

Apport de la géométrie de l'information pour la classification d'images SAR polarimétriques

Pierre FORMONT^{1,2}, Frédéric PASCAL¹, Jean-Philippe OVARLEZ², Gabriel VASILE³, Laurent FERRO-FAMIL⁴

¹SONDRA/SUPELEC

3 rue Joliot Curie, Chemin du Moulon, 91192 Gif sur Yvette Cedex, France

²ONERA, The French Aerospace Lab

ONERA DEMR/TSI - Chemin de la Hunière, 91761 Palaiseau, France

³Grenoble-Image-sPeech-Signal-Automatics Lab, CNRS

GIPSA-lab DIS/SIGMAPHY, Grenoble INP - BP 46, 38402 Grenoble, France

⁴IETR, Image and Remote Sensing Group

SAPHIR, Université de Rennes 1, Rennes, France

pierre.formont@supelec.fr, frederic.pascal@supelec.fr

jean-philippe.ovarlez@onera.fr, gabriel.vasile@gipsa-lab.grenoble-inp.fr,

laurent.ferro-famil@univ-rennes1.fr

Résumé – Ce papier présente l'utilisation de la moyenne Riemannienne pour le calcul des centres de classes dans le processus de classification H- α non supervisée en environnement non Gaussien. Des rappels sur l'estimation de matrice de covariance dans le cas non Gaussien seront effectués avant de présenter la méthode utilisée. Les centres de classes sont plus stables en utilisant cette méthode, ce qui mène à une interprétation différente de la classification.

Abstract – We discuss in the paper the use of the Riemannian mean given by the differential geometric tools. This geometric mean is used in this paper for computing the centers of class in the polarimetric H/ α unsupervised classification process. We can show that the centers of class will remain more stable during the iteration process, leading to a different interpretation of the H/ α /A classification. This technique can be applied both on classical SCM and on Fixed Point covariance matrices. Used jointly with the Fixed Point CM estimate, this technique can give nice results when dealing with high resolution and highly textured polarimetric SAR images classification.

1 Introduction

Les systèmes d'acquisition SAR polarimétriques (Pol-SAR) récents sont maintenant capable de produire des images PoLSAR avec des résolutions décimétriques. L'information polarimétrique permet de discriminer les différents mécanismes de rétrodiffusion. La décomposition entropie(H) - alpha - anisotropie, basée sur la décomposition en valeurs propres de la matrice de covariance polarimétrique (MC), a été introduite dans [1]. Cette MC est usuellement estimée sous hypothèse d'homogénéité et de distribution gaussienne du signal. L'estimateur du maximum de vraisemblance (EMV) est alors la Sample Covariance Matrix (SCM), qui suit une distribution de Wishart. Lee, dans [2], a proposé un processus de classification utilisant la décomposition H- α comme initialisation d'un algorithme K-Means standard, utilisant la MC comme vecteur d'observation. Cet algorithme calcule un centre de classe pour chacune des classes de l'image en effectuant

une moyenne arithmétique de toutes les MC qui appartiennent à la classe. L'amélioration de la résolution permet d'avoir une observation bien plus précise spatialement des différents objets présents dans l'image mais entraîne aussi une complexification du signal, notamment en termes d'hétérogénéité et de non-gaussianité. Certaines zones, usuellement considérées comme ayant des mécanismes de rétrodiffusion aléatoires peuvent devenir des rétrodiffuseurs ponctuels déterministes. Les techniques usuelles de classification, détection, filtrage, etc. utilisées pour les résolutions faibles doivent être adaptées à ces nouveaux problèmes.

