

Un modèle de décomposition pour la détection de changement dans les séries temporelles d'images RSO

Sylvain Lobry^{1,3}

Loïc Denis²

Florence Tupin¹

¹ LTCI, CNRS, Télécom ParisTech

Université Paris-Saclay, 75013, Paris, France

² Univ Lyon, UJM-Saint-Etienne, CNRS, Laboratoire Hubert Curien UMR 5516,
F-42023, SAINT-ETIENNE, France

³ Centre National d'Études Spatiales (CNES), Toulouse, France

sylvain.lobry@telecom-paristech.fr

Domaine principal de recherche : RFP

Papier soumis dans le cadre de la journée commune : NON

Résumé

Nous présentons une méthode de détection de changement pour les images radar à synthèse d'ouverture (RSO) basée sur la décomposition de séries multi-temporelles. Le modèle de décomposition proposé estime conjointement un arrière plan et les cibles présentes sur les différentes dates. Il permet de récupérer les changements dans les cibles et la date à laquelle ceux-ci se produisent. Une méthode d'optimisation exacte du modèle est présentée et appliquée à une série d'images acquises par TerraSAR-X.

Mots Clef

RSO, Détection de changement, Décomposition, Variation Totale, L0

Abstract

This paper presents a method for strong scatterers change detection in synthetic aperture radar (SAR) images based on a decomposition for multi-temporal series. The formulated decomposition model jointly estimates the background of the series and the scatterers. The decomposition model retrieves possible changes in scatterers and the date at which they occurred. An exact optimization method of the model is presented and applied to a TerraSAR-X time series.

Keywords

SAR, Change Detection, Decomposition, Total Variation, L0

1 Introduction

De nombreux capteurs embarqués sur des satellites réalisent des observations régulières de la terre. Parmi eux, les capteurs radar à synthèse d'ouverture (RSO) sont particulièrement populaires grâce à leur capacité à

acquérir des images par tout temps et à toute heure et les différents modes d'acquisition offerts (polarimétrie et interférométrie). Des missions comme Sentinel-1 (ESA) fournissent des séries temporelles avec un temps de revisite court (12 jours) et des données librement accessibles. L'arrivée de ces longues séries permet d'envisager de nouvelles applications (par exemple dans les domaines de la planification urbaine ou de la sécurité) mais nécessite aussi de nouveaux outils adaptés pour les traiter.

Dans ce papier, nous nous intéressons aux aires urbaines. Nous proposons un nouveau cadre pour la détection et le suivi des changements des cibles de forte radiométrie, caractéristiques des bâtiments en imagerie RSO. De nombreux travaux ont porté sur l'analyse des séries temporelles d'images RSO. Le problème de la détection de changement dans des images RSO a d'abord été traité par des différences entre les images [12, 1]. Plus récemment, de nombreuses approches proposent de prendre en compte la distribution spécifique des données RSO en s'appuyant sur des tests d'hypothèse (par exemple [9, 4, 2]). Un des principaux problèmes de ces méthodes est qu'il est alors nécessaire d'estimer la radiométrie de la scène. La forte variance d'estimation est un facteur limitant pour la détection de changement. Une façon d'obtenir des estimations plus fiables est d'appliquer une régularisation spatiale au niveau pixelique [7] ou par le biais de patches [14] en pré-traitement de la détection de changement.

Une autre approche se place au niveau des objets (après une segmentation par exemple) avant de chercher des changements entre les objets ([11])

Dans cet article, nous proposons un cadre permettant de combiner des tests d'hypothèses et une régularisation spatiale afin de pouvoir faire la détection de changement des cibles fortes conjointement avec la régularisation dans

les séries temporelles d'images RSO.

L'approche proposée est formulée comme un problème d'optimisation dans la section 2. On décrit dans la section 3 une méthode basée sur la recherche de la coupe minimale dans un graphe afin d'obtenir le minimiseur global. Enfin, des résultats obtenus avec notre méthode sont présentés et comparés avec ceux d'algorithmes de l'état de l'art dans la section 4.

