

Classification Contextuelle d'Images de Télédétection Utilisant la Programmation Génétique

Salim Chitroub

Laboratoire de Traitement des Signaux, Faculté d'Electronique et d'Informatique. U. S. T. H. B.

B. P. 32, El-Alia, Bab-Ezzouar, 16111, Alger, ALGERIE.

Fax : (213) (21) 24-71-87. Email: s_chitroub@hotmail.com

Résumé : Une méthode de classification contextuelle d'images de télédétection basée sur le formalisme Markov-Bayes et la programmation génétique est proposée. Le modèle Markovien de l'image pour la classification contextuelle est présenté dans un cadre général facile à utiliser et implémenter. Le formalisme Markov-Bayes permet de reformuler le modèle Markovien de l'image sous forme d'une fonction d'énergie à minimiser. Cette fonction n'est pas convexe et sa minimisation pose le problème d'optimisation combinatoire. Une méthode d'optimisation basée sur la programmation génétique est alors proposée. Les résultats obtenus sur une image réelle de télédétection sont satisfaisants.

1. Introduction

La télédétection spatiale, ou l'observation de la Terre depuis l'espace, contribue, dans une large mesure, au suivi et à la compréhension de nombreux processus de l'environnement. Grâce aux images fournies par une large gamme de capteurs embarqués dans les satellites de télédétection civile, cette dernière est devenue une technique de plus en plus utilisée que ce soit pour la gestion de l'environnement, localisation et suivi des ressources naturelles, étude de la diffusion de la maladie ou des parasites des récoltes, localisation de réseaux routiers, identification de failles sismiques, planification de grands projets de construction, etc.. [1]-[3].

La classification d'images de télédétection est une analyse quantitative qui consiste à regrouper, dans une même entité ou classe, tous les pixels ayant la même signature spectrale ou polarimétrique tout en respectant leur localisation spatiale. Le résultat est une image des régions homogènes représentant des classes correspondant aux différents thèmes au sol. Deux catégories de méthodes de classification ont été développées dans la littérature, méthodes de classification ponctuelle et méthodes de classification contextuelle. L'inconvénient de la classification ponctuelle réside dans le fait que le

pixel de l'image est classé en utilisant seulement sa valeur radiométrique sans tenir compte des valeurs des pixels voisins [3]. Le résultat est souvent une image bruitée qui présente l'apparence d'un phénomène communément appelé sel et poivre ("salt and pepper" en anglais) nuit à la lisibilité et à l'interprétation de l'image classifiée.

Les méthodes de classification contextuelle se proposent d'être des méthodes plus robustes dans le sens où elles consistent à optimiser les résultats de classification ponctuelle. Ces méthodes reposent sur la notion de l'information contextuelle (spatiale) apportée à un pixel par un voisinage qui lui est approprié, en utilisant des outils mathématiques rigoureux [3]-[9].

En raison de la capacité dont il dispose pour l'incorporation d'information de contexte, le formalisme de la modélisation du contexte spatial par les champs aléatoires de Markov "*Markov Random Fields (MRF)*" est l'outil le plus répandu. Cependant, la classification Bayésienne associée à la modélisation Markovienne d'images présente une fonction d'énergie non-convexe. Le minimum global de cette fonction est la caractéristique de l'image classifiée recherchée. La minimisation de cette fonction pose le problème d'optimisation combinatoire. Pour cela, des méthodes métaheuristiques modernes ont été considérées dans la littérature [9]-[16].

On propose dans cet article une méthode de classification contextuelle d'images de télédétection basée sur le formalisme Markov-Bayes dont la minimisation de la fonction d'énergie déduite est obtenue en utilisant la programmation génétique. La programmation génétique est une branche, mais beaucoup plus puissante, des algorithmes génétiques. La différence principale entre la programmation génétique et les algorithmes génétiques est la représentation de la solution [17]. La programmation génétique fournit une méthode pour créer automatiquement des programmes machines comme solutions de problème posé. La programmation automatique est réalisée en utilisant les principes des opérateurs génétiques.

L'organisation du reste de l'article est donnée comme suit. Le paragraphe 2 est consacré à présenter, dans un cadre général facile à utiliser et implémenter, le modèle Markovien d'image. Le formalisme Markov-Bayes ainsi déduit et la fonction d'énergie correspondante sont détaillés dans ce paragraphe. La méthode d'optimisation basée sur la programmation génétique est donnée dans le paragraphe 3. Les résultats obtenus à l'aide d'une image réelle de télédétection sont donnés et commentés dans le paragraphe 4. On conclut l'article dans le dernier paragraphe.