2 Modèle SIRV

Pour les images SAR haute résolution, des études récentes ont montré que l'hétérogénéité spatiale de la scène mène à un modèle non-Gaussien du fouillis. Un modèle de fouillis non-Gaussien couramment utilisé est le modèle produit : l'hétérogénéité spatiale de l'image SAR est prise

en compte en modélisant le m -vecteur d'information polarimétrique du fouillis, \mathbf{k} , par un SIRV (Spherically Invariant Random Vector). Un SIRV est le produit entre la racine carrée d'une variable aléatoire positive τ , appelée texture, et un vecteur gaussien indépendant de moyenne nulle \mathbf{z} , appelé speckle, et caractérisé par une CM inconnue \mathbf{M} :

$$\mathbf{k} = \sqrt{\tau} \mathbf{z}, \quad (1)$$

Dans ce modèle, la variable τ représente la variation spatiale locale d'intensité du vecteur \mathbf{k} d'un pixel à l'autre. Toute l'information polarimétrique (relations de phase dans le vecteur \mathbf{k}) est ainsi contenue uniquement dans la MC \mathbf{M} . Relativement à un pixel donné, le vecteur \mathbf{k} est donc Gaussien.

Sous hypothèse d'homogénéité et de fouillis gaussien, la texture τ est supposée constante et identique pour tous les pixels. Dans ce cas, la statistique des données secondaires est gaussienne et l'EMV de la CM est la SCM, estimé avec un N -échantillon de données secondaires \mathbf{k}_i , $i \in [1, N]$:

$$\widehat{\mathbf{M}}_{SCM} = \frac{1}{N} \sum_{i=1}^N \mathbf{k}_i \mathbf{k}_i^H \quad (2)$$

Sous hypothèse SIRV, la CM est généralement un paramètre inconnu qui peut être estimé par MV. Gini et al. ont dérivé dans [3] l'EMV $\widehat{\mathbf{M}}_{FP}$ de la CM \mathbf{M} pour une texture déterministe, qui est la solution de l'équation suivante :

$$\widehat{\mathbf{M}}_{FP} = f(\mathbf{M}) = \frac{m}{N} \sum_{i=1}^N \frac{\mathbf{k}_i \mathbf{k}_i^H}{\mathbf{k}_i^H \widehat{\mathbf{M}}_{FP}^{-1} \mathbf{k}_i}, \quad (3)$$

Cette approche a été utilisé dans [4] par Conte et al. pour dériver un algorithme permettant d'estimer la matrice solution \mathbf{M}_{FP} , appelé matrice du Point Fixe (FPE). Cet algorithme consiste à calculer le point fixe de f en utilisant la séquence définie par $\mathbf{M}_{i+1} = f(\mathbf{M}_i)$ et $\mathbf{M}_0 = \mathbf{I}$. Dans [3] et [4], il a été montré que le processus d'estimation de l'équation (3), développé pour une texture déterministe, permet d'obtenir un EMV approché sous hypothèse d'une texture aléatoire. Cette étude a été complétée par les travaux de Pascal et al. [5], qui ont établi l'existence et l'unicité du FPE, ainsi que la convergence de l'algorithme quelle que soit l'initialisation. De plus, cet estimateur suit asymptotiquement une distribution de Wishart.

3 Classification polarimétrique en environnement non-Gaussien

Les processus de classification polarimétrique classiques utilisent un algorithme K-means. Chaque pixel, représenté par sa MC, est assigné à une classe, qui possède un centre

de classes (la moyenne de tous ses éléments) et une distance est utilisée pour réassigner les pixels à chaque itération. Dans le cas Gaussien, la distance de Wishart entre la MC $\widehat{\mathbf{M}}_i$ et le centre de classe $\widehat{\mathbf{M}}_\omega$, dérivée dans [2], est utilisée :

$$D_W(\widehat{\mathbf{M}}_i, \widehat{\mathbf{M}}_\omega) = \ln \frac{|\widehat{\mathbf{M}}_\omega|}{|\widehat{\mathbf{M}}_i|} + \text{Tr}(\widehat{\mathbf{M}}_\omega^{-1} \widehat{\mathbf{M}}_i)$$

