

Classification bayésienne supervisée d’images RSO de zones urbaines à très haute résolution

Aurélien VOISIN, Vladimir KRYLOV, Josiane ZERUBIA

EPI Ariana, INRIA/I3S, CR INRIA Sophia Antipolis Méditerranée
2004, Route des Lucioles, BP 93, 06902 Sophia Antipolis, France

{Aurelie.Voisin, Vladimir.Krylov, Josiane.Zerubia} @inria.fr

Résumé – Ce papier présente un modèle de classification bayésienne supervisée d’images acquises par Radar à Synthèse d’Ouverture (RSO) très haute résolution en polarisation simple contenant des zones urbaines, particulièrement affectées par le bruit de chatoiement. Ce modèle prend en compte à la fois une représentation statistique des images RSO par modèle de mélanges finis et de copules, et une modélisation contextuelle à partir de champs de Markov hiérarchiques.

Abstract – This paper deals with the Bayesian classification of single-polarized very high resolution synthetic aperture radar (SAR) images that depict urban areas. The difficulty of such a classification relies in the significant effects of speckle noise. The model considered here takes into account both statistical modeling of images via finite mixture models and copulas, and contextual modeling thanks to hierarchical Markov random fields.

1 Introduction

Les systèmes de Radar à Synthèse d’Ouverture (RSO) ont pour avantage d’être peu affectés par les conditions atmosphériques et par l’ensevelissement [1]. Ainsi, leurs acquisitions ont un rôle important dans la gestion d’aléas, en permettant d’établir des cartographies d’utilisation et/ou de couverture des sols, ou de zones endommagées par des risques naturels (par exemple, inondations ou tremblements de terre). Dans le cadre d’une première approche face aux risques environnementaux, nous proposons d’établir des classifications d’images RSO contenant des zones urbaines, zones critiques socialement et économiquement vis-à-vis des catastrophes naturelles.

Plusieurs difficultés sont à prendre en compte. La première est due au bruit de chatoiement, qui détériore la qualité de l’image et rend, en général, difficilement utilisables des méthodes de classification développées pour des images optiques. En outre, les zones urbaines apparaissent sur les images très haute résolution (THR) comme des zones particulièrement hétérogènes, reflet des différents matériaux dont les villes sont composées (tuiles, asphalte, béton, métaux, etc.). Comme conséquence, la modélisation statistique des amplitudes des images RSO devient plus complexe.

Ainsi, comme nous en avons déjà discuté dans [2], nous modélisons les statistiques des amplitudes des images RSO de chaque classe considérée pour la classification (par exemple, végétation, zone urbaine,...) par un modèle de mélange fini grâce à l’algorithme DSEM (apprentissage par Dictionnaire combiné à un algorithme Stochastique d’Espérance Maximisation) [3]. Les Fonctions de Densité de Probabilité (FDP) des amplitudes des images RSO sont des mélanges de K FDP, sélectionnées automatiquement dans un dictionnaire parmi un choix de FDP modélisant bien certaines propriétés statistiques des images RSO. Un tel modèle offre, en outre, la possibilité d’intégrer une information supplémentaire relative à l’image RSO par le biais d’un attribut de texture dont les statistiques sont conjointement associées à celles de l’image originale grâce à des copules.

À partir de l’apprentissage des statistiques conjointes de chacune des classes, nous générons une classification bayésienne supervisée. Pour augmenter la robustesse face au bruit, nous considérons un modèle contextuel en échelle [4] via un modèle Markovien hiérarchique [5]. Celui-ci est fondé sur une structure en quad-arbre, qui possède de bonnes propriétés [6]. Ce document présente dans un premier temps brièvement la méthode d’estimation des statistiques conjointes, avant de se focaliser d’avantage sur la méthode hiérarchique (description des données et modèle mathématique). Nous montrons ensuite certains résultats de classification, avant de conclure.

2 Estimation des fonctions de densité de probabilité

Nous cherchons à modéliser les distributions statistiques de chaque classe m considérée pour la classification, $m = 1, \dots, M$, étant donné une base d’apprentissage. Pour chaque classe, les FDP $p_m(z|\omega_m)$ suivent un modèle de mélange fini de distributions de niveaux de gris indépendantes [3] :

$$p_m(z|\omega_m) = \sum_{i=1}^K P_{mi} p_{mi}(z|\theta_{mi}), \quad (1)$$

où z désigne un niveau de gris, $z \in [0; Z - 1]$, et ω_m est la m^{eme} classe. P_{mi} sont les proportions du mélange, telles que pour un m donné, $\sum_{i=1}^K P_{mi} = 1$ avec $0 \leq P_{mi} \leq 1$. Les FDP $p_{mi}(z|\theta_{mi})$ du mélange sont automatiquement choisies dans un dictionnaire prédéfini, comprenant les quatre familles de densités suivantes : Log-Normale, Weibull, Nakagami et Gamma Généralisée [3].

