

Détection de Changement Robuste en Rang Faible pour les Séries Temporelles d'Images SAR

Ammar MIAN^{1,2}, Arnaud BRELOY³, Guillaume GINOLHAC², Jean-Philippe OVARLEZ^{1,4}

¹CentraleSupélec SONDRRA, Université Paris-Saclay, 3 rue Joliot Curie, 91190 Gif-sur-Yvette, France

²LISTIC, Université Savoie Mont-Blanc, 5 Chemin de Bellevue, Annecy-Le-Vieux, 74940 Annecy, France

³LEME, Université Paris-Nanterre, 50 Rue de Sèvres, 92410 Ville-d'Avray, France

⁴DEMR, ONERA, Université Paris-Saclay, 8 Chemin de la Hunière, 91123 Palaiseau, France

ammар.mian@centralesupelec.fr

Résumé – Ce papier considère la détection de changements dans une série temporelle d'images multivariées obtenues par radar à synthèse d'ouverture. Dans ce cadre, les méthodologies classiques modélisent les données par une distribution gaussienne à moyenne nulle et une covariance non structurée. Ces deux hypothèses montrent leur limite lorsque les données sont à très haute résolution ou que la dimension de celles-ci est grande. Pour de telles images, les pixels peuvent avoir un comportement impulsif (non gaussien) et peuvent avoir une structure de rang faible. Ainsi, nous proposons de dériver un nouveau détecteur dans un cadre robuste en supposant une structure de rang faible. Les résultats de l'approche proposée sur un jeu de données UAVSAR illustrent l'intérêt de la méthode.

Abstract – This paper considers the problem of detecting changes in multivariate Synthetic Aperture Radar image time series. Classical methodologies based on covariance matrix analysis are usually built upon the Gaussian assumption, as well as an unstructured signal model. Both of these hypotheses may be inaccurate for high-dimension/resolution images, where the noise can be heterogeneous (non-Gaussian) and where all channels are not always informative (low-rank structure). In this paper, we tackle these two issues by proposing a new detector assuming a robust low-rank model. Analysis of the proposed method on a UAVSAR dataset shows promising results.

1 Introduction

L'analyse des séries temporelles d'images issues de radar à synthèse d'ouverture (SAR) a soulevé un intérêt croissant ces dernières décennies. En effet, les nombreuses applications pratiques en font un sujet actif d'étude. Dans ce cadre, la détection de changements est un problème encore difficile car il y a peu de données avec une vérité terrain fiable et précise. De plus, contrairement aux images optiques, les images SAR sont soumises à un bruit multiplicatif qui limite l'utilisation des approches classiques en traitement de l'image optique. Historiquement, les méthodes non supervisées, souvent basées sur des outils statistiques, ont été prédominantes [1].

Dans un cadre non supervisé, une solution consiste à obtenir une distance locale entre données à chaque date. Ainsi, une approche classique consiste à mesurer la cohérence entre les images [2]. D'autres approches considèrent l'utilisation d'un opérateur log-ratio comme une métrique de changement [3]. Toutefois, ces méthodes sont limitées à l'analyse de changement entre une paire d'images monovariées et ne prennent donc pas en compte toute l'information de la série d'images. En effet, les avancées des capteurs (développement de la polarimétrie) et des techniques de reconstruction (par exemple les outils temps-fréquences [4, 5]) permettent d'obtenir des images

multivariées, apportant une information utile pour caractériser les changements.

