MCO avec une fenêtre de 5×5 pixels et un pas de 1 pixel, suivant la direction horizontale. Dans un tel cas, on regarde donc les paires de pixels séparés par une distance horizontale de 1 pixel (dans la direction des lignes de l'image) et on remplit la matrice avec les fréquences correspondant à toutes les paires de valeurs observées. Cette matrice sera forcément symétrique par rapport à sa diagonale car on dénombre toujours les paires de valeurs dans les deux sens définis par la direction d'échantillonnage. Ici, on retrouve huit fois la paire (0;0), aucune fois les paires (1;2) et (2;1), deux fois les paires (0;2), (2;0) et (2;2), etc.




Figure 2a: Exemple de matrice de co-occurrence ($f=5, p=1, d=0$)

Haralick *et al.* (1973) proposent quatorze mesures différentes de texture calculables à partir de la MCO. Dans le cadre de cette recherche, seules huit de ces mesures seront retenues d'après les recommandations formulées par divers auteurs (Connors et Harlow, 1980; Unser, 1986; Parker, 1997). Ce sont la moyenne, le contraste, la corrélation, l'énergie, l'entropie, l'homogénéité, la probabilité maximale et l'écart-type. Le tableau I présente les formules de ces huit mesures calculées à partir de la version standardisée des MCO, pour laquelle la valeur de chaque case de fréquence a simplement été divisée par la somme de toutes les valeurs de la matrice. $\hat{P}(i, j)$ désigne la valeur à la case (i, j) de la MCO standardisée.

Moyenne	$\mu = \sum_i \sum_j i \cdot \hat{P}(i, j)$
Contraste	$\sum_i \sum_j (i - j)^2 \cdot \hat{P}(i, j)$
Corrélation	$\sum_i \sum_j (i - \mu)(j - \mu) \cdot \hat{P}(i, j)$
Énergie	$\sum_i \sum_j \hat{P}(i, j)^2$
Entropie	$\sum_i \sum_j -\hat{P}(i, j) \cdot \log(\hat{P}(i, j))$
Homogénéité	$\sum_i \sum_j \frac{1}{1 + (i - j)^2} \cdot \hat{P}(i, j)$
Probabilité maximale	$Max\{\hat{P}(i, j)\}$
Écart-type	$\sqrt{\sum_i \sum_j (i - \mu)^2 \cdot \hat{P}(i, j)}$
Tableau I: Formules de Haralick pour les huit mesures de texture retenues	

La mesure dénommée «moyenne» n'est pas la valeur moyenne des pixels dans la fenêtre mais plutôt l'indice i moyen (dans la MCO) de l'ensemble des paires de cette fenêtre. L'image résultante est semblable à l'image initiale à laquelle on aurait appliqué un filtre

médian (voir les figures 9a et 9b). La mesure d'écart-type ne correspond pas non plus à l'écart-type des valeurs des pixels que l'on retrouve dans la fenêtre, mais plutôt à un écart-type de l'indice i de l'ensemble des paires de pixels. Cette mesure donne des images qui pourraient provenir d'une détection d'arêtes sur l'image initiale, étant donné que les fortes valeurs d'écart-type coïncident avec les zones de transition entre deux surfaces homogènes. Le contraste constitue quant à lui un indice de la quantité de variation à travers la fenêtre d'étude. Un pixel aura une forte valeur de contraste quand sa MCO présentera de faibles valeurs sur sa diagonale, c'est-à-dire lorsque la fenêtre d'étude comptera peu de paires «symétriques», soit (0;0), (1;1), (2;2), etc. C'est en quelque sorte l'inverse pour la mesure d'homogénéité. Cette dernière est en effet un indice de la concentration des fréquences élevées le long de la diagonale de la matrice. Ainsi, dans le cas de la figure 2a, on obtiendra une forte valeur d'homogénéité et une faible valeur de contraste. L'image de la figure 2b, qui est beaucoup moins homogène, donnera les résultats inverses. L'énergie et l'entropie forment un autre couple d'indices «inverses» puisqu'une texture à forte énergie aura généralement une faible entropie. L'énergie renseigne sur le niveau de concentration des valeurs non-nulles dans la MCO, sans que cette concentration ne se fasse nécessairement sur la diagonale comme pour l'homogénéité. Au contraire, l'entropie est un indice de remplissage de la matrice, donc d'une présence équilibrée de chacune des paires possibles dans la fenêtre d'étude. De son côté, la corrélation évalue la dépendance linéaire entre les pixels composant les paires de valeurs observées. On aura habituellement une forte corrélation lorsque le pas est petit par rapport à la «périodicité» de la texture et une faible corrélation pour un pas approchant ou dépassant cette périodicité. Enfin, la probabilité maximale donne comme son nom l'indique la valeur la plus élevée dans la MCO, soit la probabilité associée à la paire la plus fréquente dans la fenêtre. Dans la figure 2a, elle vaut 0.4 car la paire (0;0) revient huit fois sur vingt.




Figure 2b: Autre exemple de matrice de co-occurrence ($f=5, p=1, d=0^\circ$)

La figure 3 montre les MCO standardisées pour les fenêtres des figures 2a et 2b ainsi que les valeurs obtenues pour les huit mesures de texture. On y remarque bien le comportement «couplé» des mesures contraste/homogénéité et énergie/entropie. La mesure de probabilité maximale est également corrélée avec les mesures d'énergie et d'entropie, puisqu'une forte valeur d'énergie implique une concentration marquée dans l'une des cases de la MCO et par le fait même une forte probabilité maximale.

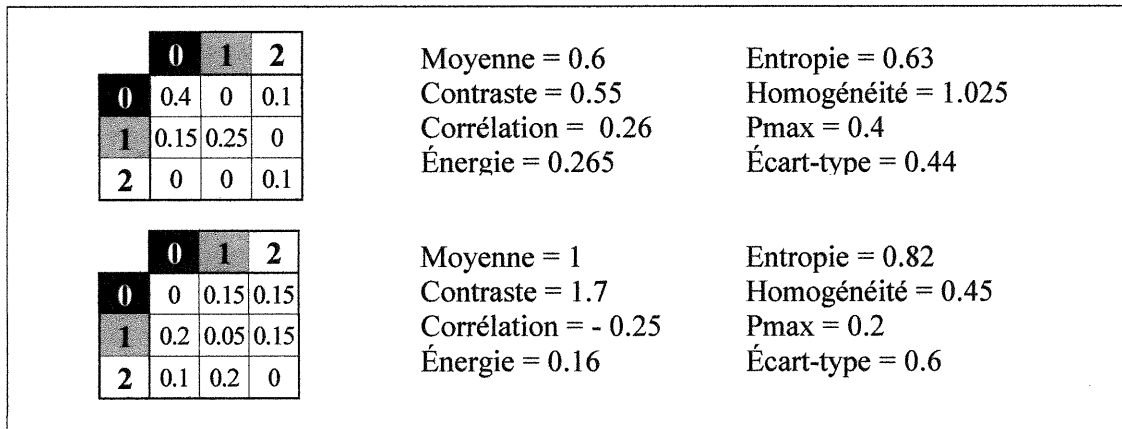


Figure 3: MCO standardisées et mesures de texture

2.2 - La méthode de Unser (1986)

En 1986, Unser a proposé une manière alternative de calculer les mesures de texture d'Haralick *et al.* (1973) permettant de réduire significativement les exigences en temps et en espace-mémoire. L'auteur remplace la MCO par deux histogrammes: l'histogramme des sommes et l'histogramme des différences. Ils définissent selon Unser les fonctions de probabilité de premier ordre suivant les axes principaux de la MCO et possèdent donc une capacité presque identique à discriminer les différentes textures d'une image. Alors que la MCO compte le nombre de chaque paire de valeurs possible que l'on retrouve dans la fenêtre d'étude, l'histogramme des sommes représente plutôt la fréquence avec laquelle on retrouve chaque somme des deux valeurs constituant les paires de pixels retrouvés dans cette fenêtre. L'histogramme des différences suit le même principe mais on s'intéresse plutôt aux différences entre les deux valeurs des pixels. L'exemple de la figure 2a donnerait donc un histogramme des sommes tel que les «valeurs-sommes» 0, 1, 2, 3 et 4 auraient respectivement des fréquences de 8, 3, 7, 0 et 2. De même, on obtiendrait un histogramme des différences dont les «valeurs-différences» -2, -1, 0, 1, et 2 auraient des fréquences respectives de 2, 0, 15,

3 et 0. C'est l'utilisation conjointe de ces deux histogrammes qui permet de calculer une très bonne approximation des mesures de texture développées par Haralick. Le tableau II présente les formules des huit mesures retenues (voir Tableau I), où $\hat{P}_s(i)$ est la valeur à l'indice i de l'histogramme des sommes standardisé et $\hat{P}_d(j)$ celle à l'indice j de l'histogramme des différences standardisé.

Moyenne	$\mu = \frac{1}{2} \sum_i i \cdot \hat{P}_s(i)$
Contraste	$\sum_j (j^2 \cdot \hat{P}_d(j))$
Corrélation	$\frac{1}{2} \left(\sum_i (i - 2\mu)^2 \cdot \hat{P}_s(i) - \sum_j (j^2 \cdot \hat{P}_d(j)) \right)$
Énergie	$\sum_i (\hat{P}_s(i)^2) \cdot \sum_j (\hat{P}_d(j)^2)$
Entropie	$-\sum_i (\hat{P}_s(i) \log(\hat{P}_s(i))) - \sum_j (\hat{P}_d(j) \log(\hat{P}_d(j)))$
Homogénéité	$\sum_i \sum_j \left(\frac{1}{1+j^2} \cdot \hat{P}_d(j) \right)$
Probabilité maximale	$Max\{\hat{P}_s(i)\}$
Écart-type	$\sqrt{\frac{1}{2} \left(\sum_i ((i - 2\mu)^2 \cdot \hat{P}_s(i)) + \sum_j (j^2 \cdot \hat{P}_d(j)) \right)}$
Tableau II: Formules de Unser pour les huit mesures de texture retenues	

2.3 - Problèmes d'application

La création des images de texture est relativement simple mais très exigeante en temps de calcul ainsi qu'en espace-mémoire, particulièrement lorsque le nombre de valeurs possibles pour chaque pixel est élevé. De plus, comme Pratt (1991) le souligne, la confiance statistique associée aux mesures de texture dépend du «taux d'occupation» de la MCO dont elles sont tirées. C'est pourquoi plusieurs chercheurs ont opté pour une réduction du nombre de niveaux de gris à 8, 16, 24 ou 32 dans leur image d'étude avant d'entreprendre la création des images de texture (Holmes *et al.*, 1984; Marceau *et al.*, 1990; Barber et LeDrew, 1991). D'après Marceau *et al.* (1990), la compression n'influence que très peu la séparabilité entre les divers types d'occupation du sol quand on utilise un grand d . Clausi (2002), qui travaille sur

des images radar, avance même qu'il est inutile d'utiliser plus de 24 niveaux de gris puisque cela n'améliore pas l'efficacité d'une analyse texturale. Une telle compression de l'échelle numérique de l'image est également opérée automatiquement dans le module TEX du logiciel Xspace qui calcule la plupart des mesures d'Haralick.

D'autre part, le choix des paramètres f , p et d pour le calcul de la MCO a fait l'objet de nombreuses études suivant plusieurs approches. Ainsi, certains auteurs ont utilisé le semi-variogramme pour déterminer la taille de fenêtre f optimale, en assumant que celle-ci correspond au point de stabilisation de la variance inter-pixel (Wulder *et al.*, 1998; Franklin *et al.*, 2000). Une méthode par coefficient de variation (l'écart-type divisé par la moyenne), calculé pour chaque indice de texture et chaque type d'occupation du sol, a également été utilisée: le f optimal est là encore celui où l'on observe une stabilisation de ce coefficient (Anys *et al.*, 1998). D'autres auteurs ont préféré opter pour une analyse systématique à partir d'un large éventail de valeurs de f , établissant comme optimale celle qui permet la meilleure distinction inter-classes (Franklin *et al.*, 2001) ou le meilleur résultat de classification (Marceau *et al.*, 1990; Messier *et al.*, 2001). Ainsi, Marceau *et al.* (1990) qui travaillent sur des images SPOT à 20 mètres de résolution concluent que le f optimal dépend du type de couvert et qu'il oscille entre 17 et 25 pixels. De même, Franklin *et al.* (2001) préconisent l'usage d'un f de 25 pixels avec des images IKONOS panchromatiques à un mètre de résolution. Cette tendance à l'utilisation d'une taille de fenêtre plutôt grande se dégage dans quelques études, comme le montre le tableau III. En ce qui a trait au pas p , la plupart des auteurs préconisent une valeur optimale de 1, sans toujours justifier leur choix. Enfin, la direction d'échantillonnage d a fait l'objet de quelques études systématiques mais le choix optimal semble être dépendant du milieu d'application (Messier *et al.*, 2001; Clausi, 2002). Toutefois, dans sa recherche fondée sur le variogramme, St-Onge (1994) suggère de tenir compte de l'azimuth solaire dans l'image étudiée, étant donné que l'orientation des ombres sur une image est déterminante pour sa texture.

Concernant les mesures de texture, leur choix varie d'un auteur à l'autre et il ne semble pas y avoir de consensus quant à une combinaison optimale de celles-ci (voir tableau III). D'ailleurs, plusieurs auteurs ne se limitent pas aux mesures tirées de la MCO et emploient une combinaison de mesures de premier, deuxième et même troisième ordre (Anys *et al.*, 1998). Retenons cependant les travaux de Clausi (2002) qui définit trois ensembles de mesures parmi celles d'Haralick dont on ne devrait choisir qu'une de chaque, tel que le montre le tableau III.

AUTEURS (DATE)	IMAGES UTILISÉES	TYPE D'ÉTUDE	PRÉ-TRAITEMENT	MESURES ET PARAMÈTRES f, p, d CHOISIS
Teillet <i>et al.</i> (1981)	MSS aéroporté (11 bandes) 20 m	cartographie forestière	compression linéaire à 256 niveaux de gris	homogénéité, corrélation (combinées aux bandes spectrales) $f=3, p=1$ ou $2, d$ non-spécifiée
Vlcek <i>et al.</i> (1987)	Imagerie aérienne (4 bandes) 2 m	cartographie d'occupation du sol en milieu mixte	filtrage et compression à 16 niveaux de gris	entropie, corrélation, somme des carrés, second moment angulaire (combinées aux bandes spectrales) $f=3, p=1$ et d horizontale
Marceau <i>et al.</i> (1990)	SPOT (3 bandes) 20 m	cartographie d'occupation du sol en milieu mixte	compression à 16 ou 32 niveaux de gris	second moment angulaire, moment inverse, entropie, contraste (combinées aux bandes spectrales) $f=17$ ou $25, p=1$ et d = moyenne des 4 directions principales
Solberg <i>et al.</i> (1996)	Imagerie aérienne (3 bandes et panchro) 0.5 à 15 m	cartographie forestière	non-spécifié	second moment angulaire, moment des différences inverses (combinées aux bandes spectrales et à des statistiques locales), f, p et d non-spécifiés
Anys <i>et al.</i> (1998)	MEIS (8 bandes) 7 m	cartographie d'occupation du sol en milieu urbain	non-spécifié	entropie (combinée aux bandes spectrales et à des mesures de premier et troisième ordres), $f=9, p=1$ et d horizontale
Wulder <i>et al.</i> (1998)	CASI (5 bandes) 1 m	calcul d'un indice de structure forestière	non-spécifié	homogénéité, contraste, dissimilarité, moyenne, écart-type, entropie (combinées au <i>NDVI</i> , au semi-variogramme et à des mesures de texture de premier ordre), $f=7, 9$ ou $11, p$ et d non-spécifiés
Podest et Saatchi (1999)	JERS-1 (RSO) 100 m	cartographie forestière	non-spécifié	moyenne, variance, entropie, $f=5, p$ et d non-spécifiés
Franklin <i>et al.</i> (2000)	MSV (3 bandes) 0.3 à 8 m CASI (5 bandes) 1 m	cartographie forestière	compression linéaire à 256 niveaux de gris	homogénéité, entropie (combinées aux bandes spectrales), f adaptable, $p=1$ et d horizontale
Franklin <i>et al.</i> (2001)	IKONOS (panchro) 0.82 m	étude de séparabilité entre des classes forestières	non-spécifié	homogénéité (et une mesure de premier ordre), $f=25, p$ et d non-spécifiés
Messier <i>et al.</i> (2001)	IRS (panchro) 6 m RADARSAT (RSO) 6 m	cartographie d'occupation du sol en milieu urbain	aucun	moyenne, entropie, énergie, contraste, homogénéité, écart-type, probabilité maximale (combinées aux bandes spectrales), $f=25, p=1$ et $d=45$ degrés
Clausi (2002)	Imagerie aérienne (RSO) 100 m RADARSAT (RSO) 100 m	cartographie des types de glaces de mer	compression à 24 niveaux de gris	[contraste, homogénéité, dissimilarité ou différence inverse] et [énergie, entropie ou probabilité maximale] et [corrélation], $f=8$ ou $16, p=1$ et d = ensemble des directions ou direction de visée

Tableau III : Récapitulatif des études antérieures utilisant l'approche par matrice de co-occurrence

2.4 - Conclusion

Comme nous venons de le voir, il existe une méthode simple et efficace qui nous permet de calculer les mesures de textures d'Haralick *et al.* (1973) sans passer par celui de la MCO. Il s'agit de la méthode de Unser (1986) qui facilitera et accélèrera beaucoup nos analyses texturales. D'autre part, notre revue des travaux antérieurs nous indique qu'il n'existe pas de méthode éprouvée nous dictant *a priori* de façon fiable la combinaison de mesures de textures et les paramètres de calcul f , p et d à retenir afin d'aboutir à une bonne discrimination inter-classes, quel que soit le milieu d'étude. Le type d'image utilisé joue d'ailleurs certainement un rôle prédominant dans ce choix. Pour caractériser de façon optimale les surfaces boisées sur une image IKONOS panchromatique, nous adopterons une approche empirique à partir d'un large éventail de combinaisons de paramètres. Les différentes étapes de notre démarche seront détaillées au chapitre suivant.

CHAPITRE III : DONNÉES, OUTILS ET DÉMARCHE

3.1 - Données utilisées

Cette recherche a été réalisée en étroite collaboration avec l'équipe Vision du CRIM (Centre de Recherche Informatique de Montréal) qui a mis à notre disposition une image panchromatique du satellite IKONOS-2 récemment acquise. Sa résolution spatiale est de un mètre et sa radiométrie est à huit bits. Elle couvre un territoire de 144 km² (12004×12004 pixels) situé au sud-ouest du Mont Saint-Bruno (Québec) et a été captée le 21 août 2000 à 15h31 T.U. (voir les figures 4 et 5). On y voit des champs, des surfaces boisées, des zones résidentielles (Longueuil, Saint-Hubert et Saint-Bruno-de-Montarville), deux terrains de golf, de grands axes routiers (route 116, autoroute 30) et l'aéroport de Saint-Hubert. La couverture nuageuse y est nulle et l'angle de visée d'environ 19 degrés.




Figure 4: Région Métropolitaine de Montréal (Image Landsat-7 ETM4). La barre blanche mesure 10 km. Le carré montre la région de l'image IKONOS utilisée pour cette étude.




Figure 5: Image IKONOS panchromatique du mois d'août.

Rappelons qu'une image panchromatique ne possède par définition qu'une seule bande spectrale qui englobe généralement les trois bandes du spectre visible, soit la bande bleue (446 à 500 nanomètres), la bande verte (500 à 578 nanomètres) et la bande rouge (620 à 700 nanomètres). Par exemple, une image panchromatique SPOT couvre l'intervalle de 510 à 730 nanomètres. Dans le cas des images IKONOS cependant, la bande panchromatique est beaucoup plus large puisqu'elle s'étend de 450 nanomètres jusqu'à 900 nanomètres. Elle comprend donc une partie de l'infrarouge rapproché, ce qui confère à IKONOS un avantage certain sur ses prédécesseurs pour la détection des boisés. En effet, on sait que les arbres en feuilles ont toujours une réponse intense dans l'infrarouge rapproché grâce à la présence de

chlorophylle. Ainsi, les images IKONOS panchromatiques devraient offrir une meilleure capacité de distinction entre les plans d'eau et les surfaces boisées que les images SPOT, sur lesquelles ces deux types d'occupation du sol peuvent se confondre. De plus, IKONOS bénéficiant d'une précision exceptionnelle grâce à sa résolution spatiale de 1 mètre, comparativement à 10 mètres pour SPOT, on peut s'attendre à de bons résultats pour la détection des boisés.

3.2 - Outils

Pour mener à bien cette recherche fondée sur la création d'images de texture, nous disposons du programme «fast.c», tel que proposé par Parker (1997), qui implémente simplement les formules de texture de Unser (1986) et permet de travailler avec 256 niveaux de gris. Nous avons évidemment dû tester l'exactitude de ce programme en vérifiant ses résultats par des calculs manuels, et ce pour diverses combinaisons des paramètres. Nous avons ainsi été amenés à corriger le code de ce programme qui ne fonctionnait pas tel que prévu. Une erreur d'indices y engendrait en effet la création de fenêtres de calcul tronquées d'une colonne et d'une ligne. Nous avons ensuite modifié ce code afin d'obtenir un outil mieux adapté à nos besoins: une nouvelle mesure, la corrélation, a notamment été ajoutée puisqu'elle fait partie, selon Unser (1986), de la combinaison optimale pour la classification texturale. Pour le reste des opérations, nous utiliserons les logiciels ImageWorks et Xspace de PCI, ce dernier comprenant divers algorithmes de classification d'image, de filtrage et de validation, ainsi que le logiciel public CVIPtools (disponible au CRIM) pour ses fonctionnalités d'égalisation d'histogramme.

3.3 - Démarche

Cette section présente en les justifiant les différents choix que nous avons été amenés à faire en ce qui concerne l'ensemble des opérations constituant notre méthode de détection des surfaces boisées. La figure 6 expose les quatre étapes de cette démarche, depuis la création des sous-images jusqu'au choix de la méthode de segmentation.

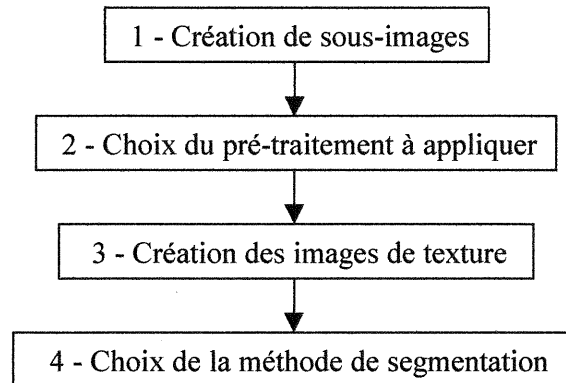


Figure 6: Organigramme de la démarche suivie

3.3.1 Création de sous-images

Il est indispensable de définir ici ce que nous considérons comme surface boisée pour les besoins de cette étude: un territoire densément couvert d'arbres matures et dont la superficie dépasse 1000 mètres carrés, ce qui équivaut à une dizaine d'arbres de 10 mètres de diamètre. Une surface boisée ne pourra toutefois pas être excessivement étroite et nous établissons sa largeur minimale à environ trois arbres matures, ce qui correspond à une trentaine de mètres. De tels seuils garantissent aux surfaces boisées un intérêt écologique non-négligeable, celles-ci constituant d'importants abris ou corridors fauniques.

