

ARTICLE DE RECHERCHE

**Vers la cartographie automatisée des surfaces boisées en milieu urbanisé
fondée sur la texture d'images IKONOS panchromatiques
(le cas de la Région Métropolitaine de Montréal)**

Pierre Bugnet^{1,2}, François Cavayas¹, Langis Gagnon²

pierre_bugnet@hotmail.com, francois.cavayas@umontreal.ca, lgagnon@crim.ca

¹ Département de Géographie, Université de Montréal,
C.P. 6128, Succursale Centre-ville, Montréal (Qc) H3C 3J7

² Centre de Recherche Informatique de Montréal,
550, rue Sherbrooke Ouest, Bureau 100, Montréal (Québec), Canada H3A 1B9

RÉSUMÉ

Nous présentons les résultats d'une analyse de performance de mesures de textures du second ordre pour la segmentation des surfaces boisées à partir d'une image IKONOS panchromatique. La méthodologie suivie comprend quatre étapes : a) égalisation locale de l'histogramme de l'image, b) création d'images de texture selon la méthode d'Unser, c) classification dirigée et d) filtrage post-classification. L'expérimentation avec une image IKONOS couvrant une zone périurbaine de la Région Métropolitaine de Montréal a démontré que les quatre mesures de texture qui permettent la meilleure délimitation des surfaces boisées sont la moyenne, le contraste, la corrélation et l'écart-type, générées à partir de fenêtres de dimension entre 17x17 et 35x35 pixels, avec des pas de 1 ou 2 pixels. Le taux de détection des boisés d'une étendue minimale de 1000 m² est élevé (près de 90 %) et les confusions avec les autres classes d'occupation du sol réduites (coefficients Kappa d'environ 0.8). Bien que l'étude se concentre sur des mesures de texture du deuxième ordre, les résultats pourraient servir de base à l'établissement d'une méthode plus générique pour l'inventaire et le suivi des surfaces boisées en milieu urbain.

ABSTRACT

We present a performance analysis of second-order texture measures to automatically segment woodlands in a panchromatic IKONOS image. The methodology is divided in four steps : a) local histogram equalization of the image, b) calculation of the texture images according to the Unser's method, c) supervised classification and d) post-classification filtering. The experimentation was carried out with an IKONOS image of the Montreal suburban area and shows that the four textures which optimize the woodland segmentation are the mean, contrast, correlation and standard-deviation, calculated over a window of dimension between 17x17 and 35x35 pixels, and with a sampling step of 1 or 2 pixels. The detection rate for woodlands of at least 1000 m² is high (around 90%) along with a low confusion with the other land cover classes (Kappa coefficients around 0.8). Although the study is based only on second order texture measures, the results could serve as the basis of a more generic method for woodland inventory and monitoring in urban areas.

INTRODUCTION

Les boisés jouent un rôle de première importance dans l'équilibre écologique des milieux urbains. L'étalement constant des villes partout dans le monde et la demande résultante pour des nouvelles terres pose avec acuité les questions de la préservation et de la mise en valeur de leur patrimoine forestier. L'inventaire précis et le suivi rigoureux des boisés sont donc de mise. Dans la Région Métropolitaine de Montréal (RMM) par exemple, la plupart des boisés sont confinés à des petits territoires (Figure 1), à l'exception de ceux se situant à la périphérie (ceinture verte). Avec l'urbanisation que connaît la RMM, même cette ceinture verte est en train de subir une fragmentation inquiétante. Compte tenu de l'étendue du territoire à couvrir (quelques 4 000 km²) et du niveau de détail demandé sur les caractéristiques des peuplements, les organismes chargés de la gestion et de l'aménagement du territoire bénéficieraient grandement d'une méthode de cartographie automatisée à partir de l'imagerie de télédétection. Cette imagerie doit nécessairement être de très haute résolution spatiale (<5 m) afin de répondre aux exigences d'un tel inventaire (Neville 1992).

Les images disponibles depuis tout récemment à partir des capteurs panchromatiques et/ou multispectraux des satellites tels que IKONOS, EROS, Quickbird ou SPOT-5 constituent une alternative intéressante face à l'imagerie aéroportée, la seule pouvant répondre jusqu'à aujourd'hui aux besoins d'un inventaire détaillé des milieux boisés. Leur plus grande stabilité géométrique et radiométrique, leur acquisition fréquente à des coûts comparables ou inférieurs constituent des avantages indéniables.

Les recherches effectuées auparavant à l'aide de l'imagerie à très haute résolution ont démontré qu'il est possible à partir des mesures spectrales et spatiales de discriminer

les peuplements forestiers et de faire l'inventaire de leurs caractéristiques (essences, densité, hauteur..) d'une façon automatique, en se rendant jusqu'à l'identification de l'arbre individuel même (St-Onge et Cavayas 1997, Gougeon et al. 1999, Bouzkraoui et Beaulieu 2000, entre autres). Ces analyses ont été effectuées pour la plupart dans des territoires forestiers. Dans le cas qui nous occupe ici, avant d'arriver à l'inventaire, il y a une autre étape fondamentale, celle de la délimitation précise des surfaces boisées à travers un milieu fortement hétérogène (infrastructures, habitations, champs agricoles, friches, etc.). Cette hétérogénéité et le niveau de détail visible sur les images rendent les procédures automatiques standard, fondées uniquement sur les teintes de gris des pixels, inefficaces quant à la discrimination entre surfaces boisées et non-boisées. La prise en compte des caractéristiques de la distribution des valeurs des niveaux de gris dans le voisinage immédiat d'un pixel est indispensable. Une voie à suivre pour quantifier ces caractéristiques est celle des mesures de texture.

Depuis une trentaine d'années, de nombreux chercheurs ont exploré le potentiel de la texture pour la classification d'images optiques. Des résultats probants ont été obtenus avec des images satellitales et aéroportées de résolution spatiale allant du mètre à quelques dizaines de mètres dans divers domaines de cartographie du territoire (Marceau et al. 1990, St-Onge 1994, Solberg et al. 1996, Messier et al. 2001). Nombreuses sont les méthodes et techniques proposées dans la littérature pour mesurer la texture, notamment : les statistiques de premier ou de deuxième ordre, le spectre de Fourier, les ondelettes, le variogramme, la densité locale des arêtes, les mesures fractales, et le spectre de texture (Weszka et al. 1976, Mitchell *et al* 1977, Hlavka 1987, Atkinson et Danson, 1988, Gong et Howarth, 1990, Pratt 1991, Gong et al. 1992, Wang 1994; Parker 1997, entre autres).