L'algorithme DSEM est utilisé pour estimer le mélange qui modélise le mieux les statistiques de chaque classe. Il combine l'utilisation d'une méthode des Log-Cumulants [7] pour estimer les paramètres des densités et un algorithme SEM [3].

Afin d'augmenter la qualité des résultats de la classification, nous proposons de modéliser une FDP conjointe. Nous générons une image texturée à partir de l'image RSO initiale en utilisant des attributs d'Haralick [2] bien choisis, qui permettent une mise en relief des zones urbaines par leur haute corrélation, tel qu'illustré sur la figure 3(b). Nous appliquons alors l'algorithme DSEM à chaque classe et à chacune des images (originale et texture). Pour chaque classe, les FDP marginales des 2 images sont combinées en vue d'estimer une FDP conjointe par le biais de copules (théorème de Sklar) [8].

Plus de détails concernant cet algorithme CoDSEM (Copules et DSEM) sont donnés dans [2].

3 Champ de Markov hiérarchique

Nous cherchons à estimer des étiquettes x_s à partir d'observations y_s , en vue de générer une carte de classification. Pour ce faire, nous allons considérer un modèle Markovien de type quad-arbre [9]. Un tel modèle présente divers avantages [6], dont la causalité induite par la structure propre de l'arbre, ainsi que la possibilité d'appliquer un algorithme non itératif (gain en temps de calcul).

Dans la suite de cet exposé, nous désignons par s un site, qui appartient à l'ensemble des sites $S = S^0 \cup \dots \cup S^R$, où R désigne la résolution la plus grossière (racine) et 0 correspond au niveau de référence. Nous pouvons définir des relations de parenté entre les différents niveaux n du quad-arbre, de telle sorte que si nous considérons un site s pour un n quelconque, nous pouvons lui attribuer un unique *parent* s^- et 4 *enfants* s^+ . L'ensemble formé par s et tous ses descendants sera noté $d(s)$. Ces notations sont schématisées dans la figure 1.

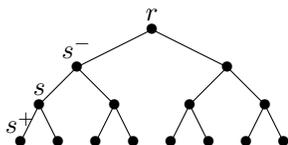


FIG. 1 – Notations utilisées sur le quad-arbre.

3.1 Les observations

Comme étape préalable, nous générons une décomposition en ondelettes [10] de l'image originale RSO, dont les approximations forment les différentes observations du graphe. Nous avons opté pour des ondelettes de Daubechies d'ordre 10. En effet, à l'issue de diverses expérimentations, ce choix a conduit à l'obtention de résultats légèrement meilleurs (gain de 1% sur le taux global de bonne classification). Empiriquement, nous avons constaté que 3 niveaux de décomposition est un bon compromis, au vu de la taille des images sur lesquelles nous travaillons (typiquement, 800×800 pixels), et de la similarité des résultats de classification obtenus pour un nombre de niveaux supérieur. Pour chaque niveau et chaque classe, l'algorithme CoDSEM est appliqué afin d'estimer le modèle d'observation (vraisemblance).

3.2 Le modèle mathématique

Nous avons choisi d'utiliser sur le quad-arbre un algorithme non itératif comparable à l'algorithme de Baum & Welsh sur chaîne de Markov, permettant d'obtenir le mode de la marginale a posteriori (MPM) [9]. En chaque site s , nous cherchons donc à maximiser les probabilités a posteriori $p(x_s|y)$. Le critère MPM a été préféré au critère MAP (Maximum A Posteriori), qui a le défaut de pénaliser les erreurs indépendamment de l'échelle à laquelle elles se produisent et de leur nombre [9]. Des informations initiales sont nécessaires :

- *Les probabilités de transition inter-niveaux* au sein de l'arbre $p(x_s|x_{s^-})$, constantes quel que soit le niveau n considéré et quel que soit le site s et son ascendant s^- . Nous avons fixé à 90% la probabilité que x_s appartienne à la même classe que son ascendant x_{s^-} .
- *Les vraisemblances* déterminées dans la partie 2.
- *Les probabilités a priori* à la résolution la plus grossière.

Pour déterminer ces dernières, nous utilisons des estimations de probabilités a priori d'après des classifications effectuées préalablement. Deux possibilités ont été considérées :

- Recherche du critère MPM sur structure hiérarchique en initialisant par une hypothèse d'équiprobabilité des classes en chaque site s ($p(x_s) = \frac{1}{M}$).
- Algorithme des K plus proches voisins (K -PPV).