Pour réaliser efficacement la caractérisation texturale des surfaces boisées sur l'image IKONOS, il est indispensable de n'en utiliser que des extraits étant donné que celle-ci occupe un espace-disque de 137.5 mega-octets. La première des opérations à réaliser est donc la création de sous-images de 512 par 512 pixels à partir de l'image initiale. Celles-ci doivent évidemment offrir une couverture arborescente assez importante, tout en restant représentatives de l'ensemble des occupations du sol de la région d'étude. On cherchera d'ailleurs à diversifier autant que possible leur provenance dans l'image initiale. Les figures 7a à 7e montrent les cinq sous-images retenues. La composition des surfaces boisées que l'on y retrouve est relativement uniforme d'une sous-image à l'autre: en effet, la carte forestière disponible pour notre zone d'étude (à l'échelle 1:20 000) nous montre que la plupart des boisés répertoriés sont constitués d'arbres feuillus (érables, bouleaux, peupliers) âgés d'une trentaine d'années en moyenne. La proportion de ces surfaces boisées dans les différentes sous-images

est cependant très variable, comme nous le montre le tableau IV. La suite des opérations sera répétée systématiquement pour chacune de ces sous-images pour tenter de faire ressortir une tendance dans les résultats de la détermination des paramètres optimaux pour les calculs de texture. Toutefois, nous ne présenterons comme illustration de la démarche que les sous-images A et B qui constituent deux cas bien distincts: la première est à moitié couverte de surfaces boisées tandis que la deuxième n'en contient qu'une de taille assez réduite.

Sous-image	A	B	C	D	E
Proportion de surfaces boisées	50 %	10 %	50 %	40 %	60 %
Autres types d'occupation du sol	bâti (résidentiel), végétalisé (non-boisé)	bâti (résidentiel et récréatif), champs agricoles, rivière, végétalisé (non-boisé)	bâti (résidentiel), végétalisé (non-boisé)	bâti (résidentiel), lac, route, végétalisé (non-boisé)	route, végétalisé (non-boisé)
<u>Tableau IV</u> : Description des sous-images choisies.					




Figure 7a: Sous-image A (l'image couvre une surface de 512 m × 512 m)



Figure 7b: Sous-image B (l'image couvre une surface de 512 m × 512 m)



Figure 7c: Sous-image C (l'image couvre une surface de 512 m × 512 m)



Figure 7d: Sous-image D (l'image couvre une surface de 512 m × 512 m)




Figure 7e: Sous-image E (l'image couvre une surface de 512 m × 512 m)

3.3.2 Choix du pré-traitement à appliquer

Dans plusieurs travaux portant sur l'analyse texturale (Haralick *et al.*, 1973; Unser, 1986), une égalisation d'histogramme est appliquée aux images initiales afin de garantir que les statistiques de premier ordre, soit la moyenne et l'écart-type des valeurs numériques, n'interviendront pas dans la discrimination texturale des régions d'une image. Celles-ci sont en effet susceptibles de varier d'une image à une autre, ou même d'une partie d'image à une autre, en raison d'une luminosité non-uniforme par exemple, ce qui risquerait d'entraîner de mauvais résultats de classification. Ojala et Pietikäinen ont d'ailleurs récemment rappelé l'importance d'un tel pré-traitement dans le processus de classification texturale (Ojala et Pietikäinen, 2001). Cette «standardisation» facilitera ainsi l'élargissement de notre méthode à d'autres images qui n'auraient pas été acquises dans les mêmes conditions radiométriques.

L'égalisation d'histogramme sera ici réalisée de façon locale, sous une fenêtre se déplaçant sur l'ensemble des pixels d'une sous-image. La taille de la fenêtre en question, sera de 32×32 pixels afin de s'accorder avec la largeur minimale d'une surface boisée telle que définie à la section 3.3.1. L'un après l'autre, chaque pixel de l'image se verra attribuer une valeur égalisée par rapport à l'ensemble des pixels de la fenêtre dont il est le centre (16^{ième} ligne, 16^{ième} colonne). L'algorithme vise à transformer la sous-image pour que son histogramme soit aussi uniformisé que possible au niveau local; ainsi, dans toute fenêtre de 32×32 pixels que l'on tirerait de l'image, chaque valeur numérique possible (0 à 255) aura une probabilité quasi-identique de se retrouver. Visuellement, cette opération rehausse le niveau de détail de zones qui semblaient constantes initialement (voir les figures 8a et 8b).




Figure 8a: Sous-image A initiale (à gauche) et égalisée localement (à droite).



Figure 8b: Sous-image B initiale (à gauche) et égalisée localement (à droite).

Tout au long de cette étude, la création des images de texture sera effectuée à partir d'images à 256 niveaux de gris, malgré les implications que l'on connaît en ce qui concerne les coûts de traitement (temps et espace-disque). Nous préférons en effet conserver le degré de quantification initial de notre image pour éviter la perte d'informations que pourrait induire une opération de compression. La méthode de Unser, présentée à la section 2.2, nous permet de procéder ainsi grâce à sa rapidité de calcul.

3.3.3 Création des images de texture

Comme nous l'avons mentionné à la section 2.4, nous adopterons une méthode empirique en ce qui concerne le choix des paramètres pour les calculs de texture puisque nous ne connaissons pas *a priori* de combinaison qui optimiserait la détection des surfaces boisées sur une image IKONOS panchromatique. Il faut donc choisir un nombre limité de valeurs pour f et p , puisqu'il serait beaucoup trop long d'essayer toutes les combinaisons possibles, d'autant plus que nous répèterons toutes les opérations sur les cinq sous-images. De plus, nous devons faire face à de fortes exigences en espace-disque puisque chaque image de texture est en format 32 bits et utilise 1 mega-octet de mémoire. Considérant le diamètre moyen des arbres présents sur notre image (une dizaine de pixels), nous choisissons donc trois tailles de fenêtre (5, 17 et 35 pixels) et six pas (1, 2, 4, 7, 11 et 16 pixels), ce qui donne les combinaisons f - p suivantes: 5-1, 5-2, 17-1, 17-2, 17-4, 17-7, 17-11, 35-1, 35-2, 35-4, 35-7,

35-11 et 35-16 (voir le tableau V). Les combinaisons 5-4 et 17-16 ont été écartées vu le nombre très réduit de paires de pixels qui y seraient disponibles pour le calcul des textures; en effet, dans le cas d'une direction horizontale, on n'utiliserait qu'une paire par ligne, soit 5 paires au total pour la combinaison 5-4 et 17 paires dans le cas 17-16.

Fenêtres d'échantillonnage	Pas d'échantillonnage	Directions d'échantillonnage	Nombre total d'images de texture par sous-image
5 x 5	1 / 2	0 / 45 / 90 / 135	64
17 x 17	1 / 2 / 4 / 7 / 11	0 / 45 / 90 / 135	160
35 x 35	1 / 2 / 4 / 7 / 11 / 16	0 / 45 / 90 / 135	192

Tableau V: Paramètres utilisés pour la création des images de textures

En ce qui concerne le paramètre d , il a été démontré que les zones ombragées créées par les arbres sur des images à très haute résolution induisent une anisotropie marquée des textures des boisés, particulièrement dans une direction proche de celle d'illumination du soleil (St-Onge, 1994). Dans un milieu urbanisé, les zones bâties sont aussi caractérisées par une telle anisotropie. Cependant, la plupart des capteurs satellitaires modernes peuvent acquérir des images avec des angles de visée variables, ce qui peut se traduire par des ombrages minimisés (cas d'observation du même côté que le soleil) ou exacerbés (cas d'observation à l'opposé du soleil). Pour obtenir un détecteur de boisés relativement robuste dans son application à d'autres images, nous pensons qu'il est préférable d'éliminer l'influence de l'angle solaire azimutal dans les images de texture sur lesquelles il sera fondé. Nous calculerons donc systématiquement les quatre images correspondant aux quatre valeurs possibles de d pour ensuite les fusionner, ce qui divisera du même coup par quatre le nombre d'images à considérer pour la suite des opérations. Pour chacune des huit mesures de texture et pour chaque combinaison $f-p$, nous créons ainsi une seule nouvelle image en attribuant à chacun de ses pixels la moyenne arithmétique des valeurs de ce même pixel dans les quatre images «orientées».

Enfin, les images moyennes de texture seront normalisées sur 256 niveaux de gris (0 à 255) afin de ramener la dynamique de toutes ces images à une même plage de valeurs. En effet, l'intervalle occupé par les valeurs de texture calculées diverge énormément selon la

mesure. À titre d'exemple, dans le cas de la sous-image A avec une combinaison $f-p$ de 17-1, la mesure d'énergie prendra des valeurs allant de 0 à 0.00024 tandis que celle de corrélation s'étalera entre 0 et 16488.

A partir des sous-images égalisées, nous créons donc 32 images de texture pour chaque combinaison, soit quatre images pour chacune des huit mesures de texture retenues, puisqu'il y a quatre directions possibles. Pour l'ensemble des cinq sous-images, quelques 2080 images de texture sont ainsi produites (voir le tableau V), sans compter les nombreuses images d'essais précédant le choix des combinaisons à retenir. À titre d'exemple, les figures 9a et 9b présentent les huit images moyennes de texture normalisées correspondant aux sous-images A et B (combinaison 5-1). Comme nous l'avons vu dans le chapitre précédent, plusieurs mesures apparaissent fortement corrélées, certaines positivement comme l'énergie et la probabilité maximale, d'autres négativement comme le contraste et l'homogénéité ainsi que l'énergie et l'entropie.

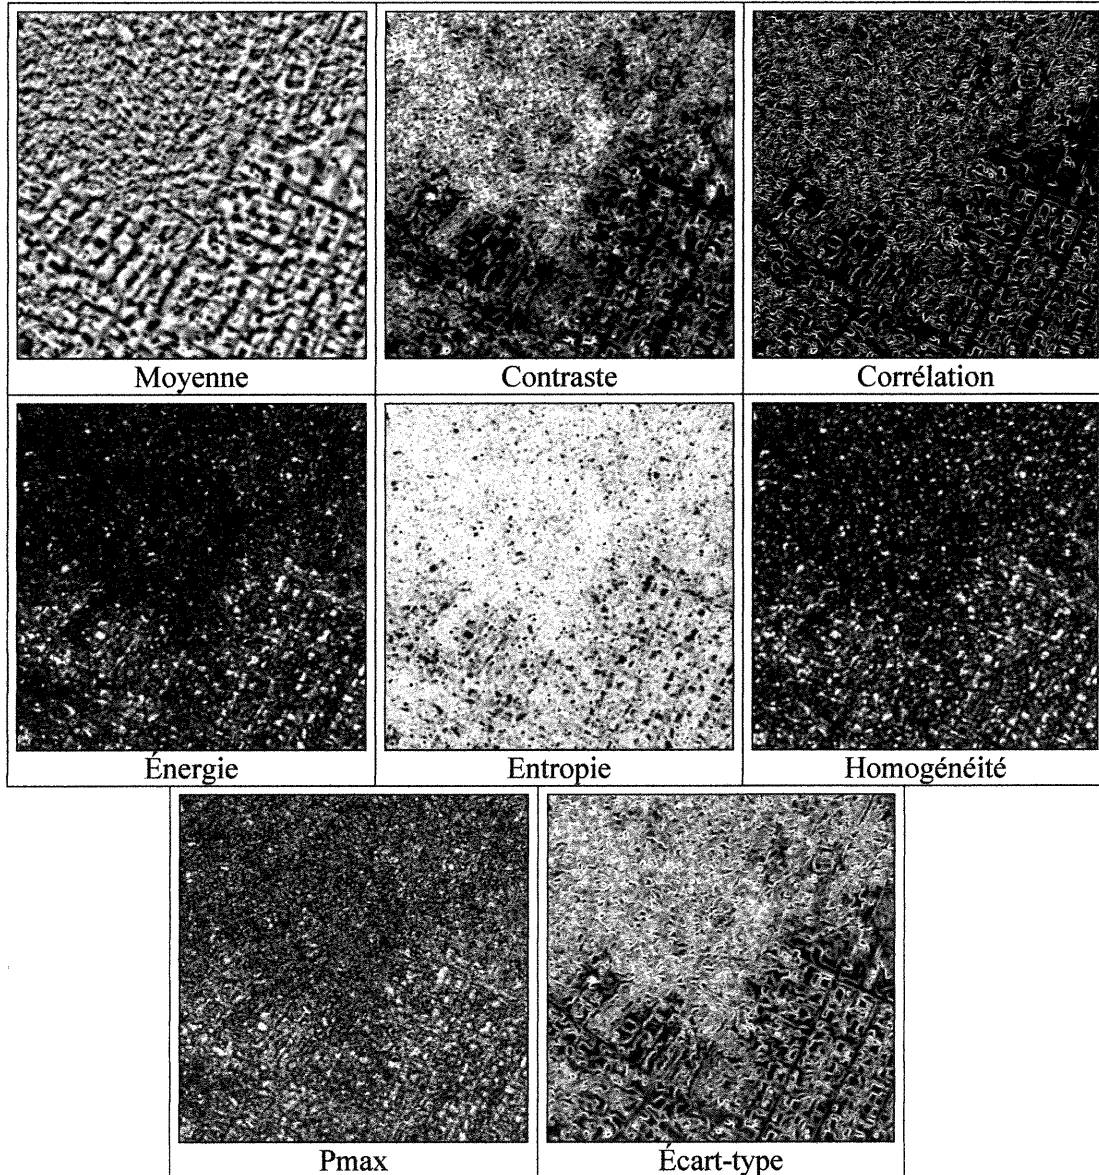


Figure 9a: Images moyennes de texture normalisées pour la sous-image A
(combinaison 5-1).




Figure 9b: Images moyennes de texture normalisées pour la sous-image B
(combinaison 5-1).

3.3.4 Choix de la méthode de segmentation

Il nous faut à présent sélectionner une méthode pour la segmentation des images entre zones boisées et non-boisées, qui constitue l'opération centrale de cette recherche. Afin de bien cerner le potentiel de la texture pour l'extraction des surfaces boisées sur une image IKONOS panchromatique, nous avons décidé de n'utiliser que les images de texture comme données d'entrées pour la segmentation. Deux pistes principales s'offrent à nous: une segmentation binaire directe de l'image en deux classes «boisé» et «non-boisé» ou une classification de l'image en plusieurs classes que l'on regrouperait par la suite pour aboutir à ces mêmes deux classes.

La première piste nous a amené à expérimenter en premier lieu les diverses méthodes de segmentation binaires (par seuillage et par relaxation) implémentées par Parker (1997), à partir des images de texture prises individuellement. Après plusieurs essais pour diverses mesures de texture et combinaisons f - p , nous en arrivons à la conclusion que l'efficacité de ces méthodes dépend beaucoup trop de l'image étudiée et que celles-ci ne sont donc pas appropriées au cadre de notre étude. L'utilisation d'une seule mesure de texture ne permettant pas de segmenter une image IKONOS panchromatique entre zones boisées et non-boisées de façon fiable, nous avons ensuite envisagé de combiner les différentes mesures pour mieux caractériser la texture de ces boisés. Une classification binaire non-dirigée à partir des huit mesures retenues a donc été réalisée à l'aide du module KCLUS de Xpace, fondé sur l'algorithme «K-Means». Malheureusement, cette méthode n'a guère donné de meilleurs résultats dans l'ensemble, sauf dans certains cas isolés (combinaisons 17-1 et 35-1 pour la sous-image A), et on ne saurait se satisfaire d'une méthode aussi peu fiable. La classification non-dirigée nous a cependant montré que la combinaison d'un petit p et d'un grand f semble être celle qui donne la détection la plus efficace, comme c'était le cas avec les segmentations à partir d'images de texture individuelles. En outre, ces résultats nous montrent que nos images de texture ont un potentiel certain pour distinguer les surfaces boisées des autres types d'occupation du sol mais qu'une classification de type binaire ne suffit pas pour mener à bien notre objectif de détection des surfaces boisées.

Nous nous orientons donc plutôt vers la deuxième piste qui implique une classification multi-classes de l'image, avec laquelle nous devrions obtenir une meilleure caractérisation texturale des diverses occupations du sol et donc une meilleure efficacité de détection des

surfaces boisées après regroupement des classes. Pour ce faire, nous emploierons une classification dirigée à partir des huit mesures de texture et des sites d'entraînement de chaque classe présente sur l'image. L'introduction de cette connaissance *a priori* du territoire, bien que rudimentaire, devrait en effet accroître significativement l'efficacité de la détection des surfaces boisées en réduisant notamment les erreurs de commission. Nous choisissons la classification par maximum de vraisemblance qui est la méthode standard généralement utilisée sous l'hypothèse de la distribution multi-normale des classes et qui permet un contrôle accru sur les paramètres régissant la règle de décision.

CHAPITRE IV : APPLICATION ET RÉSULTATS

4.1 - Entraînement du classificateur et validation des résultats

Afin de réaliser la classification dirigée par maximum de vraisemblance sur une sous-image, il faut sélectionner des sites d'entraînement pour chaque classe présente sur cette sous-image. Comme le rappelle le tableau VI, chacune des sous-images est caractérisée par son propre ensemble de classes, où l'on retrouve presque toujours le trio «boisé» / «îlot urbain» / «gazon».

Classe	«boisé»	«îlot urbain»	«gazon»	«gazon court»	«agricole»	«eau»	«route»	«béton»
Sous-image A	X	X	X					
Sous-image B	X	X	X		X	X		X
Sous-image C	X	X	X					
Sous-image D	X	X	X			X	X	
Sous-image E	X		X	X			X	

Tableau VI: Classes présentes sur chacune des sous-images

Les figures 10a et 10b présentent les sites d'entraînement pour les sous-images A et B. Dans le premier cas, nous avons délimité deux zones caractéristiques de la classe «boisé» (rouge), deux autres pour la classe «gazon» (bleu) et une plus grande pour la classe «îlot urbain» (vert) qui inclut bâtiments et routes. Dans le deuxième cas, nous retrouvons les sites «boisé» (rouge), «agricole» (vert), «eau» (bleu foncé), «gazon» (bleu pâle), «îlot urbain» (jaune) et «béton» (mauve) qui correspond aux gros bâtiments apparaissant en blanc sur l'image. Ces sites doivent refléter le plus fidèlement possible les diverses variantes de chacune des classes afin qu'elles puissent toutes être reconnues lors de la classification. Par exemple, sur la figure 10a, l'un des sites de la classe «boisé» couvre une surface boisée dense (plus foncé) tandis que l'autre correspond à un boisé plus ouvert (plus pâle). Dans le cas de la figure 10b, le site «agricole» englobe des champs relativement secs (gris pâle) mais aussi très

humides (gris foncé), voire inondés (noir). Des sites de validation doivent également être tracés pour ces classes afin de permettre une validation approfondie des résultats de classification (voir ci-après). Les sites de validation sont montrés en pointillés sur les figures 10a et 10b, en utilisant le même code de couleurs que pour les sites d'entraînement.




Figure 10a: Sites d'entraînement et de validation sur la sous-image A.



Figure 10b: Sites d'entraînement et de validation sur la sous-image B.

La validation de nos résultats de détection des surfaces boisées commencera par une vérification visuelle qui suffit parfois pour déceler certaines incohérences dans les images résultantes. Par la suite, nous quantifierons la performance de notre détection en calculant d'abord, le cas échéant, le taux de non-classification NC qui recense les pixels de la classe nulle. Sa formule est la suivante:

$$NC = \frac{\text{nb. de pixels de la classe nulle}}{\text{nb. de pixels dans la sous-image}} \times 100$$

Dans un deuxième temps, nous confronterons les surfaces détectées comme boisées avec un masque appelé «vérité-terrain» (VT) délimitant les surfaces boisées «réelles» de cette image. Par définition, ce masque provient de relevés effectués sur le terrain mais de façon générale, on utilise plutôt l'interprétation visuelle de l'image étudiée ou, si possible, une carte déjà

existante. Avec un tel masque, nous serons en mesure de calculer deux indicateurs d'efficacité, soit le taux de détection et le taux de fausses alarmes. Le premier de ces indicateurs, désigné TD, correspond au pourcentage de pixels situés sous le masque VT qui sont bien détectés comme surface boisée. Sa formule est la suivante:

$$TD = \frac{\text{nb. de pixels « boisé » sous le masque}}{\text{nb. total de pixels sous le masque VT}} \times 100$$

Le taux de fausses alarmes FA évalue de son côté les erreurs de commission, c'est-à-dire la quantité de pixels ayant été détectés comme surface boisée mais n'appartenant pas au masque VT. On le calcule ainsi :

$$FA = \frac{\text{nb. de pixels « boisé » en dehors du masque VT}}{\text{nb. total de pixels en dehors du masque VT}} \times 100$$

Le but visé par tout processus de détection est évidemment l'obtention d'un taux de détection maximal et d'un taux de fausses alarmes minimal, tout en conservant un faible taux de non-classification. En se concentrant sur la minimisation des FA, on s'assure que les surfaces détectées comme boisées le sont effectivement. A l'opposé, une simple maximisation du TD sans se soucier du FA pourrait permettre une excellente détection des surfaces boisées réelles mais de nombreux pixels non-boisés risqueraient également d'être détectés comme boisés. Il faut donc établir un compromis entre ces deux stratégies en tenant compte de l'application visée par cette détection.

Comme nous l'avons vu précédemment, la précision des images IKONOS panchromatiques nous permet de distinguer jusqu'aux arbres isolés, ceux-ci étant représentés par la juxtaposition d'une zone de pixels sombres et d'une zone de pixels brillants (voir la figure 1). Une surface boisée est un regroupement serré de plusieurs arbres que l'on peut reconnaître par sa texture moutonneuse ou «ouateuse». La variabilité spatiale des valeurs numériques y est généralement beaucoup plus forte que pour les autres types de surfaces (gazon, béton, eau) dont la texture est plus ou moins lisse. Nous sommes donc en mesure de délimiter visuellement l'ensemble des surfaces boisées présentes dans les différentes sous-images, à la manière des cartographes forestiers, pour constituer nos masques de «vérité-

terrain» VT. Les figures 11a et 11b montrent ces masques tels que tracés pour les sous-images A et B. Nous avons volontairement omis d'y inclure les arbres isolés et ceux groupés en bosquets de petite superficie ainsi que les bandes boisées de faible largeur, en accord avec notre définition d'une surface boisée (Section 3.3.1).




Figure 11a: Masque de vérité-terrain pour les surfaces boisées (sous-image A).



Figure 11b: Masque de vérité-terrain pour les surfaces boisées (sous-image B).