Parmi ces méthodes celles utilisant diverses mesures de dispersion des valeurs de niveaux de gris dans le voisinage immédiat d'un pixel sont de loin les plus employées. Des mesures de premier ordre (variance, coefficient de variation) ou de deuxième ordre (autocorrélation, covariance, inertie...) ont été ainsi utilisées (Pratt 1991, Parker 1997). Sans contredit la méthode de Haralick et al. (1973) pour le calcul des mesures de second ordre par les matrices de cooccurrence est la méthode la plus répandue en télédétection. Les différentes mesures de texture calculées par pixel sont utilisées pour générer des « images de texture ». Ces images peuvent être par la suite classifiées par des algorithmes standard afin de discriminer les différentes occupations de sol.

L'objectif de cet article est de présenter les résultats d'une analyse de performance d'une procédure automatique de segmentation des surfaces boisées à partir seulement d'images de texture de second ordre calculées sur une image IKONOS panchromatique. Nous avons fait le choix de se restreindre à des textures dans cette étude afin de nous permettre d'identifier clairement les paramètres de classification optimaux relatif à ce type de caractéristique. Ce choix n'est pas limitatif; la procédure présentée pourrait être un élément d'une méthode plus générique pour l'inventaire et le suivi des surfaces boisées en milieu urbain.

L'expérimentation est faite avec une image IKONOS couvrant une zone périurbaine de la RMM. Les mesures de texture sont calculées avec la méthode des histogrammes de sommes et de différences de Unser (1986) et constituent la base de l'approche proposée. La méthode de Unser s'apparente à celle de Haralick et al. (1973) utilisant les matrices de cooccurrence (MCO) mais les calculs sont beaucoup plus rapides et moins exigeants en espace mémoire.

Après avoir décrit les données utilisées dans cette recherche, la démarche méthodologique suivie est présentée et justifiée. L'analyse des résultats obtenus avec certains sites d'expérimentation et la discussion sur les possibilités d'établir une procédure automatique de délimitation exacte des surfaces boisées concluent cet article.

DONNÉES ET MÉTHODE

L'image panchromatique utilisée a été acquise le 21 août 2000 par le satellite IKONOS-2 dans la région du Mont Saint-Bruno (Figure 1), avec une résolution nominale de 1 mètre, un angle de visée de 19 degrés et une échelle radiométrique de 8 bits. La bande panchromatique d'IKONOS (450 à 900 nm) comprend une partie de l'infrarouge rapproché permettant de mieux distinguer les surfaces végétalisées des surfaces d'eau comparativement aux images panchromatiques couvrant uniquement le visible (par exemple SPOT-4, IRS-1C/1D). Cinq extraits de l'image initiale comprenant des zones boisées représentatives des milieux périurbains de la RMM ont été choisis à des fins d'expérimentation (Figure 2). Les sous-images A, C et D comprennent des surfaces boisées étendues. Dans la sous-image B, tel qu'indiqué par un cadre blanc, il n'y a qu'une petite surface boisée, tandis que dans la sous-image E les boisés sont dominants. Pour des raisons d'économie d'espace, seulement la première sous-image est utilisée ici à des fins d'illustration des résultats des analyses. On réfère le lecteur à Bugnet (2002) pour plus de détails.

Pour la présente analyse, une surface boisée est définie comme étant un territoire densément couvert d'arbres matures et dont la superficie et la largeur minimales sont respectivement de 1000 m² et 30 m.

La démarche méthodologique comprenait deux étapes principales :

- a) création d'images de texture avec différents paramètres d'entrée,
- b) classification dirigée des images de ces mesures de texture et analyse des résultats obtenus afin de conclure sur les mesures de texture ainsi que les paramètres d'entrée qui optimisent la délimitation des surfaces boisés.

La méthode de calcul des mesures de texture ainsi que les étapes de l'approche méthodologique sont décrites et justifiées dans les sections suivantes.

MESURES DE TEXTURE

Haralick et al. (1973) ont proposé une série de mesures pouvant être utilisées afin de caractériser les différentes textures perceptibles sur une image. Ces mesures sont calculées à partir de la MCO dans laquelle chaque élément représente la fréquence relative d'occurrence conjointe des valeurs de paires de pixels séparés d'un vecteur de translation donnée (distance et direction d'échantillonnage spécifiques), dans un voisinage d'un pixel de l'image. En d'autres mots, la MCO est une estimation de la distribution de probabilité conjointe des valeurs de pixels selon le vecteur de translation choisi. Pour une image quantifiée en L niveaux de gris, la MCO est une matrice de $L \times L$ éléments. Une zone de texture grossière aura une MCO où la majorité des ses éléments non-nuls se trouveront concentrés autour de sa diagonale principale. À l'opposée, une zone de texture fine aura une MCO où la majorité des entrées seront non-nulles. Les mesures proposées par Haralick et ses collaborateurs indiquent a) le degré de dispersion autour de la diagonale principale de la MCO (par exemple contraste, homogénéité), b) le degré de coalescence des entrées non-nulles (par exemple entropie, énergie), c) le degré

de similarité entre les valeurs de paires de pixels observées (par exemple corrélation) ou d) la tendance centrale de la distribution des éléments (exemple moyenne, probabilité maximale). En fixant la taille du voisinage et le vecteur de translation, des « images » de ces mesures peuvent ainsi être générées en procédant pixel par pixel sur l'image d'entrée. Bien que précise, il n'en demeure pas moins que cette méthode est lente et requiert beaucoup d'espace mémoire pour être appliquée. Pour remédier à cette limitation, Unser proposa en 1986 une technique alternative beaucoup plus rapide et moins exigeante en espace mémoire pour calculer un bon nombre de mesures d'Haralick sans avoir recours aux MCO.