2. Modélisation Markovienne d'Images

Les pixels des images de télédétection ne sont pas indépendants les uns des autres. La classification contextuelle consiste à intégrer, dans le processus de classification, la notion de l'information spatiale apportée à un pixel par un voisinage qui lui est approprié. En raison de la capacité dont il dispose pour l'incorporation d'information de contexte, le formalisme de la modélisation du contexte spatial par les champs aléatoires de Markov "Markov Random Fields (MRF)" est l'outil le plus répandu [6].

2.1 Champs aléatoires de Markov

L'utilisation des champs aléatoires de Markov est devenue populaire depuis la publication des résultats de Geman et Geman [18]. En général, on définit le MRF sur les graphes. Soit $g = (S, \xi)$ un graphe où $S = \{s_1, s_2, \dots, s_N\}$ est l'ensemble des sommets (sites) et ξ est l'ensemble des arêtes. Deux points s_i et s_j sont voisins s'il existe une arête $e_{ij} \in \xi$ entre eux. L'ensemble des points qui sont voisins d'un site s (voisinage de s) est noté V_s . Le système $V = \{V_s | s \in S\}$ est un système de voisinage pour g si $s \notin V_s$ et $s \in V_r \Leftrightarrow r \in V_s$. Un sous-ensemble $C \subseteq S$ est une clique si chaque paire de sites dans C est voisine. Soit ζ note l'ensemble des cliques. A chaque site du graphe, on attribue une étiquette λ appartenant à un ensemble fini des étiquettes A . Un tel étiquetage est appelé une configuration w qui a une certaine probabilité $P(w)$. La restriction de w à un sous-ensemble $T \subset S$ est notée par w_T et $w_s \in A$ désigne l'étiquette au site s . Dans ce qui suit, on utilise les mesures de probabilité assignées à l'ensemble de toutes les configurations possibles Ω . La variable est un champ aléatoire de Markov par rapport au système de voisinage V si: $w \in \Omega : P(X = w) > 0$, et $s \in S$ et $w \in \Omega$. $P(X_s = w_s | X_r = w_r, r \neq s) = P(X_s = w_s | X_r = w_r, r \in V_s)$

Le théorème d'Hammersly-Clifford fait la liaison entre les champs de Markov et la distribution de Gibbs [4], [19]. La variable aléatoire X est un champ de Markov par rapport au système de voisinage V si et seulement si $\pi(w) = P(X = w)$ est une distribution de Gibbs :

$$\pi(w) = \frac{1}{Z} \exp\left(-\sum_{c \in \zeta} \mathbf{V}_c(w)\right) \quad (1)$$

L'intérêt du théorème d'Hammersly-Clifford est de spécifier un champ de Markov de façon simple à partir d'une formulation énergétique au lieu de caractéristiques probabilistes locales ce qui est généralement plus difficile à calculer. En traitement d'images S , est considérée comme une grille L telle que $\forall s \in S : s = (i, j)$ et on définit les systèmes de voisinage homogènes d'ordre n :

$$V^n = \{V_{(i,j)}^n : (i, j) \in L\} \quad (2)$$

$$V_{(i,j)}^n = \{(k, l) \in L : (k-i)^2 + (l-j)^2 \leq n\} \quad (3)$$

Il est clair que $V^0 \equiv S$ et pour tous les $n \geq 0 : V^n \subset V^{n+1}$. Les systèmes de voisinage d'ordre un ($n=1$) et d'ordre deux ($n=2$) sont les plus utilisés dans la pratique. Les systèmes de voisinages d'ordre supérieur à deux ne sont pas utilisés car leur fonction d'énergie est trop compliquée et nécessitent un temps de calcul élevé.

2.2 Un Modèle Markovien général d'images

On présente ici la formulation mathématique générale d'un modèle Markovien d'image. Soit $R = \{r_1, r_2, \dots, r_K\}$ l'ensemble des sites et $Y = \{Y_r : r \in R\}$ l'ensemble des observations sur ces sites. L'ensemble de toutes les observations possibles $y = \{y_{r_1}, y_{r_2}, \dots, y_{r_N}\}$ est noté par Φ . On a un autre ensemble de sites $S = \{s_1, s_2, \dots, s_N\}$, chacun de ces sites peut prendre une étiquette de $A = \{1, 2, \dots, M\}$. L'espace de configuration Ω est l'ensemble de tous les étiquetages possibles $w = \{w_{s_1}, w_{s_2}, \dots, w_{s_N}\}$, $w_s \in A$. Le but est de modéliser les étiquettes et les observations avec un champ aléatoire joint $(X, Y) \in \Omega \times \Phi$. $X = \{X_s\}_{s \in S}$ est appelé le champ des étiquettes et $Y = \{Y_r\}_{r \in R}$ est appelé le champ des observations.