Pour une validation plus poussée, nous utiliserons également un autre type de taux de détection, fondé sur la matrice de confusion, qui confrontera plutôt nos résultats de détection aux sites de validation de chaque classe, sous lesquels nous évaluerons la capacité du classificateur à retrouver la classe en question. Ainsi, le taux de détection pour les surfaces boisées, désigné TD*, sera égal au pourcentage de pixels classifiés «boisé» parmi tous les pixels du site de validation de cette classe «boisé». Sa formule est la suivante:

$$TD^* = \frac{\text{nb. de pixels «boisé» dans le site de validation «boisé»}}{\text{nb. total de pixels dans le site de validation «boisé»}} \times 100$$

La matrice de confusion nous permettra également de calculer le coefficient Kappa qui possède l'avantage, par rapport au simple taux de détection, de tenir compte des erreurs d'omission et de commission et qui évalue en quelque sorte la probabilité que les résultats de classification soient dus au hasard. Cet indice est fréquemment utilisé dans les recherches en télédétection, ce qui permettra une comparaison objective de nos résultats finaux à ceux atteints dans le cadre d'études antérieures (voir Congalton et Green, 1999).

4.2 - Classification dirigée à partir des huit mesures de texture

Nous utilisons le module MLC de Xspace pour appliquer une classification par maximum de vraisemblance aux diverses combinaisons $f-p$. Pour chacune d'elles, nous fournissons au classificateur les huit images de texture en canaux d'entrée ainsi que la signature de chacune des classes sur cet ensemble de textures; les signatures ont été calculées préalablement par le module CSG de Xspace à partir des sites d'entraînement. Les pixels qui ne sont inclus dans aucune des hyper-ellipses définies par les signatures fournies sont assignés à une classe nulle. Les limites de chaque classe (équi-probabilités) sont fondées sur un seuil de trois écart-types. Les figures 12a et 12b montrent les résultats de ces opérations sur les sous-images A et B. Sur la première, les classes «boisé», «gazon» et «îlot urbain» sont représentées respectivement en vert foncé, vert pâle et gris, tandis que la classe nulle ressort en noir. Les mêmes couleurs de classe se retrouvent sur la sous-image B, auxquelles s'ajoutent les classes «agricole» en orange, «eau» en bleu et «béton» en blanc.

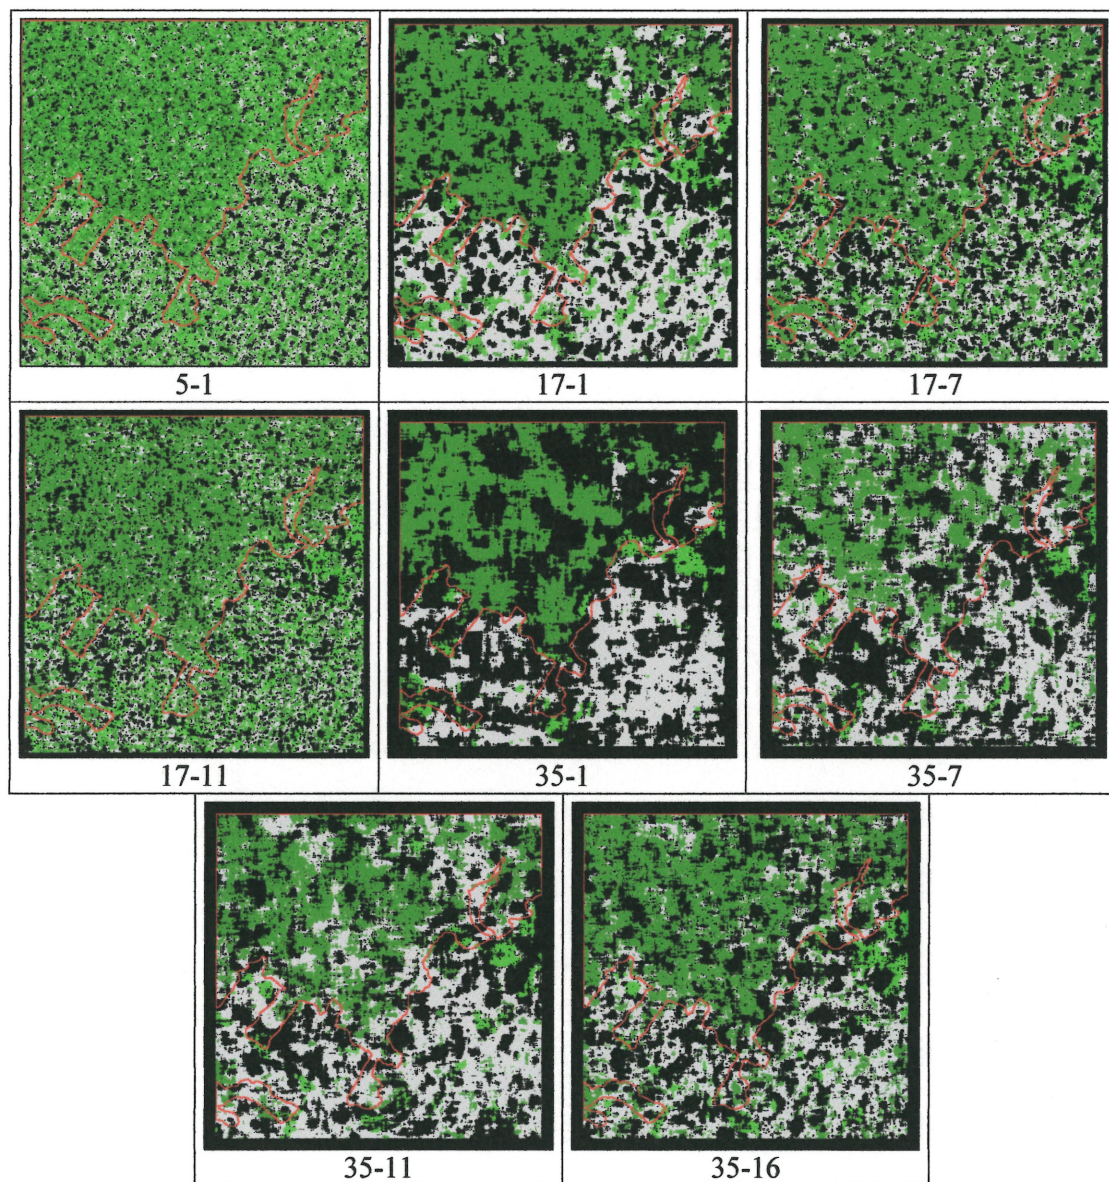


Figure 12a: Classification dirigée à partir des 8 images de texture et contour du masque VT (sous-image A)

(Légende: vert foncé: boisé, vert pâle: gazon, gris: îlot urbain, noir: non-classifié)




Figure 12b: Classification dirigée à partir des 8 images de texture et contour du masque VT (sous-image B)

(Légende: vert foncé: boisé, vert pâle: gazon, gris: îlot urbain, orange: agricole, bleu: eau, blanc: béton, noir: non-classifié)

Au regard de toutes ces images, ce qui frappe immédiatement est le nombre considérable de pixels non-classifiés. Dans le cas de la sous-image A, nous avons calculé un taux de non-classification (NC) moyen de 31 %, celui-ci atteignant 51 % pour la combinaison 35-1. Pour ce qui est de la sous-image B, nous obtenons un NC moyen de 53 % atteignant 81 %, également pour la combinaison 35-1. Toutefois, nous percevons comme prévu une certaine amélioration quant aux erreurs de commission, par rapport aux résultats de segmentation ou de classification binaires. La validation quantitative selon le masque VT vient corroborer cette affirmation mais nous fait aussi réaliser que les taux de détection n'y atteignent même pas la barre des 60 % (Tableaux VIIa et VIIb). Notons que la combinaison 35-1 donne le meilleur taux de fausses alarmes mais c'est aussi, comme nous venons de le voir, la combinaison la moins fiable de par son taux de non-classification. Des résultats semblables ont été obtenus pour les sous-images C, D et E.

	5-1	17-1	17-7	17-11	35-1	35-7	35-11	35-16
TD	40.8	55.0	55.7	55.4	40.0	35.0	38.9	47.6
FA	17.7	4.3	14.7	16.5	0.3	4.0	4.1	8.3
NC	15.7	29.7	27.2	24.0	51.0	35.5	33.5	35.0

Tableau VIIa: Résultats de la classification dirigée à partir des 8 textures (sous-image A)

	5-1	17-1	17-7	17-11	35-1	35-7	35-11	35-16
TD	22.8	43.3	19.7	21.2	35.3	28.8	20.4	24.0
FA	10.0	6.3	9.2	10.3	0.9	6.1	4.8	8.1
NC	18.0	61.3	40.5	37.0	81.0	60.7	67.3	59.2

Tableau VIIb: Résultats de la classification dirigée à partir des 8 textures (sous-image B)

Ces résultats traduisent clairement la difficulté d'établir une signature texturale des surfaces boisées qui permette une classification efficace. Cependant, une part d'explication réside assurément dans ce qu'on pourrait appeler l'effet de bordure. Nous pouvons en effet supposer que les textures calculées pour les pixels correspondant à la bordure d'une surface boisée sont peu fiables puisque les fenêtres de calcul y incluent des surfaces non-boisées.

Ainsi, la signature texturale de ces pixels ne sera probablement pas compatible avec celle de la classe «boisé» et ils seront alors déclarés «non-boisé» ou «non-classifié» lors de la classification. Dans le cas d'un boisé de taille restreinte comme celui de la sous-image B, l'influence de cette zone d'incertitude sur l'efficacité de la détection est donc déterminante puisqu'elle en représente une forte proportion. En outre, notons que cet effet de bordure sera particulièrement marqué pour les grandes fenêtres d'échantillonnage ($f=35$) qui agrandissent inévitablement la zone d'incertitude.

Dans l'ensemble, la classification dirigée s'avère une méthode satisfaisante étant donné qu'elle engendre relativement peu d'erreurs de commission et une bonne caractérisation globale des surfaces boisées. Nous tenterons de raffiner cette méthode, notamment en réduisant le nombre de mesures de textures à l'entrée. Il est en effet préférable, selon plusieurs auteurs (Barber et LeDrew, 1991; Duda *et al.*, 2001), de réduire la dimensionnalité de l'espace textural pour améliorer l'efficacité d'une classification, d'autant plus qu'il existe, nous le savons, une certaine redondance dans les huit mesures de texture retenues. Ceci devrait également permettre d'augmenter la probabilité qu'un pixel soit inclus dans l'une des hyper-ellipses définissant nos classes et donc d'abaisser le taux de non-classification. D'autre part, nous tenterons d'améliorer nos résultats de classification à l'aide de certains post-traitements.

4.3 - Choix des mesures de texture

Le module CHNSEL de Xpace permet de sélectionner automatiquement un certain nombre de canaux parmi ceux qu'on lui fournit, en se basant sur leur capacité de discriminer les différentes signatures de classes. Les mesures désignées par ce programme seront donc celles qui maximisent la divergence transformée inter-classes et qui donneront la meilleure classification texturale. Nous fournirons à CHNSEL les signatures générées lors d'une classification non-dirigée sur les huit textures, pour laquelle nous n'imposons pas de nombre fixé de classes. On s'assure ainsi que cette étape cruciale ne dépende pas de notre choix de classes ni du tracé de leurs sites d'entraînement. Le choix du nombre de mesures à conserver découle de plusieurs essais préliminaires avec les treize combinaisons retenues, plutôt que des recommandations d'autres chercheurs (par ex. Barber et LeDrew, 1991).

Le tableau VIII répertorie la fréquence de chacune des huit mesures de texture initiales dans les combinaisons optimales de quatre mesures telles que prescrites par CHNSEL pour les treize combinaisons $f-p$. Les cinq sous-images suivent un comportement assez similaire et une forte tendance se dégage quant aux quatre mesures optimales. Il s'agit de la moyenne, du contraste, de la corrélation et de l'écart-type qui se retrouvent chacune dans au moins dix des treize combinaisons optimales calculées pour chaque sous-image. Lorsque nous avons demandé de ne conserver que trois mesures, le module CHNSEL donnait une tendance beaucoup moins nette. Les quatre mesures citées précédemment formeront donc notre nouvel ensemble de départ pour la classification dirigée.

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E
Moyenne	11 / 13	12 / 13	11 / 13	13 / 13	13 / 13
Contraste	12 / 13	13 / 13	12 / 13	12 / 13	13 / 13
Corrélation	12 / 13	12 / 13	11 / 13	10 / 13	13 / 13
Énergie	3 / 13	1 / 13	3 / 13	2 / 13	0 / 13
Entropie	1 / 13	1 / 13	2 / 13	3 / 13	0 / 13
Homogénéité	1 / 13	1 / 13	1 / 13	1 / 13	0 / 13
Pmax	0 / 13	1 / 13	1 / 13	1 / 13	0 / 13
Écart-type	12 / 13	11 / 13	11 / 13	10 / 13	13 / 13

Tableau VIII: Présence de chaque mesure de texture dans la combinaison optimale.

4.4 - Classification dirigée à partir des quatre mesures de texture retenues

À partir des quatre mesures sélectionnées, soit la moyenne, le contraste, la corrélation et l'écart-type, nous procédons à une classification dirigée, pour chacune des treize combinaisons $f-p$ retenues. La démarche est la même qu'en 4.2, mais les signatures doivent préalablement être recalculées sur l'espace textural composé maintenant des quatre mesures optimales. À partir des images ainsi classifiées, nous calculons ensuite les nouveaux taux de

non-classification NC (Tableau IX), puis ceux de détection (TD) et de fausses alarmes (FA) à partir du masque VT (Tableau X).

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E	Moyenne
5-1	3.4	2.8	4.3	3.4	3.3	3.4
5-2	3.7	2.4	4.3	1.9	3.6	3.2
17-1	5.6	15.9	6.8	6.1	10.0	8.9
17-2	5.5	10.2	6.9	4.5	6.8	6.8
17-4	5.0	8.4	5.7	3.7	6.9	5.9
17-7	5.2	5.2	5.7	3.8	4.7	4.9
17-11	4.6	6.9	5.0	3.2	6.0	5.1
35-1	10.4	24.4	15.4	15.0	32.1	19.5
35-2	10.5	21.2	16.5	16.2	31.2	19.1
35-4	7.1	29.8	9.1	13.3	42.9	20.4
35-7	4.7	25.6	5.1	11.2	35.3	16.4
35-11	4.7	16.5	3.7	10.3	27.0	12.4
35-16	4.5	14.9	5.2	11.3	23.4	11.9

Tableau IX: NC sur les classifications dirigées à partir des quatre textures optimales

Le tableau IX nous indique une nette diminution du nombre de pixels non-classifiés lorsque nous utilisons seulement les quatre textures optimales comme base de la classification dirigée. Alors que les taux NC les plus élevés étaient de 51 % et 81 % pour les sous-images A et B en utilisant les huit textures (voir les tableaux VIIa et VIIb), ils ne sont plus ici que de 10.5 % et 29.8 % respectivement. Toutefois, nous voyons que ce taux atteint 42.9 % pour la combinaison 35-4 de la sous-image E, et il semble que les sous-images B et E donnent des taux NC franchement supérieurs aux trois autres. Pour chaque combinaison $f-p$, nous avons également présenté la moyenne des taux NC sur les cinq sous-images. Les valeurs résultantes s'échelonnent de 3.2 % pour la combinaison 5-2 à 20.4 % pour 35-4 et ce sont les combinaisons avec un f élevé qui donnent le plus de difficultés au classificateur. Dans l'ensemble, nous observons comme prévu des taux de non-classification réduits, ce qui est

sans aucun doute attribuable à la simplification des hyper-ellipses représentant les différentes classes, puisqu'elles sont désormais à quatre dimensions plutôt qu'à huit.

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E	Moyenne
5-1	37.8 / 10.0	39.8 / 16.8	26.8 / 10.3	27.0 / 8.9	33.8 / 7.5	33.0 / 10.7
5-2	49.4 / 20.2	13.3 / 8.4	39.7 / 16.7	26.2 / 9.2	22.1 / 5.1	30.1 / 11.9
17-1	72.5 / 7.4	39.6 / 13.3	61.9 / 10.7	72.0 / 21.3	64.2 / 9.4	62.0 / 12.4
17-2	74.2 / 10.4	38.2 / 15.1	69.7 / 14.4	75.8 / 20.0	60.3 / 6.2	63.6 / 13.2
17-4	73.3 / 24.4	15.6 / 10.5	70.7 / 29.6	65.6 / 24.0	63.8 / 7.5	57.8 / 19.2
17-7	75.6 / 36.4	14.7 / 10.1	77.6 / 48.0	68.5 / 33.9	64.5 / 13.4	60.2 / 28.4
17-11	71.6 / 26.2	25.8 / 16.4	63.1 / 27.7	57.9 / 25.5	56.4 / 9.7	55.0 / 21.1
35-1	71.2 / 2.2	44.5 / 9.6	56.5 / 5.1	74.6 / 13.2	58.4 / 4.1	61.0 / 6.8
35-2	73.6 / 1.7	41.4 / 8.5	64.6 / 6.1	76.8 / 9.5	56.7 / 1.6	62.6 / 5.5
35-4	66.1 / 3.3	34.1 / 9.6	73.1 / 15.1	72.1 / 8.9	48.7 / 0.8	58.8 / 7.5
35-7	66.8 / 24.8	24.4 / 9.6	69.7 / 32.3	66.5 / 13.6	53.9 / 3.1	56.3 / 16.7
35-11	66.9 / 28.8	22.4 / 11.0	69.1 / 40.6	65.3 / 15.2	55.0 / 5.8	55.7 / 20.3
35-16	67.7 / 25.4	29.0 / 14.7	68.1 / 40.1	69.4 / 18.3	59.1 / 6.1	58.7 / 20.9

Tableau X: Résultats de la classification dirigée à partir des quatre textures optimales (TD / FA selon le masque VT).

Les résultats de la classification dirigée présentés au tableau X montrent une amélioration plutôt mitigée de l'efficacité de la classification dirigée lorsque nous n'utilisons que les quatre textures optimales. Pour la sous-image A, alors que nous avons des TD de l'ordre de 40 à 50 % à partir des huit textures (Tableau VIIa), nous obtenons ici un niveau plus acceptable avoisinant les 70 %, sauf pour les combinaisons 5-1 et 5-2. Quant aux taux de FA, ils ont pour la plupart augmenté, particulièrement pour les p de 7, 11 et 16. Dans le cas de la sous-image B, les TD demeurent très insuffisants pour la majorité des combinaisons, n'atteignant qu'un maximum de 44.5 %. Les fausses alarmes y restent néanmoins assez faibles, sauf pour les grands p . La colonne «moyenne» fait d'ailleurs clairement ressortir la tendance selon laquelle l'efficacité de classification est meilleure pour des petits p et des grands f , tendance qui persiste depuis les premiers essais de segmentation binaire (section

3.3.4). Les classifications avec un f de 5 donnent des TD moyens réellement inacceptables de l'ordre de 30 %, tandis que les FA pour des p de 7, 11 et 16 sont beaucoup trop élevées (autour de 20 %).

Pour la suite des opérations, nous allons uniquement conserver les quatre combinaisons 17-1, 17-2, 35-1 et 35-2 qui se démarquent véritablement des autres. Nous y effectuerons une validation plus poussée à l'aide de matrices de confusion et du coefficient Kappa à partir de sites de validation de chaque classe (voir les figures 10a et 10b) et y appliquerons des traitements post-classification afin d'éliminer les zones de trop petite taille qui se retrouvent dans les images classifiées. Les figures 13 à 16 montrent les sous-images A à E classifiées (sans post-traitement) pour les quatre combinaisons f - p retenues; les couleurs représentant les classes sont les mêmes que sur les figures 12a et 12b, auxquelles viennent s'ajouter les classes «route» en gris foncé (sur les sous-images D et E) et «gazon très court» en bleu pâle (sur la sous-image E). Notons que la classe «route» de la sous-image E englobe en réalité routes et bâtiments.

