Télédétection, 2000, vol. 1, pp. 259-284
Des tirés à part sont disponibles auprès de l'éditeur
Droit de photocopie soumis à autorisation

© 2000 OPA (Overseas Publishers Association) N.V.
Publié sous licence par
Gordon and Breach Science Publishers
Imprimé en France

Cartographie forestière des régions de Mamora (Maroc) et de Matagami (Québec) par classification contextuelle basée sur les champs markoviens

MOHAMED A. EL GHOUAT[a*], JEAN-MARC BOUCHER[b†] et GOZE BERTIN BÉNIÉ[c‡]

[a]Institut National Agronomique Hassan II, BP 6202, Rabat, Maroc, [b]École Nationale Supérieure des Télécommunications de Bretagne, BP 832, 29285 BREST Cedex, France and [c]Centre d'applications et de recherches en télédétection. Université de Sherbrooke, Sherbrooke, Québec, Canada J1K 2R1

(soumis le 19 avril 1999 ; révisé le 28 juin 1999 ; accepté le 1er octobre 1999)

Dans cet article, on utilise une méthode de segmentation contextuelle basée sur les champs markoviens pour traiter des images de télédétection présentant des zones forestières et l'on évalue son efficacité pour une exploitation cartographique automatisée.

La modélisation de l'image par des champs markoviens ou champs de Gibbs permet de prendre en compte les relations de voisinage entre pixels et donc de définir le caractère homogène des régions de l'image. La distribution de probabilité du champ des classes se décrit au moyen d'une fonction d'énergie, dont la forme n'est pas connue *a priori*. Dans cet article, plusieurs fonctions d'énergie sont comparées, incluant aussi un modèle de contours. La segmentation de l'image elle-même est faite par l'algorithme ICM (*Iterative Conditional Mode*) de Besag avec deux versions, l'une classique, l'autre intégrant une décomposition pyramidale de l'image.

L'application en est faite sur une image HRV(XS) de SPOT de la zone de Mamora au Maroc, comprenant des eucalyptus jeunes, des eucalyptus âgés, du chêne-liège et du sol nu, ainsi que sur une image multispectrale TM de Landsat de la zone de Matagami au Québec, composée de conifères, feuillus, marécages et coupe totale. Les caractéristiques cartographiques des deux zones sont parfaitement connues. Une comparaison avec les méthodes classi-

* Tél.: (212) 7282947; télécopieur : (212) 7778135; mlghouat@iav.refer.ma
† Tél.: (33) 2 98001357; télécopieur: (33) 2 98001012; jm.boucher@enst-bretagne.fr
‡ Tél.: (1) 819 821 7180; télécopieur : (1) 819 821 7944; gbenie@courrier.usherb.ca

ques de classification par maximum de vraisemblance et ISODATA montre une amélioration de la classification, tant du point de vue homogénéité des régions, qu'en termes de diminution du taux d'erreur.

Mots-clés : champ markovien; segmentation; cartographie forestière; forêt

Forest Mapping of Mamora (Morocco) and Matagami (Québec) by Contextual Classification Based on Markov Field

In this paper, we investigate a method of contextual segmentation for remote sensing images based on Markov random fields with many different energy functions and establish a comparison between these models in term of classification error rate. This is applied to forest areas because of the environmental and economic importance of this domain, in order to obtain an automatic cartographic survey in the future.

Typically, an image is represented by grey level variations defined over a square lattice. The Bayesian formulation is a natural way of modelling the image structure. Prior distribution describes the tendencies and constraints that characterize an image, which corresponds to a label or class field, while conditional distribution is related to local fluctuations, such as texture or observation noise. Markov random fields have a Gibbs distribution, which only requires to know an energy function, which is easier to use than to work directly with probabilities. Gibbs fields are an efficient way for describing homogeneous characteristics of image areas and for taking into account neighbour relationships. The segmentation problem is to find the label of each pixel from the observed image by maximizing the posterior distribution computed from the Bayes rule. Using Gibbs fields leads generally to improved image segmentation methods compared to usual discriminant analysis.

In order to apply this method to image segmentation, many problems must be solved, such as the type of energy function to be used, because its pattern is not known *a priori*, and the choice of the conditional distribution. In this paper. several energy function are tried, such as a multilogistic model, a quadratic function or an absolute value function. In order to take the area boundaries into account, the energy function is also split into two additive parts, one for the class field, the other for a line process. The conditional distribution is Gaussian, with the hypothesis of independence between pixels for each class, which means that texture is only modelled by mean and variance. This is extended to the vector case for multispectral images with correlation between channels. As a Bayesian solution cannot be directly obtained because of the large number of configurations to be sought, image segmentation is made by the ICM algorithm *(Iterative Conditional Mode)* of Besag which is an iterative deterministic procedure for local optimization. As an image pyramidal representation can improve the computation time and the classification rate, three methods of image decomposition are investigated in this context.

These algorithms are applied to a HRV(XS) SPOT image of the Mamora area (Morocco) including young and old eucalyptus, cork-oaks and bare soil, and to a TM Landsat image of the Matagami area (Québec, Canada) composed of conifers, leafy trees and total cut. The cartographic characteristics of both areas are well known.

Comparison also with classic classification methods such as Maximum Likelihood and ISODATA shows that the ICM algorithm with the split energy function including the line process gives results close to the ground truth, improves the pixel classification rate and reinforces image homogeneity. Use of pyramidal analysis reduces computation time by 50%.

Keywords: Markov field; segmentation; cartography; forest

1. INTRODUCTION

Le milieu forestier, fortement hétérogène, subit des dégradations d'origines diverses parmi lesquelles celles de l'Homme sont de loin les plus importantes. Le suivi et la cartographie de ce milieu font appel à plusieurs domaines dont les plus conventionnels sont : la photointerprétation, l'arpentage, la photogrammétrie et les campagnes de collecte de données sur le terrain. Grâce à sa capacité de prise de vue sur de grandes superficies, de répétitivité et de coûts relativement bas, la télédétection s'impose progressivement comme outil fondamental. Mais les méthodes de traitement d'image numérique offrent des résultats qui sont encore loin de satisfaire les spécialistes de la gestion forestière. Aussi est-il nécessaire d'affiner les instruments d'analyse d'image numérique pour combler cette insuffisance et développer des méthodes spécifiques pour quantifier suffisamment des ressources forestières sur des images et ainsi fournir un nouvel outil de gestion aux spécialistes.

Les méthodes conventionnelles de classification utilisées en télédétection, qu'elles soient dirigées ou non, utilisent essentiellement l'information spectrale fournie par chaque pixel dans plusieurs bandes. Des paramètres texturaux, parmi lesquels on peut citer les matrices de co-occurence, le spectre de texture, l'intégrale curviligne, la dimension fractale, la décomposition morphologique, etc., peuvent y être ajoutés pour enrichir la classification, en prenant en compte la dépendance spatiale de pixels voisins. L'analyse discriminante est la méthode la plus couramment employée, car la plus simple à mettre en œuvre, puisqu'elle n'emploie qu'un critère de distance.

Depuis quelques années, la modélisation de l'image sous forme d'un champ markovien a permis de développer des méthodes de segmentation efficaces.

L'image est décrite comme un réseau de sites voisins auxquels sont associés des variables aléatoires. Un système de voisinage caractérise tous les sites voisins. Dans le cas markovien, la probabilité d'avoir pour un site donné une réalisation de cette variable aléatoire ne dépend que de son voisinage et non de l'ensemble des sites (Guyon, 1993). On associe au champ aléatoire une distribution de probabilité de Gibbs, qui dépend d'une fonction d'énergie, et dont le rôle est de mesurer le degré d'homogénéité du voisinage (Besag, 1986).