2 Un modèle de décomposition pour la détection de changement dans les cibles fortes

Les images RSO présentent de très fortes fluctuations de l'amplitude des pixels à cause du phénomène de speckle propre aux techniques d'imagerie cohérente. Partant d'une série temporelle de n images RSO specklées notées v_1 à v_n , on cherche à estimer conjointement les images des radiométries sous-jacentes (notées u_1 à u_n) et à détecter les dates de changement de radiométrie. Afin de modéliser la présence, en certains pixels, de cibles fortes, on considère le modèle de décomposition suivant [3] :

$$\forall t, \forall i, u_{t,i} = b_i + s_{t,i}, \quad (1)$$

où la radiométrie $u_{t,i}$ du pixel i à la date t est modélisée comme la somme d'une valeur b_i constante dans le temps (composante de fond) et d'une valeur $s_{t,i}$ correspondant à une cible ($s_{t,i} = 0$ en l'absence de cible). On impose deux contraintes sur ces composantes : le fond doit présenter des variations faibles (fond lisse ou constant par morceaux) et la composante de cible doit être parcimonieuse (c'est à dire $s_{t,i} = 0$ pour la plupart des pixels i).

On cherche à résoudre à la fois :

- Un problème d'estimation : on veut estimer les valeurs b_i et $s_{t,i}$ pour tous les pixels, et
- Un problème de détection : on veut détecter la présence d'une cible forte au pixel i et un changement possible de radiométrie de cette cible dans le temps.

Ainsi, il faut noter que l'on se restreint aux changements dans les cibles fortes, sans considérer ceux qui pourraient avoir lieu dans le fond.

On propose ici un cadre pour résoudre conjointement ces deux problèmes, tout en les simplifiant afin qu'une solution puisse être trouvée dans un temps raisonnable. On commence par le problème de détection, qui peut être formulé comme un test d'hypothèse hiérarchique :

$$\begin{cases} \mathcal{H}_0 : d_i = 0 \Leftrightarrow \forall t, s_{t,i} = 0 & \text{(pas de cible forte)} \\ \mathcal{H}_1 : d_i = 1 \Leftrightarrow \exists t, s_{t,i} > 0 & \text{(cible forte)}, \end{cases} \quad (2)$$

où d_i est une variable indicatrice dont la valeur est 0 si aucune cible forte n'est présente en plus du fond au pixel i et dont la valeur est 1 dans le cas contraire. En l'absence d'une cible forte (c'est à dire, sous \mathcal{H}_0), la composante $s_{t,i}$

est nulle pour toutes les dates t . Dans le cas où une cible forte est présente au pixel i , on cherche à détecter un éventuel changement en considérant les sous-hypothèses suivantes :

$$\left\{ \begin{array}{l} \mathcal{H}_{1a} : d_i = 1 \text{ et } c_i = 0 \Leftrightarrow \exists r > 0, \forall t, s_{t,i} = r \\ \hspace{15em} \text{(cible constante)} \\ \mathcal{H}_{1b} : d_i = 1 \text{ et } c_i = 1 \Leftrightarrow \exists r > 0, \exists t_c, \forall t, \\ \hspace{4em} t < t_c \Rightarrow s_{t,i} = 0 \\ \hspace{4em} t \geq t_c \Rightarrow s_{t,i} = r \quad \text{(apparition)} \\ \text{ou} \\ \hspace{4em} t < t_c \Rightarrow s_{t,i} = r \\ \hspace{4em} t \geq t_c \Rightarrow s_{t,i} = 0 \quad \text{(disparition)} \end{array} \right. \quad (3)$$

où la variable binaire c_i indique la présence ($c_i = 1$) ou l'absence ($c_i = 0$) de changement de radiométrie de la cible. En faisant l'hypothèse que les variations dues au speckle sont indépendantes entre les pixels et les dates, on peut exprimer la log-vraisemblance de chaque hypothèse à partir de la log-vraisemblance $\ell(v, b, r)$ d'une observation, en chaque pixel :