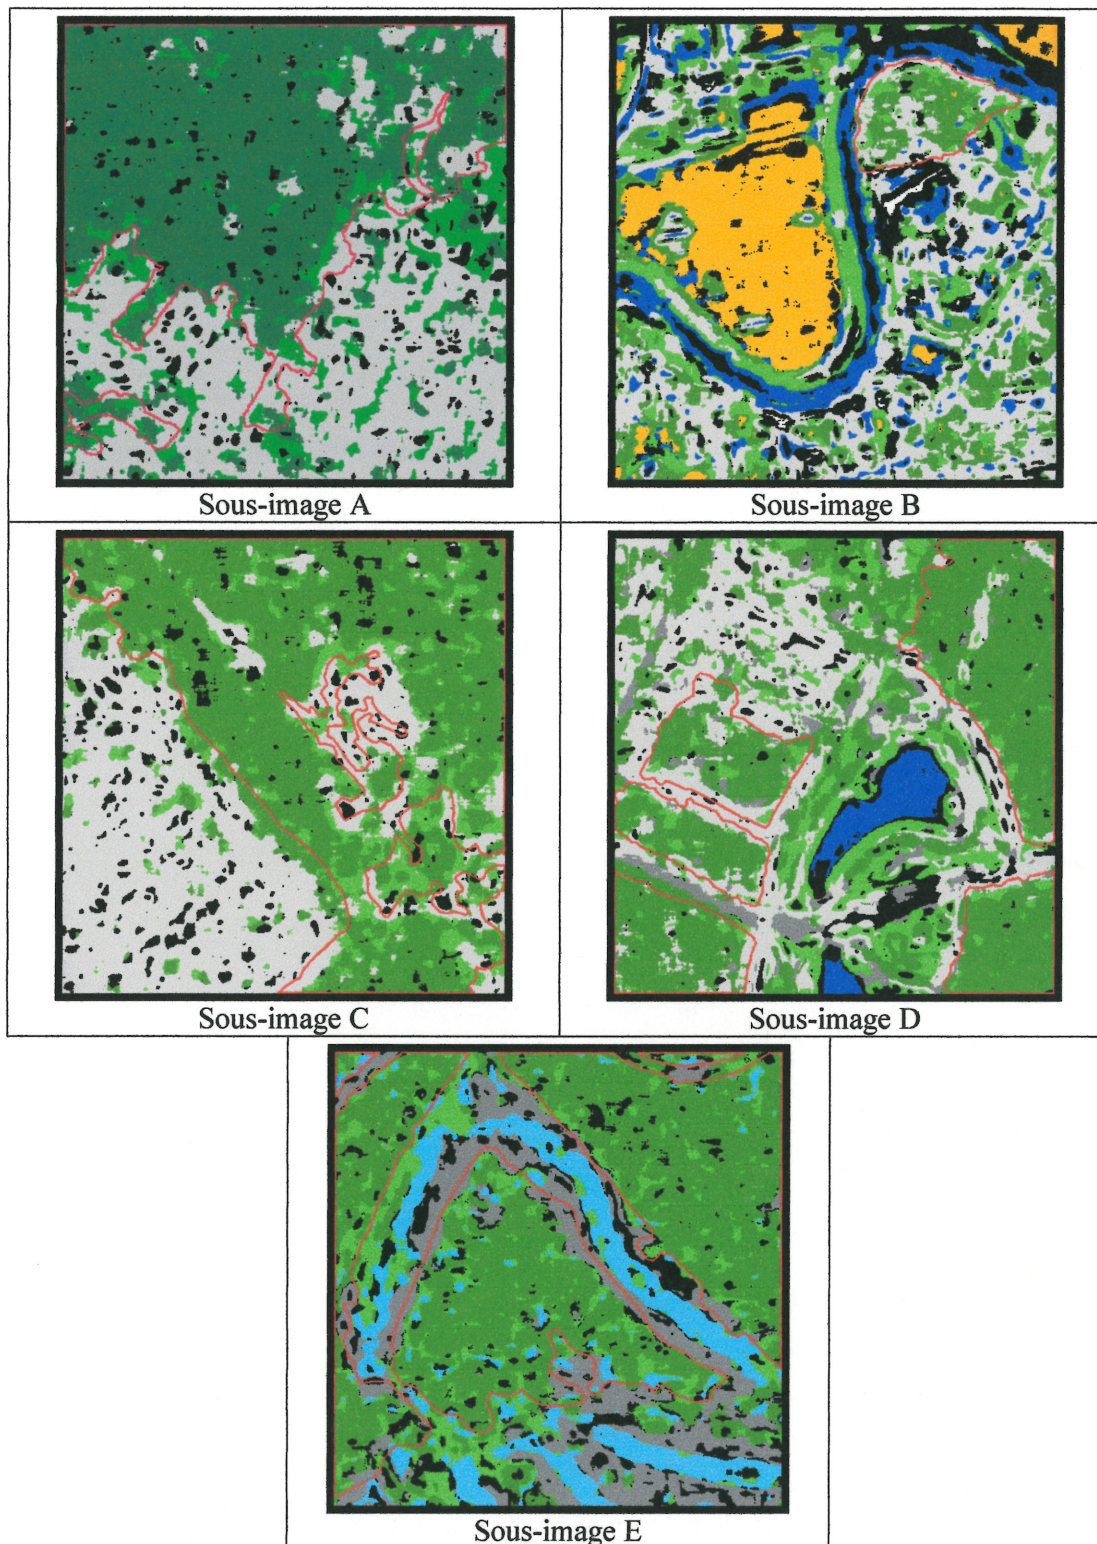


Figure 13: Classification dirigée à partir des 4 textures optimales pour la combinaison 17-1 et contour du masque VT

(Légende: vert foncé: boisé, vert pâle: gazon, gris pâle: îlot urbain, gris foncé: route, orange: agricole, bleu foncé: eau, turquoise: gazon court, blanc: béton, noir: non-classifié)

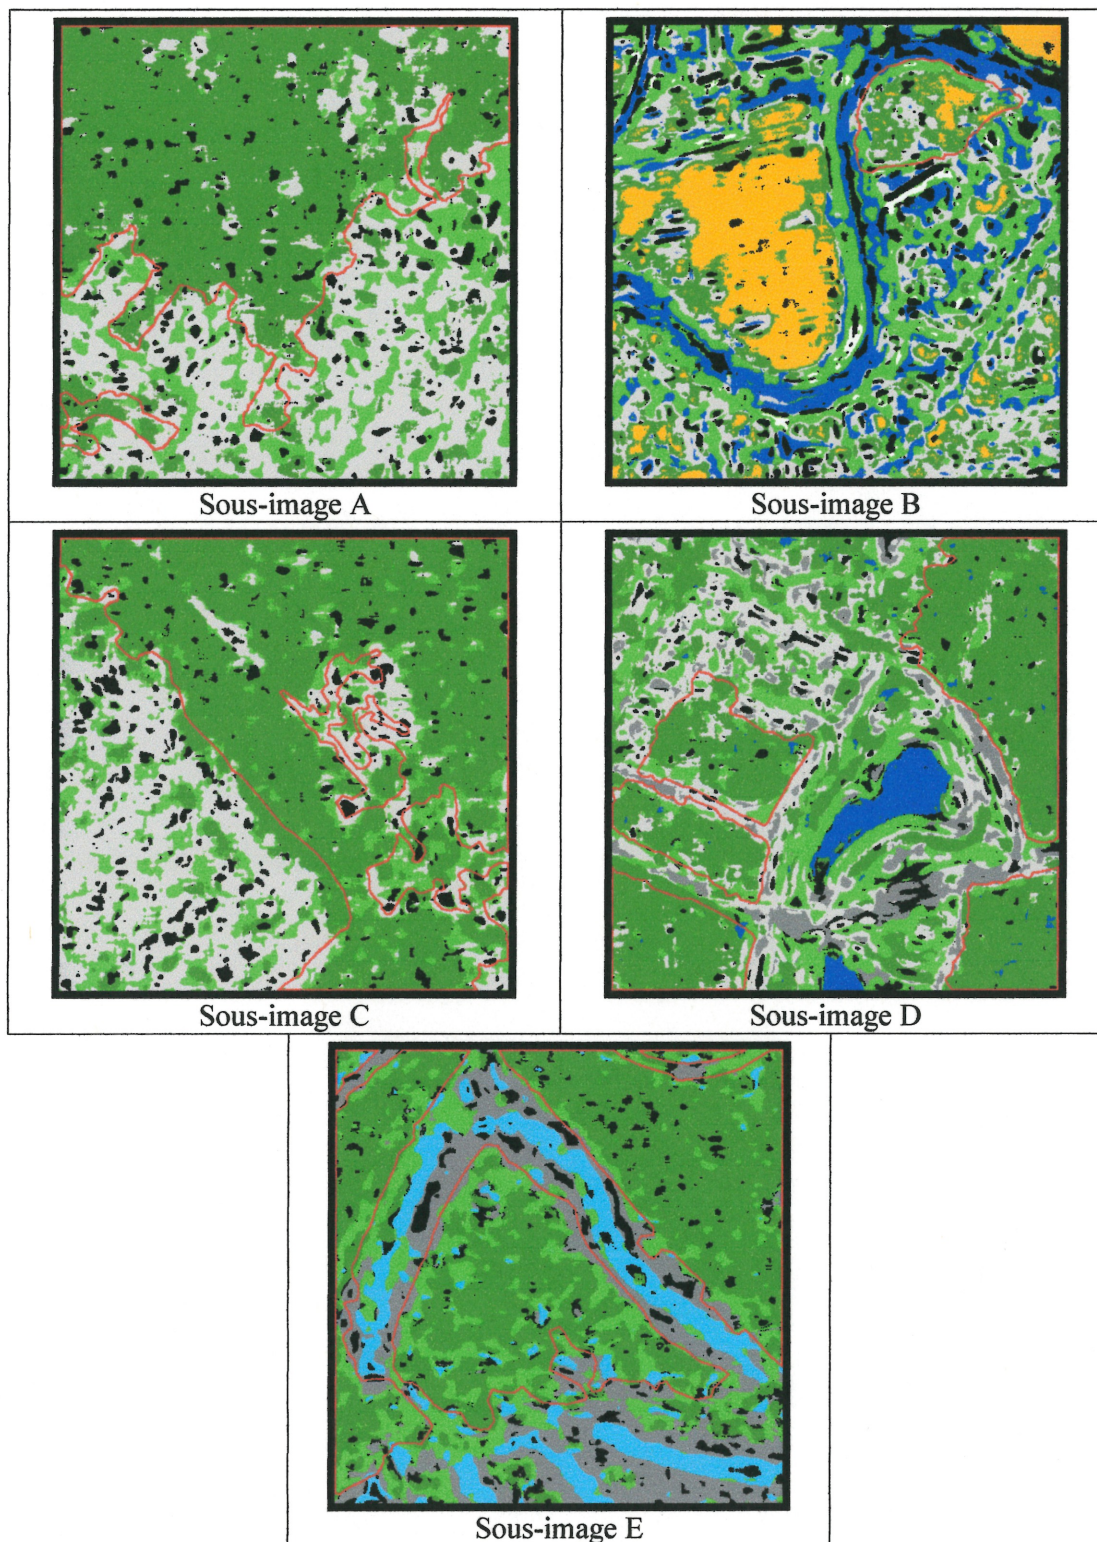


Figure 14: Classification dirigée à partir des 4 textures optimales pour la combinaison 17-2 et contour du masque VT

(Légende: vert foncé: boisé, vert pâle: gazon, gris pâle: îlot urbain, gris foncé: route, orange: agricole, bleu foncé: eau, turquoise: gazon court, blanc: béton, noir: non-classifié)

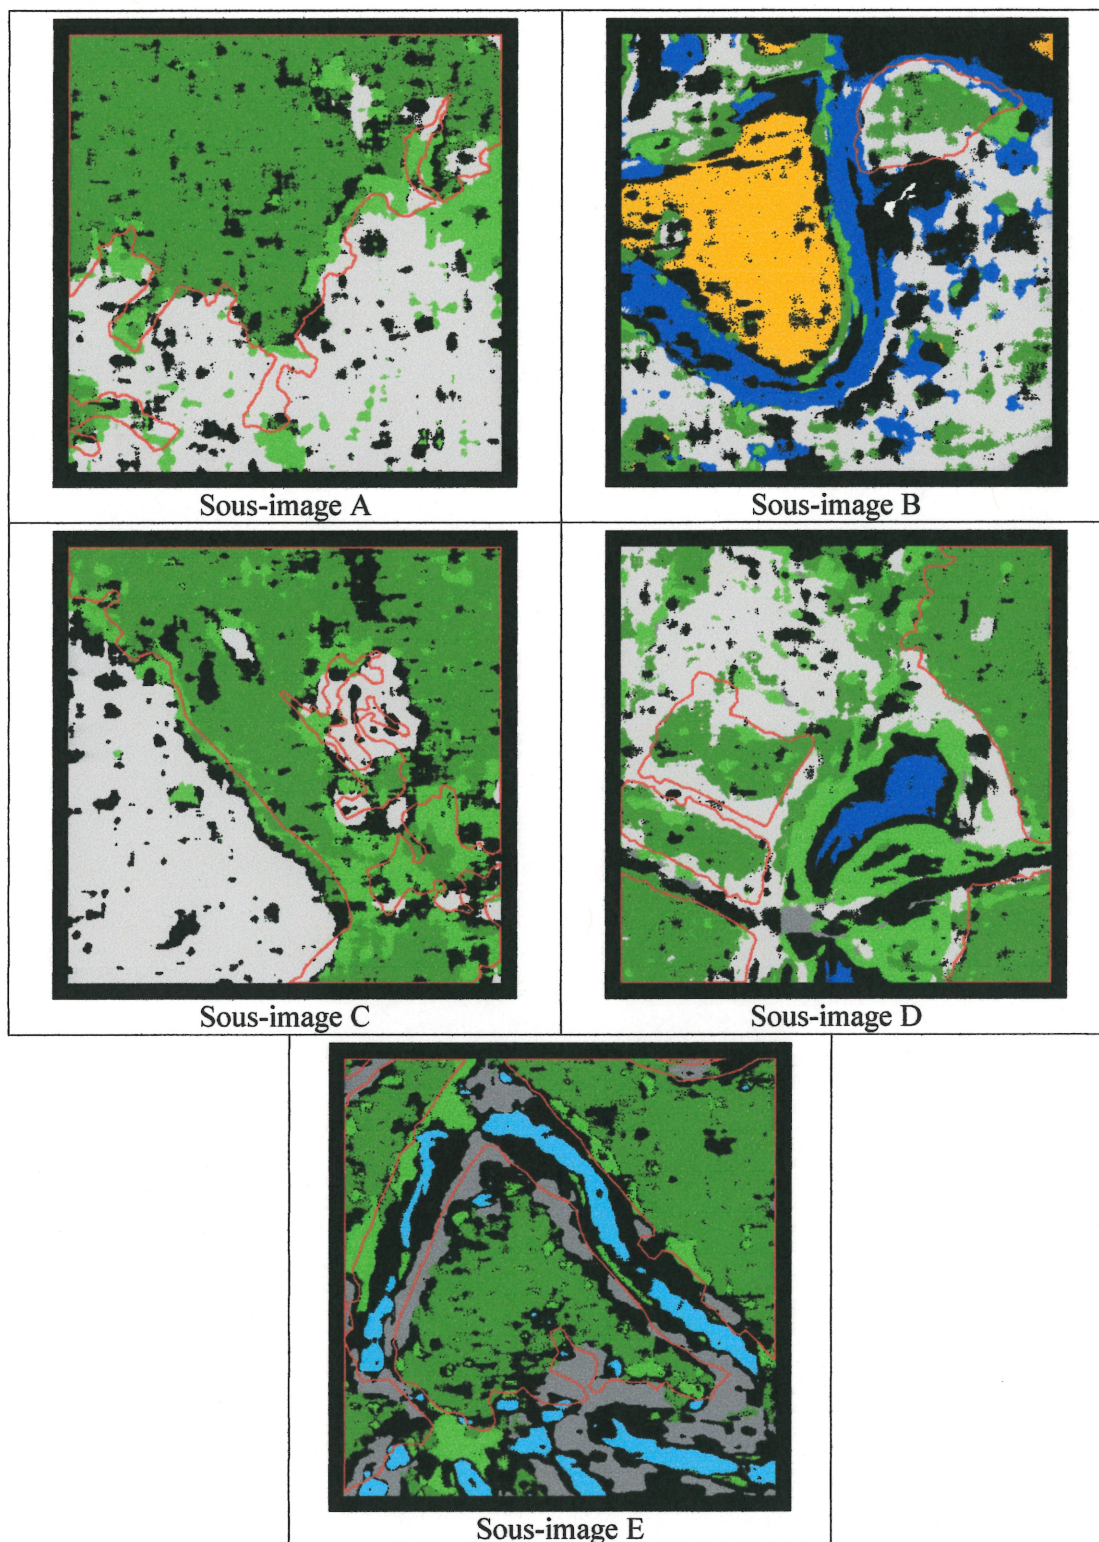


Figure 15: Classification dirigée à partir des 4 textures optimales pour la combinaison 35-1 et contour du masque VT

(Légende: vert foncé: boisé, vert pâle: gazon, gris pâle: îlot urbain, gris foncé: route, orange: agricole, bleu foncé: eau, turquoise: gazon court, blanc: béton, noir: non-classifié)

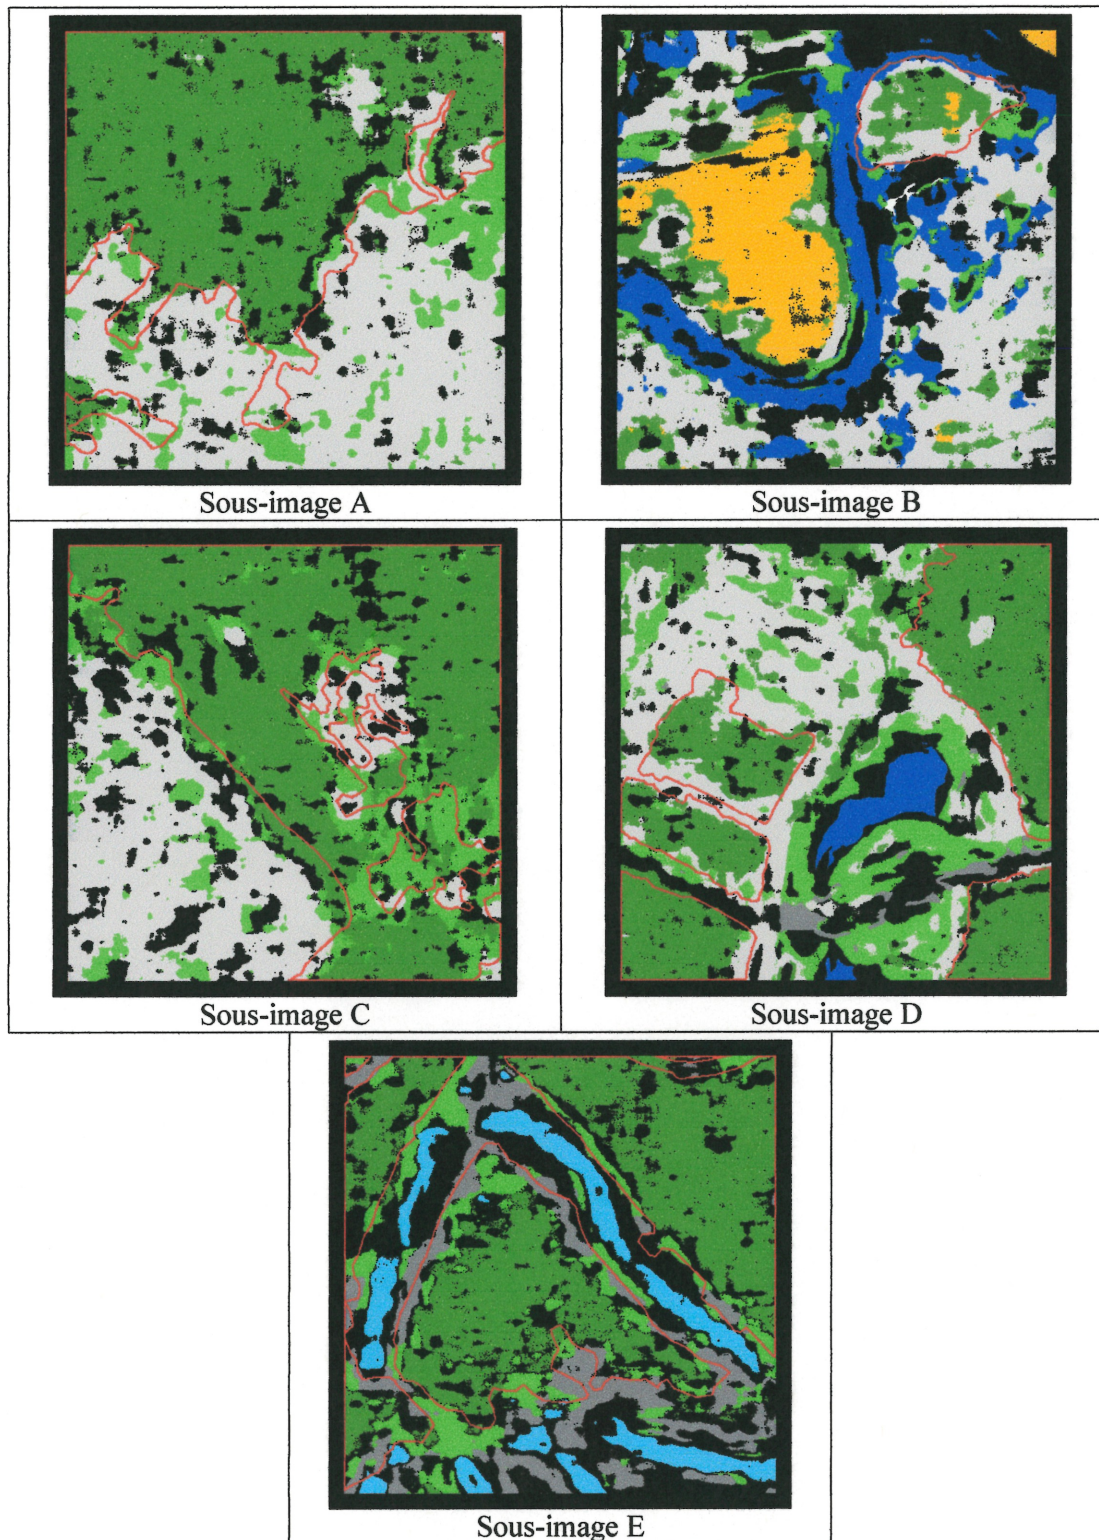


Figure 16: Classification dirigée à partir des 4 textures optimales pour la combinaison 35-2 et contour du masque VT

(Légende: vert foncé: boisé, vert pâle: gazon, gris pâle: îlot urbain, gris foncé: route, orange: agricole, bleu foncé: eau, turquoise: gazon court, blanc: béton, noir: non-classifié)

Après avoir confronté nos résultats de détection aux masques VT, regardons maintenant ce qui se passe sur nos sites de validation, à l'aide du module MLR de Xspace. Les matrices de confusion résultantes sont toutes présentées à l'annexe A et deux d'entre elles sont reproduites dans les tableaux XIa et XIb, pour la combinaison 35-2 (sous-images A et B).

		Résultat de classification			
		«non-classifié»	«boisé»	«îlot urbain»	«gazon»
Sites de validation	«boisé»	11.1 %	88.9 %	0 %	0 %
	«îlot urbain»	2.2 %	0.1 %	81.0 %	16.7 %
	«gazon»	0 %	0 %	21.4 %	78.6 %

Tableau XIa: Matrice de confusion (combinaison 35-2, sous-image A)

		Résultat de classification						
		«non-classifié»	«boisé»	«agricole»	«eau»	«béton»	«îlot urbain»	«gazon»
Sites de validation	«boisé»	2.2 %	63.2 %	2.7 %	0 %	0 %	31.9 %	0 %
	«agricole»	2.3 %	13.2 %	81.9 %	0 %	0 %	2.6 %	0 %
	«eau»	77 %	0 %	0 %	23.0 %	0 %	0 %	0 %
	«béton»	95.2 %	0 %	0 %	0 %	0 %	4.8 %	0 %
	«îlot urbain»	29.9 %	21.0 %	0 %	1.9 %	0 %	47.1 %	0 %
	«gazon»	62.3 %	0 %	0 %	8.3 %	0 %	0.2 %	29.2 %

Tableau XIb: Matrice de confusion (combinaison 35-2, sous-image B)

Les matrices de confusion nous procurent un taux de détection spécifique pour chacune des classes mais nous nous intéressons particulièrement à celui de la classe «boisé» (en gras dans les tableaux XIa et XIb), qui n'est autre que le taux TD* défini à la section 4.1. Nous présentons l'ensemble des TD* dans le tableau XII pour fins de comparaison avec les TD du tableau X.

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E	Moyenne
17-1	89.5	47.8	77.9	92.0	79.5	77.3
17-2	88.0	54.1	83.4	93.7	74.6	78.8
35-1	88.4	57.6	82.9	91.2	84.9	81.0
35-2	88.9	63.2	89.2	92.5	76.8	82.1

Tableau XII: TD* pour la classification dirigée à partir des quatre textures optimales (selon les sites de validation)

Ces résultats sont unanimes: les taux de détection calculés à partir de sites de validation s'avèrent nettement meilleurs que ceux que nous avons trouvés en nous basant sur le masque VT, et ce pour les cinq sous-images et les quatre combinaisons. Les moyennes ont ainsi augmenté de 15 % pour 17-1 et 17-2 et de 20 % pour 35-1 et 35-2, et nous atteignons même un TD* maximum de 93.7 %. En calculant ces nouveaux taux, nous avons en fait isolé l'effet de bordure exposé plus tôt: l'emploi d'une surface de validation située à bonne distance des frontières des boisés élimine l'effet éventuel d'une mauvaise classification dans cette zone de transition sur le taux de détection. Toutefois, nous ne jugerons pas de l'efficacité de notre méthode de détection en nous fondant uniquement sur ces TD*, le problème des frontières demeurant une importante limite à son application dans la mise à jour de cartes à grande échelle, par exemple. D'autre part, il ne faut pas négliger les résultats relativement modestes que nous offre la sous-image B, avec des TD* ne dépassant pas 63.2 %. Malgré une forte hausse par rapport aux TD du tableau X, ces taux sont résolument inférieurs à ceux des quatre autres sous-images, ce qui traduit une certaine confusion au sein des classes de cette sous-image. L'analyse des matrices de confusion nous indique la grande difficulté qu'éprouve le classificateur à y distinguer les classes «boisé» et «îlot urbain», alors que 30 à 40 % des pixels de validation «boisé» sont classifiés comme «îlot urbain». Pour les sous-images B, C et D, la confusion entre ces deux mêmes classes est assez limitée, ne dépassant pas 10 %. Plusieurs explications sont envisageables quant à ces résultats: une définition inadéquate des sites d'entraînement et de validation, une disparité entre les îlots urbains ou encore entre les boisés de la sous-image B et ceux des autres sous-images. Il est probable que ces trois hypothèses soient conjointement vérifiées mais la troisième d'entre elles est sans doute la plus dominante du lot. Au regard des sous-images initiales, il semble en effet que les surfaces boisées de la sous-image B soient composées d'arbres plus gros que celles des sous-images A, C, D et E (Figures 7a à 7e). Qu'il s'agisse d'arbres plus matures ou bénéficiant simplement de

meilleures conditions de croissance, ceux-ci présentent des ombres plus étendues qui occasionnent une confusion accrue des classes «boisé» et «îlot urbain» sur cette sous-image B. Nous reviendrons sur ce sujet dans la partie discussion (Chapitre V).