Pour des données multivariées, une quantité intéressante pour la détection de changement est la matrice de covariance estimée sur un voisinage spatial [6]. Sous un modèle gaussien, des outils de la théorie de l'information ont été exploités dans [7] pour obtenir une distance entre les matrices de covariances à chaque image. Afin de considérer toute la série dans son ensemble, les résultats de la littérature statistique, sur les tests d'égalité de matrices de covariance, ont été exploités dans [8]. Cette approche a permis l'obtention de résultats intéressants pour des images de résolution standard. Toutefois, lorsque les images sont très haute résolution (HR) ou de grande dimension, deux problèmes sont rencontrés :

- i)* Les récentes analyses statistiques des images HR [9] ont montré que le modèle gaussien est inexact de par l'impulsivité locale observée. Un nouveau modèle, la gaussienne composée (GC) a été proposé afin de mieux décrire les données.
- ii)* La matrice de covariance est supposée de rang plein, ce qui peut se révéler inexact en grande dimension où seulement quelques canaux peuvent contenir un signal utile.

Ainsi, une extension au modèle GC a été entreprise dans [10], tandis qu'une détection sur des matrices en rang faible

dans un cadre gaussien a été faite dans [11]. Dans ce papier, nous proposons de combiner les deux approches afin de proposer un nouveau détecteur prenant en compte les deux aspects. Pour ce faire, nous repartons du problème et considérons le Test du Rapport de Vraisemblance Généralisé (TRVG).

2 Cadre général

2.1. Données : Nous considérons un voisinage spatial de la série d'images $\{\mathbf{x}_k^t\}_{(k,t) \in [1,K] \times [1,T]}$ où k correspond à un indice spatial et t un indice temporel. La dimension des données est $\dim(\mathbf{x}_k^t) = p$.

2.1. TRVG : Afin d'obtenir une statistique de décision, nous considérons le problème dans le cadre d'un test d'hypothèses sur les paramètres d'un modèle. A chaque instant t , les données $\{\mathbf{x}_k^t\}_{k \in [1,K]}$ sont modélisées par une distribution de paramètre θ^t , ce qui mène à une vraisemblance $\mathcal{L}(\{\mathbf{x}_k^t\}_{k \in [1,K]} | \theta^t)$. Ainsi, les paramètres θ^t représentent les données à chaque date.

Pour améliorer la visibilité de ce papier, nous nous concentrons sur le cas $T = 2$ (changement entre deux acquisitions), sachant que la généralisation au cas $T > 2$ est directe. Le problème de détection peut être considéré comme choix entre les deux alternatives suivantes :

$$\begin{cases} H_0 : \theta^1 = \theta^2 = \theta^0 & (\text{absence de changement}), \\ H_1 : \theta^1 \neq \theta^2 & (\text{changement}). \end{cases} \quad (1)$$

Afin d'obtenir une statistique de décision, le TRVG est un outil qui possède des propriétés statistiques intéressantes. Dans ce cadre général son expression est la suivante :

$$\hat{\Lambda} = \frac{\max_{\theta^1, \theta^2} \prod_{t=1}^2 \mathcal{L}(\{\mathbf{x}_k^t\}_{k \in [1,K]} | H_1; \theta^t)}{\max_{\theta^0} \prod_{t=1}^2 \mathcal{L}(\{\mathbf{x}_k^t\}_{k \in [1,K]} | H_0; \theta^0)}. \quad (2)$$

Il est ainsi possible d'obtenir un détecteur en choisissant une distribution qui reflète bien le comportement des données et en dérivant l'expression précédente. Toutefois, selon le modèle choisi, le calcul de cette quantité peut amener à des problèmes d'optimisations complexes.

3 Test basés sur la matrice de covariance

La covariance étant un descripteur intéressant, nous rappelons ici les différents modèles déjà considérés dans la littérature.

3.1. Modèle Gaussien [6] : Sous cette hypothèse classique, la moyenne est supposée nulle et le changement correspond à un changement de matrice de covariance. Le TRVG, noté $\hat{\Lambda}_G$ est obtenu avec les paramètres suivants :

$$\mathbf{x}_k^t \sim \mathcal{CN}(\mathbf{0}, \Sigma^t) \quad \text{et} \quad \theta_G^t = \{\Sigma^t\} \quad (3)$$

Ce test a une expression explicite et est très bien étudié dans la littérature statistique.

