AMÉLIORATION DE LA QUALITÉ DE LA CLASSIFICATION D'UNE IMAGE MULTISPECTRALE À L'AIDE D'UN CLASSIFICATEUR CONTEXTUEL

Solofoarisoa RAKOTONIAINA[1*], Claude COLLET[2]

[1] *Laboratoire de Géophysique de l'Environnement et Télédétection, Institut et Observatoire de Géophysique d'Antananarivo (IOGA), Université d'Antananarivo, B.P. 3843, Antananarivo 101, Madagascar.*
Courriel : solofoarisoa@gmail.com
[2] *Département de Géosciences, Géographie, Université de Fribourg, Ch. du Musée 4, CH-1700 Fribourg, Suisse.*
Courriel : claude.collet@unifr.ch

Soumis le 6 février 2009; accepté le 6 décembre 2010 - © *Revue Télédétection*, 2010, vol. 9, n° 3-4, p. 259-270

Résumé

L'objectif de cette étude est de comparer la précision et la qualité de classification entre d'une part un classificateur conventionnel pour une approche pixel, le maximum de vraisemblance (MDV) et d'autre part un classificateur contextuel utilisant l'algorithme ICM (Iterated Conditional Modes) qui a été initialisé par une image classifiée à l'aide du classificateur non paramétrique kNN (k nearest neighbour). Pour illustrer notre étude, nous avons considéré une image multispectrale de SPOT dans les bandes verte, rouge et proche infrarouge de la région de Genève, en Suisse, acquise en juillet 1990. La taille de l'image est de 512 x 512 pixels. Le site d'étude est une zone mixte comportant aussi bien un tissu urbain important que des zones de végétation. La vérité-terrain est constituée d'un document cartographique couvrant une grande partie du site d'étude, numérisé à une résolution spatiale de 1 m. On a considéré 9 catégories: eau du lac, cultures, espaces vertes, forêts, eau du Rhône, bâtiments, édifices importants, eau de l'Arve et voirie (aéroport et routes).

Pour réaliser la comparaison des deux méthodes, nous avons choisi une délimitation par région à partir de la vérité-terrain pour l'extraction de l'ensemble des zones d'entraînement et de validation. Ensuite, nous avons effectué un échantillonnage aléatoire sur cet ensemble pour obtenir d'une part les zones d'entraînement et d'autre part les zones de validation. Elles représentent alors respectivement 0,94% et 1,87% de la totalité des pixels de la région d'étude.

Les conclusions suivantes ont pu être tirées de ce travail : (i) la précision globale de classification obtenue à l'aide de la méthode ICM est plus élevée par rapport à celle de MDV : elles sont respectivement égales à 96,50% et 89,75% pour ICM et MDV ; (ii) la classification contextuelle permet d'obtenir une plus grande précision et un faible mitage, particulièrement pour les zones homogènes telles que les cultures, les espaces verts et les forêts.

Mots-clés : télédétection, classification d'image, contexte, ICM, kNN, qualité

Abstract

The aim of this study is to compare the classification accuracy and quality obtained from a conventional pixel-based classifier such as the maximum likelihood and from a contextual classifier using the ICM (Iterated Conditional Modes) algorithm which is initialised by an image classified from a nonparametric classifier kNN (k nearest neighbour). Our study uses for illustration, a SPOT multispectral image with the green, red and near- infrared spectral bands covering the region of Geneva in Switzerland. The image was acquired in July 1990 and has a size of 512 x 512 pixels. The study area is heterogeneous which includes mainly urban, water and vegetation areas. The ground truth is derived from a map document covering the study site and digitized with a spatial resolution of 1 m. Nine land cover categories were considered: lake, culture, green area, forest, the Rhône river, building, large edifice, the Arve river and parts of the airport and roads. The comparison of the two methods was realised by selecting compact areas from the ground truth image for obtaining the training and test sites. Then the two samples of training and the test sites were separately and randomly extracted from these compact areas. They represent 0.94% and 1.87% of all pixels in the study area respectively.

The following conclusions drawn from this work are: (i) the overall accuracy of the classification obtained with the ICM method is greater than from the MDV: it is equal to 96.50% and 89.75% for ICM an MDV respectively; (ii) the contextual classification permits to obtain more classification accuracy particularly for homogeneous sites like culture, green area and forest.

Keywords : quality, contextual classifier, kNN, ICM

1. INTRODUCTION

Dans le cadre d'une approche de classification par pixel, par opposition à celle par segmentation ou par objet (Caloz et Collet, 2001), il est généralement admis que la prise en compte de la dimension géométrique, notamment le contexte ou voisinage, contribue aux performances de la classification. Ce constat a conduit à différents développements destinés à combiner ces deux dimensions dans le processus de classification : celui de démarches de classification hybride contextuelle et celui de méthodes de classification contextuelle. La démarche hybride contextuelle est fondamentalement basée sur la dimension thématique de luminance de l'image multispectrale, mais soit elle propose une seconde étape de post-traitement contextuel en aval de celle de classification thématique, soit elle ajoute aux données spectrales des différents canaux une information de texture. On retrouve dans la littérature des exemples de ces deux types de démarche hybride contextuelle : par l'emploi d'un classificateur thématique suivi d'un lissage contextuel (Kim, 1996), par classificateur thématique utilisant les bandes spectrales (BS) de l'image avec injection de canaux de texture (Franklin et Peddle, 1990 ; Gong *et al*, 1992 ; He et Collet, 1999 ; Shaban et Dikshit, 2001).

Cette première forme de prise en compte de la dimension géométrique souffre cependant d'une faiblesse, tout au moins conceptuelle, celle de faire toujours appel à un classificateur uniquement thématique, semblable à ceux développés dans l'approche pixel. Le développement plus récent de classificateurs contextuels vise donc à éliminer cette faiblesse en combinant simultanément les règles de ressemblance thématique et de proximité spatiale dans le processus de classification. La méthode ICM élaborée et publiée par Besag en 1986 en est une représentante.

