

# Modélisation et segmentation non supervisée d'images RSO par champs de Markov triplets et lois de Fisher

D. BENBOUDJEMA<sup>1</sup>, F. TUPIN<sup>1</sup>, W. PIECZYNSKI<sup>2</sup>, M. SIGELLE<sup>1</sup> et J.-M. NICOLAS<sup>1</sup>

<sup>1</sup>TSI, GET/Télécom-Paris, 46 rue Barrault, 75013 Paris

<sup>2</sup>CITI, GET/INT-Evry, 9 rue Charles Fourier, 91000 Evry

{ben, tupin, sigelle, nicolas}@tsi.enst.fr

wojciech.pieczynski@int-evry.fr

**Résumé** – Les champs de Markov triplets (CMT) généralisent les champs de Markov Couples (CMCouples) qui généralisent les champs de Markov cachés (CMC). Dans les champs de Markov triplets un processus auxiliaire  $U$  est introduit de sorte que le triplet  $T = (X, U, Y)$  conserve sa markovianité. Ce qui permet d'effectuer des traitements Bayésiens. L'avantage de ce modèle est qu'il offre la possibilité de modéliser les différentes stationnarités présentes dans une image donnée. L'objectif de cet article est de combiner ces champs de Markov triplets avec les distributions de Fisher pour modéliser la loi de  $Y$  conditionnelle à  $X$ , relative au bruit, et de l'appliquer à des images Radar à Synthèse d'Ouverture (RSO). Les expérimentations sur des images réelles montrent l'intérêt d'une telle combinaison en segmentation non supervisée d'imagerie RSO.

**Abstract** – The hidden Markov fields (HMF) have been extended to the pairwise Markov fields (PMF) which have been extended to the triplet Markov field (TMF). In this model (TMF) a third process  $U$  is introduced so that the markovianity of the triplet  $T = (X, U, Y)$  is conserved. This markovianity is essential to make Bayesian processing. The TMF has the advantage to model different stationnarities contained in the given image. The aim of this paper is to combine the triplet Markov field with the Fisher laws to model the law of  $Y$  conditional on  $X$ , and apply it in unsupervised segmentation of RSO images. Experiments show the practical interest of such combination on the RSO data.

## 1. Introduction

Largement utilisés, les modèles de Markov sont bien adaptés au problème de la segmentation d'images. Soit  $S$  un ensemble de pixels,  $X = (X_s)_{s \in S}$  et  $Y = (Y_s)_{s \in S}$  deux champs aléatoires avec  $X = x$  caché et  $Y = y$  observé. Chaque  $X_s$  prend ses valeurs dans un ensemble fini de classes  $\Omega = \{\omega_1, \dots, \omega_k\}$ , et chaque  $Y_s$  prend ses valeurs dans l'ensemble des nombres réels  $R$ . Le problème de la segmentation statistique d'images est d'estimer la réalisation inobservable  $X = x$  à partir de  $Y = y$ . Pour cela on choisit généralement de modéliser le processus  $X$  sous forme markovienne et la loi de  $Y$  conditionnelle à  $X$  (loi du bruit) relativement simple de façon à conserver la markovianité de  $X$  *a posteriori* (conditionnelle à  $Y$ ). Cette dernière markovianité permet alors la mise en œuvre des différents traitements bayésiens [6]. De plus, les paramètres du modèle peuvent être estimés par des méthodes générales de type EM ou ICE, ce qui permet la mise en œuvre de méthodes de segmentation non supervisée. Cependant, cette même simplicité est difficile à justifier et peut poser problème dans certaines situations, comme la présence des textures [3]. Dans le modèle « champ de Markov couple » (CMCouples), plus général

que les champs de Markov cachés (CMC) car  $X$  n'est plus nécessairement de Markov, on suppose directement la markovianité du couple  $Z = (X, Y)$  [7]. Le champ  $Y$  est alors markovien conditionnellement à  $X$  - ce qui autorise une modélisation plus complexe des bruits-, et le champ  $X$  est markovien conditionnellement à  $Y$  - ce qui autorise les mêmes traitements que dans les CMC. Par la suite, en introduisant un troisième processus supplémentaire  $U = (U_s)_{s \in S}$ , où chaque variable aléatoire  $U_s$  est à valeur dans l'ensemble fini  $\Lambda = \{\lambda_1, \dots, \lambda_m\}$ , un modèle plus général appelé « champs de Markov triplets » (CMT) à été proposé [8]. En effet, la loi de  $Z = (X, Y)$ , qui est une loi marginale de celle de  $T = (X, U, Y)$ , n'est plus nécessairement markovienne. Dans ce modèle on suppose la markovianité du triplet  $T = (X, U, Y)$ . L'avantage des CMT est qu'ils ont le pouvoir de modéliser les différentes stationnarités présentes dans une image donnée.