L'approche de Unser se base aussi sur les valeurs des paires de pixels au voisinage d'un pixel de l'image et selon un vecteur de translation spécifique. Cependant, au lieu d'une MCO, il établit deux histogrammes : l'histogramme des sommes et l'histogramme des différences des valeurs des paires de pixels. Ces histogrammes définissent les fonctions de probabilité de premier ordre suivant les axes principaux de la MCO. Utilisés conjointement, ils possèdent une capacité presque identique à la MCO pour discriminer les différentes textures d'une image. Pour une image de 256 niveaux de gris, les sommes peuvent prendre une valeur allant de 0 à 510, tandis que les différences, une valeur allant de -255 à +255. Le Tableau I présente les formules de calcul des huit mesures de texture retenues dans cette étude. La technique de Unser a été programmée en langage C en se basant sur le code proposé par Parker (1997). Ce code fut corrigé et modifié afin d'obtenir un outil adapté à nos besoins.

CRÉATION DES IMAGES DE TEXTURE

La question principale lorsque vient le temps de générer les images de texture concerne le choix de la taille f du voisinage d'un pixel ainsi que du vecteur de translation (p,d) qui optimisent la discrimination entre les différentes textures. Franklin et McDermid (1993) proposent l'utilisation des géostatistiques (portée du semi-variogramme) afin de fixer les paramètres $f-p$ dans le cas de la discrimination entre peuplements forestiers sur des images multispectrales à haute résolution. D'autres chercheurs ont proposé des valeurs qui optimisent la discrimination entre classes thématiques suite à une analyse empirique des résultats de classification d'images. À titre d'exemple, Marceau et al. (1990) ont établi de cette façon qu'une fenêtre de 15 x 15 pixels et une distance d'échantillonnage de 1 pixel optimisent la classification des occupations du sol dans le cas d'une image multispectrale à 20 m de résolution spatiale. De leur côté Messier et al. (2001) ont établi que des images de texture créées avec une fenêtre de 25x25 pixels et un pas de 1 pixel à partir d'une image IRS panchromatique (5 m de résolution) optimisent la discrimination des classes d'occupation du sol dans un milieu urbain dense. Faute de recherches dans le cas qui nous occupe ici (discrimination entre boisés et non-boisés) et tout particulièrement avec des images panchromatiques du type IKONOS, nous avons aussi opté pour l'établissement empirique des paramètres $f-p$ par analyse des résultats de classification. Le Tableau II montre les valeurs des différents paramètres utilisés dans cette étude afin de générer les images de texture. Tenant compte des 5 sous-images et des huit mesures de texture retenues, au total plus de 2000 images ont été générées à des fins d'expérimentation.

Concernant la direction d'échantillonnage, plusieurs chercheurs ont assumé l'isotropie des différentes textures et ainsi ont utilisé comme canaux d'entrée à leur

algorithme de classification, les images des moyennes des mesures de texture calculées pour les quatre directions d'échantillonnage. Il est cependant démontré que dans le cas des images à très haute résolution, les zones ombragées créées par les arbres (Figure 3), induisent une anisotropie marquée des textures des boisés particulièrement dans une direction proche à la direction d'illumination du soleil (St-Onge 1994). Dans un milieu urbanisé, les zones bâties sont aussi caractérisées par une telle anisotropie. Force est de croire que la direction d'échantillonnage dans le calcul des textures devrait tenir compte de la direction des ombres. Or, dans le cas des images IKONOS avec une direction de visée variable ceci ne s'avère pas toujours être le cas. En effet, avec une visée Est-Ouest les zones d'ombres sont passablement réduites (visée dans la même direction que le soleil) tandis qu'elles deviennent importantes pour une visée Ouest-Est (visée de la direction opposée au soleil). Dans la présente étude, nous avons ainsi choisi de moyenner les images de texture selon les quatre directions d'échantillonnage dans le but de développer une procédure simple et robuste à la plupart des conditions de prise d'images. Bien que conscient qu'un tel choix risque d'affecter les résultats, nous pensons néanmoins qu'il offre un bon compromis entre performance de classification et complexité d'implémentation pour les besoins de l'étude, à savoir l'identification des paramètres f - p optimaux pour la segmentation des boisés. Par ailleurs, une telle opération permet de réduire le nombre de canaux ce qui permet souvent d'obtenir un meilleur rendement pour un classificateur automatique (Duda et al., 2001).

Une autre question soulevée dans la littérature est la confiance statistique que l'on accorde à l'estimation de la distribution de probabilité conjointe par des MCO (ou l'équivalent par les deux histogrammes d'Unser). Comme Prat (1991) le souligne, cette

estimation est plus précise, et donc les mesures de texture plus exactes, lorsque les éléments de la MCO sont « raisonnablement » occupés. Généralement, la solution adoptée afin d'obtenir cette occupation « raisonnable » dans une MCO, est la compression de l'échelle radiométrique des images de 256 niveaux à 64, 32, 16 et même 8 niveaux. Pour éviter la perte d'exactitude des mesures de texture suite à cette compression dans le cas des textures de faible amplitude, l'égalisation de l'histogramme de l'image avant compression a été souvent appliquée (Haralick et al., 1973; Weszka et al., 1976, Unser, 1986). Dans notre cas nous avons décidé de maintenir l'échelle radiométrique telle quelle. Cependant l'idée d'égalisation l'histogramme a été retenue. En effet une telle opération réduit l'incidence des statistiques de premier ordre sur les mesures de texture (Ojala et Pietikäinen 2001). Appliquée localement, l'égalisation minimise ainsi les variations de brillance d'un bout à l'autre de l'image qui sont dues à des conditions variables d'illumination et de brume atmosphérique. Si cette décision s'avère juste, il est possible de formuler une procédure généralisable sur un ensemble d'images IKONOS sans être tenus à appliquer des corrections radiométriques pour ces effets adverses. Pour ce faire, l'égalisation a été appliquée sur une fenêtre locale de 32x32 pixels. La taille de 32 pixels a été choisi afin de s'accorder avec la largeur minimale d'une surface boisée telle qu'adoptée ici.

Après la création des images de texture en moyennant les quatre directions, les valeurs des pixels ont été normalisées à 256 niveaux de gris pour ramener leur dynamique à une même plage. La Figure 4 présente les huit images moyennes normalisées pour la sous-image A.

CLASSIFICATION ET VALIDATION

La classification dirigée par maximum de vraisemblance (MV) a été utilisée ici. Des sites d'entraînement ont été créés afin d'extraire les signatures texturales des grands ensembles d'objets visibles sur les images. À titre d'exemple pour la sous-image A, ces grands ensembles, à part les boisés, étaient : « gazon » et « îlots urbains ». Pour la sous-image B trois autres classes furent ajoutées : « agricole », « eau » et « béton » (toits des gros édifices).

