

SEGMENTATION NON SUPERVISEE D'IMAGES SATELLITE UTILISANT UN MODELE HIERARCHIQUE GENERALISE

A. Marzouki (*), Y. Delignon (**), H.C. Quelle (***),
W. Pieczynski (**)

*Laboratoire de mesures automatiques. Université de sciences et Techniques de Lille 59650 Villeneuve d'Ascq
** Groupe Image INT - ENIC, 6 rue des techniques, 59658 Villeneuve d'Ascq Cedex
*** Groupe Traitements d'images, Télécom Bretagne, BP 832, 29285 BREST cedex

RÉSUMÉ

Dans l'étude statistique des images radar, on montre que la distribution du niveau de gris varie selon la nature de chaque texture. La recherche des lois et des paramètres est facilitée par l'utilisation du système de distribution de Pearson. Ce système contient un nombre important de familles de lois, qui diffèrent par la forme de leur densité. Dans cet article, nous proposons une méthode de segmentation qui tient compte de la variété des lois au sein de l'ensemble des classes des images. Nous utilisons l'algorithme SEM pour déterminer de manière itérative l'ensemble des paramètres relatifs à chaque classe: probabilités a priori et paramètres de forme. Nous évaluons alors les performances de notre algorithme sur des images simulées et des images du SAR embarqué sur SEASAT.

I INTRODUCTION

La plupart des opérations effectuées en imagerie comportent une phase de segmentation. Au cours de cette phase, on transforme l'image originale en une image de classes. On effectue ainsi une partition de l'images en région homogènes ou textures. Les méthodes de segmentation utilisées diffèrent l'une de l'autre suivant la nature de l'image et les détails recherchés dans l'ensemble des classes. La segmentation statistique est une méthode de classification qui tient compte de la distribution des pixels. Cette distribution est donnée par une loi paramétrique pour chaque classe. Les méthodes de segmentation classiques supposent l'existence d'une seule famille de lois, commune à toutes les classes de l'image. Or, certaines études récentes montrent que la loi suivie par le niveau de gris des pixels varie d'une texture à une autre, et que pour une même image peuvent coexister plusieurs textures de lois différentes [1]. Ces lois peuvent être approchées en utilisant le système de distributions de Pearson[1,6].

Dans cet article, nous proposons une méthode de segmentation statistique, nous tenons compte en particulier de la variété de lois et des paramètres dans l'ensemble de classes

ABSTRACT

The statistical study of images shows a large variety of histogram shape within each image texture. The distribution of the grey level can be approximated in efficient way by use of Pearson system.

In this paper, we show that it is possible to take into account this variety of distributions in the Bayesian statistical segmentation of images. To estimate the parameters and the law of each image class, we use the SEM algorithm combined with Pearson system. The algorithm obtained is tested on a synthetic image and also applied to the segmentation of real SEASAT scene.

de l'image. Nous commençons par rappeler le modèle statistique adopté en imagerie radar, avant d'aborder le problème de segmentation, où nous proposons une méthode de recherche de lois utilisant l'algorithme SEM.

Une application directe de cette méthode sera illustrée par la segmentation d'une image de simulation et d'une image SAR.

II. MODELISATION DES IMAGES RADAR

Du point de vue statistique, on considère l'image comme étant la réalisation de deux champs aléatoires : le champs de classes $\xi = \{\xi_s, s \in S\}$ où ξ_s prend ses valeurs dans un ensemble fini de classes $\Omega = \{\omega_1, \dots, \omega_k\}$ et le champs de mesures $X = \{X_s; s \in S\}$ avec X_s variable aléatoire réelle. Seul le champ X est observable, le problème de la segmentation est donc l'estimation de la réalisation invisible du champs ξ à partir de la réalisation visible du champs X [4,5]. Nous supposons que la réalisation du champ X dépend de celle de ξ et d'un certain bruit. La modélisation statistique de l'image requiert donc la connaissance de la loi du couple (ξ, X) . Cette loi peut être définie par celle de ξ dite a priori et la loi de X conditionnelle à ξ .



Notre méthode ne permet pas de tenir compte des dépendances spatiales des variables $(\xi_s, X_s)_{s \in S}$, nous les supposons indépendantes dans la suite. La variable aléatoire ξ_s est définie sur l'ensemble discret Ω de K éléments, la loi du champ ξ est donc donnée par les K probabilités $\Pi(\omega_k)$, $k=1, \dots, K$, de chaque classe. Si Q_k désigne l'ensemble des pixels de la classe ω_k , $\Pi(\omega_k)$ peut être estimée par :

$$\frac{\text{card}(Q_k)}{\text{card}(S)}$$

Pour obtenir la loi de X conditionnelle à ξ , nous remarquons que X_s est une variable aléatoire réelle. La donnée des K densités de probabilité $f_X^{\xi=\omega_k}$ suffit pour déterminer complètement la loi de X conditionnelle à la réalisation $\xi = \omega_k$. Dans le cas des images radar à texture unique, la forme de l'histogramme varie selon la nature du terrain [1,5]. Pour faire un diagnostic sur la loi de X conditionnelle à ξ , nous devons tenir compte des différentes formes prises par les densités f_X^{ξ} [3,2]. Dans ce cas, l'hypothèse d'une loi unique ne semble pas justifiée, c'est pour cette raison que nous proposons d'élargir l'ensemble des lois admissibles en supposant qu'elles font partie du système de distributions de Pearson.