Pour le cas non-Gaussien, une nouvelle distance, la distance SIRV, a été dérivée dans [6] :

$$D_S(\widehat{\mathbf{M}}_i, \widehat{\mathbf{M}}_\omega) = \ln \frac{|\widehat{\mathbf{M}}_\omega|}{|\widehat{\mathbf{M}}_i|} + \frac{m}{N} \sum_{n=1}^N \frac{\mathbf{k}_n^H \widehat{\mathbf{M}}_\omega^{-1} \mathbf{k}_n}{\mathbf{k}_n^H \widehat{\mathbf{M}}_i^{-1} \mathbf{k}_n}$$

Cette expression peut se simplifier facilement en :

$$D_S(\widehat{\mathbf{M}}_i, \widehat{\mathbf{M}}_\omega) = D_W(\widehat{\mathbf{M}}_i, \widehat{\mathbf{M}}_\omega) \quad (4)$$

On retrouve ainsi l'expression du cas Gaussien. Cette distance est utilisée pour réattribuer les pixels d'une classe à l'autre à chaque itération. Les centres de classes $\widehat{\mathbf{M}}_\omega$ sont ensuite recalculés avec une métrique euclidienne, i.e. la moyenne arithmétique usuelle :

$$\widehat{\mathbf{M}}_{\omega_l} = \frac{1}{K} \sum_{k=1}^K \widehat{\mathbf{M}}_k^l \quad (5)$$

avec $\widehat{\mathbf{M}}_k^l$, $k \in [1, K]$ les K MC des pixels appartenant à la classe ω_l . Après plusieurs itérations de l'algorithme défini dans [2], les centres de classe se déplacent de manière importante par rapport à leur position initiale, ce qui rend plus difficile l'interprétation physique du résultat final de la classification.

4 Apport de la géométrie de l'information

Une théorie émergente [7, 8] permet de prendre en compte le fait que l'espace des MC n'est pas euclidien. De manière rigoureuse, la moyenne des MC d'une classe ne peut être calculée par l'expression de l'Eq. (5).

La moyenne associée à la métrique riemannienne correspond à la moyenne géométrique définie par :

$$\mathbf{M}_{\omega_l} = \arg \min_{\mathbf{M}_\omega \in \mathcal{P}(m)} \sum_{k=1}^K \left\| \log(\mathbf{M}_\omega \mathbf{M}_k^{-1}) \right\|_F^2 \quad (6)$$

avec $\|\cdot\|_F$ la norme de Frobenius et $\mathcal{P}(m)$ l'ensemble des MC hermitiennes définies positives de taille m . La solution de cette équation peut être obtenue facilement par un algorithme de descente de gradient.

On peut aussi utiliser la géométrie riemannienne de l'espace pour l'expression de la distance entre deux matrices. On a alors une distance matricielle basée sur la géométrie de l'espace plutôt que sur la statistique des matrices :

$$d_G(\mathbf{P}_1, \mathbf{P}_2) = \left\| \log(\mathbf{P}_1^{-1} \mathbf{P}_2) \right\|_F \quad (7)$$

5 Résultats sur données réelles

La figure 1 présente les jeux de données utilisés : un jeu de données acquis à Brétigny par le système RAMSES de l'ONERA en bande X et un jeu de données acquises à Paracou en Guyane par le système SETHI de l'ONERA en bande UHF. La résolution au sol est de 1.3x1.3m dans les deux cas.

La figure 2 présente la comparaison entre les résultats de classification obtenus avec le FPE en utilisant la moyenne arithmétique ou la moyenne géométrique. En utilisant la moyenne géométrique, les coins réflecteurs utilisés pour la calibration dans la partie droite de l'image, en bas, sont mieux séparés du reste de l'image en étant classés seuls dans la classe 8. Les zones urbaines donc plus hétérogènes sont représentées par les classes 1, 3, 6 et 7 alors que les zones plus homogènes (champs et forêts) sont réparties dans les classes restantes.