Le choix de procéder à une classification binaire (boisé-non-boisé) par l'intermédiaire d'une segmentation multi-classes suivie d'un regroupement binaire améliore les performances de classification. Cette façon de faire, largement utilisée en vision artificielle, fournit une approximation simple pour résoudre un problème de séparation inter-classe non-linéaire sans le recours à un réseau de neurones ou autres techniques statistiques plus complexe. Dans les figures, nous présentons néanmoins les résultats en termes de classifications multi-classes afin de faire ressortir davantage les données intermédiaires du procédure de segmentation.

Les résultats de la classification sont évalués en confrontant les surfaces détectées comme boisées avec un masque de référence (MR) délimitant les surfaces boisées dans les images (Figure 5). Ce masque a été tracé par interprétation visuelle en rejetant les arbres isolés et les bandes boisées trop étroites. Le pourcentage des pixels du masque classifiés comme « boisés » est le taux de détection (TD) des boisés, tandis que le pourcentage des pixels hors masque assignés à la classe boisée est le taux de fausses alarmes (FA), ce dernier évaluant les erreurs de commission. Pour une validation plus poussée, nous utiliserons la matrice de confusion calculée sur des sites de validation de

chaque classe pour obtenir le taux de détection TD* par classe d'occupation du sol et le coefficient Kappa. Comme seuil acceptable d'un TD ou TD* nous prendrons 85% comme il est d'usage tandis que les FA inférieurs à 10% seront considérés acceptables. En ce qui a trait au coefficient Kappa nous considérons comme indicateur du bon comportement du classificateur, un coefficient supérieur à 0.7.

ANALYSES PRÉLIMINAIRES

Le Tableau III présente les résultats de la classification MV par rapport au MR de la sous-image A, en utilisant les 8 mesures de textures du Tableau I, avec différentes combinaisons $f-p$. Il est évident que seulement certaines combinaisons $f-p$ incluant des fenêtres de grande taille (17x17 ou 35x35 pixels) ainsi que des petits pas réduisent les confusions entre les boisés et les autres classes d'occupation du sol. Toutefois, le pourcentage de pixels non classifiés (NC) est élevé. Ces résultats montrent sans équivoque que le classificateur a de la difficulté à délimiter les boisés et que le NC est élevé particulièrement pour la combinaison $f-p$ 35-1 où il atteint 51%. Des résultats similaires ont été obtenus pour toutes les autres sous-images.

Ces résultats décevants peuvent en partie être attribués à la corrélation apparente entre les différentes mesures de texture (Figure 2). À titre d'exemple l'homogénéité est presque le « négatif » du contraste et de même entre l'entropie et l'énergie. Clausi (2002) établit à cet effet trois catégories de mesures de texture fondées sur leur inter-corrélation : a) le contraste, l'homogénéité, la dissimilarité et la différence inverse, b) l'énergie, l'entropie et la probabilité maximale, et c) la corrélation. Il proscriit alors l'emploi

simultané de plusieurs mesures de texture appartenant au même groupe dans un processus de classification texturale.

Afin d'examiner les possibilités d'améliorer les résultats de la classification en ne tenant compte qu'un nombre restreint d'images de texture, les signatures texturales des classes présentes sur les sous-images ont été soumises à un algorithme de sélection des canaux (algorithme CHNSEL de EASI/PACE) fondé sur une règle de décision de Mahalanobis. Les résultats de cet algorithme indiquent le nombre et le type de canaux qui optimisent la discrimination entre les classes. Afin d'éviter toute influence aux résultats par l'imposition de notre choix de classes, les signatures texturales furent créées comme suit. L'algorithme de classification non-dirigée K-Moyenne (algorithme KCLUS de EASI/PACE) a été appliqué sur chaque sous-image et pour chacune des combinaisons $f-p$ (Tableau II). Pour chaque classe établie par l'algorithme de K-Moyenne, le vecteur des moyennes et les matrices de variance-covariance des images de texture ont été calculées et introduit dans CHNSEL. Après plusieurs essais en faisant varier le nombre des canaux, une tendance nette a été dégagée avec quatre canaux spécifiques : la moyenne, le contraste, la corrélation et l'écart-type. Les résultats confirment en partie les conclusions de Clausi puisque le contraste et la corrélation appartiennent à deux groupes distincts de mesures de texture.

Tenant compte seulement de ces quatre images de texture, l'exercice de classification et de validation fut repris. Le Tableau IV présente le NC obtenu après classification pour l'ensemble des sous-images et des combinaisons $f-p$ étudiées. Pour la sous-image A la comparaison avec le Tableau III démontre clairement la baisse substantielle des pixels non-classifiés. Cette diminution du NC est sans doute attribuable

à la simplification des hyper-ellipses représentant les classes, désormais à quatre dimensions plutôt qu'à huit. Alors que le taux le plus élevé était de 51 % pour la sous-image A en utilisant les huit textures (Tableau III), il n'est plus ici que de 10.5 %. Il va de même pour les autres sous-images sauf que pour certaines combinaisons $f-p$, le NC demeure encore élevé dépassant les 20%. Il a alors été décidé de ne conserver que les quatre images de texture sélectionnées : moyenne, contraste, corrélation et écart-type et de procéder à de nouvelles analyses afin d'étudier les effets des paramètres $f-p$ sur les classifications.

CLASSIFICATION DES IMAGES DE TEXTURE SÉLECTIONNÉES

Le Tableau V présente les résultats de la classification par sous-image et par combinaison $f-p$ en fonction du MR avec les quatre images de texture sélectionnées. Pour la sous-image A la comparaison avec le Tableau III montre que la diminution du nombre de canaux a eu un effet bénéfique sur les TD. La même constatation peut se faire pour les autres sous-images à l'exception de la sous-image B dont les TD sont très bas toute combinaison $f-p$ confondue. La fenêtre de 5x5 pixels donne systématiquement les pires taux de détection (TD) cependant aucune combinaison $f-p$ ne se démarque nettement avec un TD qui dépasse la barre de 85%. Les meilleurs scores pour les images A et C (76% et 78% respectivement) sont atteints avec une combinaison 17-7 tandis que pour la sous-image D un TD maximal comparable (77%) est atteint avec la combinaison de 35-2 . Finalement pour la sous-image E le TD maximal est bas (65%) et est atteint avec la combinaison 17-7.