3.2. Modèle Gaussien faible rang [11] : Les signaux radars peuvent se trouver dans un espace de faible dimension. De ce fait, la covariance peut avoir une structure rang faible. En incluant cette connaissance a priori dans le modèle un TRVG, noté $\hat{\Lambda}_{LRG}$, a ainsi été dérivé avec les paramètres suivants :

$$\mathbf{x}_k^t \sim \mathcal{CN}(\mathbf{0}, \Sigma_R^t + \sigma^2 \mathbf{I}) \quad \text{et} \quad \theta_{LRG}^t = \{\Sigma_R^t\} \quad (4)$$

où Σ_R^t est la covariance du signal de rang R et $\sigma^2 \mathbf{I}$ est la covariance du bruit thermique. Plus de détails sur la sélection d'ordre de modèle peuvent être trouvés dans [11] ou la section 5.2 de ce papier.

3.3. Modèle GC [10] : Lorsque les images sont hétérogènes, le modèle gaussien peut se révéler être imprécis pour modéliser le comportement des données. Pour prendre en compte les disparités locales de la réflectivité, le modèle GC a ainsi été introduit [9] pour mieux modéliser cette hétérogénéité. Il consiste en une généralisation de la gaussienne où chaque observation possède un facteur d'échelle différent souvent dénommé paramètre de texture (que l'on considère ici déterministe inconnu). Ainsi, un TRVG dans ce modèle, noté $\hat{\Lambda}_{CG}$, a pu être proposé avec les paramètres suivants :

$$\mathbf{x}_k^t \sim \mathcal{CN}(\mathbf{0}, \tau_k^t \Sigma^t) \quad \text{et} \quad \theta_{CG}^t = \{\Sigma^t, \{\tau_k^t\}_{k \in [1,K]}\}. \quad (5)$$

Il s'agit ici de tester un changement à la fois dans la matrice de covariance Σ^t (normalisée) et les paramètres de texture. Le calcul de ce TRVG possède une forme explicite mais nécessite le calcul numérique de solutions d'une équation de point fixe. Le détail théorique de cette approche a été traité dans [10].

4 Détecteur proposé

Afin de pouvoir intégrer les améliorations obtenues par le modèle GC et la structure de rang faible, nous proposons le modèle suivant :

$$\begin{aligned} \mathbf{x}_k^t &\sim \mathcal{CN}(\mathbf{0}, \tau_k^t (\Sigma_R^t + \sigma^2 \mathbf{I})) \\ \theta_{LRCG}^t &= \{\Sigma_R^t, \{\tau_k^t\}_{k \in [1,K]}\}, \end{aligned} \quad (6)$$

où Σ_R^t est la covariance normalisée de rang R correspondant au signal et $\sigma^2 \mathbf{I}$ correspond à la covariance du bruit thermique. Nous testons également dans ce modèle un changement à la fois sur la matrice normalisée du signal ainsi que sur les paramètres de textures.

Le calcul du TRVG nécessite l'utilisation de techniques d'optimisation non-convexes de majorization-minimisation similaires à celle utilisées dans [11]. Le calcul technique est omis ici pour des raisons d'espace¹. La partie suivante est ainsi dédiée à l'analyse des performances de ce nouveau détecteur, que l'on nommera $\hat{\Lambda}_{LRCG}$, sur une paire d'images UAVSAR.