Ces deux possibilités aboutissant à des résultats similaires, nous avons opté pour la première, afin d'obtenir une méthode uniquement fondée sur des recherches de critères MPM. Connaissant ces conditions initiales, nous appliquons au quad-arbre un algorithme de type « forward-backward » [9]. Les probabilités a posteriori sont estimées, puis maximisées par un algorithme de Metropolis modifié [2]. Un schéma de la méthode, baptisée CoDSEM-MPM, est donné figure 2.

4 Résultats

La méthode proposée a été validée expérimentalement sur des images RSO très haute résolution et comparée à une mé-

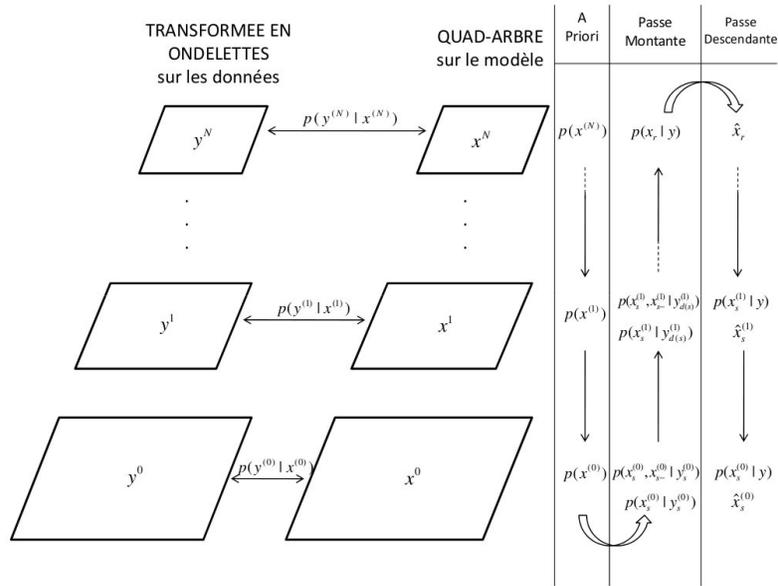


FIG. 2 – Algorithme de l’estimateur MPM sur le quad-arbre.

thode non hiérarchique, CoDSEM-MRF [2], qui combine l’estimation des statistiques (CoDSEM) à un champ de Markov simple. Nous illustrons nos résultats avec une acquisition du quai de Port-au-Prince en Haïti (COSMO-SkyMed, ©ASI, 2009) (Fig. 3), dont les caractéristiques sont : Polarisation simple HH, Stripmap (2,5 mètres de résolution au sol), image géocodée. Les classes considérées sont au nombre de 3 : zones urbaines, végétation et zones d’eau. Nous avons utilisé des vérités de terrain non exhaustives faites par une spécialiste afin d’établir une base d’apprentissage et une base de test distinctes. Les résultats obtenus ont été validés qualitativement (carte de classification en figure 3) et quantitativement (taux de bonne classification de la table 1).

TAB. 1 – Taux de bonne classification pour chacune des 3 classes considérées et taux global de bonne classification pour la base de test de l’image COSMO-SkyMed à laquelle nous avons appliqué notre algorithme hiérarchique ainsi qu’un algorithme CoDSEM-MRF.

	eau	urbain	végétation	total
CoDSEM-MRF	97, 59%	99, 03%	99, 28%	98,63%
CoDSEM-MPM	97, 62%	97, 80%	97, 92%	97,78%

Globalement, la classification obtenue est bonne pour les 3 classes considérées. L’introduction de l’élément de texture permet une meilleure discrimination des zones urbaines par rapport à la végétation et la hiérarchie sur les champs de Markov aboutit à une classification assez détaillée. Cependant, nous constatons quelques effets résiduels du bruit de chatoiement. En comparaison, la méthode non-hiérarchique aboutit à de meil-

leurs résultats numériques, mais à une classification visuelle moins précise.

Une dernière remarque concerne l’artéfact, qui, bien que non critique, fausse la classification dans la mer. L’introduction d’une classe « artéfact » ne permettrait pas d’aboutir à une meilleure classification, car les statistiques de celle-ci sont trop proches des statistiques de la classe « végétation ». Le modèle contextuel, en général robuste au bruit, trouve ici ses limites.