$$\mathcal{L}_0(b_i) = \sum_t \ell(v_{t,i}, b_i, 0) \quad (4)$$

$$\mathcal{L}_{1a}(b_i, r) = \sum_t \ell(v_{t,i}, b_i, r) \quad (5)$$

$$\mathcal{L}_{1b}^{\text{app}}(b_i, r, t_c) = \sum_{t=1}^{t_c-1} \ell(v_{t,i}, b_i, 0) + \sum_{t=t_c}^n \ell(v_{t,i}, b_i, r) \quad (6)$$

$$\mathcal{L}_{1b}^{\text{dis}}(b_i, r, t_c) = \sum_{t=1}^{t_c-1} \ell(v_{t,i}, b_i, r) + \sum_{t=t_c}^n \ell(v_{t,i}, b_i, 0), \quad (7)$$

où la log-vraisemblance $\ell(v, b, r)$, lorsque l'on considère des images RSO en amplitude peut être Rayleigh (chatoiement pleinement développé, sans cible dominante) :

$$\ell(v, b, r) = -2 \log(b + r) + \log(2v) - \frac{v^2}{(b + r)^2}, \quad (8)$$

ou la distribution de Rice (chatoiement pleinement développé avec une cible dominante) :

$$\ell(v, b, r) = -\frac{v^2 + r^2}{2b^2} - 2 \log(b) + \log[v I_0(vr/b^2)]. \quad (9)$$

avec I_0 la fonction de Bessel modifiée du premier ordre. Dans la suite de ce document, nous utilisons la distribution de Rayleigh. Ce choix est motivé par le fait que la valeur optimale de r doit être estimée dans notre problème de minimisation (à l'équation 15). Alors qu'il est possible d'obtenir une expression littérale de l'estimateur de r au sens du maximum de vraisemblance pour la distribution de Rayleigh, ce n'est pas le cas pour une distribution de Rice.

Détection de changement des cibles fortes :

Pour détecter des changements dans les cibles fortes, on peut utiliser un test de rapport de vraisemblances :

$$\log \frac{p(\{v_{t,i}\}|\mathcal{H}_{1b})}{p(\{v_{t,i}\}|\mathcal{H}_{1a})} \underset{\mathcal{H}_{1a}}{\overset{\mathcal{H}_{1b}}{\geq}} \eta. \quad (10)$$

Pour une certaine valeur de r et de b_i , l'évaluation de la log-vraisemblance sous l'hypothèse \mathcal{H}_{1b} requiert l'estimation de t_c et de choisir entre une apparition ou une disparition de la cible forte. Nous considérons donc le test du rapport des log-vraisemblances généralisé (GLRT) en remplaçant les valeurs inconnues par leur estimation au sens du maximum de vraisemblance :

$$\widehat{\mathcal{L}}_{1b}(b_i, r) \underset{\mathcal{H}_{1a}}{\overset{\mathcal{H}_{1b}}{\geq}} \mathcal{L}_{1a}(b_i, r) + \eta, \quad (11)$$

avec $\widehat{\mathcal{L}}_{1b}(b_i, r)$:

$$\widehat{\mathcal{L}}_{1b}(b_i, r) = \max_{t_c} \max [\mathcal{L}_{1b}^{\text{app}}(b_i, r, t_c), \mathcal{L}_{1b}^{\text{dis}}(b_i, r, t_c)]. \quad (12)$$

On considère donc qu'un changement a lieu au pixel i , pour une certaine radiométrie du fond b_i et de la cible r , d'après le test de l'équation (11), pour un seuil η choisi en fonction d'un taux de fausse alarme donné (augmenter η réduit le taux de fausse alarme).

Détection de cibles fortes :

Tout comme pour la détection de changement, la détection de cibles fortes est basée sur un test de rapport de vraisemblance.

$$\log \frac{p(\{v_{t,i}\}|\mathcal{H}_1)}{p(\{v_{t,i}\}|\mathcal{H}_0)} \underset{\mathcal{H}_0}{\overset{\mathcal{H}_1}{\geq}} \lambda. \quad (13)$$

Après estimation de la radiométrie des cibles, on considère le rapport de vraisemblance généralisée suivant :

$$\widehat{\mathcal{L}}_1(b_i) \underset{\mathcal{H}_0}{\overset{\mathcal{H}_1}{\geq}} \mathcal{L}_0(b_i) + \lambda, \quad (14)$$

avec :

$$\widehat{\mathcal{L}}_1(b_i) = \max_r \max [\mathcal{L}_{1a}(b_i, r), \widehat{\mathcal{L}}_{1b}(b_i, r) - \eta]. \quad (15)$$