Ce modèle est particulièrement utile pour résoudre le problème de la classification bayésienne d'image (Geman and Geman, 1984). À l'image des classes est associée une distribution de Gibbs, qui traduit la connaissance *a priori* concernant les relations de voisinages entre pixels et qui agit comme un terme de régularisation. Sur chaque classe, on superpose une texture, dont on peut exprimer la densité de probabilité conditionnelle, l'ensemble fournissant un modèle hiérarchique de l'image (Derin and Elliott, 1987). La classification bayésienne consiste à rechercher la réalisation de l'image des classes qui satisfait le maximum de la distribution de probabilité *a posteriori*. Le problème devient alors très complexe à cause du très grand nombre de configurations possibles. Une solution globale d'optimisation utilisant la méthode du recuit simulé a été proposée (Geman and Geman, 1984), mais elle est extrêmement lente à converger. Des solutions approchées ont alors été suggérées, celle de l'ICM (*Iterative Conditional Mode*) de Besag, qui ne fait qu'une optimisation locale ou celle du MPM (*Maximum Posterior Model*) (*Marroquin et al.*, 1987) où l'on recherche le maximum de la loi marginale.

Les paramètres de la fonction d'énergie, ainsi que ceux de la texture demandent à être estimés sur l'image dans le cas d'une segmentation non dirigée. Won et Derin (1992) proposent une solution où l'on estime une partie des paramètres par maximum de vraisemblance que l'on utilise ensuite pour segmenter et estimer le reste des paramètres alternativement jusqu'à stabilisation. La méthode ICE (*Iterative Conditional Estimation*) est une autre approche pour l'estimation des paramètres (Pieczynski, 1994). La forme des densités conditionnelles est souvent supposée gaussienne, mais d'autres densités ont été proposées, comme les mélanges de gaussiennnes (Delignon *et al.*, 1997) ou les lois Gamma en imagerie radar (Kelly *et al.*, 1988; Quelle *et al.*, 1996). L'utilisation d'une décomposition pyramidale de l'image associée aux modèles markoviens permet d'affiner la segmentation et d'améliorer le temps de calcul (Fau *et al.*, 1994; Boucher *et al.*, 1994; Laferté *et al.*, 1998).

Peu d'applications de ces méthodes à des images satellitaires ont été tentées. On peut citer des travaux sur les images AVHRR PSG de NOAA (Lee and Crawford, 1991) et les images HRV(XS) de SPOT (Boucher *et al.*, 1993–1994).

Dans cet article, on cherche à évaluer le potentiel de ces méthodes pour une application concrète en télédétection. À titre d'exemple et parce que

l'on connaît la nature du terrain de ces sites, on les applique à la classification de zones forestières localisées au Maroc et au Québec.

Cet article comporte quatre sections:

- une introduction à la modélisation markovienne des images et à la classification bayésienne avec la description d'un algorithme particulier, l'algorithme ICM,
- l'étude de différentes fonctions d'énergie qui constituent la connaissance *a priori* du champ des classes,
- l'introduction d'une pyramide d'images pour améliorer la robustesse de l'algorithme,
- l'application de cet algorithme de classification à une région forestière du Maroc, celle de Mamora et à une région du Québec, celle de Matagami.

2. DESCRIPTION DES RÉGIONS D'ÉTUDE

2.1. Région de Mamora

La forêt de Mamora se situe au nord-ouest du Maroc et couvre une superficie d'environ 60 km d'ouest en est et 35 km du sud au nord. Elle constitue une unité écologique typique composée d'une forêt naturelle de chênes-lièges et de plantation d'eucalyptus. La zone d'essai est caractérisée par une hétérogénéité dans la répartition des peuplements forestiers. Elle est occupée par une végétation naturelle et du reboisement. On y trouve des eucalyptus jeunes, âgés, du chêne-liège et du sol nu.

Une image HRV(XS) de SPOT, fournie par le Centre Royal de Télédétection Spatiale du Maroc, de cette région a été acquise en juillet 1991 avec la résolution spatiale de 20 m. L'échelle des images utilisées est de 1:120 000. La nature du terrain a été obtenue à partir de la photo-interprétation de photographies aériennes acquises en juillet 1991 par la Direction de la conservation foncière du cadastre et de la cartographie du Maroc à l'échelle 1:40 000 et de feuillets cartographiques au 1:50 000 et 1:100 000 relatifs à la zone choisie, suivie d'une vérification sur le terrain.

2.2. Région de Matagami

La zone de Matagami est située dans les Laurentides (Québec); l'occupation du sol montre quatre classes végétales : marécage, forêt de feuillus, forêt de conifères et coupe totale. L'image multispectrale TM de Landsat acquise en juin 1994 a été fournie gracieusement par le Centre de foresterie des Laurentides (Sainte-Foy). La nature du terrain est obtenue grâce à une classification par maximum de vraisemblance complétée par une photo-interprétation.

3. SEGMENTATION D'IMAGE AVEC MODÈLE MARKOVIEN

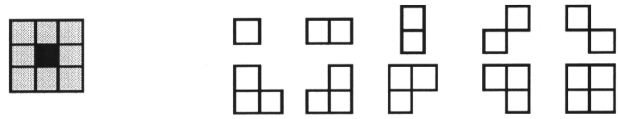
3.1. Modélisation markovienne et classification bayésienne

On note X le champ des classes, Y le champ des observations, x et y leurs réalisations. On fait l'hypothèse que le champ des classes suit un modèle markovien, c'est-à-dire que la distribution du pixel X_S au site S, conditionnellement à tous les autres pixels de l'image, ne dépend en fait que d'un petit voisinage η autour de S:

$$p(X_S = x_S | X_{\{I-S\}} = x_{\{I-S\}}) = p(X_S = x_S | X_\eta = x_\eta)$$

où X_s désigne la variable aléatoire « classe » au site S, x_S une de ses réalisations, {I-S} l'ensemble des sites de l'image excepté le site S, η un voisinage de S, $X_{\{I-S\}}$, X_η, $x_{\{I-S\}}$, x_η respectivement le champ des classes sur {I-S} et le voisinage, et une réalisation des deux champs correspondants.

Le voisinage est décomposé en un ensemble C de cliques c, correspondant à des sites mutuellement tous voisins ou uniques (figure 1).



Voisinage de deuxième ordre Type des cliques

FIGURE 1 Exemple de cliques pour un voisinage du second ordre. *Example of clique for a second order neighborhood*

Le théorème d'Hammersley-Clifford montre que le champ X_s markovien posséde une distribution de probabilité qui est une mesure de Gibbs de la forme:

$$p(X = x) = \frac{1}{Z} e^{-E_2(x)} \qquad (1)$$

où $E_2(x)$ est une fonction d'énergie et Z est une constante de normalisation ou fonction de répartition donnée par $Z = \sum_{x \in \Omega} e^{-E_2(x)}$ avec Ω l'ensemble de toutes les réalisations possibles du champ de classes.

La fonction d'énergie $E_2(x)$ est obtenue sous la forme d'une somme de potentiels locaux sur les cliques c de C, de la façon suivante (Geman and Geman, 1984):

$$E_2(x) = \sum_{c \in C} \nu_c(x)$$

où $\nu_c(x)$ est la fonction potentiel associée à chaque clique c.

Le modèle multilogistique constitue un exemple de fonction potentiel, souvent employé:

$\nu_c(x) = \beta$ si les deux pixels de la clique ont des valeurs différentes
$\nu_c(x) = -\beta$ si les deux pixels de la clique ont des valeurs identiques

où β est un réel positif à estimer. Le rôle de ce paramètre est de favoriser l'homogénéité spatiale entre pixels voisins.

La stratégie de classification bayésienne consiste à estimer le champ des classes X à partir de la réalisation observée Y. En utilisant la règle de Bayes, on exprime la probabilité *a posteriori* comme

$$P(X = x/Y = y) = \frac{P(Y = y/X = x)P(X = x)}{P(Y = y)} \qquad (2)$$

où

P(Y = y/X = x) représente la distribution de probabilité conditionnelle de l'observation "y" compte tenu du fait que la classe "x" a été retenue;
P(X = x) est la probabilité d'occurrence de la classe "x" (probabilité *a priori*);
P(Y = y) est la distribution de probabilité de l'observation "y".