La figure 3 présente les résultats de classification obtenus avec le FPE en prenant en considération la moyenne arithmétique ou la moyenne géométrique sur le jeu de données présenté Fig. 2. L'utilisation de la moyenne géométrique permet d'affiner la classification sur des zones spécifiques sur ce jeu de données. D'une manière générale, la classe 8 a vu sa taille réduire et les pixels lui appartenant en utilisant la moyenne classique réattribués aux classes voisines, 4 et 5 principalement. Cette réorganisation s'accroît lorsque l'on utilise la distance de l'Eq. (7) à la place de la distance SIRV de l'Eq. (4) pour avoir une classe 8 contenant quasiment uniquement une ligne droite dans le coin supérieur gauche de l'image, qui correspond à une route, ainsi qu'une zone indéfinie dans le coin supérieur droit. En l'absence de vérité terrain plus définie, il est difficile d'apporter une interprétation plus poussée mais sur les deux jeux de données présentés, l'utilisation de la géométrie de l'espace des MC permet d'apporter des informations supplémentaires.

6 Conclusions

Les premiers résultats d'utilisation de la métrique Riemannienne pour la classification PoLSAR sont encourageants et laissent présager d'une amélioration des classifications en employant plus intensément ces techniques. Des travaux de simulations vont être entrepris pour quantifier l'apport de cette méthode.

7 Remerciements

Les auteurs tiennent à remercier la DGA pour le financement de ces travaux et l'ONERA pour avoir fourni les jeux de données.

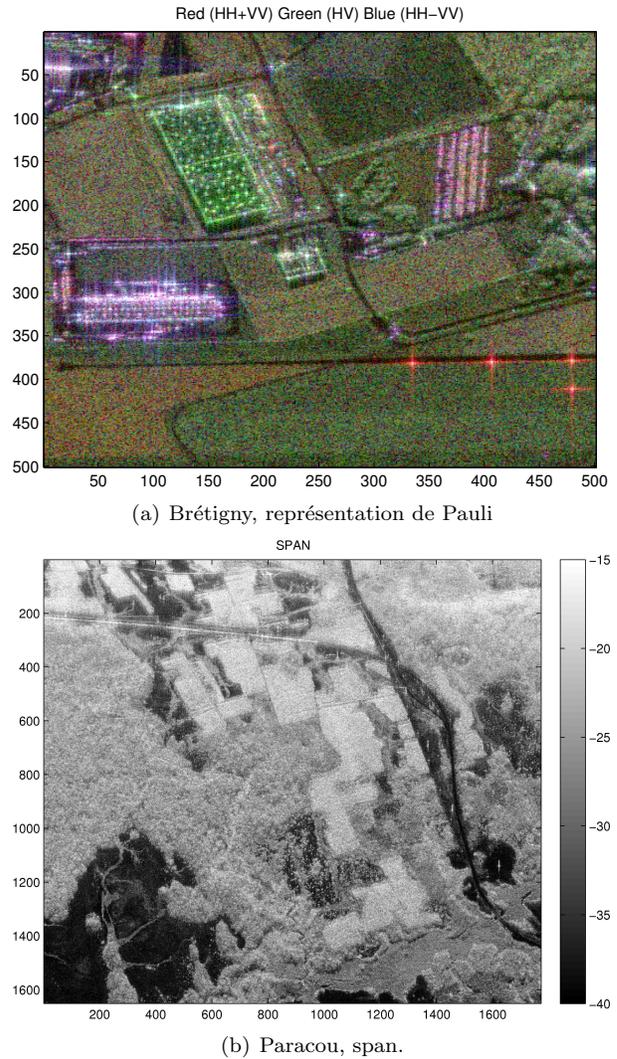
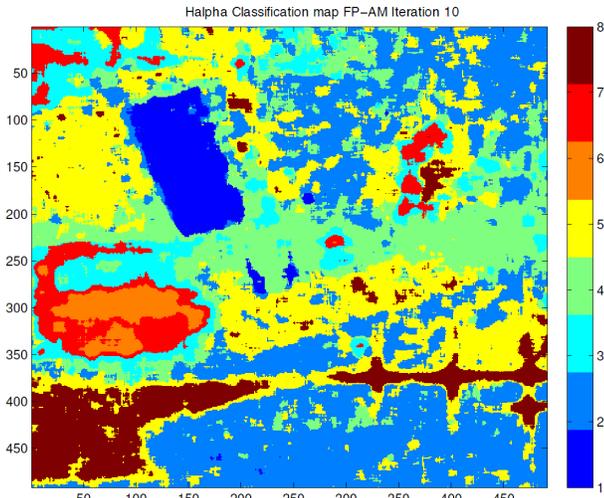