Estimation de la radiométrie du fond :

La log-vraisemblance de la radiométrie du fond peut-être exprimée à partir de l'équation (14) :

$$\widehat{\mathcal{L}}(b_i) = \max [\mathcal{L}_0(b_i), \widehat{\mathcal{L}}_1(b_i) - \lambda]. \quad (16)$$

Afin d'obtenir un fond dont la radiométrie varie de façon douce, tout en gardant la possibilité d'avoir des contours forts, on choisit une régularisation de type "variation totale" (TV) :

$$-\log p(\mathbf{b}) = \mu \sum_{i \sim j} |b_i - b_j| \equiv \mu \text{TV}(\mathbf{b}), \quad (17)$$

où la notation $i \sim j$ est utilisée pour indiquer que les pixels i et j sont voisins spatialement.

L'estimation régularisée du vecteur des m radiométries du fond implique de résoudre le problème hiérarchique suivant :

$$\hat{\mathbf{b}} = \arg \min_{\mathbf{b} \in \mathbb{R}^m} - \sum_i \widehat{\mathcal{L}}(b_i) + \mu \text{TV}(\mathbf{b}), \quad (18)$$

tel que $\mathbf{b} \geq 0$

où le terme de vraisemblance $\widehat{\mathcal{L}}(b_i)$ est implicite : il implique plusieurs minimisations. Afin d'obtenir une expression explicite de la fonction objectif à minimiser, introduisons des valeurs binaires auxiliaires et remplaçons les minimisations hiérarchiques par des optimisations sous contraintes en exploitant l'équivalence :

$$\min_t \min \{x(t), y(t)\} \Leftrightarrow \begin{cases} \min_{t,z,w} z \\ \text{s.c.} & (1-w) \cdot z = x(t) \\ & w \cdot z = y(t) \\ & w \in \{0,1\} \end{cases} \quad (19)$$

où x, y sont des fonctions quelconques de la variable t , z est une variable réelle et w est une variable binaire indiquant que le premier ($w = 0$) ou le second ($w = 1$) paramètre de $\min \{x(t), y(t)\}$ est minimum. On obtient alors le problème d'optimisation contraint suivant :

$$\begin{aligned} \arg \min_{\substack{d \in \{0,1\}^m \\ c \in \{0,1\}^m \\ a \in \{0,1\}^m \\ \mathbf{b} \in \mathbb{R}^m \\ \mathbf{r} \in \mathbb{R}^m \\ \mathbf{s} \in \mathbb{R}^{mn} \\ t_c \in \{2, \dots, n\}^m}} & - \sum_{i,t} \ell(v_{i,t}, b_i, s_{i,t}) + \lambda \|\mathbf{d}\|_0 + \eta \|\mathbf{c}\|_0 \\ & + \mu \text{TV}(\mathbf{b}) \end{aligned} \quad (20)$$

$$\text{tel que} \quad \begin{aligned} \forall i, \forall t, & (d_i - 1) \cdot s_{i,t} = 0 \\ \forall i, \forall t, & (c_i - 1) \cdot (s_{i,t} - r_i) = 0 \\ \forall i, \forall t < t_{c_i}, & c_i \cdot a_i \cdot s_{i,t} = 0 \\ \forall i, \forall t \geq t_{c_i}, & c_i \cdot a_i \cdot (s_{i,t} - r_i) = 0 \\ \forall i, \forall t < t_{c_i}, & c_i \cdot (1 - a_i) \cdot (s_{i,t} - r_i) = 0 \\ \forall i, \forall t \geq t_{c_i}, & c_i \cdot (1 - a_i) \cdot s_{i,t} = 0 \\ \forall i, & b_i \geq 0 \\ \forall i, & r_i \geq 0 \end{aligned}$$

où les variables binaires d_i, c_i et a_i indiquent respectivement la présence d'une cible forte au pixel i , le fait que sa radiométrie change dans le temps, et dans ce dernier cas si ce changement est une apparition. Les contraintes permettent d'assurer que la radiométrie du composant de cible s est 0 en l'absence d'une cible forte, constante en l'absence d'un changement ou constante par morceaux dans le cas d'une apparition/disparition de la cible. On remarque que l'introduction d'une cible (resp. d'un changement) est pénalisée si $\lambda > 0$ (resp. $\eta > 0$) ou favorisée si