En plus de la matrice de confusion, le module MLR nous permet de calculer le coefficient Kappa ainsi que son écart-type associé (présentés à l'annexe A). L'analyse du tableau XIII nous montre des coefficients Kappa relativement bas si nous considérons la valeur 0.75 comme seuil d'acceptabilité. En effet, même en tenant compte des écarts-types associés qui sont de l'ordre de 0.005, nous ne pouvons qu'être insatisfaits par de tels résultats. Aucune combinaison $f-p$ ne se démarque significativement à l'examen des moyennes, mais 17-2 semble en être une à éviter. En ce qui concerne la sous-image B, notons que les résultats sont nettement plus encourageants que lors de l'analyse préalable des taux de détection. Afin d'amoinrir encore les erreurs d'omission et de commission liées à la détection des surfaces boisées, nous procéderons maintenant à l'étape classique de traitements post-classification (ou post-traitements). Nous recalculerons ensuite les mêmes estimateurs d'efficacité (TD, FA, TD* et Kappa) puis les comparerons à ceux des tableaux X, XII et XIII.

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E	Moyenne
17-1	0.688	0.540	0.587	0.723	0.521	0.612
17-2	0.593	0.468	0.461	0.638	0.505	0.533
35-1	0.754	0.524	0.678	0.751	0.458	0.633
35-2	0.751	0.487	0.515	0.744	0.471	0.594

Tableau XIII: Coefficients Kappa pour la classification dirigée à partir des quatre textures optimales (selon les sites de validation)

4.5 - Post-traitements

La classification dirigée par maximum de vraisemblance est une classification de type «pixel par pixel», ce qui implique généralement la présence, dans les images résultantes, de plusieurs petites zones isolées d'une certaine classe à l'intérieur d'une zone plus grande d'une autre classe. Que ces pixels aient été classifiés ainsi par erreur, en raison d'un bruit radiométrique sur l'image initiale, ou qu'ils reflètent fidèlement la réalité du terrain, on

voudra habituellement les ignorer pour aboutir à une image classifiée plus lisse. Si le but visé était par exemple la mise à jour d'une carte d'occupation du sol, il faudrait en effet que l'image classifiée ait un niveau de généralisation concordant avec celui de la carte, d'où la suppression nécessaire de certains détails superflus. La méthode retenue ici sera celle du «Sieve filter», disponible dans Xspace, qui permet d'éliminer les régions dont la superficie est inférieure à un seuil prédéfini en les assimilant à la région environnante la plus étendue. Notre but étant de segmenter une image entre surfaces boisées et surfaces non-boisées, nous pouvons ainsi spécifier la superficie que nous considérons comme minimale pour qu'une région soit retenue ou non. Le seuil en question est choisi en accord avec notre définition d'une surface boisée qui établissait la superficie minimale à environ 1000 mètres carrés. Rappelons d'ailleurs que ce même seuil a régi le tracé du masque de vérité-terrain; il est donc naturel de ramener nos images classifiées à un niveau de généralisation équivalent. Comme nous pouvons le voir sur les figures 13 à 16, les pixels non-classifiés forment bien souvent de petites régions susceptibles d'être éliminées par notre méthode de post-traitement; il est donc préférable de ne pas les exclure comme nous le faisons avec la bordure.

Les résultats de cette opération appliquée aux classifications obtenues à la section 4.4 sont présentés aux figures 17, 18, 19 et 20 avec le même code de couleurs que précédemment. Une comparaison de l'ensemble de ces images à celles des figures 13 à 16 illustre clairement l'effet du post-traitement: les nombreux petits agrégats de pixels y ont disparu pour offrir des images plus homogènes correspondant mieux au niveau de détail désiré. Globalement, les résultats sont assez satisfaisants mais nous remarquons une efficacité de détection discordante selon la sous-image étudiée. En effet, les erreurs de commission affectent particulièrement les sous-images B et D, tandis que les trois autres en sont relativement dépourvues. Une autre tendance qui se manifeste dans toutes ces images sans exception est le manque de précision aux alentours des frontières des surfaces boisées; rares sont les cas où les limites des surfaces boisées détectées coïncident exactement avec ces mêmes limites sur le masque VT.

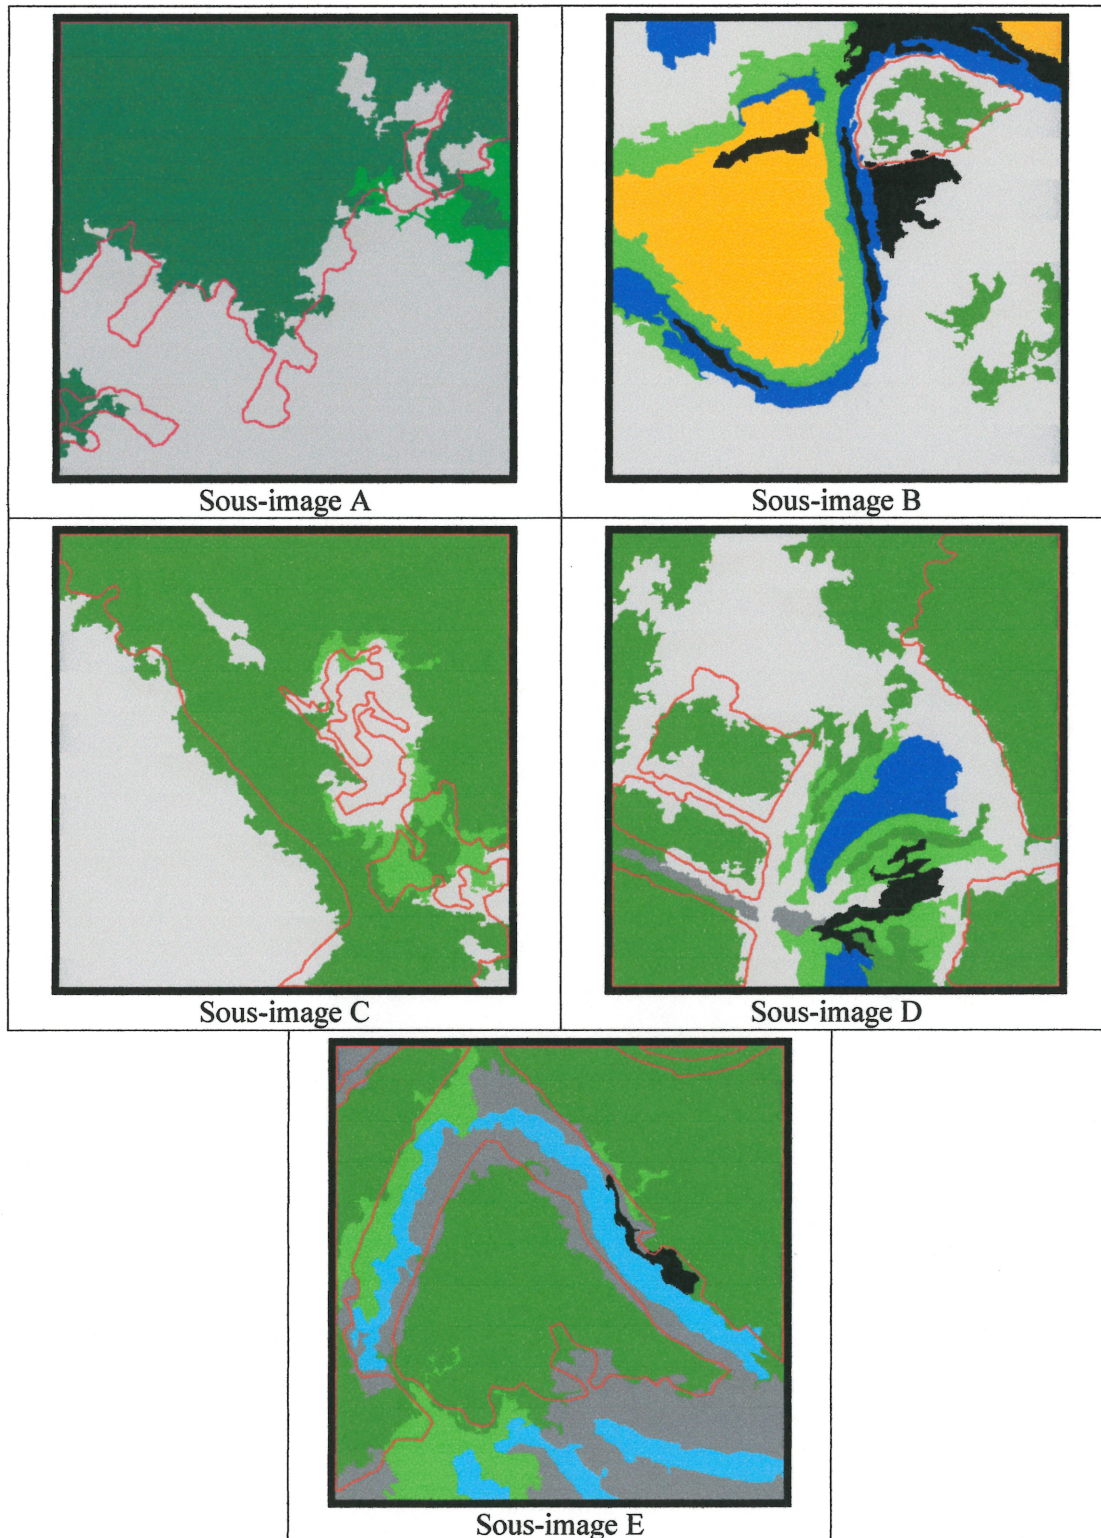


Figure 17: Classification dirigée à partir des 4 textures optimales après filtrage et contour du masque VT (combinaison 17-1)

(**Légende:** vert foncé: boisé, vert pâle: gazon, gris pâle: îlot urbain, gris foncé: route, orange: agricole, bleu foncé: eau, turquoise: gazon court, noir: non-classifié)

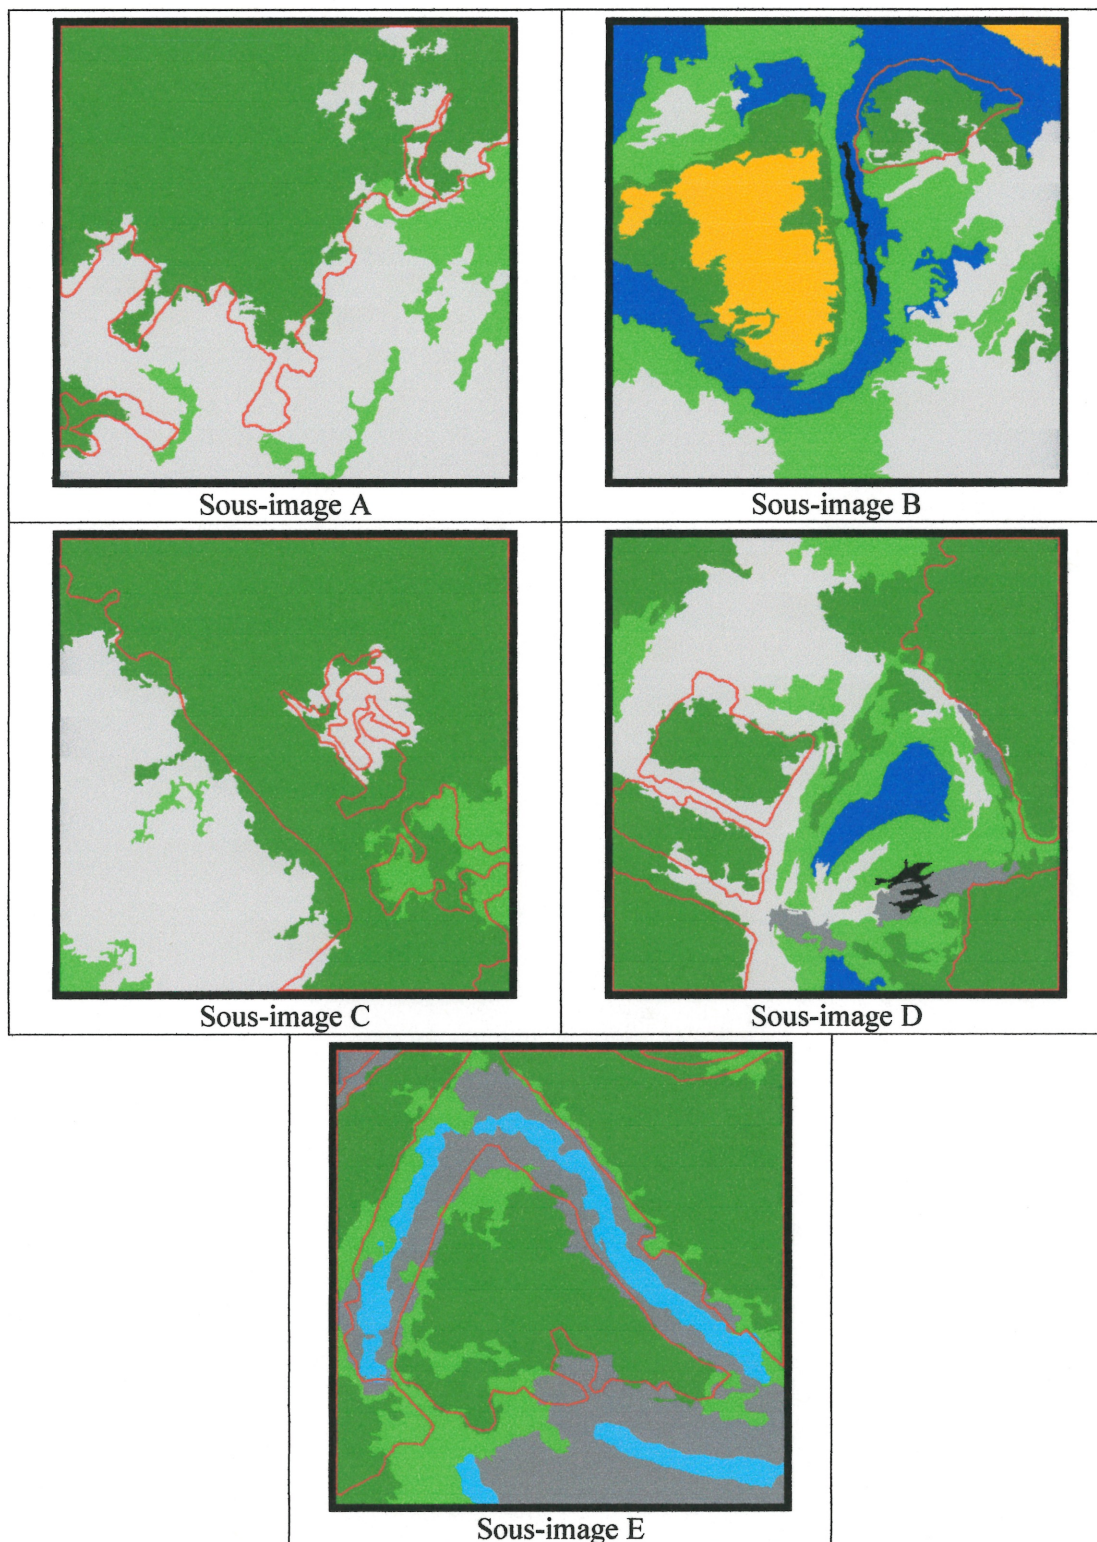


Figure 18: Classification dirigée à partir des 4 textures optimales après filtrage et contour du masque VT (combinaison 17-2)

(Légende: vert foncé: boisé, vert pâle: gazon, gris pâle: îlot urbain, gris foncé: route, orange: agricole, bleu foncé: eau, turquoise: gazon court, noir: non-classifié)

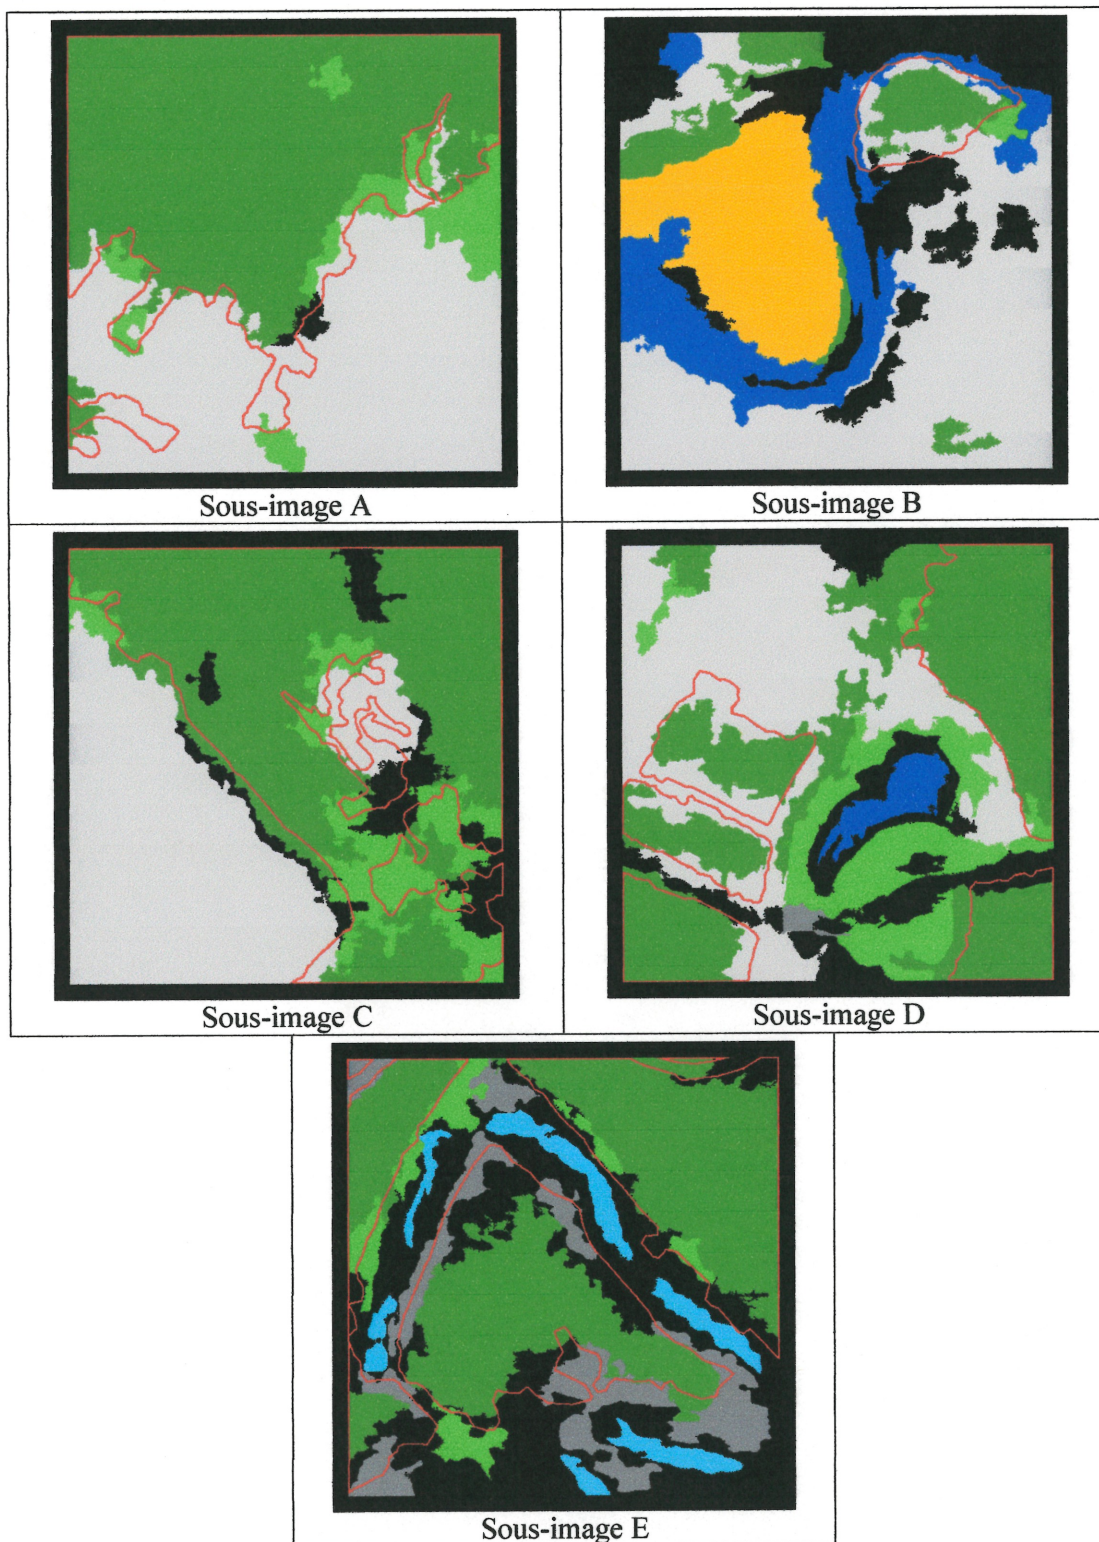


Figure 19: Classification dirigée à partir des 4 textures optimales après filtrage et contour du masque VT (combinaison 35-1)

(**Légende:** vert foncé: boisé, vert pâle: gazon, gris pâle: îlot urbain, gris foncé: route, orange: agricole, bleu foncé: eau, turquoise: gazon court, noir: non-classifié)