La densité de probabilité conditionnelle P(Y = y/X = x)de l'équation (2) peut être modélisée par une loi gaussienne. On peut simplifier en considérant, qu'à l'intérieur d'une même classe, les pixels sont indépendants, ce

qui revient à caractériser la texture de chaque classe uniquement par sa moyenne et sa variance. On obtient alors:

$$p(Y = y|X = x) = \prod_S p(Y_S = y_S|X_S = x_S)$$

Dans une image multispectrale, y_s est un vecteur, dont les composantes sont les valeurs des intensités fournies par les M canaux pour le site S considéré. Soit K le nombre total de classes et k l'une de ces classes; x_S prend des valeurs entières dans l'intervalle [1, K]. La densité de probabilité conditionnelle s'écrit:

$$P(Y_S = y_S/X_S = k) = p(y_S/k)$$
$$= \frac{1}{(2\pi|A_k|)^{M/2}} e^{-\frac{1}{2}(y_S-\mu_k)^T A_k^{-1}(y_S-\mu_k)} \quad (3)$$

A_k est la matrice de covariance entre les canaux pour la classe k;
μ_k est le vecteur des moyennes pour la classe k.

Comme on l'a vu dans les équations précédentes (1) et (3), P(Y/X) et P(X) sont des fonctions exponentielles. On peut encore les écrire sous la forme:

$$E_1(y/x) = -\ln P(Y = y/X = x) \quad (4)$$

$$E_2(x) = -\ln P(X = x) \quad (5)$$

La configuration de la classe la plus probable est celle qui présente une énergie globale minimale, avec:

$$E_G(x, y) = E_1(y/x) + E_2(x) \quad (6)$$

Cette énergie comprend un terme d'attache aux données, qui traduit les distorsions et les bruits apportés à l'image, et un terme de modélisation *a priori*.

Il n'est pas possible de trouver directement la solution bayésienne optimale par la recherche du maximum *a posteriori*, car le nombre de configurations à explorer est trop important pour le calcul de Z (K^N combinaisons si N est la dimension du voisinage).

L'algorithme ICM (*Iterated Conditionnal Mode*) (Besag, 1986) présente une solution sous-optimale. C'est une méthode de relaxation déterministe qui recherche le maximum de

$$p(X_S = x_S|Y_S = y_S, X_\eta = x_\eta)$$

et dont l'expression est aisément calculable en fonction des énergies définies en (4) et (5).

Les étapes de fonctionnement de cet algorithme sont (Besag, 1986; Fau *et al.*, 1994):

- initialisation de l'algorithme par lequel les images brutes peuvent subir une opération de classification comme l'ont fait Fau *et al.* (1994) en utilisant des techniques simples comme l'agrégation dans l'espace des mesures centrée sur l'analyse d'histogramme ou l'algorithme SEM (*Stochastic Estimation Maximization*) de Celeux et Diebolt (1986);
- formation des classes pour une configuration de voisinage donnée avec calcul de la fonction d'énergie associée à chaque pixel; le pixel est affecté à la classe d'énergie minimale;
- itération si deux images de classes successives présentent des différences significatives, c'est-à-dire si le nombre de changements est supérieur à un seuil prédéfini, le processus de classification reprend à l'étape précédente avec comme intrant, la dernière des images de classe obtenue; dans le cas contraire, le processus prend fin.

L'inconvénient majeur de cet algorithme itératif est de dépendre du choix de l'image initiale des classes, car il peut rester bloqué sur une solution correspondant à un minimum local d'énergie et non pas au minimum global.

Pour effectuer la classification, il sera nécessaire d'estimer auparavant, sur un échantillon d'apprentissage, l'ensemble des matrices de covariance et des moyennes de chaque classe. On appelle α ce vecteur à estimer. Il faut aussi estimer les paramètres des fonctions d'énergie du champ de classes que l'on note β. S'agissant d'une classification dirigée, il est facile d'estimer les paramètres α sur chaque classe. (On peut la rendre non dirigée en introduisant un module d'estimation de ces paramètres directement sur l'image observée) Différentes méthodes d'estimation peuvent être employées pour estimer les paramètres β, mais dans la suite de l'article, ils seront déterminés expérimentalement, ce qui se justifie car, dans une gamme de valeurs estimées, la sensibilité de la segmentation à ces paramètres est assez faible.

3.2. Fonctions d'énergie

Le modèle multilogistique conduit à des prises de décision parfois trop brutales et à un risque de fragmentation de la segmentation. Il impose une

contrainte d'uniformité sur chaque classe que l'on peut considérer parfois comme trop pénalisante. D'autres modèles d'énergie sont susceptibles d'améliorer les performances de la classification, notamment en mettant en avant des caractéristiques d'homogénéité ou en attachant un soin particulier à la préservation des contours de l'image.

3.2.1. Fonctions d'énergie tenant compte de l'homogénéité

Le choix des fonctions d'énergie est un problème difficile à résoudre pour obtenir de bons résultats avec un algorithme de segmentation donné.

Exemple de fonctions d'énergie:

$$E_2(x) = \beta \sum_i \sum_{j \in \eta_i} (x_i - x_j)^2 \tag{7}$$

$$E_{2_2}(x) = \beta \cdot \sum_i \sum_{j \in \eta_i} |x_i - x_j| \tag{8}$$

$$E_{2_3}(x) = \beta \cdot \sqrt{\frac{\sum_i \sum_{j \in \eta_i} |x_i - x_j|}{Cste}} \tag{9}$$

$$E_{2_4}(x) = \beta \cdot \sum_i \sum_{j \in \eta_i} \frac{(x_i - x_j)^2}{1 + (x_i - x_j)^2} \tag{10}$$

i	=	position du pixel à classer;
j	=	position du pixel voisin;
X_i	=	valeur du pixel classé;
X_j	=	valeur du pixel voisin;
η_i	=	voisinage d'un pixel i;
β	=	paramètre de régularisation de lissage;
Cste	=	constante de normalisation.

Les expressions ci-dessus permettent de faire un lien entre les valeurs de chaque pixel classé et celles des autres pixels du voisinage, ce qui définit un caractère plus ou moins homogène des pixels. Cependant, ces modèles comportent une limitation lorsque le champ de classe présente des discontinuités. Par conséquent, il est utile d'introduire d'autres modèles de fonction d'énergie qui peuvent préserver les contours dans une segmentation donnée.

3.2.2. Fonctions d'énergie tenant compte de l'homogénéité et de la préservation des discontinuités

La préservation des discontinuités dans une image exige d'introduire, dans la fonction d'énergie, un champ de lignes localisé sur l'image. Ce champ représente la présence ou l'absence des discontinuités qui permet d'arrêter le lissage sur l'image segmentée. Le champ de lignes se compose de deux champs (figure 2), l'un correspondant aux lignes horizontales ($h_{i,j}$) et l'autre correspondant aux lignes verticales. Les lignes horizontales joignent le site (i, j) au site (i+1, j) et créent des discontinuités entre les pixels le long de la direction verticale (figure 3a), tandis que les lignes verticales joignent le site (i, j) au site (i, j+1) et créent des discontinuités le long de la direction horizontale (figure 3b).

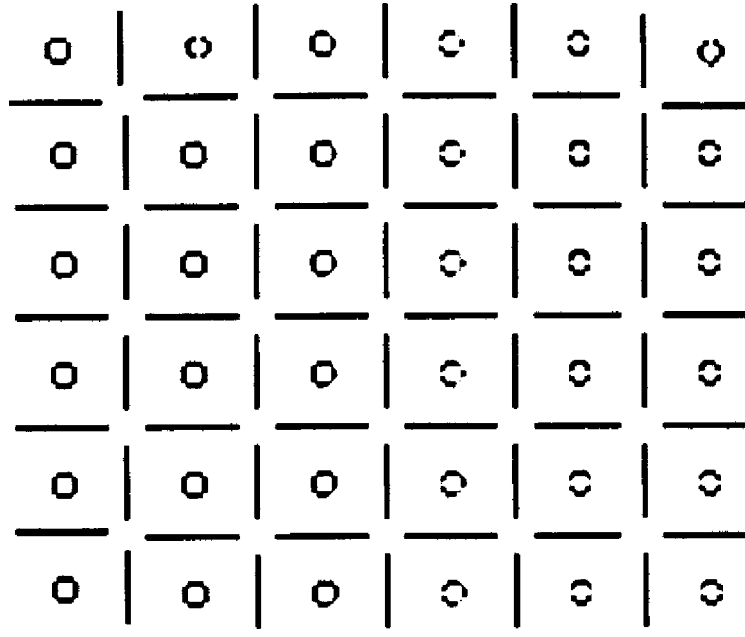


FIGURE 2 Pixels et éléments de contours pour le modèle d'image. *Pixels and contour elements for the image model*

En utilisant les trois champs de Markov (X représente le champ de classes, h et v représentent les champs de lignes horizontales et verticales res-

pectivement), la fonction d'énergie E_2 peut être dissocié en deux composantes de la façon suivante:

$$E_2(x, h, v) = E_{2,1}(x, h, v) + E_{2,2}(h, v) \tag{11}$$

$E_{2,1}(x, h, v)$ exprime la dépendance entre les intensités des pixels et la configuration des éléments linéaires;

$E_{2,2}(h, v)$ exprime la dépendance entre les éléments linéaires.