Les objectifs de cette étude sont de comparer la précision et la qualité de classification entre d'une part un classificateur conventionnel, le maximum de vraisemblance (MDV) et d'autre part un classificateur hybride contextuel et un classificateur contextuel utilisant l'algorithme ICM (*Iterated Conditional Modes*) qui a été initialisé par une image classifiée avec le classificateur non paramétrique kNN (*k nearest neighbour*). Notre hypothèse de travail est que les méthodes spatiales de classification, combinant la prise en compte de la dimension thématique (valeurs de luminance) et de la dimension géométrique (position relative, voisinage) de l'image de télédétection offrent potentiellement une capacité discriminante plus forte. Ainsi, notre objectif principal est de comparer les performances d'une démarche de classification classique (approche pixel) dont la procédure est principalement basée sur la dimension thématique avec celles d'une démarche de classification contextuelle, intégrant simultanément les deux dimensions thématique et géométrique. Dans le cadre de cette comparaison, nous évaluons aussi la démarche contextuelle hybride qui consiste à faire suivre l'étape de classification thématique d'une phase de lissage contextuel, ou alors qui inclut dans l'étape de classification une composante texturale produite par une transformation contextuelle.

2. MATÉRIEL ET MÉTHODES

Données utilisées

Pour illustrer notre étude, nous avons considéré une image multispectrale de SPOT dans les bandes verte, rouge et proche infrarouge de la région de Genève, en Suisse, acquise en juillet 1990 (figure 1) pour laquelle nous possédons des informations de validation (image de vérité-terrain) fiables. La taille de l'image est de 512 x 512 pixels. Le site d'étude est une zone mixte comportant aussi bien un tissu urbain important que des zones de végétation. La vérité-terrain est issue d'un document cartographique numérisé couvrant une grande partie du site d'étude, dont la résolution spatiale originale est de 1 m. Par une procédure d'agrégation modale, cette résolution originale à été réduite à celle de 20 m de l'image SPOT multispectrale à traiter. Neuf catégories d'occupation du sol ont été retenues: eau du lac, cultures, espaces vertes, forêts, eau du Rhône, bâtiments, édifices importants, eau de l'Arve et voirie (aéroport et routes).

Pour réaliser la comparaison des deux méthodes, afin de nous mettre dans des conditions d'analyse habituelles, nous avons choisi une délimitation par région à partir de la vérité-terrain pour l'extraction de l'ensemble des zones d'entraînement et de validation (figure 2). Nous avons ensuite effectué un échantillonnage aléatoire sur cet ensemble pour obtenir d'une part les zones d'entraînement et d'autre part les zones de validation (échantillonnage dénommé par la suite contigu-aléatoire : TCA). Cette méthode d'échantillonnage stratifié a été inspirée des travaux de Stehman

(1999). Les zones d'entraînement et les zones de validation représentent alors respectivement 0,94% et 1,87% de la totalité des pixels de la région d'étude (tableau 1).

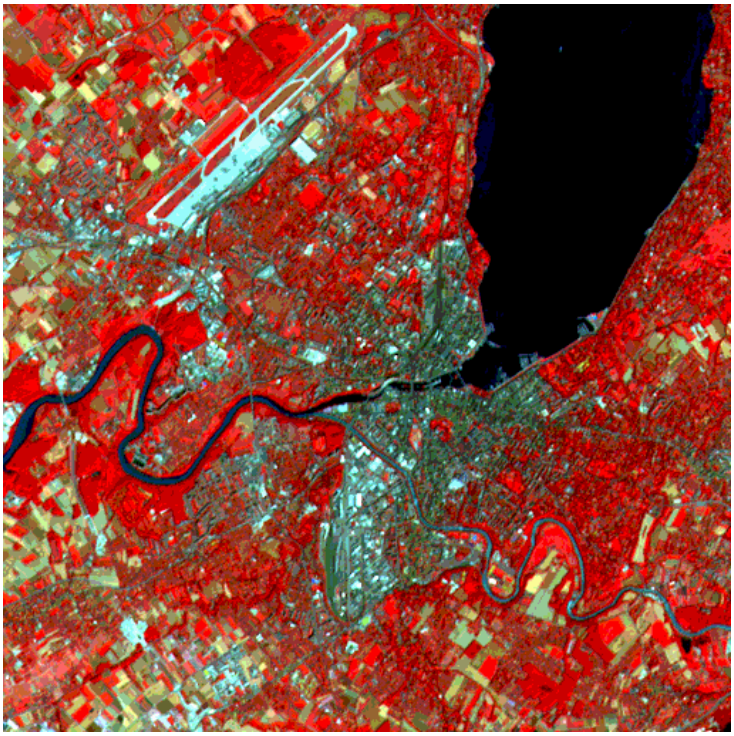


Figure 1 : Composition colorée de l'image HRV-XS de SPOT de la région de Genève (Rouge : XS3, Vert : XS2, Bleu : XS1)
Colour composition of the SPOT HRV-XS image covering the region of Geneva (Red: XS3, Green: XS2, Blue: XS1)

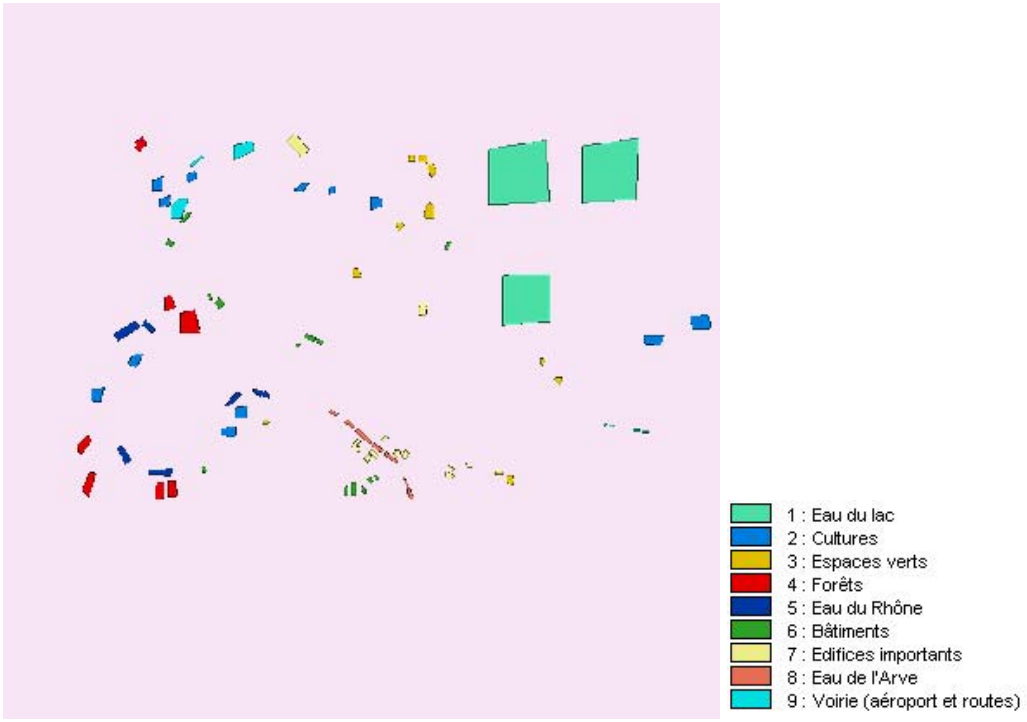


Figure 2 : Ensemble des zones d'entraînement et des zones de validation
Location of training and test sites