2.2.1 Estimateur Bayésien

Tout d'abord, on construit un estimateur Bayésien de champ des étiquettes. On peut exprimer la probabilité jointe ainsi que la probabilité conditionnelle par les distributions *a priori* et *a posteriori* :

$$P_{X|Y}(w|y) \propto P_{Y|X}(y|w)P_X(w) \quad (4)$$

L'estimateur est donné par la fonction de décision suivante :

$$\delta : \Phi \rightarrow \Omega \Rightarrow y \mapsto \delta(y) = \hat{w} \quad (5)$$

Soit $C(w, \delta(y))$ la fonction de coût. Le risque de Bayes est donné par :

$$r(P_X, \delta) = E\{C(w, \delta(y))\} \quad (6)$$

L'estimateur doit avoir un risque de Bayes minimal tel que :

$$\hat{w} = \arg \min_{\tilde{w} \in \Omega} \int_{w \in \Omega} C(w, \tilde{w}) P_{X|Y}(w|y) dw \quad (7)$$

On présente ici les estimateurs Bayésiens les plus connus [24].

2.2.2. Estimateur maximum a posteriori (MAP)

L'estimateur MAP est le plus souvent utilisé en traitement d'images. Sa fonction de coût est définie par :

$$C(w, \tilde{w}) = 1 - \Delta_{\tilde{w}}(w) \quad (8)$$

où $\Delta_{\tilde{w}}(w)$ est la masse de Dirac en \tilde{w} . Il est clair que cette fonction donne le même coût pour chaque configuration différente de \tilde{w} . En utilisant l'équation (7) et l'équation (8), l'estimateur MAP du champ des étiquettes devient :

$$\hat{w}_{MAP} = \arg \max_{w \in \Omega} P_{X|Y}(w|y) \quad (9)$$

Cet estimateur, pour une observation donnée, fournit les modes de la distribution *a posteriori*. Cependant, l'équation (9) pose un problème d'optimisation combinatoire et par conséquent, exige l'utilisation d'algorithmes spécifique d'optimisation.

2.2.3. La distribution a priori

Soit X est un MRF avec le système de voisinage $\tilde{V} = \{\tilde{v} : s \in S\}$ dont la distribution est définie par :

$$P(X = w) = \frac{1}{Z} \exp(-\tilde{U}(w)), \quad \tilde{U}(w) = \sum_{c \in \tilde{c}} \tilde{V}_c(w) \quad (10)$$

où $\tilde{U}(w)$ est la fonction d'énergie. Cette représen-

tation utilise, pour la définition de la probabilité *a priori*, la distribution de Gibbs dont l'avantage est que l'on peut travailler avec les énergies potentielles sur les cliques au lieu de l'énergie globale.

2.3. Formalisme Markov-Bayes pour la classification contextuelle d'images

On présente ici le formalisme Markov-Bayes pour la classification contextuelle d'images. Le but est de trouver une image classifiée qui maximise la probabilité *a posteriori* $P(w|Y)$, c'est à dire l'estimateur MAP :

$$\hat{w} = \arg \max_{w \in \Omega} \prod_{s \in S} P(y_s | w_s) \prod_{C \in \tilde{c}} \exp(-V_C(w_C)) \quad (11)$$

Les observations sont reliées au processus des étiquettes par le modèle qui modélise la relation entre le champ des étiquettes X et le processus des observations Y . La plupart des problèmes peuvent se formaliser par la fonction suivante [20] :

$$Y = \Psi(H(X), B) \quad (12)$$

Au niveau de chaque pixel, on a la fonction suivante:

$$\forall r \in R : Y_r = \Psi(H_r(X_{\Psi(r)}), B_r) \quad (13)$$

où $\Psi(a, b)$ est une fonction inversible en a . H_r est une fonction locale définie sur un petit sous-ensemble $\Psi(r)$ de S . B est une composante aléatoire dont la distribution est telle que $P_b() = \prod_{r \in R} P_b()$. On a alors la relation suivante :

$$P_{Y|X}(y|w) = \prod_{r \in R} P_{B_r}(\Psi^{-1}(H_r(w_{\Psi(r)}), y_r)) \quad (14)$$

En supposant que $P_b() > 0$ en chaque site $r \in R$, la distribution conditionnelle du champ des observations X sachant Y , est définie par :

$$P_{YX}(y|w) = \exp\left(\sum_{r \in R} -\log(P_{B_r}(\Psi^{-1}(H_r(w_{\Psi(r)}), y_r)))\right) \quad (15)$$