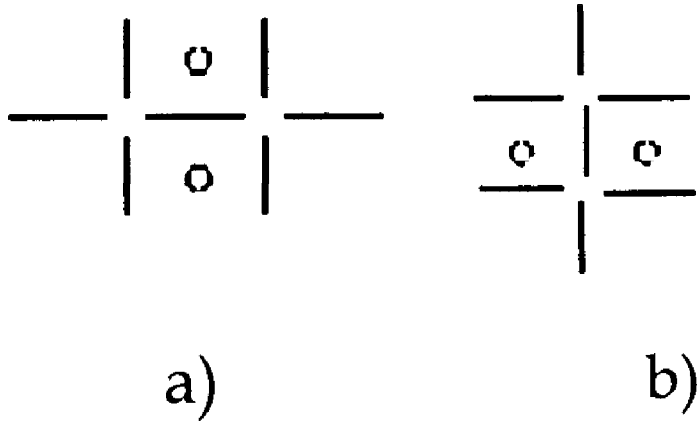


FIGURE 3 Processus de lignes a) horizontales et b) verticales. *Line process a) horizontal b) vertical*

$$E_{2,1}(x, h, v) = \tag{12}$$
$$\beta \sum_{i=1}^{F} \sum_{j=1}^{F-1} (x_{i,j} - x_{i,j+1})^2 \cdot (1 - v_{i,j}) + \beta \sum_{i=1}^{F-1} \sum_{j=1}^{F} (x_{i,j} - x_{i+1,j})^2 \cdot (1 - h_{i,j})$$

β	= paramètre positif de régularisation;
F	= dimension de la fenêtre du voisinage;
$h_{i,j}$	= valeurs associées aux éléments linéaires horizontaux;
$v_{i,j}$	= valeurs associées aux éléments linéaires verticaux;
$x_{i,j}$	= valeur du pixel classé;
$x_{i,j+1}$ et $x_{i+1,j}$	= valeurs des pixels voisins.

Le terme $E_{2,2}(h, v)$ de l'énergie *a priori* peut être choisi de deux façons différentes. La première représentation est obtenue sous la forme suivante (Blanc-Féraud et Barlaud, 1990):

$$E_{2,2_1}(h, v) = \gamma \sum_{i=1}^{F-1} \sum_{j=1}^{F-1} (v_{i,j} + h_{i,j}) \tag{13}$$

où γ est un paramètre de pénalité.

La détermination de $E_{2,2}(h, v)$ est obtenue par la sommation de tous les éléments linéaires horizontaux et verticaux sans distinguer les différentes configurations du contour.

La deuxième représentation $E_{2,2_2}(h, v)$ répond à la faiblesse de la première en distinguant chaque type de configuration (figure 4.3):

$$E_{2,2_2}(h, v) = \gamma \cdot \sum_{i=1}^{F-1} \sum_{j=1}^{F-1} V(h_{i,j}, v_{i,j}, h_{i,j+1}, v_{i+1,j}) \tag{14}$$

où V est une fonction représentant les valeurs associées à toutes les configurations décrites à la figure 4. Une faible valeur du potentiel signifie une configuration plus probable (Wright, 1989). Par exemple, dans le cas d'une image satellitaire, un potentiel élevé est associé à l'extrémité d'un contour alors qu'un potentiel plus faible est associé à un contour continu. Cela permet de traduire la faible probabilité d'occurrence des fins de lignes.

La somme des deux termes $E_{2,1}(x, h, v)$ (équation 12) et $E_{2,2_1}(h, v)$ (équation 13), présentée ci-dessus, donne la cinquième équation sous la forme suivante:

$$E_{2_5}(x, h, v) = E_{2,1}(x, h, v) + E_{2,2_1}(h, v) \tag{15}$$

alors que la somme des deux termes $E_{2,1}(x, h, v)$ (équation 12) et $E_{2,2_2}(h, v)$ (équation 14) forme la sixième fonction:

$$E_{2_6}(x, h, v) = E_{2,1}(x, h, v) + E_{2,2_2}(h, v) \tag{16}$$

En conclusion, les fonctions d'énergie E_{2_5} et E_{2_6} présentées ci-dessus tiennent compte de la préservation des discontinuités.

3.2.3. *Adaptation des fonctions d'énergie choisies aux caractéristiques spectrales des classes*

Dans le cas d'images multispectrales, y_s est un vecteur, dont les composantes correspondent à l'énergie dans chaque bande. Il se pose alors la question de savoir comment quantifier le caractère homogène d'une classe sur

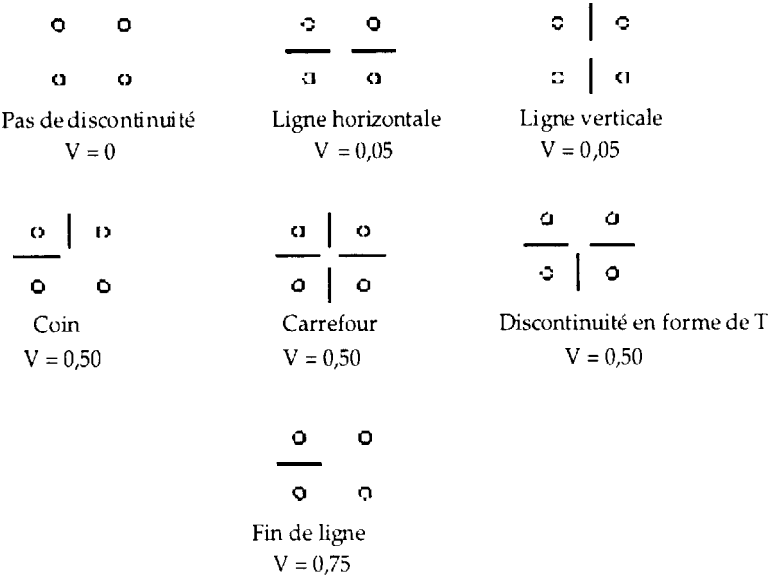


FIGURE 4 Différents types de discontinuités entre pixels de l'image et potentiels associés.
Different types of discontinuities between image pixels and their associated potentials

plusieurs bandes spectrales. On propose d'employer une moyenne arithmétique ou pondérée de l'ensemble des canaux en un site donné.

La moyenne arithmétique des moyennes spectrales fournies par l'ensemble des canaux est obtenue de la façon suivante:

$$\mu_k^{arith} = \frac{\sum_{m=1}^{M} \mu_{k,m}}{M} \tag{17}$$

où M est le nombre de canaux et $\mu_{k,m}$ la moyenne de chaque classe k dans chaque canal m. Cette moyenne remplace la valeur de $x_{i,j}$ dans les fonctions d'énergie. L'utilisation de la moyenne arithmétique présente comme inconvénient de ne pas tenir compte de la sensibilité différente de chaque canal et de les considérer comme indépendants.