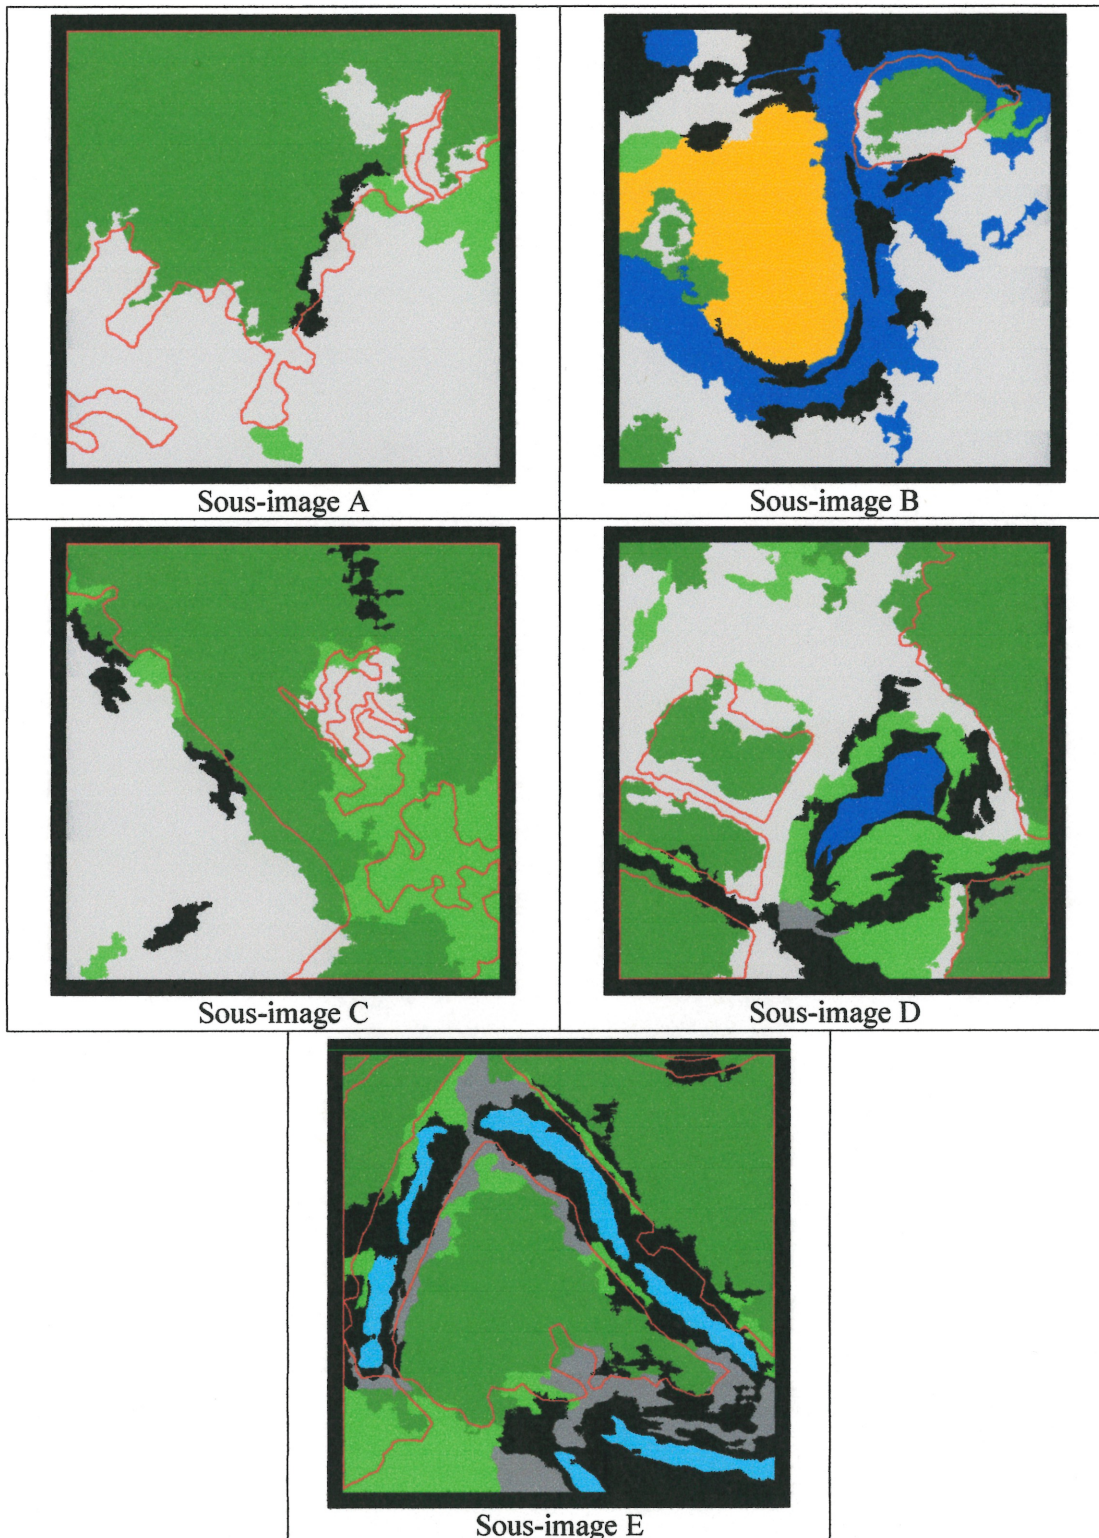


Figure 20: Classification dirigée à partir des 4 textures optimales après filtrage et contour du masque VT (combinaison 35-2)

(Légende: vert foncé: boisé, vert pâle: gazon, gris pâle: îlot urbain, gris foncé: route, orange: agricole, bleu foncé: eau, turquoise: gazon court, noir: non-classifié)

Il nous faut maintenant déterminer laquelle des combinaisons 17-1, 17-2, 35-1 et 35-2 est la plus appropriée pour la détection des surfaces boisées avec notre méthode. Nous calculons donc les nouveaux NC, TD, FA, TD* et coefficients Kappa à partir des images filtrées, ces résultats étant présentés dans les tableaux XIV, XV, XVII et XVIII. Les matrices de confusion se retrouvent à l'annexe B et nous en reproduisons deux extraits, pour la même combinaison $f-p$ qu'à la section précédente, dans les tableaux XVIa et XVIb.

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E	Moyenne
17-1	0	7.2	0	2.0	0.9	2.0
17-2	0	0.5	0	0.5	0	0.2
35-1	0.6	16.7	7.6	10.6	32.7	13.6
35-2	1.4	14.5	3.6	12.1	24.2	11.2

Tableau XIV: NC sur les classifications dirigées à partir des quatre textures optimales après filtrage.

En premier lieu, la quantité de pixels non-classifiés est nettement réduite grâce à l'étape du filtrage, avec une baisse générale d'environ 7% en comparaison avec les résultats du tableau IX. Toutefois, elle demeure relativement élevée pour les combinaisons 35-1 et 35-2, particulièrement dans le cas de la sous-image E.

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E	Moyenne
17-1	83.0 / 4.1	43.5 / 2.8	82.3 / 11.5	85.0 / 25.0	86.5 / 7.9	76.1 / 10.3
17-2	84.1 / 3.0	58.7 / 11.0	89.2 / 19.7	89.0 / 21.0	75.6 / 4.9	79.3 / 11.9
35-1	83.7 / 2.3	50.8 / 5.9	72.4 / 6.8	81.7 / 12.9	69.9 / 3.0	71.7 / 6.2
35-2	78.6 / 0.5	48.8 / 3.7	75.5 / 8.3	84.7 / 7.2	73.9 / 4.5	72.3 / 4.8

Tableau XV: Résultats de la classification dirigée à partir des quatre textures optimales après filtrage (TD / FA).

Lorsque nous comparons ensuite les tableaux X et XV, nous observons une forte hausse du TD moyen grâce au filtrage post-classification, soit environ 15 % pour 17-1 et 17-2 et 10 % pour 35-1 et 35-2. Le FA a diminué dans certains cas et augmenté dans d'autres,

mais la tendance globale est légèrement à la baisse. La sous-image B donne toujours des taux de détection insuffisants, mais conserve des FA très acceptables.

Les nouvelles matrices de confusion (annexe B et tableaux XVIa et XVIb) nous montrent également l'effet généralement positif du filtrage sur les taux de détection spécifiques à chaque classe. En comparaison avec ceux des tableaux XIa et XIb, ces taux ont pour la plupart augmenté, ce qui traduit l'élimination par l'opération de filtrage d'une partie des pixels isolés qui constituaient les erreurs de commission (voir les tableaux XVIa et XVIb).

		Résultat de classification		
		«boisé»	«îlot urbain»	«gazon»
Sites de validation	«boisé»	100 %	0 %	0 %
	«îlot urbain»	0 %	100 %	0 %
	«gazon»	0 %	21.5 %	78.5 %

Tableau XVIa: Matrice de confusion après filtrage (combinaison 35-2, sous-image A)

		Résultat de classification						
		«non-classifié»	«boisé»	«agricole»	«eau»	«béton»	«îlot urbain»	«gazon»
Sites de validation	«boisé»	0 %	73.3 %	0 %	0 %	0 %	26.7 %	0 %
	«agricole»	0 %	13.4 %	83.3 %	0.8 %	0 %	2.5 %	0 %
	«eau»	79.4 %	0 %	0 %	20.6 %	0 %	0 %	0 %
	«béton»	95.2 %	0 %	0 %	0 %	0 %	4.8 %	0 %
	«îlot urbain»	0 %	0 %	0 %	0 %	0 %	100 %	0 %
	«gazon»	0 %	0 %	0 %	70.6 %	0 %	0.2 %	29.2 %

Tableau XVIb: Matrice de confusion après filtrage (combinaison 35-2, sous-image B)

Le tableau XVII regroupe les TD* pour les quatre combinaisons retenues et les cinq sous-images. Il montre des résultats très intéressants, et même parfaits (100 %) dans plusieurs cas; l'augmentation est là aussi très nette par rapport au tableau XII et nous atteignons des TD* moyens de l'ordre de 90 %.

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E	Moyenne
17-1	100	49.9	95.4	99.7	98.0	88.6
17-2	100	77.1	100	100	88.1	93.0
35-1	100	68.1	92.5	97.4	100	91.6
35-2	100	73.3	94.0	99.7	98.9	93.2

Tableau XVII: TD* pour la classification dirigée à partir des quatre textures optimales après filtrage.

Le filtrage se fait également ressentir vivement au niveau du Kappa, comme en témoigne le tableau XVIII: alors qu'il était de l'ordre de 0.6 avant ce post-traitement, le Kappa moyen avoisine désormais 0.8, ce qui est fort acceptable. Notons que les écarts-types associés demeurent assez faibles, ceux-ci s'échelonnant entre 0.00188 et 0.00672 (voir l'annexe B). D'ailleurs, nous avons procédé à des tests statistiques afin de certifier que les écarts entre les différentes valeurs de Kappa du tableau XVIII sont bien significatifs. La réponse s'est avérée positive avec un niveau de confiance de 99 % dans tous les cas sauf deux: pour la sous-image B, entre 0.681 (17-1) et 0.677 (35-2), et pour la sous-image D, entre 0.871 (17-1) et 0.875 (35-1). Toutefois, en ce qui concerne les valeurs moyennes, les quatre combinaisons donnent des résultats statistiquement identiques, sauf dans le cas des paires 17-2 / 35-1 et 17-2 / 35-2.

	Sous-image A	Sous-image B	Sous-image C	Sous-image D	Sous-image E	Moyenne
17-1	0.894	0.681	0.854	0.871	0.711	0.802
17-2	0.805	0.770	0.901	0.808	0.679	0.793
35-1	0.962	0.722	0.927	0.875	0.560	0.809
35-2	0.971	0.677	0.868	0.909	0.638	0.813

Tableau XVIII: Coefficients Kappa pour la classification dirigée à partir des quatre textures optimales après filtrage.

L'analyse combinée de ces derniers tableaux nous amène donc à la conclusion qu'aucune des combinaisons retenues (17-1, 17-2, 35-1, 35-2) ne se démarque clairement lors des épreuves de validation. Ainsi, en privilégiant uniquement le taux de détection TD calculé

selon le masque VT, c'est 17-2 qui l'emporte avec une moyenne de 79.3 % tandis que 17-1 arrive en deuxième place avec 76.1 %. Par contre, si on met l'accent sur le taux de fausses alarmes FA, ce sont les combinaisons avec un f de 35 qui l'emportent clairement avec des moyennes de 6.2 % et 4.8 %, par rapport à 10.3 % et 11.9 % pour 17-1 et 17-2. Le taux de détection TD* calculé sur les sites de validation donne pour sa part un très léger avantage à la combinaison 35-2 (93.2 %) sur la combinaison 17-2 (93.0 %). Enfin, comme nous venons de le voir, le coefficient Kappa moyen ne permet pas de trancher en faveur de l'une ou l'autre combinaison, bien qu'il semble indiquer que 17-2 est un peu moins efficace que les trois autres, comme c'était le cas avant le filtrage. Cependant, il faut nuancer nos conclusions selon les écarts-types associés à ces taux moyens. Ainsi, dans le cas du TD*, le léger avantage détenu par 35-2 sur 17-2 n'est pas significatif étant donné que les écarts-types sont respectivement de 10.2 % et 9.2 %; pour ce qui est du Kappa, l'écart-type associé à 35-1 est le double de celui de 17-2, ce qui remet en doute un abandon de cette dernière combinaison. Rappelons par ailleurs que le coefficient Kappa est un indice d'efficacité global de la classification et qu'il dépend des taux de détection spécifiques à chacune des classes, et non pas simplement du TD*. En prenant l'exemple de la sous-image B (combinaison 35-2), on comprend bien que le Kappa calculé ne soit que de 0.677 étant donné le nombre élevé de pixels non-classifiés et la confusion existant entre les classes «eau» et «gazon» (voir le tableau XVIb).

CHAPITRE V : DISCUSSION

L'objectif visé par cette recherche étant l'élaboration d'une méthode d'extraction automatisée des surfaces boisées sur une image IKONOS panchromatique, nous avons réalisé une étude empirique afin de déterminer les paramètres de calcul des mesures de texture qui optimisent cette détection. La méthode proposée est composée des étapes suivantes: égalisation locale de l'histogramme, création d'images de texture pour les quatre mesures optimales (moyenne, contraste, corrélation et écart-type), normalisation et moyenne des directions, classification dirigée à partir des sites d'entraînement et filtrage (voir la figure 21). Dans ce chapitre, nous discuterons de certains choix que nous avons été amenés à prendre au cours de la conception de notre méthode, particulièrement en ce qui concerne le pré-traitement à appliquer aux images initiales. Puis nous analyserons les résultats obtenus et tenterons d'en tirer certaines conclusions quant aux paramètres optimaux pour le calcul des mesures de texture.

5.1 - Pré-traitement des images

Revenons tout d'abord sur l'une des étapes présentées à la figure 21: l'égalisation d'histogramme préalable à la création des images de texture. Comme nous l'avons dit précédemment, cette étape nous a été indiquée par plusieurs auteurs comme étant indispensable pour neutraliser l'effet des statistiques de premier ordre sur les signatures texturales. Toutefois, certaines mesures de textures (énergie, entropie) pourraient en être grièvement affectées puisqu'elles sont directement proportionnelles à la dispersion des valeurs dans la MCO (voir le tableau I). Or, l'égalisation tend à maximiser cette dispersion en uniformisant les probabilités d'occurrence de tous les éléments de la MCO, pour toutes les classes d'utilisation du sol. L'énergie tendra donc vers une valeur minimale tandis que l'entropie sera elle maximisée. De ce fait, nous aurions pu prévoir que les mesures d'énergie et d'entropie ne se retrouveraient pas dans la combinaison optimale de quatre textures résultant du module CHNSEL, leur potentiel discriminatoire ayant été en quelque sorte anéanti par l'égalisation.

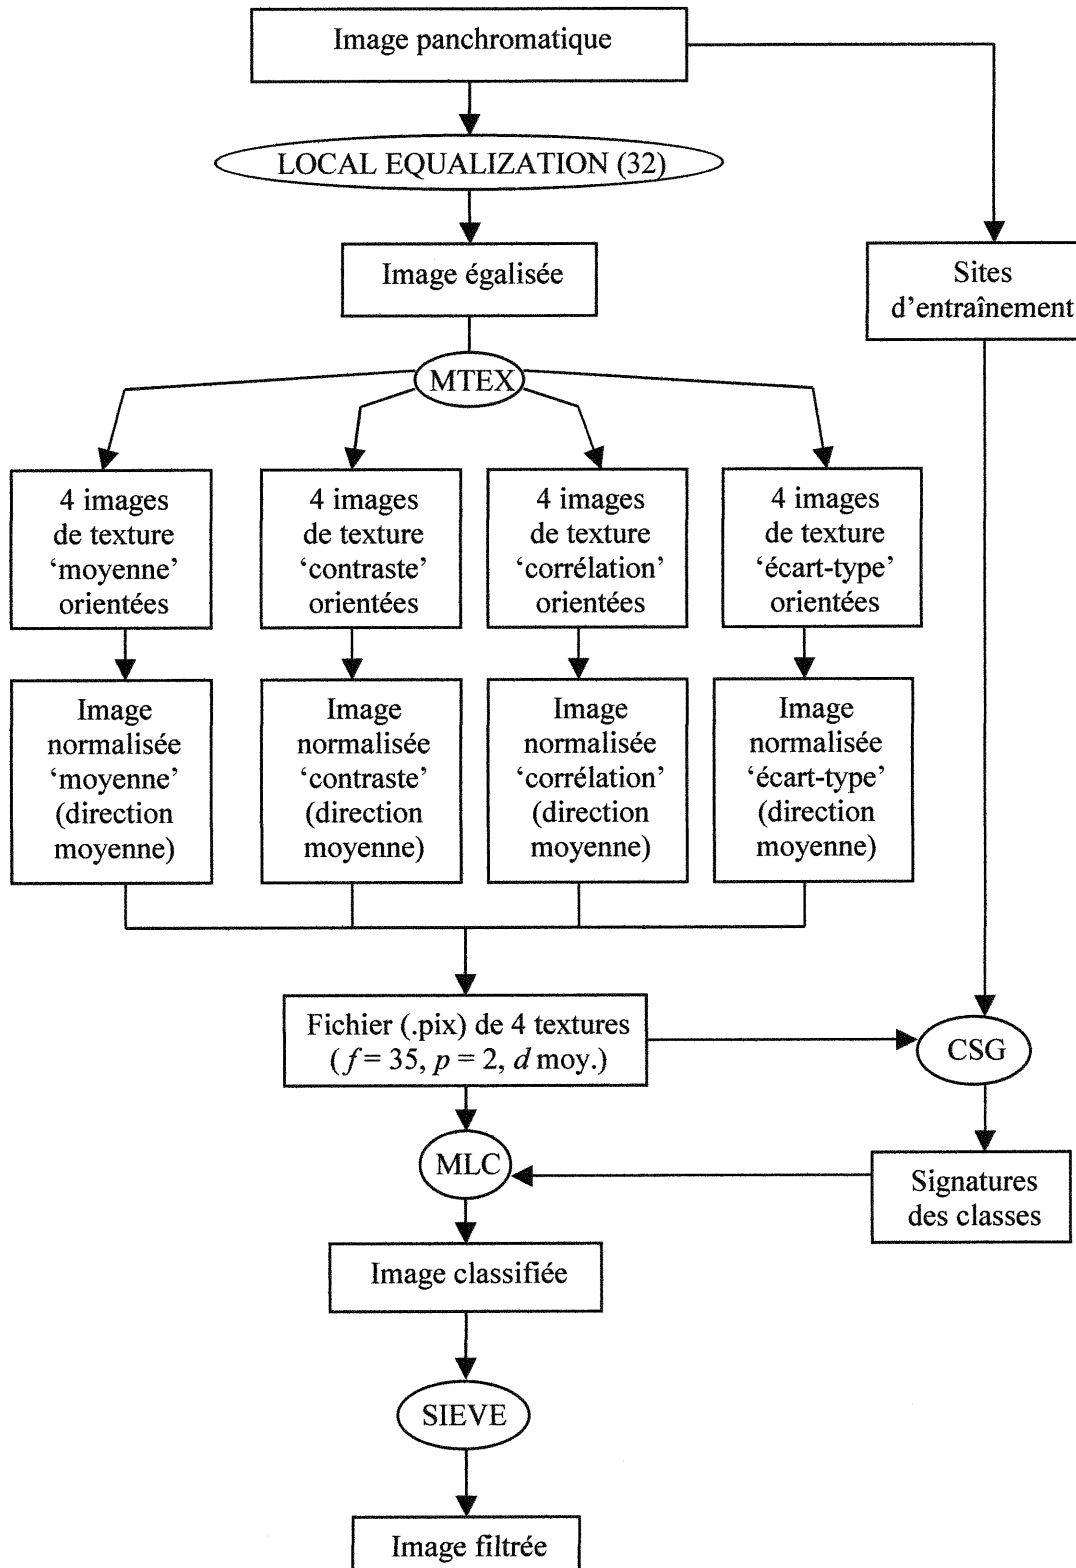


Figure 21: Organigramme de la méthode proposée (encadrés: étapes, encerclés: opérations)

D'autre part, nous avons procédé à un test visant à évaluer l'influence de l'égalisation d'histogramme sur la capacité de la texture à discriminer les diverses classes. Pour ce faire, nous avons calculé les différences absolues entre les valeurs de chaque pixel et de son voisin immédiat dans les directions 0° , 90° et 45° , avant et après égalisation. Ce test est appliqué successivement à chacune des cinq sous-image. A partir de ces différences, nous récoltons pour chaque classe la moyenne et l'écart-type des valeurs en utilisant les sites d'entraînement tracés plus tôt. Le tableau XIX présente les résultats obtenus pour la sous-image B qui est la plus variée au niveau de l'utilisation du sol. Les chiffres fournis par les quatre autres sous-images sont semblables à ceux-ci.

		Écart inter-pixel (0°)		Écart inter-pixel (90°)		Écart inter-pixel (45°)	
		Moy.	σ	Moy.	σ	Moy.	σ
Boisé	sans égalis.	13.3	10.9	15.5	13.1	17.8	14.4
	avec égalis.	28.9	25.2	33.5	29.6	38.9	32.9
Ilot Urbain	sans égalis.	12.0	12.9	13.9	14.2	16.7	16.6
	avec égalis.	23.6	23.6	27.5	26.7	32.7	30.6
Gazon	sans égalis.	6.2	5.0	5.8	4.8	5.9	5.0
	avec égalis.	35.8	30.9	33.9	29.8	33.8	30.1
Agricole	sans égalis.	6.1	4.8	6.8	5.3	7.0	5.5
	avec égalis.	55.1	46.6	61.3	49.0	61.6	48.9
Eau	sans égalis.	1.9	1.6	2.0	1.8	1.9	1.7
	avec égalis.	39.9	36.4	40.6	35.3	38.4	32.4
Béton	sans égalis.	3.4	5.0	3.8	3.6	4.3	6.7
	avec égalis.	10.0	9.2	11.9	9.6	12.0	11.9

Tableau XIX: Différences inter-pixel sur la sous-image B
(sans et avec égalisation d'histogramme).