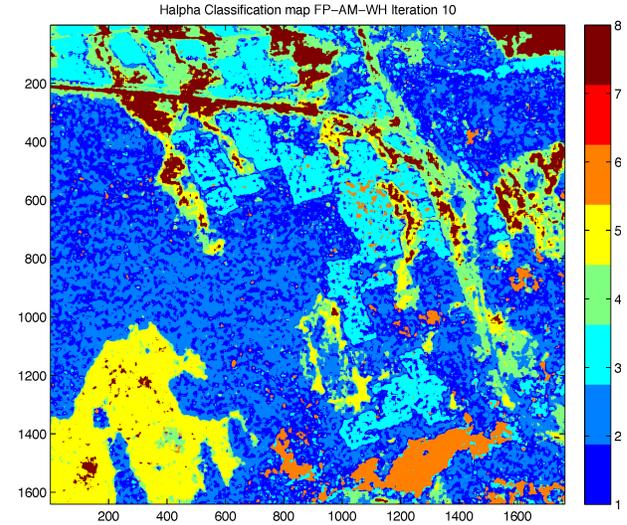
FIGURE 1 – Jeux de données.

Références

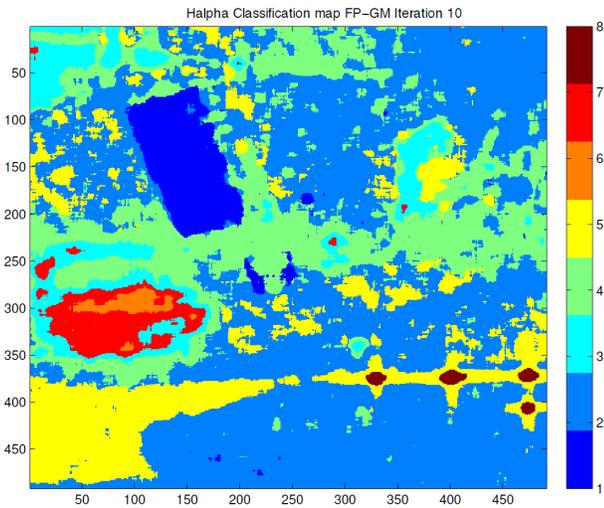
- [1] S. R. Cloude and E. Pottier, "An entropy based classification scheme for land applications of polarimetric SAR", *IEEE Trans. on GRS*, Vol. 35, No. 1, pp.68-78, Jan. 1997.
- [2] J. S. Lee, M. R. Grunes, T. L. Ainsworth, D. Li-Jen, D. L. Schuler, and S. R. Cloude, "Unsupervised Classification Using Polarimetric Decomposition and the Complex Wishart Classifier," *IEEE Trans. on GRS*, vol. 37, no. 5, pp. 2249-2258, 1999.
- [3] F. Gini and M. V. Greco, "Covariance Matrix Estimation for CFAR Detection in Correlated Heavy Tailed Clutter," *Signal Processing*, Vol.82, No.12, pp.1847-1859, 2002.
- [4] E. Conte, A. DeMaio, and G. Ricci, "Recursive Estimation of the Covariance Matrix of a Compound-Gaussian Process and its Application to Adaptive CFAR Detection," *IEEE Trans. on IP*, Vol.50, No.8, pp.1908-1915, 2002.
- [5] F. Pascal, Y. Chitour, J.P. Ovarlez, P. Forster and P. Larzabal, "Covariance Structure Maximum Likelihood Estimates