En fin, on a la distribution *a posteriori* se met sous la forme suivante :

$$\frac{1}{Z} \exp\left(\sum_{r \in R} -\log(P_{B_r}(\Psi^{-1}(H_r(w_{\Psi(r)}), y_r))) + \sum_{c \in \tilde{c}} \tilde{V}_c(w)\right) \quad (16)$$

On remarque que la distribution *a posteriori* est aussi une distribution de Gibbs avec le système de voisinage V le plus petit qui contient tous les cliques dans \tilde{c} et les ensembles $\{\psi(r) : r \in R\}$:

$$\forall s \in S : V_s = \left(\bigcup_{r \in \Psi^{-1}(s)} \Psi(r) \{s\} \right) \cup \tilde{V}_s \quad (17)$$

On note la fonction d'énergie correspondante par $U(w, y)$:

$$\begin{aligned} U(w, y) &= \sum_{r \in R} -\log(P_{B_r}(\Psi^{-1}(H_r(w_{\Psi(r)}), y_r))) + \sum_{C \in \mathcal{C}} \tilde{V}_C(w) \\ &= \sum_{r \in R} V_r((w_{\Psi(r)}), y_r) + \sum_{C \in \mathcal{C}} \tilde{V}_C(w) \end{aligned} \quad (18)$$

On définit $V_r((w_{\Psi(r)}), y_r)$ d'une manière précise [20] :

$$V_r((w_{\Psi(r)}), y_r) = V_r(w_{\Psi(r)}) + \sum_{s \in \Psi(r)} V_{s,r}(w_s, y_r) \quad (19)$$

Donc, elle peut se mettre sous la forme :

$$\sum_{r \in R} V_r((w_{\Psi(r)}), y_r) = \sum_{r \in R} V_r(w_{\Psi(r)}) + \sum_{r \in R} \sum_{s \in \Psi(r)} V_{s,r}(w_s, y_r) \quad (20)$$

$$\sum_{r \in R} V_r((w_{\Psi(r)}), y_r) = \sum_{r \in R} V_r(w_{\Psi(r)}) + \sum_{s \in S} V_s(w_s, y_{\Psi^{-1}(s)}) \quad (21)$$

Finalement, on a la fonction d'énergie suivante :

$$\begin{aligned} U(w, y) &= \sum_{s \in S} V_s(w_s, y_{\Psi^{-1}(s)}) + \sum_{C \in \mathcal{C}} V_C(w) \\ &= U_1(w_s, y_{\Psi^{-1}(s)}) + U_2(w) \end{aligned} \quad (22)$$

La fonction d'énergie globale donnée dans (22) est la somme des deux termes suivants : Terme d'attache aux données caractérisé par la fonction d'énergie $U_1(w_s, y_{\Psi^{-1}(s)})$. Ce terme est directement calculé à partir des observations, pour cette raison il est appelé attache aux données. Terme de régularisation caractérisé par la fonction d'énergie $U_2(w)$. Ce terme traduit les interactions locales dans un voisinage spatial. C'est à travers ce terme que la classification optimale d'images est obtenue en utilisant des algorithmes d'optimisation.

3. Optimisation

La méthode de classification contextuelle déduite du formalisme Markov-Bayes donne une fonction d'énergie non-convexe (expression (22)) qui doit être minimisée pour trouver l'estimateur de champ des étiquettes (image classifiée optimale). Malheureusement, c'est un problème très dur, appelé problème combinatoire. Si on considère, par exemple, une image de taille 16×16 avec deux étiquettes (classes) possibles, on doit explorer

un espace de configurations de 2^{256} éléments pour trouver le minimum global de la fonction d'énergie (22) qui correspond à l'image classifiée recherchée. Cependant, ce problème combinatoire peut être exprimé sous la forme générale d'un « problème d'optimisation ».

Pour résoudre les problèmes d'optimisation combinatoire, les « métaheuristiques », principalement le recuit simulé, la méthode de recherche tabou et les algorithmes génétiques, se sont imposées comme des moyens efficaces. La méthode du recuit simulé repose sur une analogie avec le processus de recuit employé par les métallurgistes, les algorithmes génétiques s'inspirent de l'évolution des espèces dans la nature, et la méthode de recherche tabou exploite le concept de mémoire. Ces trois approches, totalement différentes, permettent en principe de trouver une bonne solution aux problèmes d'optimisation, moyennant un temps de calcul acceptable.