Tableau 1 : Taille en pixels des zones d'entraînement (ze) et des zones de validation (zt)
Number of pixels of training sites (ze) and test sites (zt)

Id	Classes	ze	zt
1	Eau du lac	1541	3041
2	Cultures	234	475
3	Espaces verts	97	175
4	Forêts	196	362
5	Eau du Rhône	108	229
6	Bâtiments	66	142
7	Edifices importants	107	199
8	Eau de l'Arve	34	106
9	Voirie (aéroport et routes)	90	187
	Total	*2473*	*4916*
	Pourcentage	*0,94 %*	*1,87 %*

Méthodes

D'après ce qui a été décrit dans la partie Introduction, nous nous proposons donc d'expérimenter et d'évaluer la qualité de classification produite par des représentants de ces trois approches :

- *pour l'approche pixel*, la méthode paramétrique du maximum de ressemblance (MDV) et celle non paramétrique des k plus proches voisins (kNN) ;

- *pour la démarche hybride contextuelle*, celle faisant appel aux deux étapes successives utilisant les classificateurs thématiques MDV et kNN et le lisseur contextuel de filtre modal de taille 3x3 (MF3), approches appelées respectivement par la suite MDV-MF3 et kNN-MF3 ; ainsi que celle proposant l'injection, lors de la classification d'images, d'une information contextuelle (approche pixel + texture), l'indice d'entropie calculée pour la bande spectrale IR (XS3) de l'image multispectrale avec une fenêtre de taille 5x5 (ENT5), approche appelée par la suite (BS+ENT5) ;

- *pour l'approche contextuelle*, la méthode markovienne utilisant l'algorithme ICM de Besag dont l'image d'initialisation a été produite par le classificateur MDV et kNN.

La description plus détaillée des méthodes de classification mises en œuvre ne concerne que celles moins connues et usitées : kNN et ICM. Nous présentons aussi brièvement la distance de Jeffries-Matusita utilisée comme mesure de séparabilité spectrale des classes.

2.2.1. Méthode kNN

La méthode de classification kNN est une méthode de classification supervisée non paramétrique c'est-à-dire qu'elle ne prend pas en compte la nature de la distribution des classes étudiées (gaussienne ou non par exemple). Sa théorie a été introduite pour la première fois en 1967 par Cover et Hart. Son principe est assez simple, mais sa mise en œuvre exige des ressources informatiques élevées. Elle assigne un pixel inconnu x à la classe C_i si la classe majoritaire dans les k voisins les plus proches de x est la classe C_i. La recherche qui s'effectue sur tous les pixels appartenant aux zones d'entraînement utilise la notion de distance spectrale. Dans notre cas, nous avons utilisé la distance classique, la distance euclidienne. Tintrup *et al*. (1998) et Pal *et al*. (2001) ont choisi la valeur optimale donnée au paramètre k égale à $\sqrt{N}$ (racine carrée du nombre total de pixels des zones d'entraînement). Dans notre cas, après expérimentations, en faisant varier la valeur de k, nous avons trouvé que, dans notre cas d'application, la meilleure qualité de classification a été obtenue pour une valeur de k égale à 5 et non pas 50 comme suggéré par ces deux auteurs.

2.2.2. Méthode ICM

La classification contextuelle adoptée ici est celle utilisant l'algorithme ICM (Besag, 1986). C'est une méthode qui, lors de la classification d'un pixel, prend en compte non seulement les valeurs radiométriques de celui-ci mais aussi celles des classes des pixels appartenant à son voisinage, d'où l'appellation de classification contextuelle. On dit que la méthode est de type markovien. Le principe de cette méthode a été décrit par Fau *et al*. (1993) et par Simonetto (1997). Nous en donnerons ci-après une description brève (Rakotomanana *et al*. 2006).

Une image est modélisée par deux champs aléatoires : $X=(X_S)_{S\in S}$ le champ des classes et $Y=(Y_S)_{S\in S}$, celui des observations, où S représente l'ensemble des pixels de l'image. Pour tout s appartenant à S, X_S prend ses valeurs dans

un espace fini Ω, où Ω représente l'ensemble des valeurs des K classes présentes sur l'image, et Y_S dans l'ensemble des réels R. Les réalisations de X sont inobservables et le but de la classification est d'estimer X=x à partir de l'observation Y=y. La stratégie consiste à utiliser le critère du MAP (*Maximum A Posteriori*) pour évaluer une estimation de x. Celle-ci sera alors donnée par la valeur qui maximise la probabilité *a posteriori* :

$$\hat{x} = \arg\max_{x \in X} P(X = x / Y = y)$$

Toutefois, les solutions des méthodes bayésiennes ne sont pas calculables directement et des procédures d'approximation sont alors nécessaires. L'algorithme ICM de Besag (1986) est une des méthodes pour trouver la solution approchée du MAP. Selon cette méthode, le champ des classes X est supposé markovien, c'est-à-dire que la probabilité de chaque pixel individuel s ne dépend que de son voisinage. De plus ce champ de classes suit une distribution de Gibbs. La probabilité *a priori* de X peut alors s'écrire :

$$P(X = x) = \frac{1}{Z} e^{-U_2(x)} \quad \text{avec}$$

$$U_2(x) = \sum_{c \in C} \varphi_c(x)$$

U_2 étant la fonction d'énergie de Gibbs, Z est une constante de normalisation, C l'ensemble des cliques c engendrées par le voisinage V_S, et les fonctions φ_c désignant les fonctions potentielles associées aux cliques c (ensemble des pixels voisins) de C. Le modèle du voisinage utilisé est donné à la figure 3 (Kato, 1994) où seules les cliques doubles sont considérées dans les calculs (voisinage du second ordre).