III. UTILISATION DU SYSTEME DE PEARSON

Ce système contient la famille de densités unimodales [6], vérifiant l'équation :

$$\frac{df^{\xi}(x)}{dx} = -\frac{(x+a)}{c_0 + c_1x + c_2x^2} f^{\xi}(x)$$

Les paramètres c_0, c_1, c_2 et a varient suivant la forme de la densité. Leur donnée caractérise complètement le système de distribution de Pearson. Pour les estimer nous utilisons la méthode des moments.

En effet, notons par μ la moyenne de X , par m_n les moments centrés d'ordre n , et par β_1 et β_2 les paramètres fonctions de la dissymétrie et de l'aplatissement de la distribution :

$$\beta_1 = \frac{m_3}{\sqrt{m_2^3}}, \beta_2 = \frac{m_4}{m_2^2}$$

On montre alors [6] qu'il existe une transformation unique donnant $C^t = (c_0, c_1, c_2, a)$ en fonction de $M^t = (\mu, m_2, \beta_1, \beta_2)$. Dans le graphe (β_1, β_2) , appelé graphe de Pearson, nous pouvons reporter huit familles de lois connues. La loi normale apparaît comme un cas particulier correspondant à $\beta_1 = 0$ et $\beta_2 = 3$.




Fig 1 : Graphe de Pearson

Dans ce graphe, nous distinguons les distributions suivantes :

- I : Distribution bêta de première espèce
- III : Distribution gamma, exponentielle
- V : Distributions gamma inverse, de Wald,...
- VI : Distributions bêta de seconde espèce, de Fischer,...
- N : Distribution gaussienne

II. APPROCHE BAYESIENNE

La segmentation des images requiert une stratégie de classification. Cette stratégie tient compte du modèle stochastique des images et permet d'obtenir un taux d'erreur minimum. L'approche bayésienne semble bien adaptée dans notre cas. Pour chaque pixel s de l'image, le critère de décision bayésien consiste à estimer la réalisation ξ_s par la classe ξ_s^* dont la probabilité conditionnelle à $X_s = x_s$ (probabilité à posteriori) est maximale. Cette probabilité est calculée à partir de Π et f_X^{ξ} par:

$$P(\xi = \omega_k / X = x) = \frac{\Pi(\xi = \omega_k) f_X^{\xi}(X = x / \xi = \omega_k)}{\sum_{l=1}^K \Pi(\xi = \omega_l) f_X^{\xi}(X = x / \xi = \omega_l)}$$

ou encore :

$$P(\xi = \omega_k / X = x) = \frac{f_{\xi, X}(\xi = \omega_k, X = x)}{f(x)}$$

f étant la densité de X_s .

La règle de Bayes r_g est alors définie comme suit:

$$r_g(x_s): \xi_s \Leftrightarrow P[\xi_s / X_s = x_s] = \sup_{\xi} P[\xi / X_s = x_s]$$

ou encore:

$$r_g(x_s): \xi_s \Leftrightarrow f_{\xi_s, X_s}(\xi_s, x_s) = \sup_{\xi} f_{\xi_s, X_s}(\xi, x_s)$$

V. ALGORITHME SEM

La segmentation de l'image nécessite la connaissance des paramètres: $\theta_k = (C_k^t, \Pi(\omega_k))$ relatifs à chaque classe ω_k . Pour calculer θ_k , nous utilisons l'algorithme itératif SEM (Stochastic Estimation Maximisation) [7]. Cet algorithme est une procédure itérative permettant de définir une suite $\theta^{(q)}$ en utilisant des tirages stochastiques. Son avantage principal par rapport à l'algorithme EM est sa moindre dépendance des conditions initiales [7].

Nous proposons la généralisation de l'algorithme SEM en incluant la reconnaissance de la forme des densités :

Initialisation $q = 0$

On choisit aléatoirement l'ensemble de paramètres ainsi que la probabilité a priori $\Pi^{q=0}$ de chaque classe .

Itération : q

Elle comporte trois étapes :

Etape S :

Pour chaque pixel s , un tirage stochastique est effectué selon la loi a posteriori dans l'ensemble des classes $\Omega = \{\omega_1, \omega_1, \dots, \omega_K\}$. Ce tirage définit une partition (Q_1, \dots, Q_K) de l'image en K classes.

Etape E :

A partir de l'image obtenue, l'estimation des quatre premiers moments centrés, et par suite du vecteur C_k^t permet de représenter la densité de chaque classe dans le graphe (β_1, β_2) .