3.1. Programmation Génétique

La programmation génétique est une autre méthode basée sur la théorie de la sélection naturelle proposée pour la première fois par John Koza [17]. Koza s'est inspiré des concepts des algorithmes génétiques de John Holland [21]. Pour cela, certains disent que la programmation génétique est une branche des algorithmes génétiques. Elle a apporté quelques avantages en permettant la variation des tailles des chromosomes, et en changeant les techniques de croisement. Par exemple, un croisement avec un seul père, en programmation génétique, peut donner deux fils différents, or ce n'est pas le cas dans les algorithmes génétiques. La programmation génétique consiste à générer des programmes informatiques d'une manière aléatoire. Elle est constituée de quatre étapes essentielles :

1. Générer une population initiale.
2. Exécuter chaque programme et lui assigner une valeur qui indique son aptitude à résoudre le problème posé.
3. Créer une nouvelle population des programmes en utilisant les opérations génétiques.
4. Répéter les étapes 2 et 3 jusqu'à atteindre l'optimum.

3.2. Classification contextuelle utilisant la programmation génétique

Tout d'abord, pour rendre le lecteur plus familier avec l'application de la programmation génétique pour résoudre le problème combinatoire posé

on donne les significations des terminologies utilisées par les algorithmes génétiques dans notre application. Dans cette application de la programmation génétique, on démarre à partir d'un individu qui représente une image classifiée ponctuellement (la configuration initiale). La population initiale est constituée de N images, représentant la même scène observée, générées aléatoirement à partir de l'image classifiée ponctuellement. Soient W_1, W_2, \dots, W_N les N images ainsi générées. L'évaluation d'une population consiste à calculer la fonction d'adéquation (expression (22)) pour chaque configuration W_i . Dans la sélection, on choisit les configurations les mieux adaptés pour générer la prochaine population. Le croisement consiste à permuter, avec une probabilité de croisement, entre deux configurations de la même population. La mutation consiste à changer, avec une probabilité de mutation, plusieurs pixels dans toutes les configurations de la population. Pour le codage, on a opté pour le codage décimal (dans notre cas il s'agit du niveau de gris) où chaque chromosome représente l'étiquette de la classe à laquelle appartient le pixel. Le croisement utilisé est le croisement interne. La politique appliquée est « meilleur de tous » i.e. le croisement se fait entre la meilleure configuration et le reste de $(N-1)$ configurations de la population. La mutation est une opération assez importante vu son rôle dans notre cas. En fait, le croisement ne rapporte pas de nouveaux changements à la population, tandis que la mutation change des pixels et apporte de nouveaux changements.

La probabilité de sélection de la configuration est calculée en fonction de l'adéquation de la configuration. La probabilité d'adaptation cumulative de la configuration W_i , notée pac_i , est calculée en fonction de la probabilité de sélection p_i , telle que :

$$pac_i = \begin{cases} pac_i = p_i \\ \sum_{j=1}^i p_j \end{cases} \quad (23)$$

La sélection utilise la probabilité d'adaptation cumulative pour sélectionner la configuration convenable.

4. Résultats Expérimentaux

Le but de ce paragraphe est d'évaluer les performances de la méthode d'optimisation basée sur la programmation génétique sur les problèmes de classification contextuelle des images de télédétection en utilisant le formalisme Markov-Bayes décrit dans le sous-paragraphe 2. 2. 4.

Les tests ont été réalisés sur une image radar fournie par le système AirSAR de la NASA/JPL. On remercie Pr S. B. Serpico et Dr F. Melgani, de l'Université de Gênes en Italie, d'avoir eu la bonté de me fournir les images radar du système aéroporté AirSAR. Le système a fourni neuf images radars en trois bandes fréquentielles (bandes C, L, et P) et en trois polarisations chacune (HH, HV, VV). On a choisi l'image de la bande L polarisation HV pour réaliser les expériences (image de la figure 1 après une amélioration du contraste), car elle est la moins bruitée par le speckle. L'image, acquise en juillet 1989, représente une scène d'étude de 250x350 pixels d'une région agricole située près de Feltwell en Royaume Uni (tous droits réservés à *Hunting Technical Services Ltd. (UK)*). Les champs agricoles sont représentés par cinq classes de la couverture terrestre correspondant, respectivement, à cinq types de récoltes : carottes, pommes de terre, sol nu, chaume et betteraves à sucre.

La figure 2 représente le résultat de la classification ponctuelle de l'image radar de la figure 1. Ce résultat a été obtenu en utilisant la méthode de la classification non-supervisée floue proposée dans [22]. Cette image est la configuration initiale à optimiser en utilisant les deux méthodes d'optimisation : recuit simulé et programmation génétique. La méthode de recuit simulé a été utilisée à titre de comparaison avec la méthode basée sur la programmation génétique. Les résultats obtenus avec ces deux méthodes sont donnés dans les figures 3 et 4, respectivement. La température initiale, l'énergie initiale, l'énergie finale (ou le minimum atteint par la méthode), et le temps d'exécution des deux méthodes sont rassemblés dans le tableau 1.