$\lambda < 0$ (resp. $\eta < 0$). Ainsi, la formulation des problèmes de détection justifie l'introduction d'une régularisation de type L0 dans l'expression du problème d'optimisation (20) et offre ainsi un point de vue différent de l'introduction de pénalisation L0 dans un cadre bayésien (a priori de parcimonie). Le choix de valeurs négatives pour λ et η n'est pas souhaitable en pratique (il revient à favoriser des solutions non parcimonieuses) mais s'interprète du point de vue du test d'hypothèses comme un choix favorisant la probabilité de détection au détriment de la probabilité de fausse alarme (i.e., détection d'un changement ou d'une cible même si la vraisemblance est plus faible sous cette hypothèse).

3 Optimisation

Résoudre le problème d'optimisation présenté dans l'équation 20 peut sembler compliqué puisque il implique une fonction objectif non convexe, des contraintes non linéaires et un mélange de variables entières et réelles. Après avoir discrétisé les variables réelles afin d'obtenir un problème discret, on peut obtenir le minimum global du problème en cherchant la coupe minimale dans un graphe construit selon la méthode proposée dans [5].

En effet, dans l'optimisation hiérarchique (18), le terme de log-vraisemblance $\mathcal{L}(b_i)$ est séparable (il peut être évalué indépendamment pour chaque pixel i et valeur de fond b_i). La fonction objectif du problème (18) est donc la somme d'un terme non convexe mais séparable et d'un terme convexe impliquant des paires de pixels. Elle remplit donc les conditions d'application de la méthode d'optimisation discrète exacte par graph-cut d'Ishikawa [5].

La construction du graphe est présentée sur la figure 1. Le graphe est composé de plusieurs couches, chacune ayant autant de noeuds que de pixels dans chacune des images (soit m noeuds). Chaque couche représente une valeur possible pour le fond (le nombre de couches dépend donc de la quantification choisie). Les noeuds voisins dans le graphe sont reliés par des paires d'arcs. La source (\mathcal{S}) et le puits (\mathcal{T}) sont reliés à la première et dernière couche. La capacité des arcs est égale à $(\beta_{n+1} - \beta_n)\mu$ pour les arcs horizontaux (en noir sur la figure 1), $\mathcal{L}(\beta_n)$ pour les arcs allant de haut en bas (en bleu) et ∞ pour les arcs allant de bas en haut (en rouge), avec β_1, \dots, β_n les valeurs quantifiées du fond b .

En pratique, la détection de cible et d'un éventuel changement se fait donc en chaque point et pour chaque valeur possible du fond β_n (ce qui fournit le poids $\mathcal{L}(\beta_n)$). La recherche de coupe minimale dans le graphe construit selon la figure 1 permet d'obtenir l'image de fond. On déduit de cette image les valeurs des cibles en identifiant les valeurs $s_{i,t}$ maximisant la log-vraisemblance $\mathcal{L}(b_i)$.




FIGURE 1 – Construction du graphe, d'après [5].

4 Résultats

Afin d'illustrer la méthode proposée, nous avons appliqué notre algorithme sur une série temporelle acquise par TerraSAR-X sur Saint-Gervais (France). On montre les différents produits de la décomposition (image de fond, série d'images de cibles, carte de changement et série d'images régularisées) permettant d'évaluer visuellement les résultats obtenus par notre décomposition sur la figure 2. Un zoom sur les images d'entrées et sur la carte de changement obtenue par la décomposition proposée est montré dans la figure 3b.