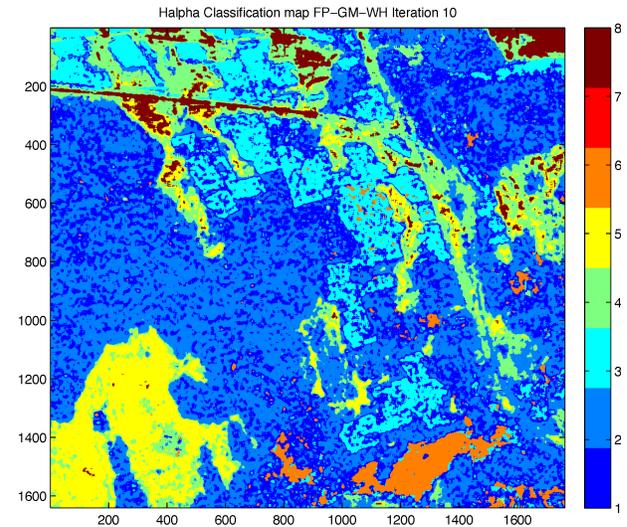
(a) FPE et moyenne arithmétique



(a) FPE, moyenne arithmétique



(b) FPE et moyenne géométrique



(b) FPE, moyenne géométrique

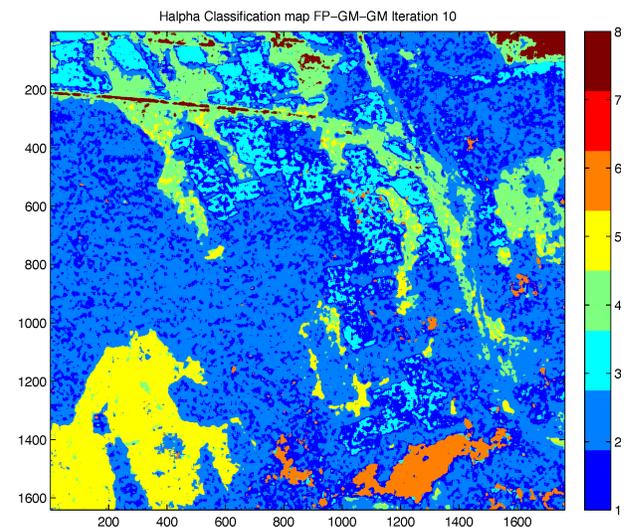
FIGURE 2 – Comparaison entre les résultats de classifications avec le FPE après 10 itérations pour les moyennes arithmétique et géométrique.

in Compound Gaussian Noise : Existence and Algorithm Analysis”, *IEEE Trans. on SP*, Vol. 56, No. 1, pp. 34-48, Jan. 2008.

[6] G. Vasile, J.P. Ovarlez, F. Pascal and C. Tison, “Coherency Matrix Estimation of Heterogeneous Clutter in High Resolution Polarimetric SAR Images”, *IEEE Trans. on GRS*, Vol.48, No.4, pp.1809-1826, April 2010.

[7] M. Moakher, “Differential Geometric Approach to the Geometric Mean of Symmetric Positive-Definite Matrices”, *SIAM J. Matrix Anal. Appl.*, Vol.26, No.3, pp.735-747, 2005

[8] F. Barbaresco, “Innovative Tools for Radar Signal Processing Based on Cartan’s Geometry of SPD Matrices and Information Geometry”, *IEEE International Radar Conference, Rome*, May 2008



(c) FPE, moyenne géométrique, distance géométrique

FIGURE 3 – Comparaison entre les résultats de classifications avec le FPE après 10 itérations pour les moyennes arithmétique et géométrique.