En interprétant les images résultats finaux de la classification contextuelle (figures 3 et 4), on constate que les méthodes d'optimisation : recuit simulé et programmation génétique ont rendu l'image de la configuration initiale (figure 2) plus homogène et plus claire. Ceci se caractérise par le changement du nombre de pixels des différentes classes avant et après le processus d'optimisation (figure 5) ce qui reflète l'immigration des pixels mal classifiés dans les premières configurations d'une classe à une autre. Bien que ces méthodes rencontrent certaines difficultés dans la séparation du bruit (ou pixel mal classifié) et du pixel contour, l'aperçu général de l'image résultat de la classification contextuelle est plus net et plus parlant sur l'état de la surface de la scène imagée que celui de l'image de la configuration initiale. Ces résultats font ressortir des détails qui sont difficiles à discriminer dans l'image de la figure 2.

A titre de comparaison, on constate que les résultats du recuit simulé et programmation génétique se ressemblent, mais leurs temps d'exécution sont différents. La programmation génétique est la méthode la plus coûteuse en temps de calcul (tableau 1). On justifie la qualité de la méthode de la programmation génétique par le fait que la température initiale choisie est relativement petite par rapport à ce qu'il faut pour aboutir à un meilleur résultat de cette méthode [17]. Quoique l'image obtenue soit plus nette et précise, si on augmente la valeur de la température initiale, ceci se fait au détriment du temps de calcul qui devient prohibitif. Les mêmes remarques peuvent être reformulées pour la méthode recuit simulé qui converge théoriquement vers l'optimum global en temps infini [23].

5. Conclusion

Dans cet article, une méthode de classification contextuelle d'images de télédétection est présentée. En premier lieu, la modélisation Markovienne d'images est abordée et le formalisme Markov-Bayes est déduit. Ceci consiste à utiliser les champs aléatoires de Markov et l'estimation Bayésienne, en particulier l'estimation par le Maximum A Posteriori (MAP).

En second lieu, la méthode de classification contextuelle, déduite du formalisme Markov-Bayes, donne une fonction d'énergie non-convexe qui doit être minimisée pour trouver l'image classifiée optimale. C'est un problème très dur, appelé problème d'optimisation combinatoire qui exige l'utilisation d'algorithmes spécifiques d'optimisation. Parmi les différentes méthodes d'optimisation globale, on est uniquement intéressé aux métaheuristiques « modernes ». L'objectif étant d'apporter une contribution à une plus grande diffusion des méthodes métaheuristiques, dans la résolution des problèmes combinatoires posés par la classification contextuelle d'images de télédétection. Ainsi, la métaheuristique d'optimisation globale basée sur la programmation génétique a été développée. L'application de la méthode dans la classification contextuelle d'images a été alors détaillée ainsi que la procédure de sa mise en œuvre. Les résultats obtenus sont très satisfaisants.

Références

- P. M. Mather, *Computer Processing of Remotely-Sensed Images*, John Wiley & Sons, 1987.
- C. Elachi, *Space-borne Radar Remote Sensing: Applications and Techniques*. IEEE Press, New York, 1998.
- J. A. Richards and X. Jia, *Remote Sensing Digital Image Analysis*, Springer-Verlag, Berlin, 1999.
- J. Besag, "Spatial interaction and the statistical analysis of lattice system (with discussion)", *Journal of Royal Statistics Society*, B-36, pp. 192-236, 1974.
- S. Chitroub, R. Khedam, H. Belhadj, and B. Sansal, "Compound deterministic pseudo annealing-Markov random field model for contextual classification of remotely sensed imagery", *Proceedings of SPIE, EUROPTO Series, Image and Signal Processing for Remote Sensing Conference*, 21-25, September 1998, Barcelona, Spain, Vol. 3500, pp. 435-446.
- R. Chellappa and A. K. Jain (Editors), *Markov Random Fields: Theory and Application*. Academic Press, 1993.
- S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions and the Bayesian restoration of image", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 6, No. 6, pp. 721-741, 1984.
- Y. Jung and P. H. Swain, "Bayesian contextual classification based on modified M-estimates and Markov random fields", *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 34, No. 1, pp. 67-74, January 1996.
- S. Chitroub A. Houacine, A. Allaoua, M. D. Aroua, and B. Sansal, "A New deterministic annealing for image contextual classification," In *Proceedings of IEEE International Conference on Acoustic, Speech, and Signal Processing (ICASSP)*, June 5-9, 2000, Istanbul, Turkey, pp.2243-2246.
- M. Krueger, *Méthode d'analyse d'algorithmes d'optimisation stochastiques à l'aide d'algorithmes génétiques*. Thèse de Doctorat en Informatique et Réseaux, Ecole nationale supérieure des télécommunications, ENST-Paris, France, 1990.
- R. Azencott, *Parallel Simulated Annealing: An Overview of basic Techniques*. In R. Azencott, editor, *Parallel Simulated Annealing: Parallelization Techniques*, pp. 37-46, John Willy & Sons, 1992.
- F. Glover and M. Laguna, *Tabu Search, Modern Heuristic Techniques for Combinatorial Problems*. University of Colorado, Boulder, USA, 1992.
- C.R. Reeves (Ed.), *Modern Heuristic Techniques for Combinatorial Problems*. Advanced Topics in Computer Science, Chapter 4, McGraw-Hill, 1995.
- Z. Michalewicz, *Genetic Algorithms + Data Structures = Evolution Programs*. Springer-Verlag Heidelberg, 1996.