Une évaluation qualitative de la méthode est montrée sur la figure 4. Elle montre la courbe ROC obtenue avec notre méthode sur l'image présentée dans la figure 2, et la compare avec des algorithmes classiques de détection de changement ([8], [6], [13] and [7]). [8] applique un test du maximum de vraisemblance sur des régions segmentées, alors que [6] teste le rapport des vraisemblances au niveau pixelique. Les performances obtenues sont proches de celles de [13] qui utilise un rapport des vraisemblances après une étape de débruitage non-local. Néanmoins, on peut noter que notre algorithme ne détecte que les changements impliquant les forts rétro-diffuseurs, ce qui explique une grande partie des différences constatées avec le résultat obtenu par l'algorithme de Su *et al.* [13].

5 Conclusion

Dans ce papier, nous avons introduit un algorithme de détection de changement applicable à des séries temporelles d'images RSO. Cette méthode utilise un modèle de

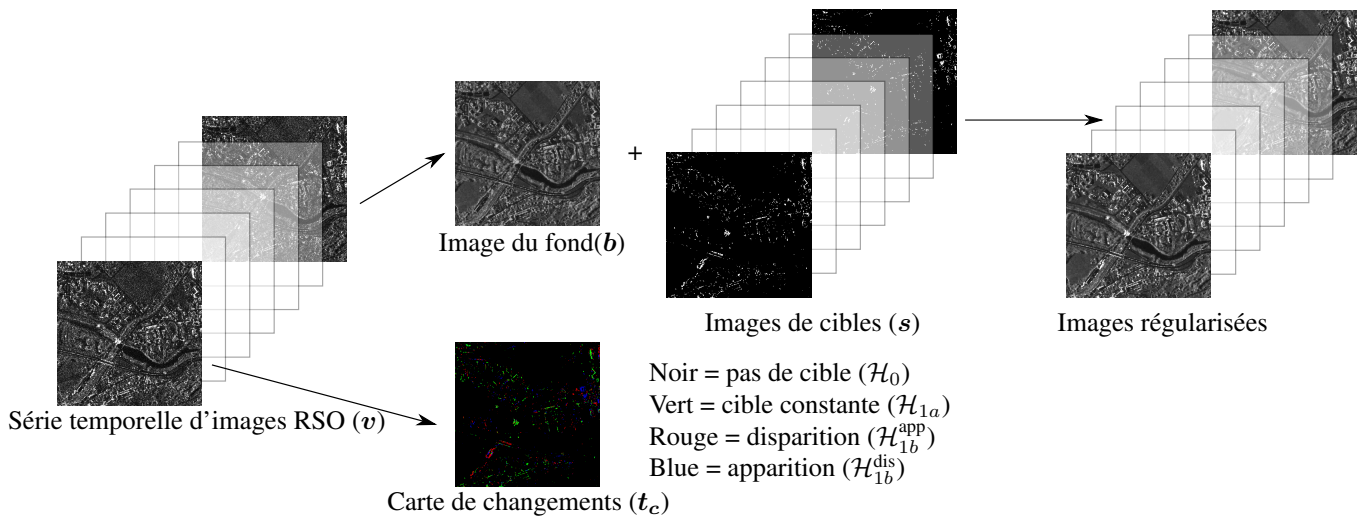


FIGURE 2 – Résultats sur une série temporelle d'images acquises par TerraSAR-X sur le site de Saint-Gervais, France et recalées en utilisant la méthode proposée dans [10]. Cette série est composée de 13 images acquises entre le 31 mai 2009 et le 25 septembre 2011. À partir d'une série temporelle, l'algorithme proposé permet d'obtenir un fond représentant la totalité de la série, une série de cibles et une carte de changements. Les images régularisées sont obtenues à chaque date en ajoutant le fond et l'image de cibles correspondant à la date voulue. Dans cette illustration, nous montrons seulement la première et la dernière date de la série.