Concernant les fausses alarmes pour la sous-image A, la comparaison des Tableaux III et V montre que la diminution du nombre de canaux a causé une baisse du FA à l'exception des combinaisons incluant la plus grande fenêtre (35x35) et les plus grands pas (7, 11 et 16). Pour les autres sous-images, il y a au moins deux combinaisons f - p où le FA demeure inférieur à 10% tout particulièrement pour la sous-image E.

Tenant compte de ces résultats, il est clair qu'il n'y aucune combinaison qui se démarque avec un TD élevé, ainsi qu'un FA et un NC bas. En général les combinaisons avec grand f (35 x 35) petit p (1 ou 2) offrent un bon compromis pour les sous-images A,C,D, et E avec un TD parmi les plus élevés et un FA réduit en deçà de 10% dans presque tous les cas. Cependant le NC demeure très élevé (Tableau IV). Parmi les autres combinaisons, celles avec une fenêtre de 17x17 et un pas de 1 ou 2 donnent un TD parmi les plus élevés et un FA relativement bas aux alentours de 10% (à l'exception de la sous-image D où les FA sont de 20% environ). Le NC pour ces combinaisons est ici inférieur à 10%. Ces quatre combinaisons 17-1, 17-2, 35-1 et 35-2 ont donc été retenues pour les analyses subséquentes.

La Figure 6 montre les classifications obtenues avec ces combinaisons pour la sous-image A. Il est clair que les TD obtenus en deçà de 85% doivent être attribuées en grande partie à ce qu'on pourrait appeler l'effet de bordure. En effet, rares sont les limites des surfaces boisées détectées coïncidant exactement avec le contour du MR. 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 n'est probablement pas compatible avec celle de la classe « boisés » et ils sont alors assignés à une autre classe.

Pour un petit boisé comme dans la sous-image B (Figure 2), l'influence de cette zone d'incertitude sur l'efficacité de la détection est déterminante puisqu'elle en représente une forte proportion. Quant à la taille de la fenêtre, les résultats du Tableau V ne montrent pas d'une façon nette si le passage de la fenêtre de 17 à 35 pixels a aggravé cet effet de bordure pour l'ensemble des sous-images.

La Figure 6 nous permet aussi de constater que les FA dans le cas des combinaisons 17-1 ou 17-2, sont dus à la présence des nombreuses petites zones assignées à la classe boisée. Par contre ces petites zones sont absentes dans le cas des combinaisons 35-1 et 35-2. L'augmentation de la taille de la fenêtre de 17 à 35 a donc eu un effet bénéfique (voir aussi Tableau V). Nous pouvons en effet supposer que les signatures texturales des pixels de ces petites zones tendent à se rapprocher de celles de la classe d'occupation du sol environnante lorsque la fenêtre d'échantillonnage augmente. La même tendance s'observe pour toutes les autres sous-images et les 4 combinaison $f-p$ retenues (Tableau V). Cependant pour certaines d'entre elles le FA demeure encore élevé avec plusieurs petites zones assignées à la classe boisée. Que ces petites zones aient été classifiées ainsi par erreur, en raison d'un bruit radiométrique sur l'image initiale, ou qu'ils reflètent la réalité du terrain, on veut habituellement les ignorer pour aboutir à une image classifiée plus uniforme. Le filtre « passoire » (module SIEVE de EASI/PACE) nous permet d'éliminer dans une image classifiée les régions dont la superficie est inférieure à un seuil prédéfini en les assimilant à la région environnante la plus étendue. Dans notre cas, ce seuil a été choisi en suivant notre définition d'une surface boisée qui établit la superficie minimale à environ 1000 m². Les résultats de cette opération sont présentés à la Figure 7.

La comparaison des Figures 7 et 8 permet de constater l'effet du post-traitement : les nombreux petits agrégats de pixels, en particulier les non-classifiés, y ont disparu pour offrir des images plus homogènes correspondant mieux au niveau de détail désiré (boisé versus non-boisé). La validation des résultats de classification avec le MR montre que le filtrage a amélioré en général les différents taux. En comparant les Tableaux V et VII, nous observons une forte hausse (de 10 à 15 %) du TD, alors que le FA présente une légère tendance à la baisse. La sous-image B donne toujours des taux de détection insuffisants, mais conserve des FA acceptables. Tel qu'attendu, le filtre post-classification a eu aussi un effet sur le NC en permettant une réduction de 7% environ (Tableau IV versus Tableau VI). Toutefois, il demeure relativement élevé pour les combinaisons 35-1 et 35-2, particulièrement pour la sous-image E. Fait intéressant aussi à noter est que ce ne sont pas nécessairement les mêmes combinaisons $f-p$ avant et après filtrage qui offrent un TD maximal. Ainsi : a) pour la sous-image B avant filtrage le TD maximal est atteint avec la combinaison 35-1 (45%) et après filtrage par la combinaison 17-2 (59%), et b) pour la sous-image D avant filtrage le TD maximal est atteint avec la combinaison 35-2 (77%) et après filtrage par la combinaison 17-1 (89%). Ceci est observable aussi pour les FA et les NC. Ces résultats démontrent que le filtrage, même s'il procure une amélioration générale, agit d'une façon non prévisible pour une combinaison $f-p$ spécifique. L'exemple tiré des Figures 6 et 7 le montre clairement. Dans la Figure 6, à l'intérieur de la zone indiquée par un carré blanc, nous observons un petit polygone correctement assigné à la classe boisé. Dans le cas de la combinaison 17-1, le classificateur a mal classifié les pixels reliant ce petit polygone avec le grand polygone boisé adjacent. Pour la combinaison 17-2, le classificateur a par contre réussi à relier ces

deux polygones. Ainsi après filtrage (Figure 7) le petit polygone boisé a disparu pour la combinaison 17-1 au profit du polygone plus massif « îlot urbain » faute de pixels de liaison avec le grand polygone boisé. Ceci n'est pas le cas avec la combinaison 17-2 où le petit polygone boisé est demeuré intact après filtrage, grâce à sa liaison (même si c'est d'un seul pixel) avec le grand polygone boisé.