On obtient la probabilité a priori $\Pi^{(q)}(\omega_k)$ par:

$$\Pi^{(q)}(\omega_k) = \frac{\text{card}(Q_k)}{\text{card}(S)} \text{ où } k = 1, 2, \dots, K.$$

Etape M:

On calcule la probabilité a posteriori P_{ξ}^X et on retourne à l'étape S.

VI. RESULTATS OBTENUS

Pour tester l'algorithme, nous avons simulé la réalisation de deux classes de bruit. La densité de chaque classe est choisie parmi les distributions du système de Pearson. Nous avons choisit une distribution de type I (loi bêta de première espèce) pour la première classe et une distribution de type IV pour la seconde. Nous avons ensuite appliqué l'algorithme sur l'image bruitée obtenue et sur une image radar multivue.

Image de simulation

L'image 2 représente la segmentation d'une image composée d'une série d'anneaux bruités (Image 1) après dix itérations.

Dans le tableau 1, nous présentons les paramètres choisis pour l'image originale.

Les résultats de la segmentation montrent que le nombre d'itérations nécessaires pour la convergence de l'algorithme dépend de l'initialisation.

Le tableau 2 représente des paramètres estimés après dix itérations, les probabilités d'erreur théoriques et celles obtenues sont pratiquement égales (de l'ordre de 0.26).

Classe	Type	μ	σ^2	β_1^2	β_2	Π
1	1	150	500	0	2.7	0,68
2	6	150	700	1.2	5	0,32

Tab 1 : paramètres caractéristiques de l'image idéale

Classe	Type	μ	σ^2	β_1^2	β_2	Π
1	1	150	505	0.007	2.7	0.68
2	6	150	670	1.17	4.8	0.32

Tab 2: paramètres estimés après 10 itérations




Image 1 : Image simulée




Image 2 : Image segmentée.

Image SAR

Pour évaluer les performances de cette méthode, nous avons comparé les résultats de notre algorithme à celui utilisant la loi gaussienne sur une image de la côte bretonne (Image 3).



Nous avons remarqué une supériorité de la segmentation multi-lois (Image 4) vis à vis de celle utilisant uniquement des lois normales (Image 5): très bonne stabilité à la convergence, élimination moindre des différentes classes, meilleure visibilité des détails de l'image,....

Le tableau 3 contient les différents paramètres estimés après dix itérations, nous remarquons en particulier la forte dissymétrie de l'histogramme de la classe 2.

Classe	Type	μ	σ^2	β_1^2	β_2	Π
1	1	121	15	0	2.2	0.4
2	4	130	63	2.3	24.6	0,6

Tab 3 : Paramètres estimés après 10 itérations




Image 3 : Image SAR originale




Image 4 : Image SAR segmentée à l'aide de distributions gaussiennes.



Image 5 : Image SAR segmentée à l'aide des distributions du système de Pearson.

CONCLUSION

Dans cet article nous avons présenté une nouvelle méthode de segmentation des images tenant compte de la diversité des distributions du niveau de gris des pixels.

La densité de chaque classe a été choisie parmi les distributions unimodales du système de Pearson. L'identification du mélange de lois a nécessité l'utilisation de l'algorithme SEM.

Pour tester la méthode, nous avons réalisé la segmentation d'une image de simulation et d'une image SAR.

Les résultats obtenus semble montrer dans le cas des images radar que notre algorithme est plus performant que celui utilisant la modélisation gaussienne.

Tout au long de cet article, nous avons négligé la corrélation entre pixels, une étude en cours montrera l'influence d'un tel phénomène sur la validité de notre méthode.

REFERENCES

- [1] Y. Delignon, R. Garello et A. Hillion, "Etude statistique d'images SAR de la surface de la mer," dans le *colloque GRETSI 1991, Juan-Les-pins*, pp. 573-576, Sept 1991.
- [2] C. Quelle, J.M. Boucher et W. Pieczynski, "Local parameter estimation and unsupervised segmentation of SAR images", *IEEE Geoscience and Remote Sensing Symposium (IGARSS 92) Houston, USA*, mai 1992.
- [3] P. Masson and W. Pieczynski, "SEM algorithm and unsupervised statistical segmentation of satellite images", *IEEE Geoscience and Remote Sensing*, vol 31, n°3, mai 1993.
- [4] A.L. Maffett & C.C. Wackerman, "The modified beta density function as a model for synthetic aperture radar clutter statistics," *IEEE Transactions on geoscience and remote sensing*, vol n°29, n°2, march 1991, pp. 277-283.
- [5] P.A. Kelly, H. Derin, K.D. Hartt, "Adaptative segmentation of speckled images using a hierarchical random field model," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol 36, (no.10), pp. 1628-1641, 1988.
- [6] Johnson et Kotz, "Distribution in statistics : Continuous Univariate Distributions I", *Wiley, 1969*, pp. 112-139.
- [7] G. Celeux, J. Diebolt, "L'algorithme SEM : Un algorithme d'apprentissage probabiliste pour la reconnaissance de mélange de densités," *Revue de statistiques appliquées*, vol 34, n°2, 1986.