Nous proposons dans cet article une étude de la segmentation non supervisée d'image RSO. Pour ce faire, nous utilisons les CMT, permettant la prise en compte des variations des stationnarités, que nous combinons avec les lois de Fisher afin de modéliser la loi de  $Y$  conditionnelle à  $X$ . Le choix de la distribution de Fisher a été motivé par

le fait qu'elle est bien adaptée à la classification d'images RSO [4] du fait qu'elle modélise aussi bien les surfaces naturelles que les surfaces non naturelles : sa capacité à modéliser les distributions à tête lourde ou queue lourde est unique. De plus, des études récentes ont montré leur intérêt en milieu urbain [9]. Ainsi, via des exemples pratiques, nous montrons l'intérêt d'une telle combinaison en segmentation non supervisée d'images RSO. Aussi, pour un traitement non supervisé, nous proposons une technique d'estimation des paramètres ECI, proche de celle introduite dans [1].

## 2. Champs de Markov triplets

Dans les champs de Markov cachés (CMC), on considère deux processus aléatoires :  $X = (X_s)_{s \in S}$  le processus des classes et  $Y = (Y_s)_{s \in S}$  la variable observable ( $S$  étant l'ensemble de pixels). Le problème est de retrouver le champ inobservé  $X$  à partir de sa version bruitée  $Y$ . Dans ce modèle on choisit généralement de modéliser le processus caché  $X$  sous forme markovienne et de restreindre la famille des lois de  $Y$  conditionnelle à  $X$  qui modélise le bruit, de façon à ce que la loi conditionnelle à  $Y$  soit encore markovienne. Il devient alors possible d'appliquer les méthodes bayésiennes d'estimation MPM ou MAP. Largement utilisés, les CMC peuvent cependant présenter certaines faiblesses, notamment pour la modélisation d'images non stationnaires. Pour y remédier, les champs de Markov triplets (CMT) ont été proposés. Les CMT sont des extensions des modèles classiques dans lesquels un processus auxiliaire  $U = (U_s)_{s \in S}$  est introduit tel que la loi du triplet  $T = (X, U, Y)$  est de Markov. Ce processus  $U$  peut avoir différentes interprétations physiques et qui, dans ce cas représente les différentes stationnarités présentes dans le champ  $X$ . Considérons le couple  $(X, U)$  de Markov et supposons que  $\Lambda = \{a, b\}$  (deux stationnarités). L'énergie du couple  $(X, U)$  s'écrit alors comme suit:

$$\begin{aligned} W(x, u) = & \sum_{(i,j) \in C_H} \alpha'_i (1 - 2\delta(x_i, x_j)) \\ & - (\alpha_{aH}^2 \delta^*(u_s, u_i, a) + \alpha_{bH}^2 \delta^*(u_s, u_i, b)) (1 - \delta(x_s, x_i)) \\ & + \sum_{(i,j) \in C_V} \alpha'_j (1 - 2\delta(x_i, x_j)), \\ & - (\alpha_{aV}^2 \delta^*(u_s, u_i, a) + \alpha_{bV}^2 \delta^*(u_s, u_i, b)) (1 - \delta(x_s, x_i)) \end{aligned} \quad (1)$$

où  $C_H$  (respectivement  $C_V$ ) est l'ensemble des cliques d'ordre deux horizontales (respectivement verticales), et  $\delta^*(a, b, c) = 1$  pour  $a = b = c$  et  $\delta^*(a, b, c) = 0$  sinon. En supposant que les variables aléatoires  $Y_s$  sont indépendants conditionnellement à  $X$ , et que  $p(y_s | x, u) = p(y_s | x_s)$ , la loi du triplet  $T = (X, U, Y)$  s'écrit sous la forme  $p(x, u, y) = \gamma \exp[-W(x, u) + \sum_{s \in S} \text{Log}(p(y_s | x_s))]$ , qui est bien une loi markovienne.