La fonction potentielle utilisée est la même quelque soit le type de clique :

$$\varphi_c(x) = \begin{cases} +\beta \text{ si les deux pixels de la clique ont des valeurs différentes} \\ -\beta \text{ si les deux pixels ont la même valeur} \end{cases}$$

β est un paramètre empirique qui prend en général une valeur comprise entre 0,5 et 1,5. Il décrit le degré d'influence du voisinage sur l'affectation de classe au pixel considéré.

Pour le champ d'observations Y, on admet que les classes suivent la loi gaussienne –ce qui est souvent le cas pour des images optiques- et que l'image considérée est multispectrale. Ainsi, le champ Y peut être modélisé par la loi normale multidimensionnelle.

$$P(Y_s = y_s / X_s = k) = \frac{1}{(2\pi)^{m/2} |\Sigma_k|^{1/2}} \exp\left\{-\frac{1}{2}(y_S - \mu_k)^t \Sigma_k^{-1} (y_S - \mu_k)\right\}$$

où Σ_k est la matrice de covariance entre les m bandes pour la classe k et que μ_k désigne le vecteur des moyennes pour la classe k associée au site s.

En supposant que P est positive, on peut poser :

$$U_1(y,x) = -\ln [\, P(Y_s = y_s / X_s = k) \,]$$

On pourrait alors comme dans le cas précédent, attribuer une énergie U_1 comparable à U_2 à ce champ d'observations.

Ainsi sous l'hypothèse markovienne, la stratégie bayésienne qui consiste à rechercher le maximum de la probabilité de X revient alors à rechercher le minimum de la somme des deux énergies : énergie de Gibbs (U_2) et énergie de Gauss (U_1). Soit :

$$\hat{x} = \arg\min_{x \in \Omega} [U_1(y,x) + U_2(x)]$$

Chaque pixel est alors affecté systématiquement à la classe k qui rend la somme des deux énergies précédentes minimale.

Les grandes étapes de l'algorithme sont les suivantes (Rakotoniaina, 2003) :

Étape 1 : Initialisation

L'algorithme ICM est initialisé à l'aide d'une image classifiée existante (on dit souvent image grossièrement classifiée). La classification par la méthode ICM dépend beaucoup de cette image d'initialisation. D'après l'étude de Cortijo *et al*. (1998), MDV n'est pas souvent le bon choix pour initialiser ICM surtout lorsque les distributions des classes se recouvrent. C'est pour cela que dans nos expérimentations nous avons aussi considéré celle issue de kNN.

Étape 2 : Balayage de l'image

En chaque pixel, on calcule l'énergie U relativement à chaque classe et on affecte le pixel à la classe qui rend son énergie minimale.

Étape 3 : Test d'arrêt de l'itération

Si le pourcentage total de changements de classes lors de l'étape 2 est supérieur à un seuil où si le nombre d'itérations donné n'est pas atteint, on recommence l'étape 2, sinon le processus itératif est terminé.

La convergence de l'algorithme ICM a été démontrée par Besag (1986). Dans notre cas, après la 10^{e} itération, le pourcentage des changements est inférieur à 2%.

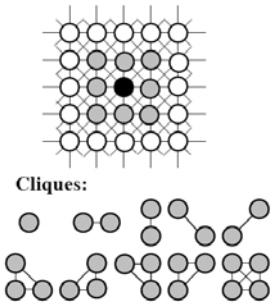


Figure 3 : Modèle de V_S et cliques retenues pour la classification ICM
Model of V_S and cliques retained for the ICM classification

2.2.3. Mesure de séparabilité spectrale des classes

Nous avons établi la séparabilité des classes des zones d'entraînement à l'aide de la distance de Jeffries-Matusita (Wang *et al*. 2004 ; Colditz *et al*. 2006).

L'indice de séparabilité des classes, défini par la relation suivante (Richards et Jia, 1999) a été utilisé pour évaluer la séparabilité des classes :

$$J_{ij} = 2\left(1 - e^{-B_{ij}}\right)$$

dans laquelle B_{ij} désignant la distance de Bhattacharyya est définie par :

$$B_{ij} = \frac{1}{8}\left(m_i - m_j\right)^t \left\{\frac{C_i + C_j}{2}\right\}^{-1} \left(m_i - m_j\right) + \frac{1}{2}\ln\left\{\frac{\left|\frac{C_i + C_j}{2}\right|}{\left|C_i\right|^{1/2}\left|C_j\right|^{1/2}}\right\}$$

où m_i et m_j désignent respectivement les vecteurs moyennes des classes i et j considérées tandis que C_i et C_j sont les matrices de covariance entre les deux classes i et j.

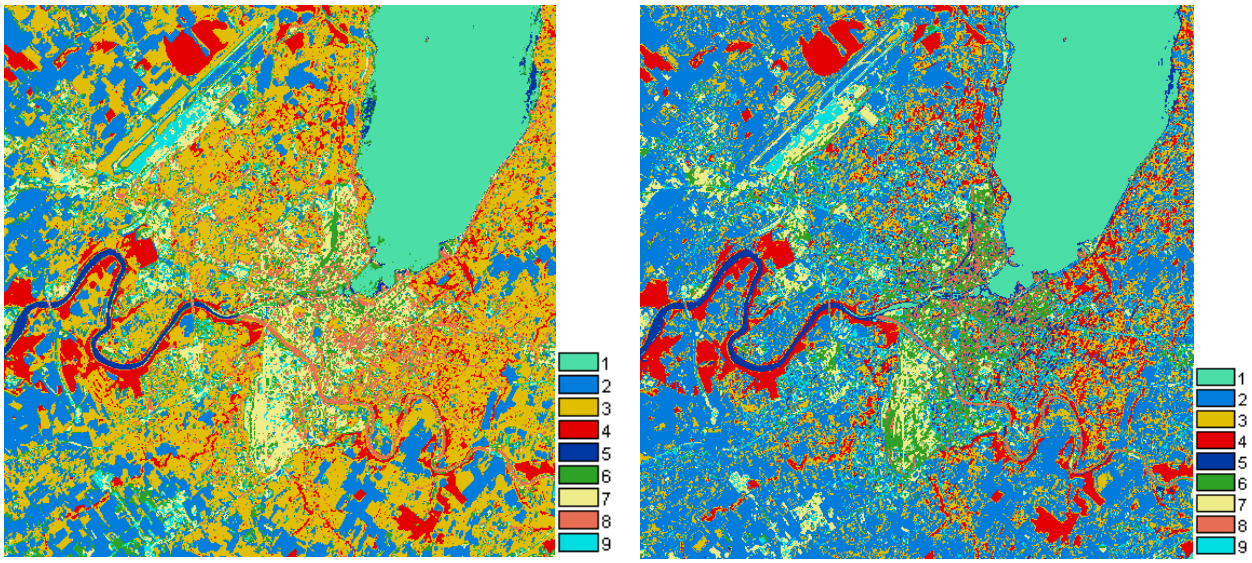
La valeur prise par cet indice est comprise entre 0 et 2. D'après ce qu'a rapporté Wang *et al.* (2004), un indice de séparabilité supérieur à 1,90 indique une bonne séparabilité de classes tandis qu'une valeur inférieure à 1,0 montre une faible séparabilité (recouvrement plus ou moins accentué des signatures spectrales des classes considérées).