La moyenne pondérée a été proposée afin de pallier cet inconvénient. Généralement, les différentes bandes ne présentent pas la même précision; par conséquent, il est préférable d'introduire un poids dans la détermination de la valeur de la moyenne de chaque classe. Le calcul de la moyenne pondérée se présente comme suit:

$$\mu_k^{pondérée} = \frac{\sum_{m=1}^{M} P_k^m \cdot \mu_{k,m}}{\sum_{m=1}^{M} P_k^m} \tag{18}$$

avec P_k^m, le poids correspondant à la classe k dans le canal m.

La détermination du poids peut être obtenue en utilisant la formule suivante:

$$P_k^m = \frac{1}{\sigma_{k,m}^2} \tag{19}$$

avec $\sigma_{k,m}^2$, la variance de la classe k dans le canal m.

3.3. Analyse pyramidale et adaptation à l'algorithme ICM

L'algorithme ICM présente une difficulté d'initialisation. Pour améliorer ses performances, l'idée est d'employer une décomposition pyramidale de l'image. Ces pyramides ont souvent été employées en compression d'image ou en classification (Kim and Crawford, 1991; Boucher *et al.*, 1994). Chaque niveau de la pyramide peut être obtenu par filtrage suivi d'un sous-échantillonnage en conservant un pixel sur deux suivant les lignes et les colonnes, ce qui donne des images de taille de plus en plus réduites à des résolutions de plus en plus faibles. On applique alors l'algorithme ICM sur la plus petite image et l'on utilise le résultat de la classification obtenue comme initialisation pour une classification de l'image à la résolution immédiatement supérieure. Comme conséquence, on améliore la robustesse de l'algorithme vis-à-vis de l'initialisation et l'on gagne aussi en temps de calcul, car le nombre global d'itérations nécessaires à la convergence d'ICM s'en trouve réduit. Par contre, le volume des données est légèrement augmenté.

Le filtre peut être construit empiriquement (Meyer *et al.*, 1987) ou provenir de la théorie des ondelettes (Daubechies, 1988; Mallat, 1989; Fau *et al.*, 1994). Dans cette étude, on compare les filtres de Burt, de Meyer et de Daubechies.

En opérant de manière séparable en lignes et colonnes, le filtre bidimensionnel possède une réponse impulsionnelle, qui est le produit de convolution de celle des filtres monodimensionnels h(n) dans chaque direction.

Le filtre de Burt (Burt, 1983) a été introduit pour créer la première analyse pyramidale non-orthogonale, la pyramide Laplacienne dérivée d'une pyramide Gaussienne. Il satisfait à des contraintes de normalisation, de symétrie, d'unimodalité et d'équidistribution au niveau supérieur. Il est symétrique, de taille 2M+1. On a ainsi, pour M = 2, h(3) = 0,4; h(2) = h(4) = 0,25; h(1) = h(5) = 0,05.

Le filtre de Meer (Meer, et al. 1987) cherche à s'approcher d'un filtrage passe-bas parfait, dont la réponse impulsionnelle est un sinus cardinal. Il propose l'utilisation d'un filtre demie-bande de taille 13. On a ainsi h(6) = 0,475; h(5) = h(7) = -0,298; h(4) = h(8) = 0; h(3) = h(9) = -0,087; h(2) = h(10) = 0; h(1) = h(11) = 0,051; h(0) = h(12) = 0.

Le filtre de Daubechies (Daubechies, 1988) permet d'effectuer une analyse multirésolution de l'image et de la décomposer sur des bases d'ondelettes orthogonales à support compact. Les filtres obtenus sont de types conjugués en quadrature. Pour un filtre de taille 4, on a h(0) = 0,483; h(1) = 0,836; h(2) = 0,224; h(3) = -0,129.

Une fois que la pyramide de l'image observée est construite, en choisissant un des filtres mentionnés ci-dessus, l'adaptation de l'analyse pyramidale à l'algorithme ICM se déroule comme suit:

1) effectuer une segmentation de l'image du dernier niveau de la pyramide par un algorithme d'initialisation;

2) cette image segmentée sert d'initialisation pour l'algorithme ICM;

3) l'algorithme ICM pour le niveau courant est appliqué;

4) si l'on n'est pas au niveau 0 (résolution originale) de la pyramide, il faut projeter l'image segmentée résultant de la convergence de l'algorithme ICM sur le niveau de résolution immédiatement supérieur. Cette image va servir d'initialisation. Il faut ensuite reprendre au pas 3). Si l'on est au niveau 0 de la pyramide, l'algorithme prend fin : l'image segmentée de ce niveau constitue le résultat de l'algorithme global.

4. APPLICATION AUX IMAGES SATELLITAIRES : RÉSULTATS ET ANALYSE

L'algorithme ICM a été appliqué à l'image de Mamora (figure 5), en choisissant consécutivement les différents modèles de fonction d'énergie proposés dans la section 3.2, ainsi qu'avec le modèle multilogistique

classique. Les fonctions d'énergie sont composées de quatre modèles simples de lissage E_{2_2}, E_{2_3} et E_{2_4} de deux modèles complexes préservant les discontinuités E_{2_5} et E_{2_6}, Les résultats de l'application de l'algorithme ICM, utilisant le troisième et le sixième modèle de fonction d'énergie sont présentés à titre d'exemples sur les figures 6b et 6c. La figure 6d présente le résultat du modèle multilogistique. La figure 5 canal 1 représente la carte de la réalité de terrain. Les pourcentages d'erreur sont présentés sur le tableau I. Ces pourcentages d'erreur dépendent du paramètre β de régularisation du lissage et du paramètre γ de régularisation de pénalité utilisé dans le cas des fonctions préservant les discontinuités E_{2_5} et E_{2_6}. Ces paramètres sont déterminés d'une manière expérimentale.

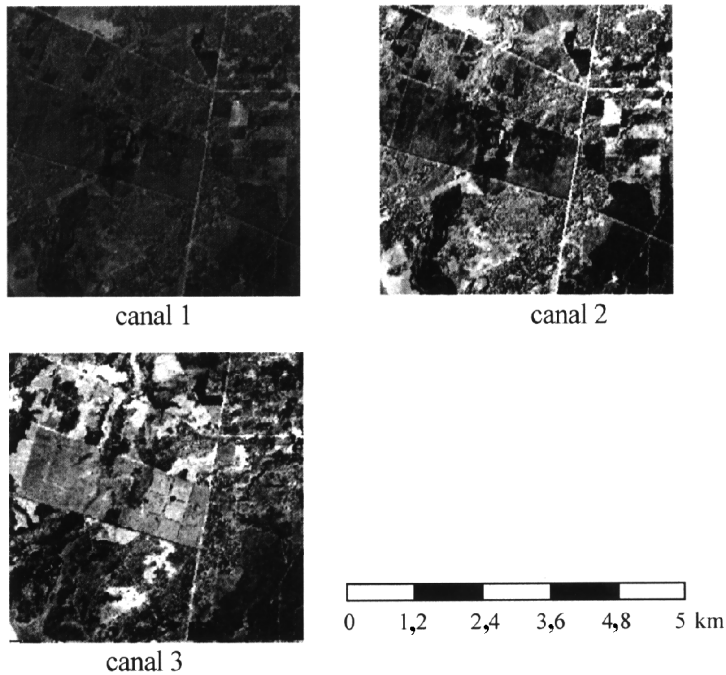


FIGURE 5 Image multispectrale HRV(XS) de SPOT de la région de Mamora. *SPOT multispectral image HRV(XS) (Mamora area)*

L'analyse des résultats montre que la fonction E_{2_3} introduit, d'une part, trop de lissage et, d'autre part, une perte de discontinuité. Le pourcentage d'erreur de classification évalué en pourcentage de pixels erronés est de

24 %. L'analyse du résultat de l'ICM avec la fonction E_{2_6} montre que toutes les classes sont bien discriminées. Les contours sont assez bien préservés et il n'existe pas trop de lissage. Le résultat obtenu est plus proche de la réalité de terrain avec un pourcentage d'erreur de 20 %. Cette sixième fonction d'énergie semble la plus efficace pour effectuer une classification des images satellitaires.