Ce test nous permet d'étudier pour chaque classe la variation-type entre des pixels voisins, qui représente une information texturale, et son comportement face à l'égalisation d'histogramme. Une première observation est l'augmentation systématique de la moyenne et

de l'écart-type lorsqu'on égalise l'image, pour chaque classe et chaque direction étudiée. Cette augmentation permet-elle de mieux distinguer les différentes classes ou au contraire vient-elle semer de la confusion? Il appert que certaines classes initialement caractérisées par des écarts inter-pixels semblables (boisé-îlot urbain, gazon-agricole) aient clairement bénéficié de l'étape d'égalisation, alors que d'autres initialement bien distinctes (boisé-gazon, eau-gazon) n'en ressortent que plus confuses. Ainsi, les surfaces d'eau qui sont reconnues pour leur texture lisse et uniforme présentent, après égalisation, une variabilité locale plus élevée que les zones boisées elles-mêmes, se rapprochant fortement des surfaces gazonnées (voir la figure 8b) comme nous l'avons vu au chapitre précédent. Nous sommes donc en droit de nous demander si l'étape d'égalisation ne nuit pas à l'efficacité de notre méthode de détection texturale.

Nous avons donc entrepris à nouveau l'ensemble des étapes d'optimisation et de classification avec les images de texture calculées directement sur les sous-images initiales. La série d'étapes reprise comprend la création des images de texture pour les cinq sous-images et les treize combinaisons f - p utilisées précédemment, le calcul des signatures de classes et l'optimisation des mesures de textures et des paramètres f et p (classification dirigée et filtrage). Nous avons conservé les masques de vérité-terrain et les sites d'entraînement et de validation tels que tracés au chapitre IV pour permettre une comparaison fiable entre les résultats finaux. Quand nous lui avons fourni les nouvelles signatures texturales, le module CHNSEL a extrait de façon tout aussi marquée les quatre mêmes mesures optimales, soit la moyenne, le contraste, la corrélation et l'écart-type. Une classification dirigée a donc été réalisée avec le module MLC à partir des nouvelles images correspondantes et les combinaisons 17-1, 17-2, 35-1 et 35-2 sont là encore ressorties comme les plus intéressantes. En comparaison avec les résultats sur des images égalisées, les taux de détection étaient généralement à la baisse mais les fausses alarmes y étaient moins nombreuses. De son côté, le taux moyen de non-classification dépassait les 20%, ce qui est définitivement trop élevé (il n'était que de 2% avec les images égalisées). En nous basant sur ces résultats, il nous faut privilégier l'emploi d'une étape d'égalisation d'histogramme, qui possède l'avantage théorique de permettre l'extension de notre méthode à d'autres images IKONOS qui ne présenteraient pas les mêmes statistiques de premier ordre que notre image initiale.

En outre, rappelons que nous avons préféré ne pas compresser les valeurs à 8, 16 ou 32 niveaux de gris mais que nous avons plutôt conservé les 256 niveaux originaux. Il est très

difficile de se prononcer quant à l'influence qu'aurait pu avoir cette opération de compression sur nos résultats de détection étant donné que ces derniers dépendent étroitement et simultanément de plusieurs opérations (égalisation, choix des paramètres pour les calculs de texture, classification, filtrage). Or, nous ne disposons pas du temps et des ressources nécessaires à la réalisation d'une étude exhaustive qui nous aurait peut-être permis d'isoler les effets de la compression.

Si notre méthode est appliquée ultérieurement à une image dont le niveau de quantification n'est pas 256, il n'est pas garanti que l'on obtiendra une détection optimale des surfaces boisées. Bien que le temps d'exécution et les besoins en espace-mémoire en seraient certainement amoindris, il est en effet possible que les mesures de textures et les paramètres f et p retenus ne soit plus ceux qui donnent la meilleure caractérisation texturale des boisés. Nous pensons donc qu'il est préférable de maintenir à 256 le degré de quantification des images initiales pour la production des images de textures.

5.2 - Mesures et paramètres optimaux

Le choix de la combinaison optimale des mesures de texture semble raisonnable étant donné que celle-ci contient des mesures de texture relativement peu corrélées entre elles. Il eût été curieux, par exemple, d'y retrouver conjointement les mesures de contraste et d'homogénéité qui offrent essentiellement la même information. D'ailleurs, la combinaison retenue s'accorde bien avec les directives de Clausi qui proscrivent l'emploi simultané de certaines mesures de textures dans un processus de classification texturale (Clausi, 2002). Parmi les mesures qu'il a considérées, Clausi a en effet établi trois catégories fondées sur leur corrélation. Il en est venu à la conclusion qu'il fallait n'utiliser qu'un seul représentant de chacun de ces groupes pour éviter la redondance. Le premier d'entre eux comprend le contraste, l'homogénéité, la dissimilarité et la différence inverse, ces deux dernières mesures n'ayant pas été définies par la méthode de Unser. Le deuxième regroupement contient l'énergie, l'entropie et la probabilité maximale, tandis que la corrélation constitue à elle seule le troisième groupe. Notre combinaison optimale comporte donc une seule mesure du premier et du troisième regroupement (contraste et corrélation), mais aucune du deuxième. Les deux autres mesures que nous avons retenues (moyenne et écart-type) n'ont pas été

considérées par Clausi. À tout le moins, la redondance semble écartée par notre combinaison optimale.

Le choix des paramètres servant à la création des images de texture a commencé par la fixation de la direction d'échantillonnage d , en prenant la moyenne des quatre images directionnelles correspondant aux quatre angles disponibles (0° , 45° , 90° et 135°). Le choix aurait certes pu être fondé sur la direction des rayons du soleil dans l'image, en adoptant par exemple le d qui s'en approche le plus, afin d'optimiser la caractérisation texturale des surfaces boisées. Celle-ci est en effet grandement influencée par la direction des ombres associées aux arbres et il s'avère que les directions parallèles et perpendiculaires à l'angle solaire azimutal sont les plus aptes à capter la texture anisotrope des boisés (St-Onge, 1994). Cependant, nous avons préféré opter pour la moyenne des directions afin d'aboutir à un détecteur de boisés plus robuste aux variations d'éclairement solaire: on pourra ainsi traiter indifféremment des images aux orientations d'éclairement bien distinctes et en tirer des résultats compatibles. Cet atout viendra certainement compenser la perte d'information occasionnée par la fusion des quatre images directionnelles en une seule image moyenne.

Toutefois, il pourrait être intéressant d'adapter le choix du paramètre d selon les paramètres d'acquisition de l'image à traiter. En effet, il serait peut-être profitable d'employer un d fondé sur l'angle azimutal du soleil dans le cas où ce dernier est à l'opposé de celui du capteur et que les ombres sont clairement définies et orientées. Par contre, quand ces deux angles sont semblables et que les ombres sont quasi-absentes, on opterait pour un d moyen puisque la texture des boisés serait alors *a priori* isotrope. Cette option reste cependant à expérimenter avant d'être adoptée avec confiance.

Les deux autres paramètres reliés à la création des images de texture (f et p) ont quant à eux fait l'objet d'une étude systématique fondée sur treize combinaisons, ce qui nous a permis d'en arriver à des conclusions intéressantes. D'une part, il s'est avéré que les combinaisons ayant des valeurs de p élevées (7, 11 et 16) sont à éviter puisqu'elles engendrent des taux de fausses alarmes inacceptables. Ce sont les pas de 1 et 2 qui donnent les meilleurs résultats de détection, ce qui est assurément dû à leur capacité accrue à capter la micro-texture (à l'échelle du mètre). Or, on sait que les surfaces boisées sont caractérisées par une forte variabilité spatiale des valeurs de brillance sur les images panchromatiques de type IKONOS, d'où la nécessité d'opérer à une échelle des plus réduites pour ce qui est de

l'échantillonnage des paires de pixels. Notons que plusieurs auteurs en sont arrivés à cette même conclusion dans leur travaux sur les glaces de mer (Holmes *et al.*, 1984; Barber et LeDrew, 1991). D'autre part, nous avons rapidement pu délaisser les combinaisons ayant une petite valeur de f (5-1 et 5-2) car elles produisaient des taux de détection nettement insuffisants. Nous en déduisons que la région prise en compte dans le calcul de la texture autour d'un pixel doit être assez grande pour englober la périodicité de la texture des boisés; la taille de la fenêtre d'échantillonnage optimale est donc forcément supérieure ou égale au diamètre d'un arbre. Parmi les deux f retenus (17 et 35), aucun ne se démarque comme étant le meilleur; cependant, un examen des résultats de validation selon le masque de vérité-terrain nous montre que le taux de détection est supérieur pour un f de 17 que pour un f de 35, mais que le taux de fausses alarmes y est également plus grand. Le choix des paramètres f et p optimaux pour notre méthode de détection des surfaces boisées dépendra donc des exigences liées au type de l'application visée. Par exemple, dans le cadre d'un projet de protection stricte des boisés, qui requiert un TD maximal, nous opterions pour la combinaison 17-2. Notons toutefois que la combinaison 17-1 donnerait des résultats statistiquement équivalents, si l'on se fie au Kappa. Toutefois, il faut dire que la fenêtre réellement optimale est peut-être de 15 ou 19, ou encore 25. Seule une étude exhaustive, trop longue et coûteuse en espace-disque pour être réalisable dans le cadre de ce projet, permettrait de la déterminer avec certitude.

5.3 - Efficacité de détection des surfaces boisées

En ce qui a trait aux résultats atteints, cette étude vient confirmer le potentiel de la dimension texturale dans le domaine de la cartographie forestière, avec des TD* moyens très convenables de l'ordre de 90 %. En isolant le cas problématique de la sous-image B, ces taux grimpent d'ailleurs à des valeurs de 97 à 98 %. La validation selon le masque VT donne quant à elle des résultats assez satisfaisants avec des TD de l'ordre de 72 à 79 % et des FA de 5 à 12 %. Les différences entre le TD et le TD* s'expliquent principalement par des problèmes de classification aux alentours des frontières entre surfaces boisées et non-boisées. Les coefficients Kappa obtenus sont dans l'ensemble acceptables, avec des moyennes aux alentours de 0.8, mais on peut dire qu'une bonne détection des surfaces boisées exige de meilleurs résultats que ceux-ci. Étant donné que cet indice tient compte de toutes les classes que nous avons définies, un meilleur choix de celles-ci améliorerait probablement le Kappa en

réduisant la confusion inter-classes que l'on peut observer dans les matrices de confusion. En effet, la classe îlot urbain englobe souvent arbres, gazon et bâtiments, d'où sa proximité texturale avec les autres classes. La solution passe peut-être par la définition de classes plus spécifiques, par exemple «arbre», «gazon», «eau», «béton», «asphalte», etc. D'autre part, la présence de pixels non-classifiés, bien que nettement atténuée par la réduction du nombre de mesures de texture utilisées ainsi que par le filtrage, demeure non-négligeable tel qu'illustré par les figures 23 à 26, particulièrement pour un f de 35. Une meilleure définition de classes devrait également permettre de remédier en grande partie à ce problème. D'autres techniques de classification pourraient aussi être envisagées pour permettre de séparer l'espace textural de classification de façon plus souple; la classification par réseau de neurones aurait en ce sens un potentiel certain.

Tout au long de cette étude, nous avons pu observer que la sous-image B donnait presque invariablement les pires résultats parmi ceux des cinq sous-images. Nous avons conclu à une disparité significative entre la taille des arbres sur cette sous-image et celle sur les quatre autres; la confusion de la classe «boisé» avec la classe «îlot urbain» serait ainsi bien plus forte sur la première, ce qui expliquerait les piètres résultats obtenus. Ceci met en évidence la principale limite de notre méthode de détection, soit l'impossibilité de détecter simultanément et efficacement toutes les surfaces boisées d'une image sur laquelle on retrouverait des arbres de tailles variables. En effet, comment choisirait-on un échantillon boisé représentatif de ces diverses tailles d'arbres lorsque viendrait le temps de construire les sites d'entraînement? Le problème se complique encore davantage lorsque l'image contient plusieurs espèces d'arbres de formes bien distinctes, par exemples des érables rouges et des épinettes noires. Pour mener à bien une telle détection, nous devons donc adopter une stratégie itérative qui consistera à appliquer l'un après l'autre plusieurs détecteurs, chacun ayant sa cible propre (boisés de jeunes feuillus, boisés de feuillus matures, boisés de conifères...). Les paramètres f et p optimaux seront vraisemblablement différents pour chacune d'entre elles. Finalement, une mise en commun de toutes les zones détectées aboutirait à une segmentation de l'image entre surfaces boisées et non-boisées.

CHAPITRE VI : CONCLUSION

Dans le cadre de cette étude, nous avons développé et analysé l'exactitude d'une méthode de détection automatisée des surfaces boisées à partir d'une image IKONOS panchromatique à très haute résolution (1 m.). La plupart des travaux antérieurs dans ce domaine incorporaient seulement la texture comme donnée auxiliaire à une analyse multispectrale classique, afin d'en améliorer les résultats. Dans notre cas, nous avons préféré éviter le recours à toute autre source de données que l'image panchromatique, ce qui nous a permis d'évaluer à quel point la texture peut à elle seule y distinguer les surfaces boisées des surfaces non-boisées. Pour la création des images de texture, nous nous sommes servis de l'algorithme de Unser qui permet un calcul accéléré des mesures de Haralick à partir des histogrammes des sommes et des différences. Plus de 2000 images de textures ont ainsi été générées pour couvrir un ensemble de treize combinaisons fenêtre-pas ($f-p$). Les essais préliminaires de détection des boisés à l'aide d'algorithmes de segmentation ou de classification non-dirigée nous ont démontré qu'une classification binaire entre surfaces boisées et non-boisées n'est pas possible. Il a donc fallu adopter une stratégie multi-classes et un classificateur de type supervisé. La validation des résultats a été réalisée selon deux méthodes: l'une par comparaison avec notre masque de vérité-terrain, nous donnant les taux de détection TD et de fausses alarmes FA, et l'autre selon des sites de validation de chaque classe, nous donnant le taux de détection des boisés TD* et le coefficient Kappa. Nous avons déterminé quatre mesures de texture optimales pour la discrimination inter-classes: la moyenne, le contraste, la corrélation et l'écart-type. En ce qui concerne les paramètres liés au calcul de ces mesures, nous avons d'emblée fixé d à une moyenne des quatre directions disponibles. Alliée à l'égalisation d'histogramme réalisée sur l'image initiale, cette direction moyenne permettrait une application élargie de notre méthode à des images acquises sous diverses conditions d'éclairage. Une étude systématique nous a ensuite permis de réduire à quatre le nombre de combinaisons fenêtre-pas ($f-p$), soit 17-1, 17-2, 35-1 et 35-2. Nous pouvons en tirer les conclusions suivantes: le pas d'échantillonnage p doit être maintenu petit pour capter adéquatement la forte variabilité spatiale associée aux boisés, et la taille de fenêtre f doit être assez grande pour inclure au minimum un arbre entier. Les combinaisons retenues engendrent des efficacités de détection assez semblables mais une certaine tendance semble

toutefois se dégager: le taux de détection TD est favorisé par un f de 17 tandis qu'un f de 35 permet plutôt de mettre l'accent sur la réduction des fausses alarmes FA.

Les résultats obtenus par notre méthode de détection sont d'un niveau acceptable, particulièrement après l'étape de filtrage. Ainsi, nous obtenons des TD* moyens avoisinant les 90 % et des coefficients Kappa autour des 0.8. Les problèmes surviennent principalement aux alentours des frontières entre zones boisées et non-boisées, ce qui se traduit par des TD de l'ordre de 75 % seulement, ceux-ci étant calculés selon le masque de vérité-terrain. Les erreurs de commission, évaluées par le taux FA, sont assez réduites, avec des valeurs moyennes de 5 à 12 %. Toutefois, nous avons éprouvé quelques difficultés avec la sous-image B en raison de la nature discordante des arbres qui s'y retrouvent. En effet, la texture d'un boisé dépend fortement de la taille des arbres qui le composent, ainsi que de sa structure. Les paramètres caractérisant notre détecteur pourront être ajustés pour permettre son application à divers types de boisés; dans le cas où l'on en retrouverait plusieurs dans une même image, on pourrait d'ailleurs combiner les résultats obtenus pour chacun de ces types. En ce qui concerne les zones frontalières, plusieurs solutions sont envisageables: le recours à une méthode de détection des arbres individuels comme celle de Bouzkraoui et Beaulieu (2000), l'utilisation d'une fenêtre de taille variable que l'on rapetisserait pour le traitement de ces zones critiques, ou encore l'application d'un détecteur multi-résolution, pour lequel on répèterait les opérations en dégradant chaque fois la résolution spatiale de l'image initiale.

Quoi qu'il en soit, nous avons vérifié l'hypothèse selon laquelle la texture permet de caractériser assez efficacement les surfaces boisées sur une image IKONOS panchromatique pour les extraire avec un taux de confiance acceptable. La rapidité et la simplicité d'application de la méthode proposée lui confèrent un intérêt non-négligeable pour la cartographie automatisée d'un territoire urbanisé comme celui de la R.M.M., que ce soit par elle-même ou en association avec d'autres types de données (radar, multispectrales,...).

Bien qu'elles soient fondées sur l'imagerie IKONOS, nos conclusions pourraient certainement être étendues à d'autres images à très haute résolution spatiale caractérisées par une bande panchromatique englobant le proche infrarouge, comme c'est le cas pour Quickbird. En outre, nous espérons que cette recherche ouvrira la voie à d'autres études en cartographie automatisée sur les images à très haute résolution, afin que de telles données puissent être exploitées au maximum de leur potentiel. Cependant, nous avons probablement

atteint les limites de la classification pixel par pixel et il semble qu'il soit désormais préférable de se tourner vers une classification de type contextuel. Ainsi, Guindon (2000) préconise plutôt une approche orientée-objet fondée sur des règles logiques pour extraire l'information contenue dans les images à haute résolution. Ses travaux ont effectivement donné de bons résultats quant à la reconnaissance du réseau routier, mais il reste à appliquer cette méthode à la détection des surfaces boisées.

RÉFÉRENCES

Anys, H.; Bannari, A.; He, D.-C.; Morin, D. (1998) Cartographie des zones urbaines à l'aide des images aéroportées MEIS-II. *International Journal of Remote Sensing*, Vol.19, No.5, pp.883-894.

Atkinson, P.M.; Danson, F.M. (1988) Spatial resolution for remote sensing of forest plantations. *International Geoscience and Remote Sensing Symposium 1988 Proceedings*, IEEE, pp.221-223.

Barber, D.G.; LeDrew, E.F. (1991) SAR sea ice discrimination using texture statistics: a multivariate approach. *Photogrammetric Engineering and Remote Sensing*, Vol.57, No.4, pp.385-395.

Bouzkraoui, M.; Beaulieu, J.-M. (2000) Détection des arbres individuels dans des images de haute résolution. *Actes-Vision Interface 2000*, Association Canadienne de Traitement d'Images et Reconnaissance de Formes, pp.311-317.

Clausi, D.A. (2002) An analysis of co-occurrence texture statistics as a function of grey level quantization. *Journal Canadien de Télédétection*, Vol.28, No.1, pp.45-62.

Congalton, R.G.; Green, K. (1999) *Assessing the accuracy of remotely sensed data: principles and practices.* CRC Press, 137 p.

Connors, R.W.; Harlow, C.A. (1980) A theoretical comparison of texture algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-2, No. 3, pp.204-222.

Duda, R.O.; Hart, P.E.; Stork, D.G. (2001) *Pattern classification.* 2nd Edition, Wiley & Sons, 654 p.

Franklin, S.E.; Hall, R.J.; Moskal, L.M.; Maudie, A.J.; Lavigne, M.B. (2000) Incorporating texture into classification of forest species composition from airborne multispectral images. *International Journal of Remote Sensing*, Vol.21, No.1, pp.61-79.

Franklin, S.E.; Wulder, M.A.; Gerylo, G.R. (2001) Texture analysis of IKONOS panchromatic data for Douglas-fir forest age class separability in British Columbia. *International Journal of Remote Sensing*, Vol.22, No.13, pp.2627-2632.

Galloway, M. (1975) Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*, Vol.4, pp.172-199.

Guindon, B. (2000) A framework for the development and assessment of object recognition modules from high-resolution satellite images. *Canadian Journal of Remote Sensing*, Vol. 26, No. 4, pp.334-348.

Haralick, R.M.; Shanmugam, K.; Dinstein, I. (1973) Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 3, No. 6, pp.610-621.

Haralick, R.M. (1979) Statistical and structural approaches to texture. *Proceedings of the IEEE*, Vol. 67, No. 5, pp.786-804.

Hlavka, C.A. (1987) Land-use mapping using edge density texture measures on TM simulator data. *IEEE Transactions on Geoscience and Remote Sensing*, GE-25, No.1, p.104-108.

Holmes, Q.A.; Nuesch, D.R.; Shuchman, R.A. (1984) Textural analysis and real-time classification of sea-ice types using digital SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, GE-22, No.2, pp.113-120.

Laporte, J.M. (1983) Texture analysis on SPOT simulations. *17th Symposium on Remote Sensing of Environment*, pp.1243-1252.

Lévesque, J.; King, D.J. (1999) Airborne digital camera image semivariance for evaluation of forest structural damage at an acid mine site. *Remote Sensing of Environment*, Vol.68, No.2, pp.112-124.

Logan, T.L.; Strahler, A.H. (1979) Use of a standard deviation based texture channel for Landsat classification of forest strata. *Machine Processing of Remotely Sensed Data Symposium*, p.395.

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*, Vol.28, No.4, pp.513-519.

Messier, N.; Cavayas, F.; André, P. (2001) Cartographie de l'occupation du sol en milieu urbain, à partir d'images satellites de haute résolution spatiale: le cas de Beijing (Chine). *Compte-rendu du 23^{ième} Symposium Canadien sur la Télédétection*, Vol.2, pp.829-834.

Nagao, M.; Matsuyama, T. (1980) *A structural analysis of complex aerial photographs.* Plenum Press, 199 p.

Neville, R.A. (1992) An airborne imager for forestry and mapping. *Proceedings of the International Forum on Airborne Multispectral Scanning for Forestry and Mapping*, Leckie, D.G. et Gillis, M.D. (Eds), Val Morin, Québec, pp.22-30.

Ojala, T.; Pietikäinen, M. (2001) Texture classification. In: *CVonline – Compendium of Computer Vision*, Fisher, R.B. (ed),
http://www.dai.ed.ac.uk/cvonline/local_copies/ojala1/texclas.htm

Parker, J.R. (1997) *Algorithms for image processing and computer vision.* Wiley Computer Publishing, 418 p.

Pekkarinen, A. (2002) A method for the segmentation of very high spatial resolution images of forested landscapes. *International Journal of Remote Sensing*, Vol.23, No.14, pp.2817-2836.

Podest, E.; Saatchi, S. (1999) Application of texture to JERS-1 SAR imagery for tropical forest land cover classification. *Geoscience and Remote Sensing Symposium 1999 Proceedings*, IEEE, Vol. 2, pp.1451-1453.