3. RÉSULTATS

Les distances de Jeffries-Matusita correspondant aux différentes catégories des zones d'entraînement et calculées par rapport aux bandes spectrales de l'image sont présentées au tableau 2. Les images classifiées à l'aide des différentes méthodes sont consignées dans les figures 4 à 6 et les performances de classification individuelles et globales sont résumées dans les tableaux 3 et 4.

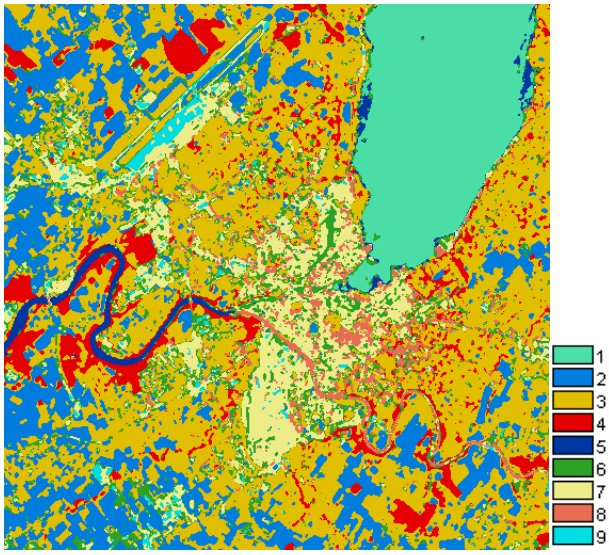
Tableau 2 : Distances de Jeffries-Matusita entre les différentes classes des zones d'entraînement.
Les distances particulièrement faibles sont celles entre les classes 2 et 3 (cultures et espaces verts) d'une part et entre les classes 6 et 7 (bâtiments et édifices importants) d'autre part
Jeffries-Matusita distances between different classes of training sites. The shortest distances are these between classes 2 and 3 (cultures and green areas) and between classes 6 and 7 (buildings and large edifices)

	1	2	3	4	5	6	7	8	9
1	0	2	2	2	1.9998	1.9906	1.9944	2	2
2		0	0.7298	1.5941	1.9999	1.7807	1.9362	1.9789	1.9864
3			0	1.3596	1.9998	1.8593	1.9749	1.9479	1.9783
4				0	2	1.9878	1.9999	1.9934	1.9998
5					0	1.9445	1.9408	1.9594	1.9996
6						0	0.5495	1.5993	1.2181
7							0	1.6930	0.8007
8								0	1.9618
9									0

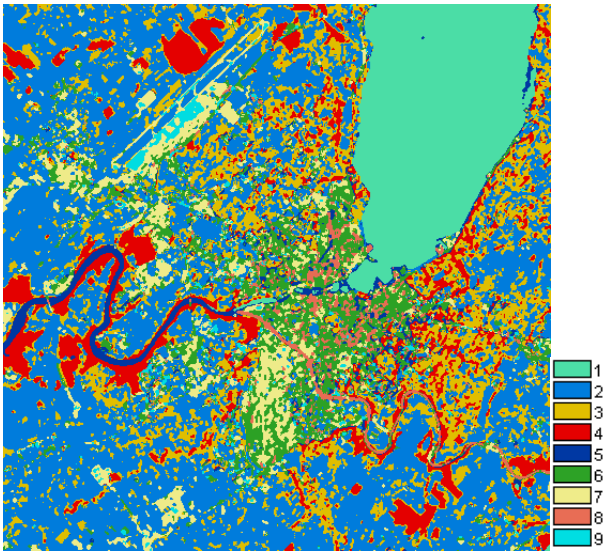


a) Classificateur MDV b) Classificateur kNN

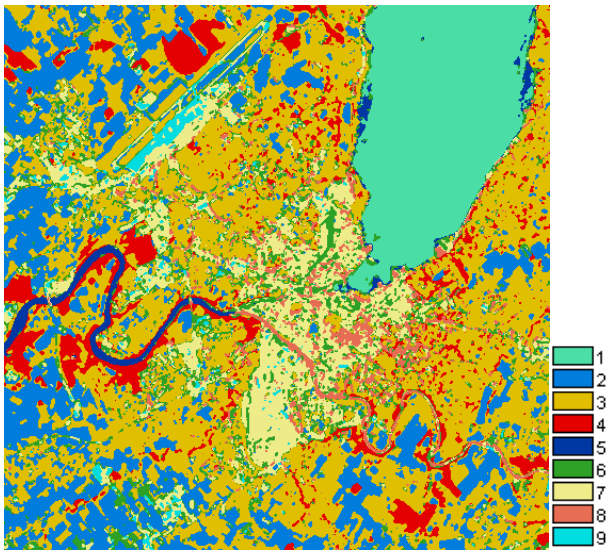
Figure 4 : Images classifiées par une approche pixel, à l'aide respectivement du classificateur thématique MDV (a) et kNN (b)
Images classified by a pixel-based approach: MDV (a) and kNN (b)