En conclusion, les résultats de validation montrent que le classificateur appliqué aux combinaisons $f-p$ choisies permet d'approcher dans la majorité des cas des scores acceptables. Cependant son manque d'exactitude proche des frontières des zones boisées pose un problème sérieux. Le filtrage post-classification aide à dépasser certains autres problèmes liés au classificateur (pixels non classifiés, fausses alarmes, confusions inter-classes) mais il ne peut pas corriger cet effet de bordure. Pour mieux circonscrire les limitations du classificateur, une deuxième série de tests a été effectuée à l'aide de sites de validation. Les résultats de ces tests sont présentés et analysés dans la suite.

ANALYSE DU POTENTIEL DU CLASSIFICATEUR MV

Les sites de validation ont été soigneusement sélectionnés à l'intérieur des zones des différentes classes d'occupation du sol, afin de minimiser l'influence de l'effet de bordure dans le calcul des TD*. Les matrices de confusion nous procurent un taux de détection spécifique pour chacune des classes mais seulement les TD* concernant la « classe » boisée sont présentés ici. Le Tableau VIII nous montre les TD* obtenus à partir des quatre images de texture sélectionnées sans aucun post-traitement. Il est évident que si les boisés sont de grande étendue avec des arbres de taille plus ou moins uniforme (sous-images A, C, D), il existe au moins une combinaison $f-p$ permettant d'atteindre un

TD* dépassant 85%. Lorsque le boisé couvre une petite étendue (cas de la sous-image B) le classificateur n'est plus efficace. La sous-image E est un autre exemple intéressant car même si les boisés sont dominants, les arbres ne sont pas d'une taille uniforme. Ici aussi le classificateur a une certaine difficulté à bien classifier les boisés. En effet juste pour une combinaison (35-1) le TD* atteint la barre de 85%.

Concernant la capacité du classificateur à discriminer entre les différentes occupations des sols, le Tableau IX montre qu'à l'exception des images A et D, des confusions importantes inter-classes sont présentes (coefficient kappa < 0.7).

Des tests ont été aussi effectués après filtrage post-classification (Tableaux X et XI). L'élimination des petites zones non classifiées ou assignées à une autre classe que la classe majoritaire environnante, améliore substantiellement les résultats de la classification lorsque ces classes sont étendues et dont la plupart de pixels ont été correctement assignés par le classificateur. Ainsi les TD* des boisés pour toutes les sous-images sauf la sous-image B atteignent un score parfait ou presque. Ceci se reflète aussi dans les coefficients Kappa. Mais même pour la sous-image B les scores obtenus sont relativement intéressants avec plus de 75% de pixels bien assignés et une réduction de la confusion inter-classes pour au moins deux des combinaisons *f-p* (Tableau XI). Bien qu'après filtrage aucune combinaison *f-p* ne se démarque nettement, la combinaison 35-2 semble être un bon compromis pour l'ensemble des boisés analysés.

En guise de conclusion, le classificateur MV avec le post-traitement appliqué sur des images de texture sélectionnées, créées avec une grande fenêtre de l'ordre de 35x35 pixels avec un pas de l'ordre de 2, peut constituer la base pour nous permettre d'extraire

avec suffisamment de confiance des « noyaux » des surfaces boisées et ce à travers un milieu hautement hétérogène.

DISCUSSION

Tel que montré par les résultats obtenus que ce soit par rapport au MR ou aux sites de validation, il est possible de localiser automatiquement les surfaces boisées en procédant comme suit (Figure 8) : a) égalisation locale de l'histogramme de l'image panchromatique, b) création des images de texture : moyenne, contraste, corrélation et écart-type en fixant une grande fenêtre et un petit pas, c) prise de la moyenne des images de texture créées dans les quatre directions disponibles, d) choix des sites représentatifs des grandes classes d'occupation du sol pour l'entraînement d'un classificateur et classification des images moyennes de texture, et e) filtrage post-classification. Les boisés sont localisés avec grande exactitude lorsqu'elles couvrent des surfaces étendues et incluent des arbres de taille plus ou moins uniforme. Cette exactitude diminue cependant en deçà d'un seuil d'acceptabilité dans certains cas. Les expériences ici ont montré que ceci arrive a) aux frontières des surfaces boisées étendues, b) lorsque les surfaces boisées sont de faible étendue et couvertes des grands arbres; et c) lorsque les arbres à l'intérieur des boisés plus ou moins étendues sont de taille variable. À la lumière de notre expérience les effets probables de chacune des étapes de cette procédure sur les résultats seront analysées et des orientations de recherche seront identifiées afin d'arriver à améliorer la procédure dans ces cas problématiques.

Tout au long de cette étude, et contrairement à la plupart des études précédentes, les images de texture ont été calculées en maintenant l'échelle radiométrique de l'image

panchromatique à 256 niveaux de gris. Il est difficile de départager le pour et le contre de cette décision car une foule d'autres paramètres et traitements peuvent avoir influencé les résultats de la classification. Seule une répétition de l'expérience avec différents taux de compression de l'histogramme de l'image originale aurait pu nous le démontrer. Cependant il est possible que les mesures de textures et les paramètres $f-p$ retenus ici ne soient plus les meilleurs avec des images dont l'histogramme a été compressé.

D'autre part, la pertinence de l'égalisation locale d'histogramme a été analysée, étant donné que cette opération semblait engendrer une certaine confusion entre des classes initialement distinctes. Une telle opération peut aussi avoir un effet sur le potentiel discriminatoire de certaines mesures de texture. En effet, l'énergie et l'entropie dépendent du degré d'uniformité des histogrammes des sommes et des différences (Tableau I), qui est théoriquement maximisée par l'égalisation d'histogramme d'une portion de l'image à l'autre. Toutefois, la reprise complète du processus de détection à partir des sous-images non-égalisées n'a pas fourni des résultats plus intéressants qu'avec des images égalisées, surtout pour le NC qui atteignait des taux bien au-delà des taux rapportés dans la section précédente. L'égalisation locale de l'histogramme est donc proposée ici comme une étape de base d'une procédure générale de délimitation des surfaces boisées sur des images IKONOS panchromatiques.