## 3. Log-statistiques

### 3.1 Loi de Fisher en amplitude

Pour pallier le bruit multiplicatif des images RSO (speckle), le choix d'une distribution  $p(y_s | x_s)$  appropriée est indispensable. Pour cela nous avons choisi d'utiliser la distribution de Fisher. En effet, contrairement aux lois K, Beta, Weibull, qui modélisent, généralement, une partie de la scène [2, 5], l'utilisation de la loi de Fisher permet de prendre en compte toute la diversité de la scène. De plus, la loi de Fisher est bien adaptée à la classification d'images RSO car elle modélise aussi bien les surfaces naturelles que les surfaces non naturelles. En effet, sa capacité à modéliser les distributions à tête lourde ou queue lourde est unique et elle offre ainsi l'avantage d'utiliser une seule distribution (Fisher) au lieu d'attribuer des distributions différentes à chaque classe, comme cela est parfois nécessaire dans le cas d'images radar. La distribution des Fisher en amplitude est donnée par :

$$\begin{aligned} F_{\text{Amplitude}}(\mu, L, M) = & (\Gamma(L + M) / \Gamma(L) \Gamma(M)) \\ & \times (L/M \cdot ((\sqrt{L/M} \cdot y / \mu)^{2L-1} / (1 + (\sqrt{L/M} \cdot y / \mu)^2)^{M+L}))^{\frac{1}{2}}, M > L \end{aligned} \quad (2)$$

où  $\Gamma(\cdot)$  est la fonction Gamma et  $(\mu, L, M)$  sont la moyenne et les paramètres de forme.

### 3.2 Statistiques de seconde espèce

Les statistiques de seconde espèce peuvent être définies d'une façon analogue que les statistiques classiques. Celles-ci sont définies comme suit :

– Première fonction caractéristique de seconde espèce :

$$\phi_x(s) = \int_0^{+\infty} y^{s-1} p(y|x) dy \quad (3)$$

– Seconde fonction caractéristique de seconde espèce :

$$\psi_x(s) = \log(\phi_x(s)) \quad (4)$$

– Moment d'ordre  $r$  de seconde espèce :

$$\tilde{m}_r = \left. \frac{d^r \phi_x(s)}{ds^r} \right|_{s=1} \quad (5)$$

– Cumulant d'ordre  $r$  de seconde espèce :

$$\tilde{k}_r = \left. \frac{d^r \psi_x(s)}{ds^r} \right|_{s=1} \quad (6)$$

Dans le cas de la loi de Fisher, la fonction caractéristique de seconde espèce s'écrit :

$$\phi_f(s) = \mu^{s-1} \frac{\Gamma\left(L + \frac{s-1}{2}\right) \Gamma\left(M + \frac{1-s}{2}\right)}{L^{\frac{s-1}{2}} \Gamma(L) M^{\frac{1-s}{2}} \Gamma(M)}, \quad (7)$$