5 Conclusion

Nous avons comparé le comportement de 2 méthodes contextuelles de classification : un modèle contextuel spatial (champ de Markov) et un autre en échelle (Markov hiérarchique). Ces modèles contextuels sont combinés à une modélisation des statistiques des amplitudes des images RSO par modèle de mélanges finis et de copules en vue d’obtenir une classification bayésienne supervisée. Bien que les images fournies par l’ASI aient subi un prétraitement de géoréférencement, les statistiques des différentes classes restent globalement inchangées, de même que les effets du bruit de chatoiement. Les 2 méthodes envisagées présentent une certaine robustesse au bruit, mais aboutissent à des résultats assez différents. L’une génère une classification lissée tandis que l’autre est plus précise mais est plus affectée par certaines rétrodiffusions d’ondes. Il est alors difficile de porter un jugement sur la meilleure méthode, celle-ci dépendant de l’utilisation finale. Toutefois, nous aurions tendance à favoriser la méthode hiérarchique, car il est toujours possible d’effectuer un lissage en fin de classification si nécessaire. En outre, il offre la possibilité d’utiliser ultérieurement des données supplémentaires facilement intégrables dans l’arbre telles

que, par exemple, d'autres acquisitions à des résolutions différentes (remplaçant alors la décomposition en ondelettes), ou bien des acquisitions provenant d'autres capteurs (optique ou radar) pour rendre la classification plus précise.

6 Remerciements

Les auteurs remercient l'INRIA ainsi la Direction Générale de L'Armement (DGA) pour le financement partiel de ce travail de recherche. Nous remercions également l'Agence Spatiale Italienne (ASI) pour les images COSMO-SkyMed fournies. Enfin, nous voudrions remercier G. Moser et S. B. Serpico de l'Université de Gênes (DIBE) pour des discussions fructueuses ainsi que Michaela De Martino pour les vérités de terrain.

Références

- [1] C. Oliver et S. Quegan. *Understanding Synthetic Aperture Radar images*. SciTech Publishing, 2004.
- [2] A. Voisin, G. Moser, V. Krylov, S. B. Serpico et J. Zerubia. *Classification of very high resolution SAR images of urban areas by dictionary-based mixture models, copulas and Markov random fields using textural features*. Proc. of SPIE (SPIE Symposium on Remote Sensing 2010), Vol. 7830, pp. 78300O, 2010.
- [3] V. Krylov, G. Moser, S. B. Serpico et J. Zerubia. *Enhanced dictionary-based SAR amplitude distribution estimation and its validation with very high-resolution data*. IEEE Geosci. Remote Sens. Lett., 8(1) :148-152, 2011.
- [4] S. Geman et D. Geman. *Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images*. IEEE Trans. Pattern Anal. Machine Intell., 6(6) :721-741, 1984.
- [5] P. Fieguth. *Statistical image processing and multidimensional modeling*. Springer, 2011.
- [6] C. Graffigne, F. Heitz, P. Pérez, F. Prêteux, M. Sigelle et J. Zerubia. *Hierarchical Markov random field models applied to image analysis : a review*. Proc. SPIE Conf. on neural, morphological, stochastic methods and signal processing 2568, 1995.
- [7] C. Tison, J.-M. Nicolas, F. Tupin et H. Maitre. *A new statistical model for Markovian classification of urban areas in high-resolution SAR images*. IEEE Trans. Geosci. Remote Sens., 42(10) :2046-2057, 2004.
- [8] R. B. Nelsen. *An introduction to copulas*. Springer, New York (2nd ed.), 2006.
- [9] J.-M. Laferté, P. Pérez et F. Heitz. *Discrete Markov modeling and inference on the quad-tree*. IEEE Transactions on Image Processing, 9(3) :390-404, 2000.
- [10] I. Daubechies *Orthonormal bases of compactly supported wavelets*. Communications on Pure and Applied Mathematics, 41 :909-996, 1988.

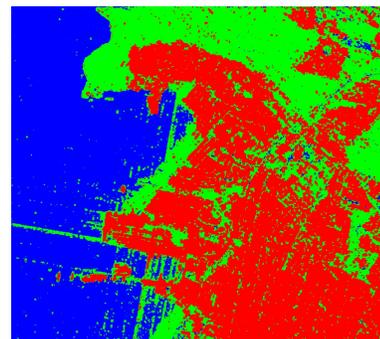
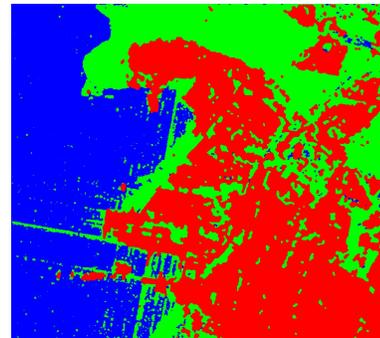


FIG. 3 – De haut en bas : (a) : Image RSO originale (COSMO-SkyMed, ©ASI) 900×800 pixels ; (b) : Image texturée extraite de l'image RSO. Les zones urbaines sont mises en relief ; (c) : Carte de classification obtenue par CoDSEM-MRF ; (d) : Carte de classification obtenue par CoDSEM-MPM ; [Rouge : zones urbaines || Bleu : zones d'eau || Vert : végétation].