- R. Chelouah and P. Siarry, "Tabu Search applied to Global Optimization", *European Journal of Operational Research*, Vol. 123, pp. 256-270, 2000.
- R. Chelouah and P. Siarry, "Continuous Genetic Algorithm: An algorithm for the global optimization of multi-minima functions", *Journal of Heuristics*, Vol. 6, pp. 191-213, 2000.
- Koza, John R. 1992. *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. Cambridge, MA: The MIT Press.
- S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions and the Bayesian restoration of image", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 6, No. 6, pp. 721-741, 1984.
- J. Moussouris, "Gibbs and Markov random system with constraints", *Journal of Statistical Physics*, Vol. 10, No. 1, pp. 11-33, January 1974.
- Z. Kato, *Modélisation Markoviennes Multirésolutions en Vision par Ordinateur. Application à la*

- Segmentation d'Images SPOT*. Thèse de Doctorat, Spécialité Sciences de l'Ingénieur, Université de Nice Sophia Antipolis, Nice, France, 1994.
- J. H. Holland, *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor, MI, Internal report, 1975.
- S. Chitroub, A. Houacine, and B. Sansal, "Robust optimal fuzzy clustering algorithm applicable to multispectral and polarimetric synthetic aperture radar images", *Proceedings of SPIE, EUROPTO Series, Image and Signal Processing for Remote Sensing Conference*, 21-25, September 1999, Florence, Italy, Vol. 3871, pp. 325-336.
- P. J. Van Laarhoven and E. H. L. Aarts, *Simulated Annealing: Theory and Applications*. Dordrecht: D. Reidel Publisher Company, Netherlands, 1987.
- J. Marroquin, S. Mitter, and T. Poggio, "Probabilistic solution of ill-posed problems in computational vision", *Journal of the American Statistical Association*, Vol. 82, pp. 76-89, 1987.

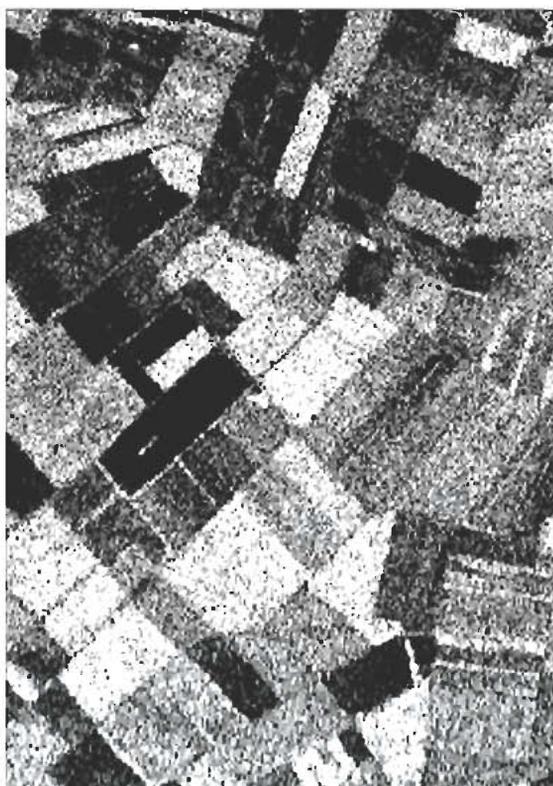


Fig. 1 Image SAR du système AirSAR (tous droits réservés à Hunting Technical Services Ltd. (UK)).



Fig. 2 Configuration initiale (image ponctuellement classifiée).