Le choix des paramètres servant à la création des images de texture a commencé par la fixation du d , en prenant la moyenne des quatre images directionnelles. Ce qui a motivé cette décision était d'aboutir à un détecteur de boisés plus robuste aux variations de la direction d'éclairement solaire et de visée. Toutefois, l'expérimentation avec des

images acquises sous différentes conditions est nécessaire afin d'établir les limites de validité de cette opération.

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 (Tableau II), ce qui a permis d'en arriver à des conclusions intéressantes. D'une part, les combinaisons ayant un p élevé (7, 11 et 16) sont à éviter puisqu'elles engendrent des FA inacceptables même si dans plusieurs cas elles maximisent le TD (Tableau V). En règle générale, ce sont les p de 1 et 2 qui permettent d'atteindre des TD parmi les plus élevés tout en diminuant les FA en deçà de 10%. Ceci est assurément dû à leur capacité accrue de 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 IKONOS panchromatiques, d'où la nécessité d'opérer à une échelle des plus réduites pour l'échantillonnage des paires de pixels. D'autre part, les combinaisons ayant un petit f (5-1 et 5-2) ont été délaissées car elles produisaient des TD 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 bien capter la périodicité de la texture du boisé (i.e. l'alternance brillant (partie éclairée)-sombre (partie ombragée) des arbres composants les boisés). La taille de la fenêtre d'échantillonnage optimale est donc forcément égale ou supérieure au diamètre d'un arbre. Parmi les deux f retenus (17 et 35), aucun ne se démarque comme étant le meilleur. Avant post-traitement la fenêtre de 35x35 pixels montre une supériorité avec des FA réduits (Tableau V). Après post-traitement, un $f=17$ maximise les TD pour toutes les sous-images examinées. Il se pourrait donc qu'il existe

une taille optimale de fenêtre d'échantillonnage située entre 17 et 35. Seule une étude encore plus exhaustive que la présente, permettrait de le déterminer avec certitude.

Il y a cependant un prix à payer pour l'emploi de grandes fenêtres : l'effet de bordure. Cet effet, comme il l'a été démontré, pose un problème important au classificateur. Dans la plupart des cas, un filtrage post-classification peut résoudre le problème des petites zones des pixels non-classifiés ou mal-assignés par le classificateur mais il n'apporte pas une solution viable au problème des bordures. Nous croyons qu'un classificateur plus souple comme un réseau de neurones peut constituer une solution viable pour mieux tenir compte de la variabilité inhérente de la texture des boisés composées des arbres de forme et de taille différentes. Cependant, le problème de bordure demande selon nous une autre approche. Nous pouvons par exemple considérer les pixels assignés à la classe boisée comme des « germes » d'un algorithme de croissance de région. En partant de ces germes et en se servant d'une des images de texture (par exemple, le contraste), nous pourrions chercher de proche en proche à étendre les surfaces boisées jusqu'à ce qu'une variation significative de la mesure de texture choisie soit repérée.

CONCLUSIONS

Les résultats obtenus démontrent que la méthode établie dans cette étude peut constituer la base pour une délimitation automatique des surfaces boisées dans un milieu fortement hétérogène qu'est le milieu urbain. La texture constitue effectivement un bon moyen pour généraliser le niveau du détail élevé d'une image panchromatique à très haute résolution et discriminer entre classes thématiques aussi générales que surfaces

boisées ou îlots urbains. Des améliorations du rendement de la l'approche proposée sont possibles afin de minimiser certaines erreurs de délimitation aux frontières de boisées ainsi que pour des surfaces boisées fortement hétérogènes. La simplicité et la rapidité de l'approche proposée ici lui confèrent un intérêt non-négligeable pour la délimitation automatisée des surfaces boisées. Bien que fondée sur l'imagerie IKONOS, l'approche peut certainement être étendue à d'autres images à très haute résolution spatiale dont la bande panchromatique englobe le proche infrarouge, comme celles provenant du satellite Quickbird.

REMERCIEMENTS

Les auteurs remercient le Conseil de Recherches en Sciences Naturelles et Génie (CRSNG) du Canada, le Fonds Nature et Technologie (NATEC) du Gouvernement du Québec ainsi que le CRIM pour leur support financier. Les auteurs sont aussi redevables aux arbitres pour leurs commentaires pertinents.

BIBLIOGRAPHIE

Atkinson, P.M., Danson, F.M. 1988. Spatial resolution for remote sensing of forest plantations. In *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. In *Actes-Vision Interface 2000*, Association Canadienne de Traitement d'Images et Reconnaissance de Formes, pp.311-317.

Bugnet, P. 2002, Cartographie automatisée des surfaces boisées en milieu urbanisé fondée sur la texture d'images IKONOS panchromatiques, Mémoire de M.Sc., Département de Géographie, Faculté d'Arts et Sciences Université de Montréal

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.

Duda, R.O., Hart, P.E., Stork, D.G. 2001. *Pattern classification*. 2nd Edition., John Wiley & Sons, Inc. 654 pages.

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

Gougeon, F.A., Leckie D, Scott, I., Paradine, D., 1999. Individual tree crown species recognition: the Nahmint study, *Proceeding International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry*, Hill D.A. and Leckie D.G., eds, Victoria, BC, February 10-12 1998, pp. 209-223.

Gong, P., Howarth, P. 1990. The use of structural information for improving land-cover classification accuracies at the rural-urban fring, *Phot. Eng. Rem. Sens.*, **56**, pp. 67-73.

Franklin, S. E., G. J. McDermid, 1993. Empirical relations between digital SPOT HRV and CASI spectral response and lodgepole pine (*Pinus contorta*) forest stand parameters. *Int. J. Remote Sensing*. **14**, 12. pp. 2331-2348.

Gong, P., D. Marceau, D. , Howarth, P. J., 1992. A comparison of spatial texture extraction algorithms for land-use classification with SPOT HRV data. *Rem. Sens. Environ.* **40**, pp. 137-151.

Guindon, B. 2000. A framework for the development and assessment of object recognition modules from high-resolution satellite images. *Journal Canadien de Télédétection*, 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.

Hlavka, C. A. 1987. Land-use mapping using edge density texture measures on TM simulator data, *IEEE Trans. Geosc. Rem. Sens.*, GE **25**, pp. 104-107.

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*, Vol.22, No.2, pp.113-120.