TABLEAU I Résultats des différents modèles de fonction d'énergie : pourcentage d'erreur et paramètres de lissage et de pénalité. *Results for various energy functions; error rate; smoothing and penalties parameters*

Fonction	*Paramètre de lissage*	*Paramètre de pénalité*	*% d'erreur*
E_{2_1}	1	-	29
E_{2_2}	1	-	26
E_{2_3}	1	-	24
E_{2_4}	1	-	37
E_{2_5}	0,2	6	22
E_{2_6}	0,2	10	20

La méthode de la moyenne pondérée a donné de meilleurs résultats par rapport à la méthode de la moyenne arithmétique utilisée pour incorporer les caractéristiques spectrales des classes dans les fonctions d'énergie.

L'analyse pyramidale de l'algorithme ICM a été appliquée afin de réduire le temps de traitement. Dans cette application, les trois algorithmes utilisés sont:

- ICMP-F-Burt : algorithme ICM pyramidal utilisant le filtre de Burt;
- ICMP-F-Meer : algorithme ICM pyramidal utilisant le filtre de Meer;
- ICMPO-F-Daubechies : algorithme ICM pyramidal par ondelettes utilisant les filtres de Daubechies.

Le résultat de l'algorithme ICMP-F-Burt (figure 7a) s'avère meilleur par rapport à ceux des autres algorithmes de classification pyramidale (figures 7b et 7c), puisque la forme des objets est davantage conservée et le pourcentage d'erreur est réduit. En comparant ICMP-F-Burt à l'algorithme ICM sans analyse pyramidale, nous concluons que l'algorithme ICM pyramidal utilisant le filtre de Burt donne des résultats proches de ceux de l'algorithme ICM.

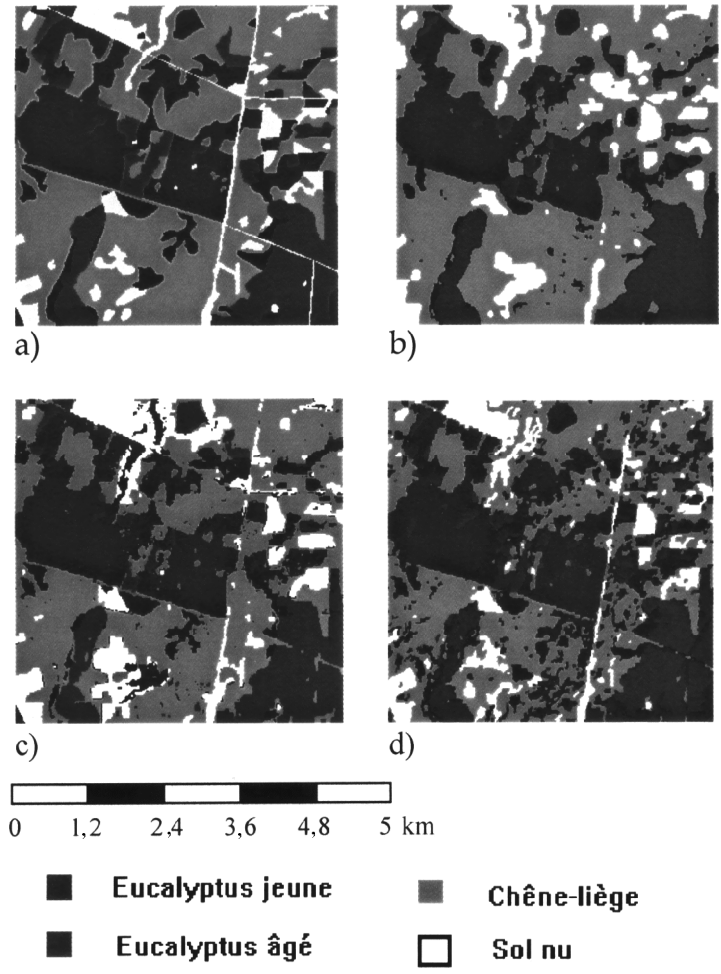


FIGURE 6 Résultats de classification et comparaison visuelle avec la carte de la réalité de terrain pour la région de Mamora. a) Carte de réalité de terrain de Mamora. b) Résultat de la classification markovienne obtenue à l'aide de l'algorithme ICM par la troisième fonction de lissage. c) Résultat de la classification markovienne obtenue à l'aide de l'algorithme ICM par la sixième fonction de préservation des discontinuités. d) Résultat de la classification markovienne obtenue à l'aide de l'algorithme ICM utilisant le modèle multilogistique. *Classification results and visual comparison with the ground truth map. (Mamora area)* (voir image couleur I à la fin de cette revue)

Les résultats du tableau II permettent de constater que les différences de rapidité entre les algorithmes ICM pyramidaux et l'algorithme ICM sans

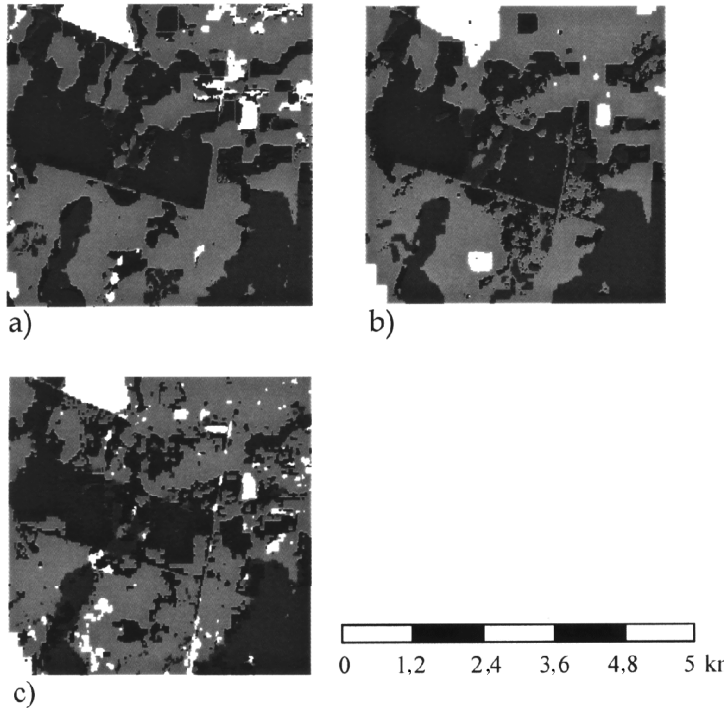


FIGURE 7 Résultats de classification avec les algorithmes pyramidaux pour la région de Mamora. a) Résultat de l'algorithme ICMP-F-Burt b) Résultat de l'algorithme ICMP-F-Meer c) Résultat de l'algorithme ICMPO-F-Daubechies. *Classification results with pyramidal algorithms (Mamora area)* (voir image couleur II à la fin de cette revue)

analyse pyramidale sont de l'ordre de 50 %. Généralement, moins de 8 itérations sont nécessaires lorsque l'analyse pyramidale est utilisée, alors que sans l'analyse pyramidale, l'algorithme ICM converge après 28 itérations.

Une étude comparative a été effectuée entre les résultats de l'algorithme ICM avec la fonction E_{2_6}, dans sa structure pyramidale (ICMP-F-BURT) ou non, et ceux des algorithmes conventionnels de classification (tableau III). L'objectif de cette étude est de déterminer l'algorithme le plus efficace du point de vue précision et rapidité. Les algorithmes conventionnels de classification sont : l'algorithme du maximum de vraisemblance dirigé (MDV), l'algorithme Isodata non dirigé et l'algorithme ICM avec modèle multilogistique (ICM classique).