1. Un code python pour la méthode proposée est disponible sur <https://github.com/AmmarMian/Robust-Low-Rank-CD>

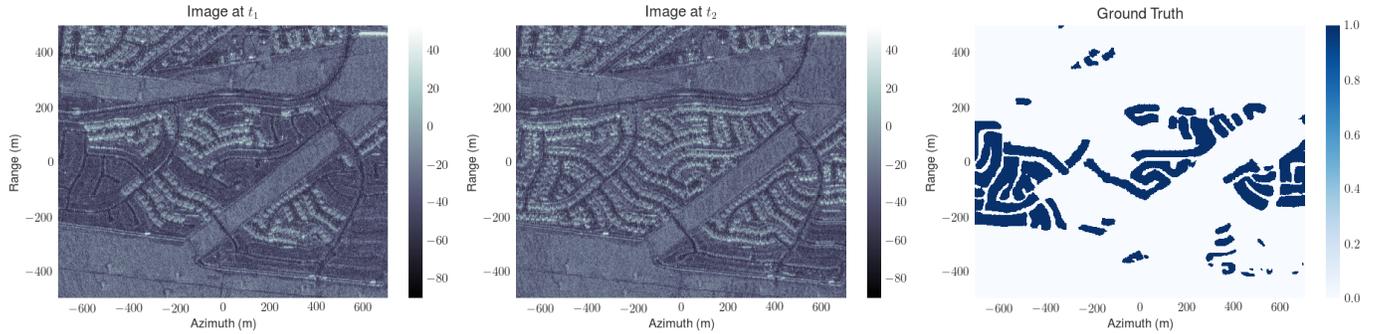


FIGURE 1 – Données UAVSAR utilisées dans cette étude. Gauche : 23 Avril 2009. Milieu : 15 Mai 2011. Droite : Vérité terrain.

5 Résultats sur des données UAVSAR

5.1. Description des données : Pour quantifier la performance de la méthode proposée, une paire de deux images UAVSAR² (NASA/JPL-Caltech), a été choisie. La disponibilité d'une vérité terrain obtenue par [7], permet ainsi de quantifier les performances de détection. Les images présentées à la Figure 1 ont une résolution de 1.67 m en distance et 0.6 m en azimuth et possèdent trois canaux de polarisations.

Afin d'améliorer la quantité d'information utile pour la détection de changement, chaque polarisation de l'image a été décomposée grâce à la transformée en ondelettes présentée dans [5]. Cette opération permet en effet d'améliorer les performances de détection [4]. Ainsi nous avons ici une dimension des pixels de $p = 12$.

5.2. Estimation du rang et du niveau de bruit :

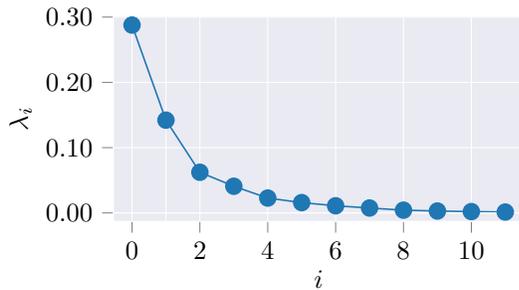


FIGURE 2 – Répartition moyenne des valeurs propres.

Pour pouvoir utiliser le détecteur proposé, le rang R doit être estimé a priori. Pour ce faire, diverses méthodes existent dans la littérature [12]. Dans ce papier, nous considérons une approche simple en considérant la distribution moyenne des valeurs propres de la matrice de covariance empirique sur les deux images. Les valeurs propres sont ainsi tracées à la Figure 2. Pour ces données, le choix d'un rang $R = 3$ semble approprié pour séparer la partie signal et bruit puisqu'il permet de conserver 81% de la variance totale.

La variance du bruit est quant à elle estimée localement sur la fenêtre locale en moyennant les $(p - R)$ plus faibles valeurs propres de la matrice de covariance empirique.