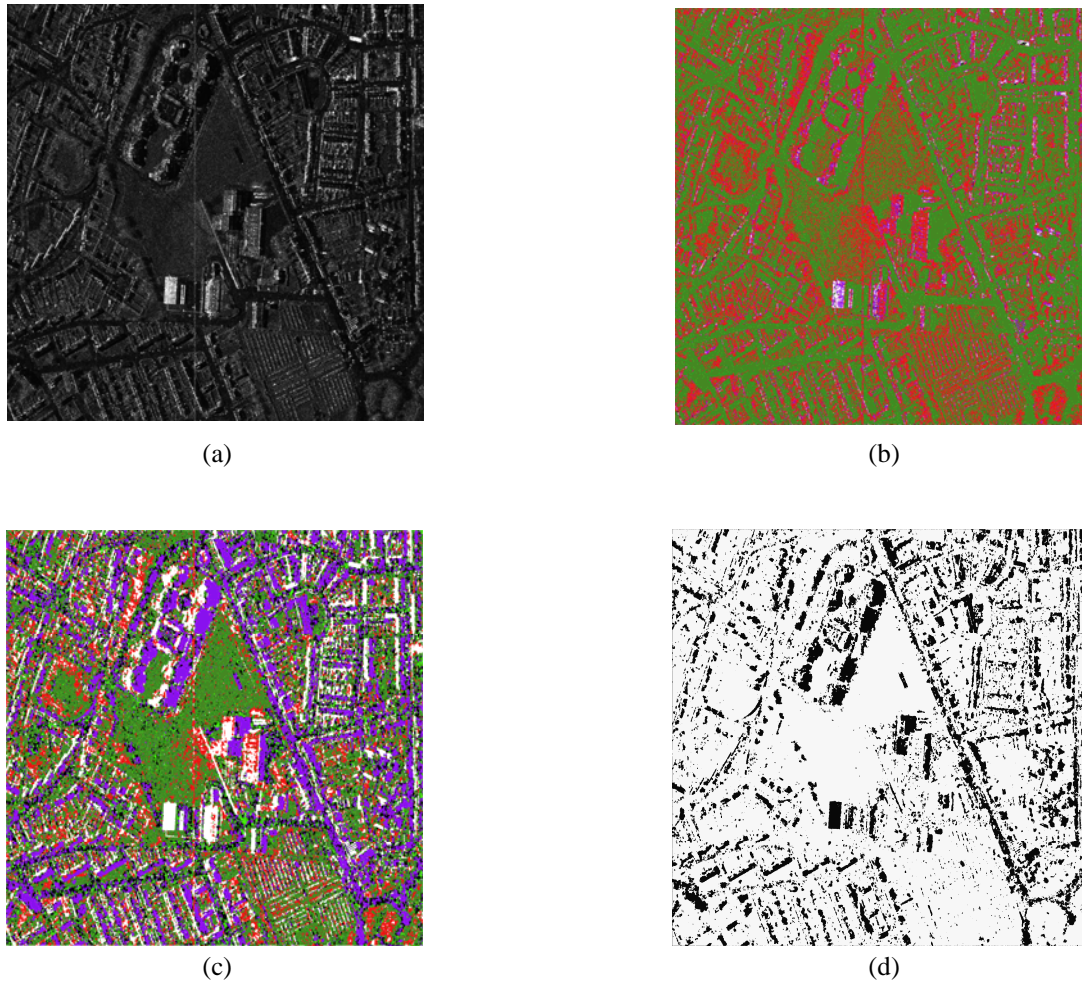


FIG. 1 : (a) ville de Bayard, (b) segmentation MPM fondée sur CMC+Gaussien, (c) segmentation MPM fondée sur CMT+Fisher, (d)  $U = u$  estimé

#### 4. Estimation des paramètres

Dans cette section nous abordons le problème de l'estimation des paramètres du modèle. Pour cela nous utilisons l'algorithme de l'Estimation Conditionnelle Itérative (ECI). Celui-ci consiste à prendre un estimateur  $\hat{\theta} = \hat{\theta}(X, Y)$  défini à partir des données complètes  $(X, Y)$  et de l'approcher par l'espérance conditionnelle à  $Y = y$ . Cette espérance est calculée de la manière itérative suivante :  $\theta_{n+1} = E_{\theta_n}[\hat{\theta}(X, Y) | Y = y]$ . Celle-ci n'est pas explicitement calculable ; cependant la simulation des réalisations de  $X$  selon sa loi *a posteriori* est possible. On utilise alors l'approximation classique suivante :  $\theta_{n+1} = (\hat{\theta}(x^1, y) + \dots + \hat{\theta}(x^l, y)) / l$ , où  $l$  représente le nombre de réalisations. Etant donné qu'un estimateur  $\hat{\theta} = \hat{\theta}(X, Y)$  est nécessaire pour l'ECI, nous utilisons :

- La méthode des moindres carrés décrite dans [1] pour l'estimation du paramètre  $\alpha$  définissant l'énergie du couple  $(X, U)$ ;

- Les log-moments pour l'estimation des paramètres liés au bruit relatifs à la loi de Fisher de  $Y$  conditionnelle à  $X$ , et ce grâce au lien existant entre ces log-cumulants et les paramètres  $\mu, L$  et  $M$ . Ces log-cumulants se calculent empiriquement par :

$$\tilde{k}_1 = E[(\log(y))] \quad (8)$$

$$\tilde{k}_r = E[(\log(y) - \tilde{k}_1)^r], \quad r > 1 \quad (9)$$

#### 5. Résultats

Dans cette section nous présentons les résultats de la segmentation non supervisée d'une image radar en utilisant le modèle proposé et en supposant que l'image contient deux stationnarités. Ces résultats sont comparés à ceux obtenus à partir du modèle classique (CMC en supposant le bruit gaussien). L'image (2048x2048) de la




FIG. 2 : Zoom sur une partie de FIG. 1.