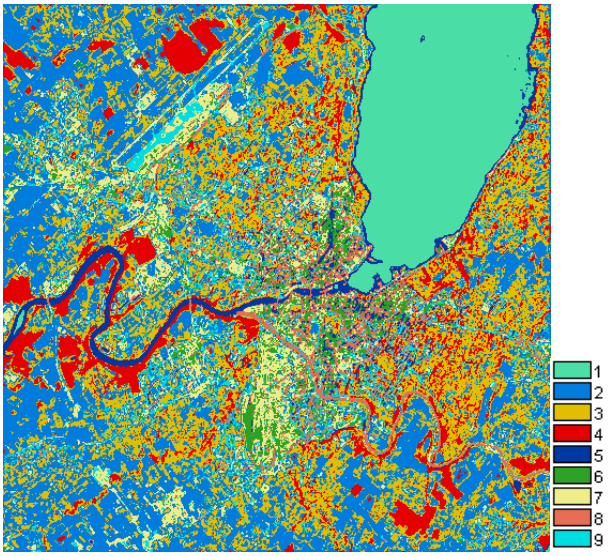
a) Classificateur MDV suivi d'un lissage MF3



b) Classificateur kNN suivi d'un lissage MF3

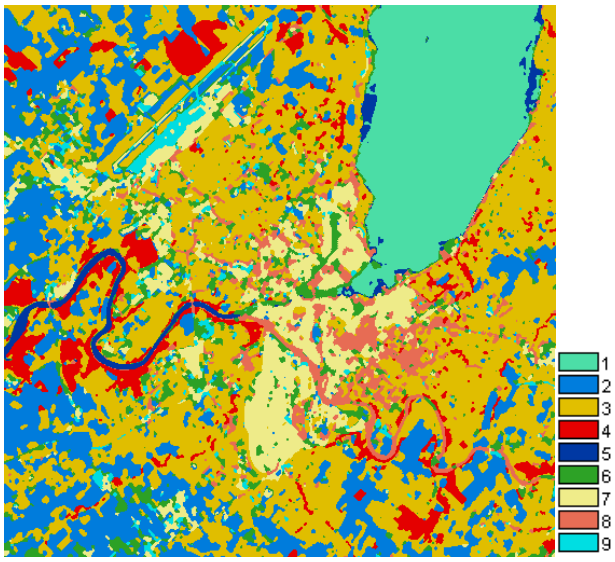


c) Classificateur MDV avec bandes spectrales et indice d'entropie ENT5

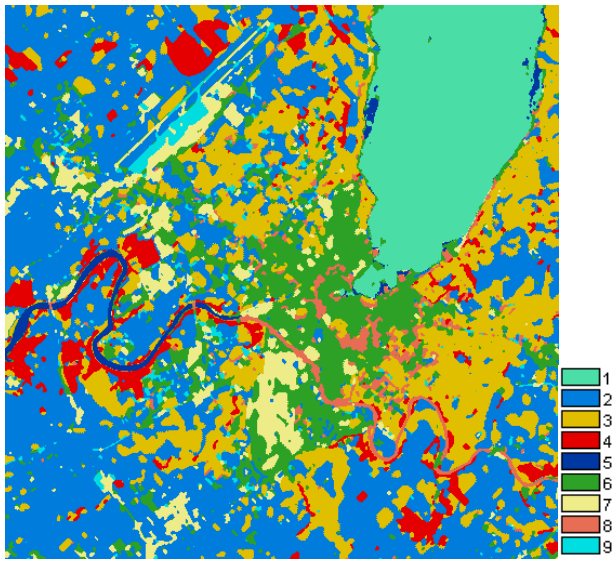


d) Classificateur kNN avec bandes spectrales et indice d'entropie ENT5

Figure 5 : Images classifiées obtenues par démarches hybrides contextuelles : avec une seconde étape de lissage (a) et (b), par injection d'un canal d'entropie conjointement aux 3 bandes spectrales (c) et (d)
Images classified by hybrid contextual approaches: with a second step of smoothing (a) and (b), by injection of the entropy component both into the three spectral bands (c) and (d).



a) Classificateur contextuel ICM initialisé avec image MDV



b) Classificateur contextuel ICM initialisé avec image kNN

Figure 6 : Images classifiées à l'aide de la méthode contextuelle ICM obtenues respectivement à l'aide d'une image d'initialisation par MDV et par kNN
Images classified by ICM contextual method initialized with an image MDV and kNN respectively.

Tableau 3 : Comparaison de la précision globale (PG), des précisions individuelles (en pourcentage) et de l'indice kappa entre les approches pixel, hybrides et contextuelle pour les méthodes faisant appel au classificateur thématique MDV
Comparison of the overall accuracy (PG), individual accuracies (in percentage) and the kappa coefficient between pixel, hybrid and contextual approaches for the methods using the thematic classifier MDV

Classes	MÉTHODES / DÉMARCHES			
	Pixel	Hybrides Contextuelles		Contextuelle
	MDV	MDV-MF3	MDV (BS+ENT5)	ICM (MDV)
1: eau du lac	99,97	100	100	100
2: cultures	45,26	43,58	67,37	44
3: espaces verts	89,14	93,71	90,86	94,86
4: forêt	96,96	97,79	96,69	97,24
5: eau Rhône	93,01	96,51	92,14	96,51
6: bâtiments	26,06	23,94	36,62	23,94
7: édifices import.	77,39	93,92	76,38	84,42
8: eau Arve	88,68	88,68	90,57	89,62
9: voirie	81,28	80,75	79,14	86,10
PG	*89,75*	*90,17*	*92,13*	*90,46*
kappa	*0,8285*	*0,8357*	*0,8680*	*0,8404*

Tableau 4 : Comparaison de la précision globale (PG), des précisions individuelles (en pourcentage) et de l'indice kappa entre les approches pixel, hybrides et contextuelle pour les méthodes faisant appel au classificateur thématique kNN
Comparison of the overall accuracy (PG), individual accuracies (in percentage) and the kappa coefficient between pixel, hybrid and contextual approaches for the methods using the thematic classifier kNN

Classes	MÉTHODES / DÉMARCHES			
	Pixel	Hybrides Contextuelles		Contextuelle
	kNN	kNN-MF3	kNN (BS+ENT5)	ICM (kNN)
1: eau du lac	100	100	100	100
2: cultures	90,95	95,16	85,68	92,63
3: espaces verts	44	52	79,43	96
4: forêt	97,51	98,34	97,24	97,79
5: eau Rhône	98,25	98,69	98,69	96,94
6: bâtiments	53,52	55,63	50	59,86
7: édifices import.	70,85	90,40	76,38	85,43
8: eau Arve	81,13	94,91	87,74	92,45
9: voirie	84,49	87,70	78,07	88,77
PG	93,35	*94,77*	*94,12*	*96,50*
kappa	0,8880	*0,9120*	*0,9012*	*0,9412*

4. DISCUSSION

La discussion des résultats porte avant tout sur la comparaison des performances de classification entre l'approche pixel et celle contextuelle, ainsi qu'entre les différentes démarches et méthodes contextuelles expérimentées.