TABLEAU II Comparaison des différents algorithmes de classification markovienne pyramidale (zone de Mamora). *Comparison of various pyramidal markovian classification algorithms. (Mamora area)*

Algorithme	*Iter niv –2*	*Iter niv-1*	*Iter niv-0*	*Iter Equi*	*Tps CPU*	*Erreur (%)*
ICM-2	----	----	----	28	17 min 31 s	20
ICMP-F-Burt	4	4	7	8,3	9 min 14 s	22
ICMP-F-Meer 3		6	7	7,6	8 min 46 s	24
ICMPO-F-Daubechies	5	6	5	4,2	7 min 23 s	28

TABLEAU III Temps de CPU et pourcentages d'erreur des différents algorithmes de classification markovienne pyramidale et de classification conventionnelle (zone de Mamora). *CPU time and error rate for various pyramidal markovian classification algorithms and for conventional classification algorithms. (Mamora area)*

Algorithme	*MDV*	*ISODATA*	*ICM multilogistique*	*ICM* E_{2_6}	*ICMP-F-Burt* E_{2_6}
Temps de CPU	5 min	6 min 46 s	15 min 28 s	17 min 31 s	9 min 14 s
% d'erreur	26	32	24	20	22

L'analyse des résultats obtenus montre que l'algorithme ICM avec la fonction d'énergie E_{2_6} est le seul algorithme qui a discriminé toutes les classes avec le moins de confusion. Le taux de bonne classification de l'algorithme ICM est de 80 %. On peut également conclure que l'algorithme ICMP-F-Burt a aussi montré de bonnes performances, même s'il a perdu quelques contours. Cela est dû à l'effet de filtrage et de sous-échantillonnage utilisé lors de la construction de la pyramide.

Le tableau III résume les temps de calcul nécessaires pour les différents algorithmes de classification markovienne et conventionnelle pour la zone de Mamora. Le temps de traitement de l'algorithme ICM, qui incorpore les contraintes spatiales et la préservation des discontinuités, est clairement plus long que celui des algorithmes conventionnels. Cependant, l'analyse pyramidale permet d'assurer un gain en temps de 50 % en comparant à l'algorithme ICM.

En conclusion, l'application de l'algorithme ICM à l'image satellitaire de Mamora indique une précision accrue de la classification en comparaison avec les méthodes conventionnelles. L'analyse pyramidale permet de diminuer le temps de calcul de 50 %, tout en conservant des performances comparables.

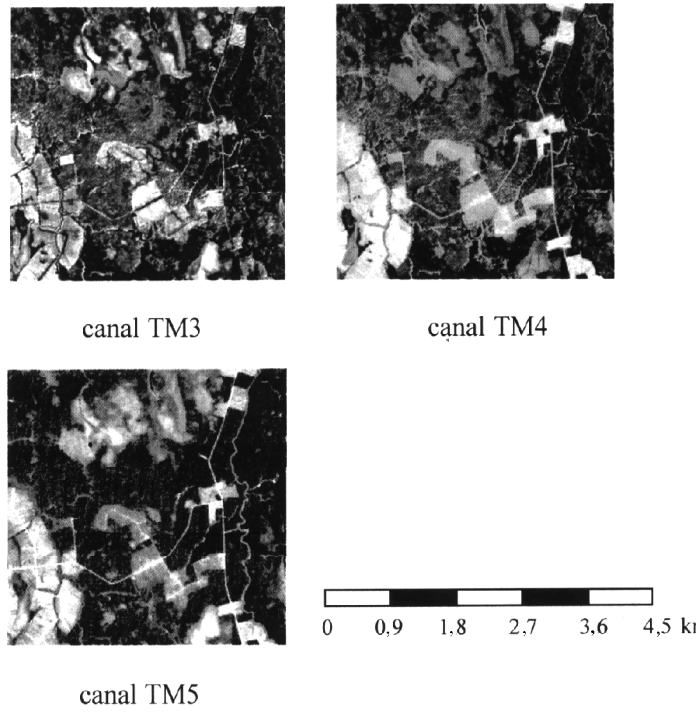


FIGURE 8 Image TM de LANDSAT de la région de Matagami. *LANDSAT TM image (Matagami area)*

TABLEAU IV Comparaison des différents algorithmes de classification markovienne pyramidale (zone de Matagami). *Comparison of various pyramidal markovian classification algorithms. (Matagami area)*

Algorithme	*Iter niv-1*	*Iter niv-0 Iter*	*Iter Equi*	*Tps CPU*	*% d'erreur*
ICM	----	----	22	15 min 54 s	20
ICMP-F-Burt	4	6	7,2	8 min 36 s	19
ICMP-F-Meer	4	7	8,2	9 min 12 s	24
ICMPO-F-Daubechis	5	6	4,6	7 min 04 s	28

En plus de l'image de base de Mamora, l'algorithme ICM a été testé sur une autre image représentant la zone forestière de Matagami (figure 8). Les résultats de la classification markovienne pyramidale sont présentés sur les figures 9 et 10 et sur le tableau IV. Le tableau V représente les temps de calcul et les pourcentages d'erreur.

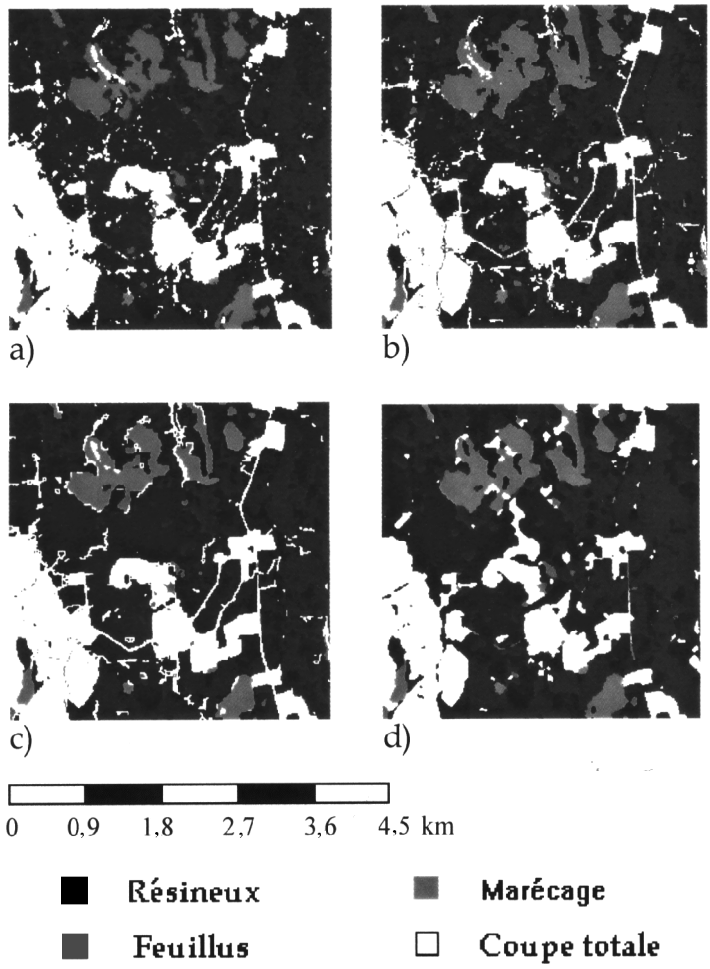


FIGURE 9 Résultats de classification et comparaison visuelle avec la carte de la réalité de terrain pour la région de Matagami. a) Carte de réalité de terrain de Matagami b) Résultat de la classification markovienne obtenue à l'aide de l'algorithme ICM par la troisième fonction de lissage c) Résultat de la classification markovienne obtenue à l'aide de l'algorithme ICM par la sixième fonction de préservation des discontinuités d) Résultat de la classification markovienne obtenue à l'aide de l'algorithme ICM utilisant le modèle multilogistique. *Classification results and visual comparison with the ground truth map. (Matagami area)* (voir image couleur III à la fin de cette revue)

L'analyse des résultats de la classification de l'image de Matagami a permis de confirmer que l'algorithme ICM avec E_{2_6} reste le plus précis par

rapport aux autres algorithmes. De plus, l'analyse pyramidale permet d'assurer un gain en temps de 50 % par rapport au cas sans analyse pyramidale. Le résultat de l'algorithme ICM classique présente toujours le problème de pixels isolés et celui de la séparation des surfaces d'intensité uniforme.