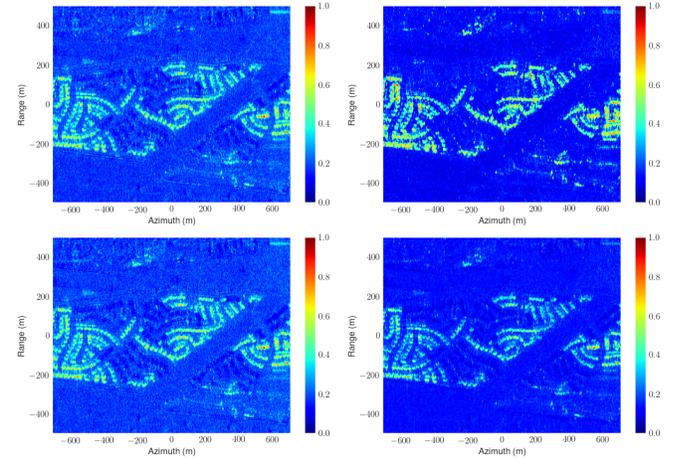


FIGURE 3 – Résultats normalisés avec $(p = 12, K = 25)$. Haut-Gauche : $\hat{\Lambda}_G$. Haut-Droite : $\hat{\Lambda}_{LRG}$. Bas-Gauche : $\hat{\Lambda}_{CG}$. Bas-Droite : $\hat{\Lambda}_{LRCG}$ (proposé).

5.3. Résultats : Afin de quantifier l'efficacité de la combinaison entre structure rang faible et modèle robuste, les performances de détection sont comparées aux détecteurs suivants :

- i) le détecteur classique gaussien proposé dans [6] (Section 3.1)
- ii) le détecteur rang faible gaussien dérivé dans [11] (Section 3.2)
- iii) le détecteur GC proposé dans [10] (Section 3.3).

La Figure 3 présente le résultat normalisé des différents détecteurs en utilisant des patches de taille 5×5 . En première observation, les détecteurs rang faible délivrent des résultats avec moins de fausses alarmes comparativement aux détecteurs sans cette contrainte. Ce résultat est attendu puisque seuls les plus fortes composantes du signal sont considérées pour la détection, ce qui diminue la contribution du bruit.

Nous traçons ensuite, la courbe ROC correspondante en Figure 4. La méthode proposée permet d'obtenir les meilleures performances de détection pour n'importe quelle probabilité de fausse alarme. Le gain est le plus apparent en comparaison avec le détecteur rang faible gaussien qui a une plus faible probabilité de détection lorsque le taux de fausses alarmes augmente. Ce résultat peut s'interpréter par le fait que lorsque le modèle

2. Disponible sur <https://uavsar.jpl.nasa.gov/>.

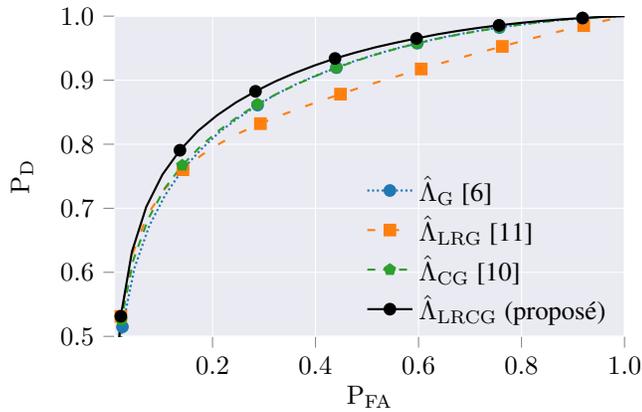


FIGURE 4 – Probabilité de détection P_D en fonction de la probabilité de fausse alarme P_{FA} avec ($p = 12, K = 25$)

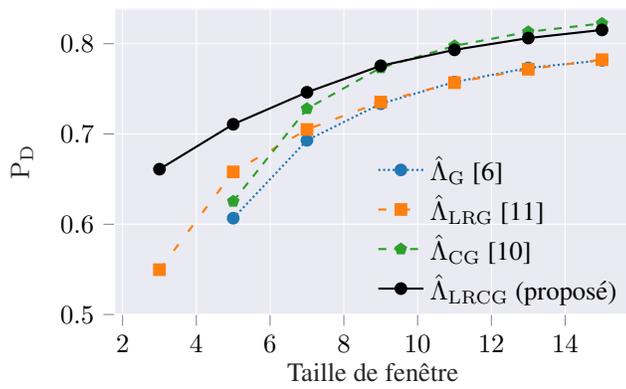


FIGURE 5 – P_D en fonction de la taille de la fenêtre à $P_{FA} = 5\%$ avec ($p = 12, R = 3$)

choisi est gaussien, une structure faible rang introduit la perte d'une partie de la puissance du signal alors que pour le cas GC, cette même puissance est capturée dans les termes de texture.