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 des occupations du sol en milieu urbain, à partir d'images satellites de haute résolution spatiale : le cas de Beijing. *Actes du 23^e symposium canadien sur la télédétection*, 21-24 août 2001, Ste-Foy, Québec, pp. 829-834

Mitchell, O. R., Meyers, C. R., Boyne, W. A. 1977, A Max-Min Measure for Image Texture Analysis, *IEEE Transactions on Computers*, Vol. C-26, pp. 408-414

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. and Gillis M.D. (Eds), Val Morin, Québec, pp. 22-30.

Ojala, T. et Pietikäinen, M. 2001. Texture classification. In: *CVonline—Compendium of Computer Vision*, Fisher, R.B. (ed),

Disponible au <www.dai.ed.ac.uk/cvonline/local_copies/ojala1/texclas.htm> [2002]

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

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

Pratt, W.K , 1991. *Digital Image Processing*. 2nd Edition, Wiley & Sons

Solberg, R., Solberg, A.H.S., Koren, H., Aas, K. 1996. The suitability of future high-resolution satellite imagery for forest inventory. In *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, Département de géographie, Université de Montréal*

St-Onge B., Cavayas F. 1997. Automated Forest Structure Mapping from high resolution imagery based on directional semivariogram estimates. *Remote Sensing of Environment*, 61: pp. 82-95.

Unser, M. 1986. Sum and difference histograms for texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 8, pp.118-125.

Wang L., He, D. C. 1990. A new statistical approach for texture analysis, *Phot. Eng. Rem. Sens.*, **56**, pp. 61-66.

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.

LISTE DES SYMBOLES ET ACRONYMES

- f : Largeur de la fenêtre de calcul des textures
- FA : Pourcentage de pixels détectés comme « boisé » sur l'ensemble du segment « non-boisé » (Fausses alarmes)
- MCO : Matrice de co-occurrence
- MR : Masque de référence des boisés dans les images
- MV : Maximum de vraisemblance
- NC : Pourcentage de pixels non-classifiés sur l'ensemble des segments « boisé » et « non-boisé »
- p : Distance d'échantillonnage entre 2 pixels sélectionnés à l'intérieur de la fenêtre de texture (Pas)
- RMM : Région métropolitaine de Montréal
- TD : Pourcentage de pixels détectés comme « boisé » sur l'ensemble du segment « boisé » (Taux de détection)
- TD* : Pourcentage de pixels détectés comme « boisé » sur les sites de test de type « boisé » (Taux de détection *)

FIGURES



Figure 1: Image Landsat-7 ETM4 de la RMM. L'absence des surfaces boisées étendues dans l'île de Montréal (peu de zones brillantes) et la « ceinture verte » (zone boisée quasi-continue dans les banlieues autour de l'île) sont apparentes (surfaces brillantes). La barre blanche mesure 10 km. Le carré montre la région de l'image IKONOS utilisée pour cette étude.



Figure 2: Les 5 sous-images 512×512 pixels tirées de l'image IKONOS panchromatique. Première rangée : sous-images A et B; deuxième rangée : sous-images C et D; troisième rangée : sous-image E.




Figure 3: Exemple d'anisotropie de texture créée par les ombres projetés par des arbres (agrandissement de l'image IKONOS panchromatique)




Figure 4: Exemples d'images de texture du second ordre du Tableau I pour la sous-image A, moyennées selon les 4 directions avec la combinaison $f-p$ de 5-1. Première rangée : moyenne, contraste, corrélation; deuxième rangée : énergie, entropie, homogénéité; troisième rangée : probabilité maximum, écart-type.



Figure 5: Contours du MR pour les surfaces boisées de la sous-image A.




Figure 6: Résultat de la classification par MV à partir des 4 textures optimales pour la sous-image A avant post-traitement. En haut : combinaisons $f-p$ de 17-1 et 17-2. En bas : combinaisons 35-1 et 35-2. Les classes « boisés », « gazon » et « îlots urbains » sont respectivement en vert foncé, vert pâle et gris. Les pixels non-classifiés sont en noir.




Figure 7: Identique à la Figure 6 mais après application du filtre morphologique de post-traitement.




Figure 8 : Organigramme de la méthodologie utilisée dans cette étude. Les cases ovales représentent des opérations; les cases rectangulaires, des résultats.

TABLEAUX

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	$-\sum_i (\hat{P}_s(i) \cdot \log(\hat{P}_s(i))) - \sum_j (\hat{P}_d(j) \cdot \log(\hat{P}_d(j)))$
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 I: Formules de Unser pour les huit mesures de texture retenues. $\hat{P}_s(i)$ est la valeur à l'indice i de l'histogramme de fréquences relatives des sommes. $\hat{P}_d(j)$ est l'indice j de l'histogramme de fréquences relatives des différences.

Dimensions f de la fenêtres d'échantillonnage	Pas d'échantillonnage p	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 II: Paramètres utilisés pour la création des images de textures

	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 III: Performance (en %) de la classification MV sur la sous-image A à partir des

8 textures du Tableau I pour différentes combinaisons f - p . Les chiffres en caractère gras représentent les meilleurs résultats.

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

Tableau IV: Pourcentage de pixels non-classifiés (NC) lors de la classifications MV à

partir des quatre textures optimales pour différentes combinaisons $f-p$. Les NC

acceptables sont en caractère gras.

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

Tableau V: Résultats des TD et FA (en %) de la classification MV à partir des quatre textures optimales pour différentes combinaisons $f-p$. En caractère gras les TD ou FA acceptables.

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

Tableau VI: Résultat des NC (en %) de les classifications MV à partir des quatre textures optimales après post-traitement. En caractère gras les NC acceptables.

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

Tableau VII: Résultats des TD et FA (en %) de la classification MV à partir des quatre textures optimales après post-traitement. En caractère gras les TD ou FA acceptables

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

Tableau VIII: Résultats des TD* pour la classification MV à partir des quatre textures optimales avant post-traitement. En caractère gras les TD* acceptables.

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

Tableau IX: Coefficients Kappa pour la classification dirigée à partir des quatre textures optimales avant post-traitement. En caractère gras les Kappa acceptables

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

Tableau X: Résultats des TD* pour la classification MV à partir des quatre textures

optimales après post-traitement. En caractère gras les TD * acceptables.

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

Tableau XI: Coefficients Kappa pour la classification dirigée à partir des quatre textures optimales après post-traitement. En caractère gras les Kappa acceptables.