- Pratt, W.K. (1991)** *Digital image processing*. 2nd Edition, Wiley & Sons, 698 p.
- Solberg, R.; Solberg, A.H.S.; Koren, H.; Aas, K. (1996)** The suitability of future high-resolution satellite imagery for forest inventory. *Geoscience and Remote Sensing Symposium 1996 Proceedings*, IEEE, Vol. 4, pp.2307-2309.
- St-Onge, B. (1994)** L'apport de la texture des images numériques de haute résolution à la cartographie forestière automatisée. *Thèse de doctorat non-publiée, Département de géographie, Université de Montréal*, 251 p.
- St-Onge, B.; Cavayas, F. (1995)** Estimating forest stand structure from high resolution imagery using the directional variogram. *International Journal of Remote Sensing*, Vol.16, No.11, pp.1999-2021.
- Teillet, P.M.; Goodenough, D.G.; Guindon, B.; Meunier, J.-F.; Dickinson, K. (1981)** Digital analysis of spatial and spectral features from airborne MSS of a forested region. *Proceedings of the 15th International Symposium on Remote Sensing of Environment*, Vol.2, pp.883-903.
- Unser, M. (1986)** Sum and difference histograms for texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 8, pp.118-125.
- Vleck, J.; Jayasinghe, D.; King, D.; Yuan, X.; Cadeau, F. (1987)** Spectral and spatial classification of land-cover types in multispectral aerial video imagery. *Proceedings of the 11th Canadian Symposium on Remote Sensing*, pp.99-107.
- Weszka, J.; Dyer, C.; Rosenfeld, A. (1976)** A comparative study of texture measures for terrain classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-6, pp.269-285.
- Wulder, M.A.; LeDrew, E.F.; Franklin, S.E.; Lavigne, M.B. (1998)** Aerial image texture information in the estimation of northern deciduous and mixed wood forest leaf area index (LAI). *Remote Sensing of Environment*, Vol.64, No.1, pp.64-76.

ANNEXE A

Matrices de confusion et coefficients Kappa (avant le post-traitement)

Codes associés aux classes dans les matrices de confusion

	0	20	40	60	80	100	120
A	Non-classifié	Boisé	Ilot urbain	Gazon	-	-	-
B	Non-classifié	Boisé	Agricole	Eau	Béton	Ilot urbain	Gazon
C	Non-classifié	Boisé	Ilot urbain	Gazon	-	-	-
D	Non-classifié	Boisé	Eau	Ilot urbain	Gazon	Route	-
E	Non-classifié	Boisé	Gazon court	Gazon	Route	-	-

MLR A 17-1 :

Code	Areas Pixels	Percent Pixels Classified by Code			
		0	20	40	60
20	6781	2.6	89.5	3.9	4.0
40	6216	6.5	5.7	75.1	12.6
60	1055	4.8	0.9	31.2	63.1

Average accuracy = 75.91%
Kappa Coefficient = 0.68810

Overall accuracy = 81.16%
Standard Deviation = 0.00502

MLR A 17-2 :

Code	Areas Pixels	Percent Pixels Classified by Code			
		0	20	40	60
20	6781	3.2	88.0	7.7	1.1
40	6216	5.6	7.9	60.3	26.2
60	1055	5.0	1.2	20.6	73.2

Average accuracy = 73.82%
Kappa Coefficient = 0.59282

Overall accuracy = 74.62%
Standard Deviation = 0.00535

MLR A 35-1 :

Code	Areas		Percent Pixels Classified by Code			
	Pixels		0	20	40	60
20	6781		9.5	88.4	0.0	2.1
40	6216		7.9	0.2	83.8	8.0
60	1055		0.0	0.0	31.2	68.8

Average accuracy = 80.36%
Kappa Coefficient = 0.75367

Overall accuracy = 84.93%
Standard Deviation = 0.00449

MLR A 35-2 :

Code	Areas		Percent Pixels Classified by Code			
	Pixels		0	20	40	60
20	6781		11.1	88.9	0.0	0.0
40	6216		2.2	0.1	81.0	16.7
60	1055		0.0	0.0	21.4	78.6

Average accuracy = 82.82%
Kappa Coefficient = 0.75083

Overall accuracy = 84.62%
Standard Deviation = 0.00450

MLR B 17-1 :

Code	Areas		Percent Pixels Classified by Code						
	Pixels		0	20	40	60	80	100	120
20	2370		4.3	47.8	0.0	0.3	0.0	39.9	7.6
40	4960		4.0	2.4	92.3	0.4	0.0	0.9	0.0
60	1520		43.0	0.0	0.0	55.7	0.0	0.5	0.9
80	105		74.3	1.0	0.0	0.0	9.5	15.2	0.0
100	2542		11.3	27.8	0.0	4.7	0.0	44.9	11.3
120	528		77.1	0.0	0.0	0.2	0.0	1.9	20.8

Average accuracy = 45.18%
Kappa Coefficient = 0.53997

Overall accuracy = 65.03%
Standard Deviation = 0.00496

MLR B 17-2 :

Code	Areas Pixels	Percent Pixels Classified by Code						
		0	20	40	60	80	100	120
20	2370	4.6	54.1	9.7	0.0	0.0	30.4	1.1
40	4960	1.9	14.0	81.6	0.2	0.0	2.4	0.0
60	1520	42.1	0.0	0.0	55.9	0.0	0.0	2.0
80	105	22.9	0.0	0.0	0.0	24.8	15.2	37.1
100	2542	13.7	21.0	2.8	6.5	0.3	31.6	24.1
120	528	59.5	0.0	0.0	16.5	2.1	0.0	22.0

Average accuracy = 44.99% Overall accuracy = 59.24%
 Kappa Coefficient = 0.46782 Standard Deviation = 0.00518

MLR B 35-1 :

Code	Areas Pixels	Percent Pixels Classified by Code						
		0	20	40	60	80	100	120
20	2370	3.2	57.6	0.0	0.0	0.0	39.2	0.0
40	4960	5.7	0.4	93.9	0.0	0.0	0.0	0.0
60	1520	84.4	0.0	0.0	15.0	0.0	0.6	0.0
80	105	100.0	0.0	0.0	0.0	0.0	0.0	0.0
100	2542	14.7	33.3	0.0	0.8	0.0	51.2	0.0
120	528	65.9	0.0	0.0	8.5	0.0	2.5	23.1

Average accuracy = 40.12% Overall accuracy = 63.79%
 Kappa Coefficient = 0.52394 Standard Deviation = 0.00477

MLR B 35-2 :

Code	Areas Pixels	Percent Pixels Classified by Code						
		0	20	40	60	80	100	120
20	2370	2.2	63.2	2.7	0.0	0.0	31.9	0.0
40	4960	2.3	13.2	81.9	0.0	0.0	2.6	0.0
60	1520	77.0	0.0	0.0	23.0	0.0	0.0	0.0
80	105	95.2	0.0	0.0	0.0	0.0	4.8	0.0
100	2542	29.9	21.0	0.0	1.9	0.0	47.1	0.0
120	528	62.3	0.0	0.0	8.3	0.0	0.2	29.2

Average accuracy = 40.74% Overall accuracy = 60.40%
 Kappa Coefficient = 0.48733 Standard Deviation = 0.00499

MLR C 17-1 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6800	0.6	77.9	1.5	20.0
40	5050	13.2	3.1	80.5	3.2
60	948	38.7	0.0	45.5	15.8

Average accuracy = 58.07%

Overall accuracy = 74.32%

Kappa Coefficient = 0.58735

Standard Deviation = 0.00528

MLR C 17-2 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6800	2.3	83.4	0.7	13.5
40	5050	12.7	10.5	49.3	27.5
60	948	40.3	0.0	36.2	23.5

Average accuracy = 52.10%

Overall accuracy = 65.55%

Kappa Coefficient = 0.46076

Standard Deviation = 0.00539

MLR C 35-1 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6800	3.3	82.9	0.1	13.6
40	5050	9.5	0.0	90.3	0.2
60	948	19.2	0.0	66.9	13.9

Average accuracy = 62.39%

Overall accuracy = 80.73%

Kappa Coefficient = 0.67847

Standard Deviation = 0.00502

MLR C 35-2 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6800	5.1	89.2	0.1	5.6
40	5050	22.3	0.1	53.2	24.3
60	948	21.5	0.0	68.1	10.3

Average accuracy = 50.93%
 Kappa Coefficient = 0.51453

Overall accuracy = 69.17%
 Standard Deviation = 0.00492

MLR D 17-1 :

Code	Areas	Percent Pixels Classified by Code					
	Pixels	0	20	40	60	80	100
20	5100	2.7	92.0	0.0	0.5	4.6	0.2
40	1525	3.5	0.0	96.5	0.0	0.0	0.0
60	3740	10.7	4.7	0.0	74.9	6.7	3.0
80	1007	0.0	50.5	0.0	2.6	46.9	0.0
100	465	77.2	0.0	0.0	2.8	0.0	20.0

Average accuracy = 66.05%
 Kappa Coefficient = 0.72313

Overall accuracy = 80.50%
 Standard Deviation = 0.00484

MLR D 17-2 :

Code	Areas	Percent Pixels Classified by Code					
	Pixels	0	20	40	60	80	100
20	5100	3.1	93.7	1.3	0.1	1.7	0.0
40	1525	0.0	1.6	98.4	0.0	0.0	0.0
60	3740	9.1	12.3	0.0	45.5	20.8	12.3
80	1007	0.0	39.2	0.0	15.5	45.3	0.0
100	465	26.2	0.0	0.0	2.2	0.0	71.6

Average accuracy = 70.91%
 Kappa Coefficient = 0.63764

Overall accuracy = 74.10%
 Standard Deviation = 0.00523

MLR D 35-1 :

Code	Areas		Percent Pixels Classified by Code					
	Pixels		0	20	40	60	80	100
20	5100		5.9	91.2	0.0	0.0	2.9	0.0
40	1525		12.3	0.0	87.7	0.0	0.0	0.0
60	3740		11.9	0.3	0.0	81.0	6.0	0.8
80	1007		10.8	19.2	0.0	1.3	68.7	0.0
100	465		92.7	0.0	0.0	0.0	6.7	0.6

Average accuracy = 65.86%

Overall accuracy = 82.06%

Kappa Coefficient = 0.75072

Standard Deviation = 0.00450

MLR D 35-2 :

Code	Areas		Percent Pixels Classified by Code					
	Pixels		0	20	40	60	80	100
20	5100		7.5	92.5	0.0	0.0	0.0	0.0
40	1525		10.5	0.0	89.5	0.0	0.0	0.0
60	3740		7.6	0.0	0.0	77.0	15.1	0.3
80	1007		10.6	12.7	0.0	18.6	58.1	0.0
100	465		74.8	0.0	0.0	0.0	0.9	24.3

Average accuracy = 68.29%

Overall accuracy = 81.63%

Kappa Coefficient = 0.74414

Standard Deviation = 0.00457

MLR E 17-1 :

Code	Areas		Percent Pixels Classified by Code				
	Pixels		0	20	40	60	80
20	5461		7.8	79.5	0.3	12.4	0.0
40	1319		12.1	0.0	84.8	3.0	0.1
60	1299		53.7	13.2	1.5	18.0	13.5
80	522		14.0	12.3	0.0	6.1	67.6

Average accuracy = 62.48%

Overall accuracy = 70.28%

Kappa Coefficient = 0.52118

Standard Deviation = 0.00674

MLR E 17-2 :

Code	Areas	Percent Pixels Classified by Code				
	Pixels	0	20	40	60	80
20	5461	9.8	74.6	0.0	15.4	0.2
40	1319	11.6	0.0	87.3	0.1	1.1
60	1299	26.9	3.5	0.4	20.4	48.7
80	522	9.2	7.3	0.0	13.6	69.9

Average accuracy = 63.04%

Overall accuracy = 68.06%

Kappa Coefficient = 0.50451

Standard Deviation = 0.00668

MLR E 35-1 :

Code	Areas	Percent Pixels Classified by Code				
	Pixels	0	20	40	60	80
20	5461	12.7	84.9	0.0	2.3	0.0
40	1319	47.8	0.6	43.9	7.7	0.0
60	1299	92.6	0.0	0.5	2.0	4.9
80	522	1.9	18.4	0.0	0.0	79.7

Average accuracy = 52.63%

Overall accuracy = 65.78%

Kappa Coefficient = 0.45836

Standard Deviation = 0.00546

MLR E 35-2 :

Code	Areas	Percent Pixels Classified by Code				
	Pixels	0	20	40	60	80
20	5461	21.9	76.8	0.0	1.3	0.0
40	1319	32.0	0.0	59.6	6.2	2.2
60	1299	67.8	0.0	0.3	19.5	12.4
80	522	33.7	0.4	0.0	0.0	65.9

Average accuracy = 55.43%

Overall accuracy = 64.82%

Kappa Coefficient = 0.47128

Standard Deviation = 0.00569

ANNEXE B
Matrices de confusion et coefficients Kappa
(après filtrage)

P-MLR A 17-1 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6781	0.0	100.0	0.0	0.0
40	6216	0.0	0.0	100.0	0.0
60	1055	0.0	3.4	73.4	23.2

Average accuracy = 74.41%

Overall accuracy = 94.24%

Kappa Coefficient = 0.89414

Standard Deviation = 0.00344

P-MLR A 17-2 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6781	0.0	100.0	0.0	0.0
40	6216	0.0	0.0	77.4	22.6
60	1055	0.0	0.0	21.8	78.2

Average accuracy = 85.20%

Overall accuracy = 88.36%

Kappa Coefficient = 0.80495

Standard Deviation = 0.00422

P-MLR A 35-1 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6781	0.0	100.0	0.0	0.0
40	6216	0.0	0.0	100.0	0.0
60	1055	0.0	0.0	28.5	71.5

Average accuracy = 90.49%

Overall accuracy = 97.86%

Kappa Coefficient = 0.96161

Standard Deviation = 0.00216

P-MLR A 35-2 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6781	0.0	100.0	0.0	0.0
40	6216	0.0	0.0	100.0	0.0
60	1055	0.0	0.0	21.5	78.5

Average accuracy = 92.83%
Kappa Coefficient = 0.97115

Overall accuracy = 98.38%
Standard Deviation = 0.00188

P-MLR B 17-1 :

Code	Areas	Percent Pixels Classified by Code						
	Pixels	0	20	40	60	80	100	120
20	2370	0.0	49.9	0.0	0.0	0.0	50.1	0.0
40	4960	0.0	0.0	100.0	0.0	0.0	0.0	0.0
60	1520	43.0	0.0	0.0	56.2	0.0	0.8	0.0
80	105	83.8	0.0	0.0	0.0	0.0	16.2	0.0
100	2542	0.0	26.8	0.0	0.0	0.0	73.2	0.0
120	528	0.0	0.0	0.0	0.0	0.0	100.0	0.0

Average accuracy = 55.88%
Kappa Coefficient = 0.68076

Overall accuracy = 74.32%
Standard Deviation = 0.00672

P-MLR B 17-2 :

Code	Areas	Percent Pixels Classified by Code						
	Pixels	0	20	40	60	80	100	120
20	2370	0.0	77.1	0.0	0.0	0.0	22.9	0.0
40	4960	0.0	16.0	84.0	0.0	0.0	0.0	0.0
60	1520	0.0	0.0	0.0	100.0	0.0	0.0	0.0
80	105	0.0	0.0	0.0	0.0	0.0	36.2	63.8
100	2542	0.0	13.1	0.0	0.0	0.0	86.9	0.0
120	528	0.0	0.0	0.0	100.0	0.0	0.0	0.0

Average accuracy = 69.60%
Kappa Coefficient = 0.76968

Overall accuracy = 81.56%
Standard Deviation = 0.00573

P-MLR B 35-1 :

Areas		Percent Pixels Classified by Code						
Code	Pixels	0	20	40	60	80	100	120
20	2370	0.0	68.1	0.0	0.0	0.0	31.9	0.0
40	4960	2.0	0.0	95.5	2.6	0.0	0.0	0.0
60	1520	84.4	0.0	0.0	15.0	0.0	0.6	0.0
80	105	100.0	0.0	0.0	0.0	0.0	0.0	0.0
100	2542	0.0	0.0	0.0	0.0	0.0	100.0	0.0
120	528	0.0	0.0	0.0	74.4	0.0	2.5	23.1

Average accuracy = 60.33%

Overall accuracy = 77.53%

Kappa Coefficient = 0.72178

Standard Deviation = 0.00619

P-MLR B 35-2 :

Areas		Percent Pixels Classified by Code						
Code	Pixels	0	20	40	60	80	100	120
20	2370	0.0	73.3	0.0	0.0	0.0	26.7	0.0
40	4960	0.0	13.4	83.3	0.8	0.0	2.5	0.0
60	1520	79.4	0.0	0.0	20.6	0.0	0.0	0.0
80	105	95.2	0.0	0.0	0.0	0.0	4.8	0.0
100	2542	0.0	0.0	0.0	0.0	0.0	100.0	0.0
120	528	0.0	0.0	0.0	70.6	0.0	0.2	29.2

Average accuracy = 61.26%

Overall accuracy = 74.46%

Kappa Coefficient = 0.67671

Standard Deviation = 0.00653

P-MLR C 17-1 :

Areas		Percent Pixels Classified by Code			
Code	Pixels	0	20	40	60
20	6800	0.0	95.4	1.6	3.0
40	5050	0.0	0.0	100.0	0.0
60	948	0.0	32.9	41.8	25.3

Average accuracy = 73.59%

Overall accuracy = 92.05%

Kappa Coefficient = 0.85373

Standard Deviation = 0.00417

P-MLR C 17-2 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6800	0.0	100.0	0.0	0.0
40	5050	0.0	0.0	100.0	0.0
60	948	0.0	71.2	0.0	28.8

Average accuracy = 76.27%
Kappa Coefficient = 0.90093

Overall accuracy = 94.73%
Standard Deviation = 0.00358

P-MLR C 35-1 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6800	0.7	92.5	0.0	6.8
40	5050	0.0	0.0	100.0	0.0
60	948	1.2	1.7	0.0	97.2

Average accuracy = 96.56%
Kappa Coefficient = 0.92709

Overall accuracy = 95.81%
Standard Deviation = 0.00302

P-MLR C 35-2 :

Code	Areas	Percent Pixels Classified by Code			
	Pixels	0	20	40	60
20	6800	0.0	94.0	0.0	6.0
40	5050	11.6	0.0	88.4	0.0
60	948	0.0	0.0	0.0	100.0

Average accuracy = 94.14%
Kappa Coefficient = 0.86842

Overall accuracy = 92.25%
Standard Deviation = 0.00382

P-MLR D 17-1 :

Code	Areas	Percent Pixels Classified by Code					
	Pixels	0	20	40	60	80	100
20	5100	0.0	99.7	0.0	0.3	0.0	0.0
40	1525	0.0	0.0	100.0	0.0	0.0	0.0
60	3740	0.0	0.0	0.0	100.0	0.0	0.0
80	1007	0.0	51.5	0.0	3.1	45.4	0.0
100	465	98.5	0.0	0.0	1.5	0.0	0.0

Average accuracy = 69.03%
Kappa Coefficient = 0.87131

Overall accuracy = 91.32%
Standard Deviation = 0.00365

P-MLR D 17-2 :

Code	Areas	Percent Pixels Classified by Code					
	Pixels	0	20	40	60	80	100
20	5100	0.0	100.0	0.0	0.0	0.0	0.0
40	1525	0.0	0.0	100.0	0.0	0.0	0.0
60	3740	0.0	0.0	0.0	72.5	27.5	0.0
80	1007	0.0	43.3	0.0	0.0	56.7	0.0
100	465	26.2	0.0	0.0	0.2	0.0	73.5

Average accuracy = 80.56%
Kappa Coefficient = 0.80772

Overall accuracy = 86.60%
Standard Deviation = 0.00431

P-MLR D 35-1 :

Code	Areas	Percent Pixels Classified by Code					
	Pixels	0	20	40	60	80	100
20	5100	0.0	97.4	0.0	2.6	0.0	0.0
40	1525	12.1	0.0	87.9	0.0	0.0	0.0
60	3740	0.0	0.0	0.0	100.0	0.0	0.0
80	1007	0.0	23.0	0.0	0.0	77.0	0.0
100	465	93.3	0.0	0.0	0.0	6.7	0.0

Average accuracy = 72.45%
Kappa Coefficient = 0.87506

Overall accuracy = 91.42%
Standard Deviation = 0.00357

P-MLR D 35-2 :

Code	Areas	Percent Pixels Classified by Code					
	Pixels	0	20	40	60	80	100
20	5100	0.0	99.7	0.0	0.3	0.0	0.0
40	1525	10.5	0.0	89.5	0.0	0.0	0.0
60	3740	0.0	0.0	0.0	99.0	1.0	0.0
80	1007	0.0	0.0	0.0	6.9	93.1	0.0
100	465	78.3	0.0	0.0	0.0	21.7	0.0

Average accuracy = 76.27%
Kappa Coefficient = 0.90871

Overall accuracy = 93.69%
Standard Deviation = 0.00309

P-MLR E 17-1 :

Code	Areas	Percent Pixels Classified by Code				
	Pixels	0	20	40	60	80
20	5461	0.0	98.0	0.0	2.0	0.0
40	1319	0.2	0.0	99.6	0.0	0.2
60	1299	33.3	28.3	3.8	4.6	30.1
80	522	0.0	0.0	0.0	0.0	100.0

Average accuracy = 75.56%
Kappa Coefficient = 0.71088

Overall accuracy = 84.27%
Standard Deviation = 0.00620

P-MLR E 17-2 :

Code	Areas	Percent Pixels Classified by Code				
	Pixels	0	20	40	60	80
20	5461	0.0	88.1	0.0	11.9	0.0
40	1319	0.0	0.0	98.9	0.0	1.1
60	1299	0.0	0.0	0.4	31.3	68.3
80	522	0.0	12.5	0.0	0.0	87.5

Average accuracy = 76.46%
Kappa Coefficient = 0.67942

Overall accuracy = 81.13%
Standard Deviation = 0.00650

P-MLR E 35-1 :

Code	Areas	Percent Pixels Classified by Code				
	Pixels	0	20	40	60	80
20	5461	0.0	100.0	0.0	0.0	0.0
40	1319	59.1	0.0	40.9	0.0	0.0
60	1299	97.9	0.0	0.2	0.2	1.6
80	522	0.0	20.5	0.0	0.0	79.5

Average accuracy = 55.15%
 Kappa Coefficient = 0.55950

Overall accuracy = 74.62%
 Standard Deviation = 0.00522

P-MLR E 35-2 :

Code	Areas	Percent Pixels Classified by Code				
	Pixels	0	20	40	60	80
20	5461	1.1	98.9	0.0	0.0	0.0
40	1319	38.4	0.0	59.7	1.9	0.0
60	1299	79.7	0.3	0.3	19.7	0.0
80	522	32.4	0.0	0.0	0.0	67.6

Average accuracy = 61.47%
 Kappa Coefficient = 0.63789

Overall accuracy = 79.01%
 Standard Deviation = 0.00555

REMERCIEMENTS

François, pour m'avoir entraîné dans l'univers de la télédétection et pour tes précieux conseils qui ont su me guider à travers cette recherche. Conrad et Bob, pour votre assistance et vos commentaires très appréciés.

Langis, pour ta grande disponibilité et ton expertise qui m'ont permis de mener à bien cette recherche, et toute l'équipe Vision (Marc, Mario, Valérie) pour votre appui continu pendant mon séjour au CRIM.

Muriel, pour ta patience et ton attention constante...