Figure 1 représente la région de Bayard et contient six classes. En l'absence de la vérité terrain, il nous est difficile de comparer quantitativement les résultats de classification obtenus. Cependant, en effectuant des zooms sur certaines zones tel que celui représentés dans Figure 2, nous remarquons que beaucoup de détails sont conservés par la nouvelle méthode. Les expérimentations montrent ainsi, que la méthode proposée permet non seulement d'avoir des résultats de classification bien plus précis mais également d'extraire deux informations simultanément, à savoir le champ des classes  $X$  et le champ des stationnarités  $U$ . Les estimées des différents paramètres des deux modèles CMT+Fisher et CMC+Gaussien sont représentées dans le Tableau 1.

TAB. 1 : Estimées obtenues par l'ECI

Paramètres	Gaussien	Fisher
$\alpha_H, \alpha_V$	0.47, 0.64	0.75, 0.74
$\alpha_H, \alpha_V$	-	0.68, 1.2
$\alpha_H, \alpha_V$	-	0.51, 1.1
$\sigma_1, \sigma_2, \sigma_3$	0.04, 0.07, 0.19	-
$\sigma_4, \sigma_5, \sigma_6$	0.56, 1.16, 2.45	-
$\mu_1, \mu_2, \mu_3$	0.07, 0.2, 0.47	0.05, 0.07, 0.08
$\mu_4, \mu_5, \mu_6$	1.07, 1.49, 1.83	0.09, 0.17, 0.25
$L_1, L_2, L_3$	-	0.98, 1.26, 1.03
$L_4, L_5, L_6$	-	1.12, 1.21, 1.06
$M_1, M_2, M_3$	-	6.7, 26.65, 31.65
$M_4, M_5, M_6$	-	39.37, 28.47, 5.72

## 6. Conclusion

Nous avons proposé dans cet article une méthode originale de segmentation d'images RSO fondée sur les champs de Markov triplets (CMT) et la distribution de Fisher. Afin de rendre ce traitement automatique nous avons également présenté une méthode d'estimation des paramètres fondée sur le principe générale de l'ECI. Une étude comparative entre l'utilisation des CMT combinée aux lois de Fisher et le modèle classique a été abordée. Les expérimentations présentées montrent l'intérêt d'une telle combinaison pour le traitement des images radar de zones urbaines. En effet, en plus de l'amélioration des

résultats de la segmentation une information supplémentaire est extraite.

Comme perspective on pourrait envisager d'appliquer ce modèle dans la reconstruction 3D.

## Références

- [1] D. Benboudjema and W. Pieczynski, *Unsupervised image segmentation using triplet Markov fields*, Computer Vision and Image Understanding, Vol. 99, No. 3, pp. 476-498, 2005.
- [2] A. Lopes, R. Touzi and E. Nezry, *Adaptive Speckle filters and scene heterogeneity*, IEEE Transactions on Geoscience and Remote Sensing, Vol. 28, No. 6, pp. 992-1000, 1990.
- [3] D. Melas and S. P. Wilson, *Double Markov Random Fields and Bayesian Image Segmentation*, IEEE Trans. on Signal Processing, Vol. 50, No. 2, pp. 357-365, 2002.
- [4] J-M. Nicolas and F. Tupin, *Gamma Mixture modeled with second kind statistics : Application to SAR image processing*, IGARSS, pp. 2489-2491, 2002.
- [5] C. J. Oliver, *A model for non-Rayleigh scattering statistics*, Optica Acta, Vol. 31, No. 6, pp. 701-722, 1984.
- [6] P. Pérez, *Markov random fields and images*, CWI Quarterly, Vol. 11, No. 4, pp. 413-437, 1998.
- [7] W. Pieczynski and A.-N. Tebbache, *Pairwise Markov random fields and segmentation of textured images*, Machine Graphics and Vision, Vol. 9, No. 3, pp. 705-718, 2000.
- [8] W. Pieczynski, D. Benboudjema, and P. Lanchantin, *Statistical image segmentation using Triplet Markov Fields*, SPIE's International Symposium on Remote Sensing, September 22-27, Crete, Greece, 2002.
- [9] C. Tison, J-M. Nicolas, F. Tupin and H. Maitre, *A New Statistical Model for Markovian Classification of Urban Areas in High-Resolution SAR Images*, IEEE Transactions on Geoscience and Remote Sensing, Vol. 42, No. 10, pp. 2046-2057, 2004.