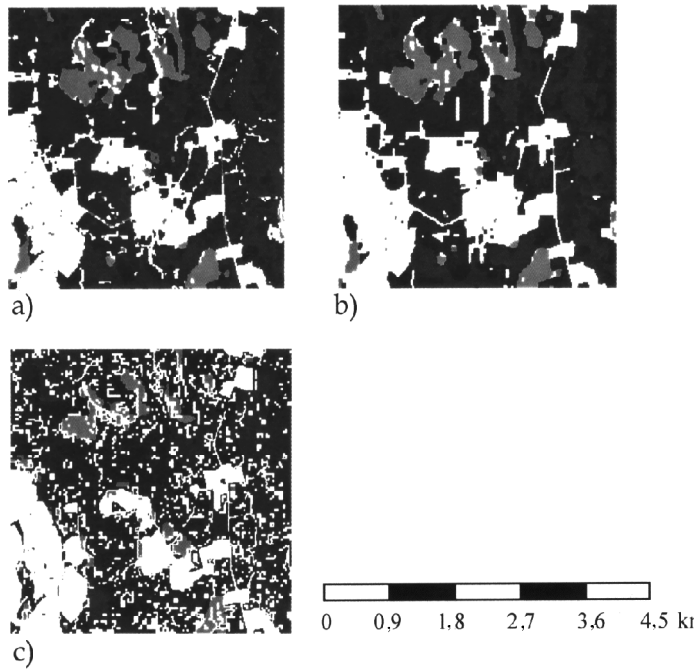


FIGURE 10 Résultats de classification avec les algorithmes pyramidaux pour la région de Matagami. a) Résultat de l'algorithme ICMP-F-Burt b) Résultat de l'algorithme ICMP-F-Meer c) Résultat de l'algorithme ICMPO-F-Daubechies. *Classification results with pyramidal algorithms (Matagami area)* (voir image couleur IV à la fin de cette revue)

TABLEAU V Temps de CPU et pourcentages d'erreur des différents algorithmes de classification markovienne pyramidale et de classification conventionnelle (zone de Matagami). *CPU time and error rate for various pyramidal markovian classification algorithms and for conventional classification algorithms. (Matagami area)*

Algorithme	*MDV*	*ISODATA*	*ICM multilogistique*	*ICM* E_{2_6}	*ICMP-F-Burt* E_{2_6}
Temps de CPU	5 min	6 min 46 s	16 min 10 s	18 min 54 s	8 min 36 s
% d'erreur	26	32	24	18	19

5. CONCLUSION

Cette étude a montré, sur deux exemples concrets, l'intérêt que pouvait présenter, pour la segmentation automatique d'images de télédétection, la modélisation par champ de Gibbs associée à une méthode bayésienne. On constate une meilleure homogénéité des classes obtenues comparativement à ce que donnent des algorithmes classiques de classification non dirigée, tels que l'ISODATA. Le choix de la fonction d'énergie, sans être crucial, conditionne quand même les performances et il paraît judicieux d'employer une représentation complexe incluant une fonction d'énergie liée à un processus de ligne.

Les méthodes bayésiennes de segmentation utilisant les champs de Markov pourraient être rejetées *a priori*, dans un contexte opérationnel, à cause de leur aspect itératif et des temps de calcul qui en découlent. On a vérifié que, dans le cas de l'algorithme ICM, le plus simple à mettre en oeuvre même s'il présente des inconvénients en terme d'optimalité, on obtient des durées comparables aux algorithmes classiques, notamment en utilisant une analyse pyramidale d'image.

L'application à la forêt de ces algorithmes n'est pas spécifique, et on peut penser obtenir aussi de bons résultats dans le domaine de la cartographie de zones agricoles. Cette étude peut aussi être poursuivie en introduisant une corrélation entre pixels d'une même classe dans la distribution conditionnelle gaussienne et en associant des algorithmes d'estimation de paramètres pour le champ des classes et celui des textures.

Remerciements

Nous exprimons nos remerciements au Centre Royal de Télédétection du Maroc, ainsi qu'au Centre de foresterie des Laurentides au Québec, pour la mise à notre disposition des données utilisées dans cette recherche et d'autre part, à l'Agence canadienne de développement international et au Programme de la Francophonie pour leur aide financière.

Références

Besag, J. (1986) On the Statistical Analysis of Dirty Pictures. Journal of Royal Statistical Society, vol. 48, n° 3, p. 259–302.

Blanc-Féraud, L. et Barlaud, M. (1990) Restauration d'image bruitée par analyse multirésolution et champs de Markov. Traitement du Signal, vol. 10, n° 2, p. 171–184.

Boucher, J.M, Bénié, G.B. and Plehiers. S. (1994) Local and Global Multiscale Image Classification. Proceedings of S.P.I.E., vol. 2303, p. 485–493.

Boucher, J.M. et Léna, Ph. (1993–1994) Classification bayésienne non supervisée. Application à la forêt de Paimpont. Photo-interprétation, n° 1993/4–1994/1–2, p. 75–84.

Burt, P.J. and Adelson, E.H (1983) The Laplacian pyramid as a compact image code. IEEE Trans. Commun., vol. 31, n° 4, p. 532–540.

Celeux, G. et Diebolt, J. (1986) L'algorithme SEM : un algorithme d'apprentissage probabiliste pour la reconnaissance de mélange de densités. Revue de statistique appliquée, vol. 34, n° 2, p. 35–52.

Daubechies, I. (1988) Orthonormal Bases of Compactly Supported Wavelets. Communications on Pure and Applied Mathematics, vol. XLI, p. 909–996.

Delignon, Y., Marzouki, A. and Pieckzynski, W. (1997) Estimation of generalized mixtures and its application in image segmentation. IEEE Trans. on Image Processing, vol. 6, n° 10, p. 1376–1387.

Derin, H., and Elliott, H. (1987) Modeling and Segmentation of Noisy and Textured Images Using Gibbs Random Fields. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 9, n° 1, p. 39–55.

Fau, R., Bénié, G.B., Boucher, J.M. et He, D.C. (1994) Segmentation markovienne pyramidale d'images. Canadian Journal of Remote Sensing, vol. 20, n° 2, p. 150–155.

Geman, S. and Geman, D. (1984) Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 6, n° 6, p. 721–741.

Guyon, X. (1993) Champs aléatoires sur un réseau. Modélisations, statistique et applications. éd. Masson, Paris, 226.

Kelly, P.A., Derin, H. and Hartt, K.D. (1988) Adaptive segmentation of speckled images using a hierarchical random field model, IEEE Trans. on Acoustic, Speech and Signal Processing, vol. 36, n° 10, p. 1628–1641.

Kim, K. and Crawford, M.M. (1991) Adaptive Parametric Estimation and Classification of Remotely Sensed Imagery Using a Pyramid Structure. IEEE Transactions on Geoscience and Remote Sensing, vol. 29, n° 4, p. 481–493.

Laferté, J.M., Heitz, F. et Perez, P. (1998) Modèles markoviens d'images et algorithmes d'estimation non linéaire sur le quadarbre. Traitement du Signal, vol. 15, n° 3, p. 213–230.

Lee, S. and Crawford, M.M. (1991) An adaptive reconstruction system for spatially correlated multispectral multitemporal images. IEEE Transactions on Geoscience and Remote Sensing, vol. 29, n° 4, p. 494–508.

Mallat, S. (1989) A Theory for Multiresolution Signal Decomposition: the Wavelet Representation. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 11, n° 7, p. 674–693.

Marroquin, J., Mitter, S. and Poggio, T. (1987) Probabilistic solution of ill-posed problems in computational vision. Journal of the American Statistical Association, vol. 82, p. 76–89.

Meer, P. Baugher, E.S., and Rosenfeld, A. (1987) Frequency Domain Analysis and Synthesis of Image Generating Kernels. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 9, n° 4, p. 512–522.

Pieckzynski, W. (1994) Champs de Markov cachés et estimation conditionnelle itérative. Traitement du Signal, vol. 11, n° 2, p. 141–153.

Quelle, H.Ch., Boucher, J.-M. and Pieckzynski, W. (1996) Adaptive parameter estimation and unsupervised image segmentation. Machine Graphics and Vision, vol. 5, n° 4, p. 613–631.

Won, C. S. and Derin, H. (1992) Unsupervised segmentation of noisy and textured images using markov random fields. vol. 54, n° 4, p. 308–328.

Wright, W. (1989). A Markov Random Field Approach to Data Fusion and Colour Segmentation. Image Computer Vision, vol. 7, p. 144–150.