L'analyse des tableaux de performance de classification (tableaux 3 et 4) permet d'observer que les précisions globales obtenues sont plus élevées pour les méthodes et démarches contextuelles, quelle que soit la méthode contextuelle considérée (post-classification, injection de canal de texture ou ICM), que pour celles obtenues avec l'approche pixel (méthodes MDV et kNN). Comparée au classificateur thématique MDV (tableau 3), la méthode ICM offre une précision globale un peu semblable lorsqu' elle est initialisée avec une image résultante de MDV (respectivement 89,75% et 90,46%), ceci rejoint les observations faites par Cortijo *et al*. (1998) présentées plus haut. Par contre, quand ICM est initialisée avec une image résultante de kNN (tableau 4), le gain en précision globale de classification entre MDV et ICM (kNN) est de l'ordre de 7%. Par ailleurs, en examinant les précisions individuelles des classes entre ces deux méthodes, on note qu'elles sont toujours supérieures à celle de MDV (tableaux 3 et 4). Pour certaines classes (cultures et bâtiments), les gains observés atteignent même plus de 47% et de 33% respectivement.

Lorsqu'on compare les précisions globales obtenues par la démarche hybride avec post-classification MDV-MF3 et par la méthode ICM initialisée avec une image MDV (tableau 3), on constate que cette dernière est légèrement supérieure (90,46% vs 90,17%). Cette constatation est surtout valable pour les structures fines (voirie, eau de l'Arve, eau du Rhône). Par contre, pour les zones plus homogènes (édifices importants, forêt), les précisions individuelles obtenues avec la post-classification l'emportent par rapport à celles de ICM-MDV. On remarque que la démarche utilisant un canal de texture, MDV(BS+ENT5), a permis une meilleure précision de classification que celle des deux autres méthodes contextuelles expérimentées (tableau 3).

On observe que la méthode ICM initialisée avec une image kNN a permis d'obtenir la meilleure précision globale (96,50%) par rapport aux autres méthodes contextuelles (tableau 4).

Les méthodes MDV et kNN se comportent différemment avec les démarches hybrides contextuelles (post-classification et injection de canal texture). Avec MDV, la précision globale obtenue est plus élevée avec l'approche MDV(BS+ENT5) qu'avec MDV-MF3. Elle est respectivement égale à 92,13% et 90,17% (tableau 3). Par contre, les précisions individuelles de certaines classes entre ces deux méthodes ne suivent pas cette tendance. Les précisions individuelles des classes plus homogènes : 'espaces vertes', 'forêt', et 'édifices importants' sont élevées pour l'approche MDV-MF3 par rapport à MDV(BS+ENT5) alors que pour les classes plus hétérogènes ou fines : 'cultures', 'eau de l'Arve', cette dernière l'emporte par rapport à la première (tableau 3). C'est pratiquement l'inverse que l'on observe avec kNN. En effet, l'approche kNN-MF3 l'emporte par rapport à kNN(BS+ENT5) pour la précision globale (94,77%

vs 94,12%) et pour les précisions individuelles de certaines classes :'cultures', 'bâtiments' et 'eau de l'Arve' (tableau 4).

Lorsqu'il y a confusion de classes pour les classes non séparées (par exemple entre 'cultures' et 'espaces vertes' ou entre 'bâtiments' et 'édifices importants') et qu'elles sont caractérisées par des valeurs de la distance de Jeffries Matusita faibles (tableau 2), les précisions individuelles obtenues restent faibles avec les classificateurs thématiques tels MDV ou kNN, alors qu'elles se trouvent améliorées avec le classificateur contextuel ICM (tableaux 3 et 4).

En général, quand la distribution des classes ne suit pas la loi gaussienne, la méthode kNN offre une meilleure précision de classification que celle MDV.

5. CONCLUSION

Globalement, l'approche de classification contextuelle apporte de meilleurs résultats que l'approche pixel basée sur la seule dimension thématique de l'image.

En effet, les conclusions suivantes ont pu être tirées de ce travail : (i) la précision globale de classification obtenue à l'aide de la méthode ICM est plus élevée par rapport à celle de MDV : elles sont respectivement égales à 96,50 % et 89,75 % pour ICM-kNN et MDV; (ii) la classification effectuée à l'aide de la méthode ICM dépend de l'image d'initialisation utilisée : la précision globale obtenue est égale seulement à 90,46% quand MDV est utilisée, alors qu'elle atteint 96,50% avec kNN; (iii) la classification contextuelle permet d'obtenir une plus grande précision et un faible mitage, particulièrement pour les zones homogènes telles que les cultures, les espaces vertes et les forêts ; (iv) en comparant les précisions globales obtenues entre approches hybrides contextuelles et ICM, cette dernière l'emporte quand on se base sur kNN alors que si on utilise MDV, l'approche hybride contextuelle avec injection de canal texture : MDV(BS+ENT5) permet d'obtenir la précision globale élevée (avec 92,13%).

La faiblesse de la méthode ICM, comme mentionnée ci-dessus, est sa trop forte dépendance à l'image d'initialisation utilisée. Chou et Brown (1990) et Van Deusen (1995) ont proposé des solutions à cet effet. Nous sommes actuellement en train d'y travailler afin d'améliorer la classification effectuée avec cette approche. Par ailleurs, nous avons constaté que les précisions individuelles sont plus élevées pour une ou plusieurs classes dans l'une ou l'autre des méthodes appliquées. Ainsi, il serait pertinent d'envisager la combinaison de plusieurs classificateurs pour rehausser la précision de la classification (Cortijo et Pérez de la Blanca, 1998 ; Buttrey et Caro, 2002 ; Wang *et al*. 2004). Dans cette orientation, nous expérimentons actuellement la combinaison de classificateurs selon la règle de décision de Dempster-Shafer. Enfin, avec l'arrivée des images à très haute résolution spatiale, l'utilisation d'une nouvelle approche intégrant cette notion de contexte et appelée par la communauté scientifique « classification orientée-objet », est incontournable pour les futurs traitements de ces types d'images (Yan *et al*, 2006 ; Zhou *et al.* 2008).