Enfin, la Figure 5 montre l'évolution de la probabilité de détection P_D , pour une probabilité de fausse alarme fixée à $P_{FA} = 5\%$, lorsque la taille de la fenêtre locale augmente. L'augmentation de la taille de la fenêtre permet d'obtenir une meilleure détection avec moins de fausses alarmes mais cela a un coût sur la résolution de la détection. L'intérêt des méthodes rang faible est explicite ici car elles permettent d'obtenir un niveau de détection équivalent aux détecteurs non rang faible tout en gardant une taille de fenêtre plus faible. La méthode proposée offre les meilleurs résultats de détection, ce qui pouvait être attendu puisque celle-ci a été dérivée en utilisant un modèle plus approprié pour les données.

Références

[1] M. Hussian, D. Chen, A. Cheng, H. Wei, and D. Stanley, "Change detection from remotely sensed images : From pixel-based to object-based approaches," *ISPRS Journal of photogrammetry and remote sensing*, vol. 80, pp. 91–106, 2013.

[2] M. Preiss, D. A. Gray, and N. J. S. Stacy, "Detecting scene changes using synthetic aperture radar interferometry," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, no. 8, pp. 2041–2054, Aug 2006.

[3] Y. Bazi, L. Bruzzone, and F. Melgani, "An unsupervised approach based on the generalized Gaussian model to automatic change detection in multitemporal SAR images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 4, pp. 874–887, April 2005.

[4] A. Mian, J.-P. Ovarlez, G. Ginolhac, and A. M. Atto, "Multivariate change detection on high resolution monovariate SAR image using linear time-frequency analysis," in *2017 25th European Signal Processing Conference (EUSIPCO)*, Aug 2017, pp. 1942–1946.

[5] A. Mian, J.-P. Ovarlez, A. M. Atto, and G. Ginolhac, "Design of new wavelet packets adapted to high-resolution SAR images with an application to target detection," *IEEE Transactions on Geoscience and Remote Sensing*, 2019.

[6] K. Conradsen, A. A. Nielsen, J. Schou, and H. Skriver, "A test statistic in the complex Wishart distribution and its application to change detection in polarimetric SAR data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 41, no. 1, pp. 4–19, Jan 2003.

[7] A. D. C. Nascimento, A. C. Frery, and R. J. Cintra, "Detecting changes in fully polarimetric SAR imagery with statistical information theory," *IEEE Transactions on Geoscience and Remote Sensing*, vol. to appear, pp. 1–13, 2019.

[8] D. Ciunzo, V. Carotenuto, and A. D. Maio, "On multiple covariance equality testing with application to SAR change detection," *IEEE Transactions on Signal Processing*, vol. 65, no. 19, pp. 5078–5091, Oct 2017.

[9] M. Greco and F. Gini, "Statistical analysis of high-resolution SAR ground clutter data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 3, pp. 566–575, 2007.

[10] A. Mian, G. Ginolhac, J.-P. Ovarlez, and A. M. Atto, "New robust statistics for change detection in time series of multivariate SAR images," *IEEE Transactions on Signal Processing*, vol. 67, no. 2, pp. 520–534, Jan 2019.

[11] R. B. Abdallah, A. Mian, A. Breloy, M. N. E. Korso, and D. Lautru, "Detection methods based on structured covariance matrices for multivariate SAR images processing," *IEEE Geoscience and Remote Sensing Letters*, 2019.

[12] P. Stoica and Y. Selen, "Model-order selection : a review of information criterion rules," *IEEE Signal Processing Magazine*, vol. 21, no. 4, pp. 36–47, July 2004.