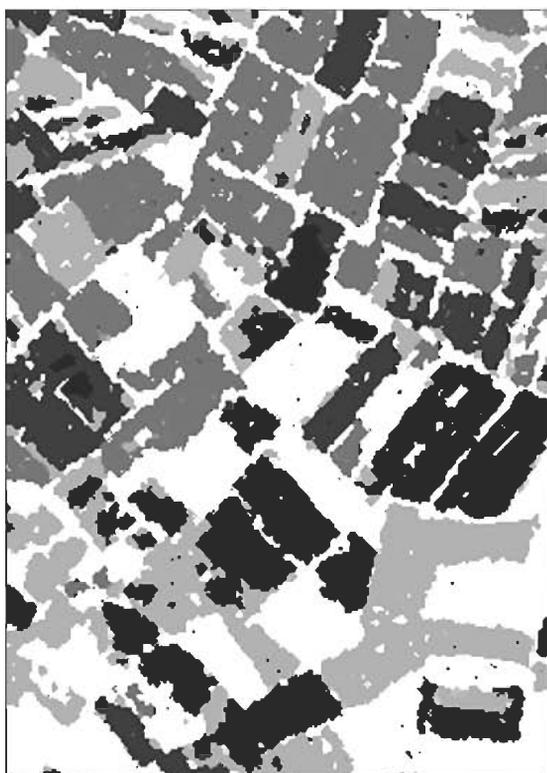


Fig. 3 Recuit simulé.

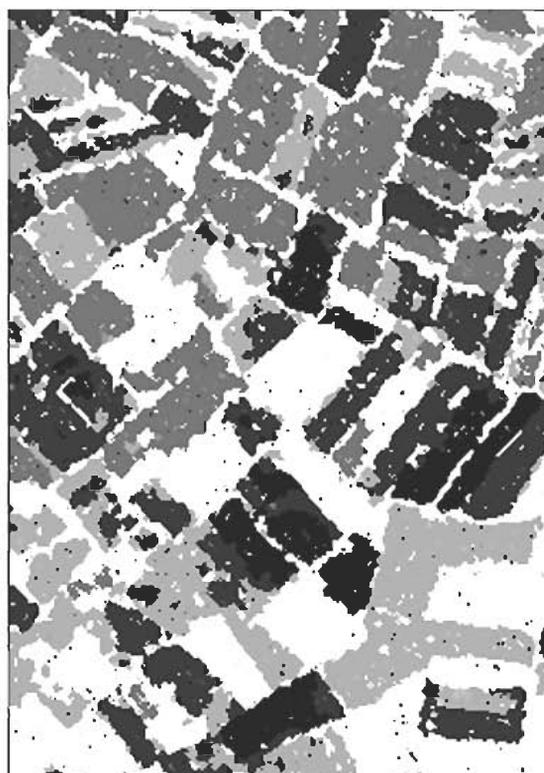


Fig. 4 Programmation génétique.

Tableau 1. Température initiale, Energie initiale, Energie finale (le minimum atteint par la méthode), et temps d'exécution (sur Pentium II, 255 MHZ) des deux méthodes d'optimisation.

Méthodes	Température initiale	Energie initiale	Energie finale	Temps d'exécution
Recuit simulé	5	782845.5	541049	15 min
Programmation génétique	5	782845.5	575940	1 heure 35 min

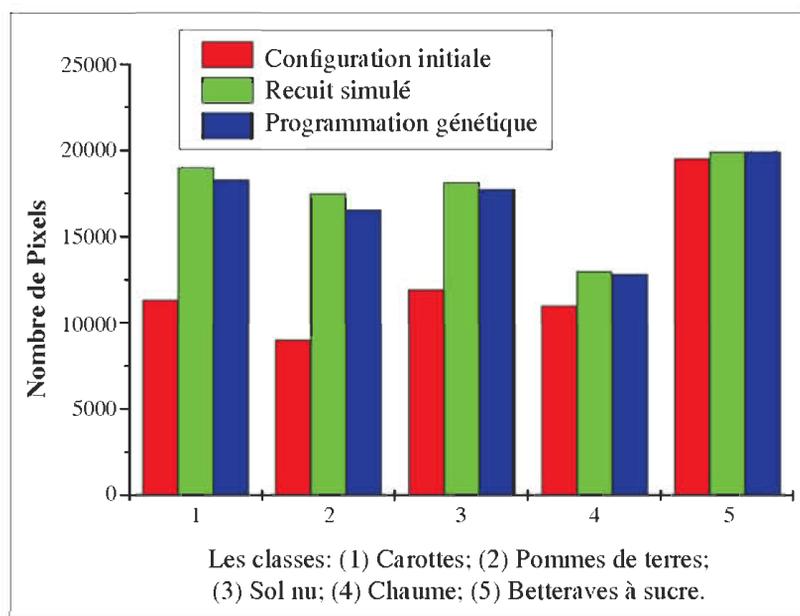


Fig. 5 Nombre de pixels par classe dans les trois images classifiées.