REMERCIEMENTS

Les auteurs remercient le projet SARIMA (Soutien aux Activités de Recherche en Informatique et Mathématique en Afrique) pour le financement permettant au premier auteur d'effectuer un séjour de recherche en septembre 2007 au Département de Géosciences de l'Université de Fribourg, Suisse. Nous adressons également nos remerciements sincères aux évaluateurs pour leurs critiques et propositions constructives afin d'améliorer la cohérence et la compréhension de cet article.

RÉFÉRENCES

Besag, J. (1986) On the statistical analysis of dirty pictures. Journal of the Royal Society, series B, vol. 48, n°3, p. 259-302.

Buttrey, S.E. and Karo, C. (2002) Using k-nearest neighbor classification in the leaves a tree. Computational Statistics & Data Analysis, 40, p. 27-37.

Caloz, R. et Pointet, A. (2003) Analyse comparative de la classification contextuelle et du maximum de vraisemblance : synthèse et cas d'étude. Télédétection, vol. 3, p. 311-322.

Caloz, R. et Collet, C. (2001) Précis de télédétection, Volume 3 : Traitements numériques d'images de télédétection. Presses de l'Université du Québec, Sainte-Foy, Canada, 386 p.

Chou, P.B. and Brown, C.M. (1990) The theory and practice of Bayesian image labelling. International Journal of Computer Vision, 4, p. 185-210.

Colditz, R.R., Wehrmann, T., Bachmann, M., Steinnocher, K., Schmidt, M., Strunz, G. and Dech, S. (2006) Influence of image fusion approaches on classification accuracy: a case study. International Journal of Remote Sensing, vol. 27, no 15, p. 3311-3335.

Cortijo, F.J. and Perez de la Blanca, N. (1998) Improving classical contextual classifications. International Journal of Remote Sensing, vol. 19, no 8, p. 1591-1613.

Cover, T.M. and Hart, P.E., (1967) Nearest neighbor pattern classification. IEEE Trans. Inform. Theory, 13, p. 21-27.

Fau, R., Bénié, G.B., Boucher, J.-M.et He, D.-C. (1993) Segmentation markovienne pyramidale d'images. In Actes 16ème Symposium canadien sur la télédétection, 8ème Congrès de l'Association Québécoise de télédétection, p. 701-708.

Franklin, S.E. and Peddle, D.R. (1990) Classification of SPOT HRV imagery and texture features, International Journal of Remote Sensing, vol. 11, no 3, p. 551-556.

Gong, P., Marceau, D.J. and Howarth, P.J. (1992) A comparison of spatial feature extraction algorithms for land-use classification with SPOT HRV, Remote Sensing of Environment, 40, p. 137-151.

He, H. and Collet, C. (1999) Combining spectral and textural features for multispectral image classification with artificial neural networks. This paper is presented at a conference. In International Archives of Photogrammetry and Remote Sensing, 3-4 June 1999, Vallaloïd Spain, vol. 32, part 7-4-3 W6.

Kato, Z. (1994) Modélisations markoviennes multirésolutions en vision par ordinateur. Applications à la segmentation d'images SPOT. Thèse spécialité « Sciences de l'Ingénieur », Université de Nice Sophia Antipolis, France, 144 p.

Kim, K.E. (1996) Adaptive majority filtering for contextual classification of remotely sensed data. International Journal of Remote Sensing, vol. 17, no 5, p. 1083-1087.

Pal, S.K., Bandyopadhyay, S. and Murthy, C.A. (2001) Genetic classifiers for remotely sensed images: comparison with standard methods. International Journal of Remote Sensing, vol. 22, no 13, p. 2545-2569.

Rakotomanana, F., Rakotoniaina, S., Randremanana, R.V., Rasolomamonjy, J.A., Bénié, G.B. et Rakotondraompiana, S. (2006) Amélioration de la classification d'image par la méthode contextuelle ICM : application à la détection des gîtes larvaires potentiels du paludisme à Madagascar. Télédétection, vol. 6, no 1, p. 19-29.

Rakotoniaina, S. (2003) Analyse contextuelle des images fusionnées en télédétection. Rapport de stage postdoctoral, AUF/ Cartel, Université de Sherbrooke, Canada, 58 p.

Richards, J.A. and Jia, X. (1999) Remote Sensing Digital Image Analysis - An introduction. Springer, 363 p.

Shaban, M.A. and Dikshit, O. (2001) Improvement of classification in urban areas by the use of textural features : the case of Lucknow city, Uttar Pradesh, International Journal of Remote Sensing, vol. 22, no 4, p. 565-593.

Simonetto, E. (1997) Etude d'un algorithme de classification pyramidale et application sur les images de télédétection. Rapport de stage, CARTEL, Université de Sherbrooke, Canada, 45 p.

Stehman, S.V. (1999) Basic probability sampling designs for thematic map accuracy assessment. International Journal of Remote Sensing, vol. 20, no 12, p. 2423-2441.

Tintrup, F., De Natale, F. and Ginsto, D. (1998) Compression algorithms for classification of remotely sensed images. IEEE International Conference on Acoustics, Speech & Signal Processing (ICASSP), Seattle, WA, p. 2565-2568.

Van Deusen, P.C. (1995) Modified Highest Confidence First Classification. Photogrammetric Engineering & Remote Sensing, vol. 61, no 4, p. 419-425.

Wang, L., Sousa, W.P. and Gong, P. (2004) Integration of object-based and pixel-based classification for mapping mangroves with IKONOS imagery. International Journal of Remote Sensing, vol. 25, no 24, p. 5655-5668.

Yan, G., Mas, J.-F., Maathuis, B.H.P., Xiangmin, Z. and Van Dijk, P.M. (2006) Comparison of pixel-based and object-oriented image classification approaches – a case study in a coal fire area, Wuda, Inner Mongolia, China. International Journal of Remote Sensing, vol. 27, no 18, p. 4039-4055.

Zhou, W., Troy, A. and Grove, M. (2008) A comparison of object-based with pixel-based land cover change detection in the Baltimore Metropolitan area using multitemporal high resolution remote sensing data. 2008 IEEE International Geoscience and Remote Sensing Symposium, IV-683 – IV-686.