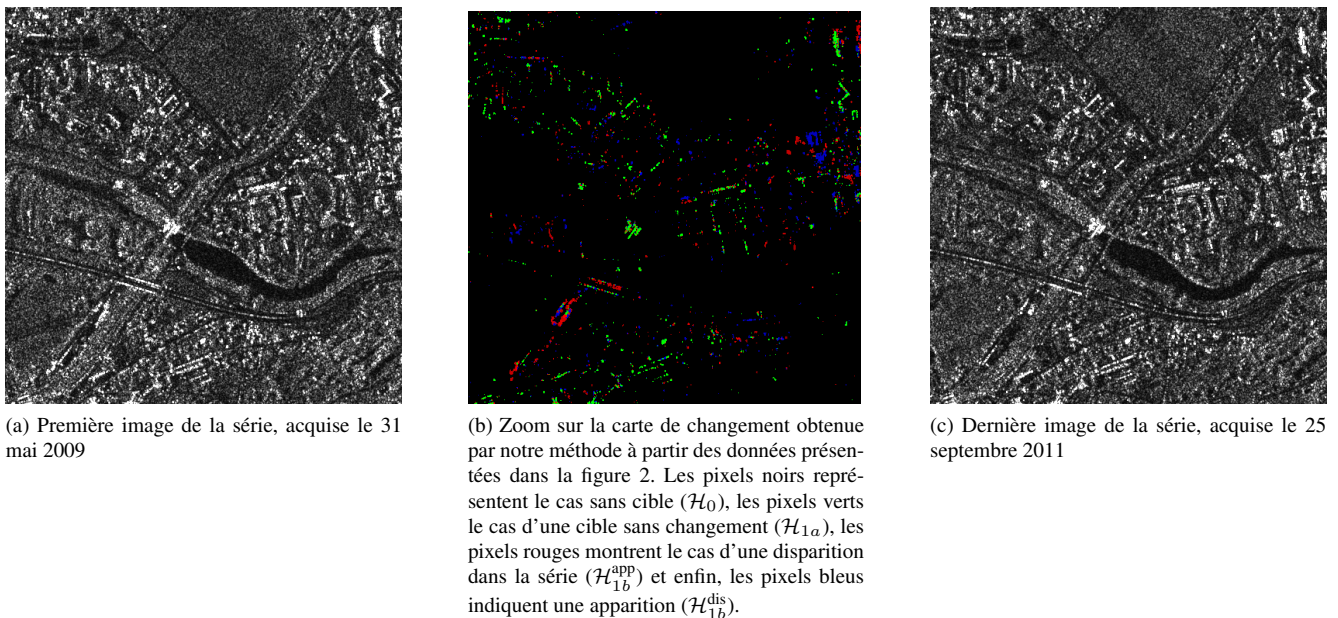


FIGURE 3 – Zoom sur la carte de changement et sur la première et dernière image de la série (voir figure 2).

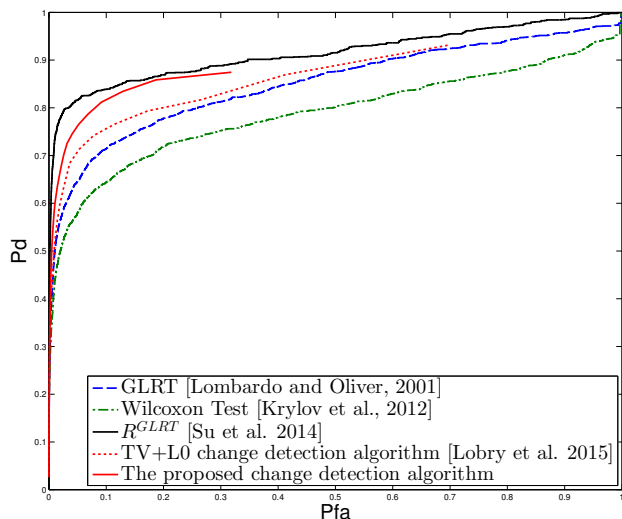


FIGURE 4 – Courbe ROC comparant les performances de notre algorithme avec celles d’algorithmes classiques de détection de changements. La série utilisée est la même que celle montrée sur la figure 2.

décomposition d’image dans le but de régulariser le fond et de détecter les cibles fortes conjointement. Ce modèle prend en compte la possibilité que les cibles fortes puissent être affectées par des changements, et donne la carte des changements en sortie de l’algorithme.

Le modèle proposé peut être optimisé de manière exacte par recherche de coupe minimale dans un graphe et donne des résultats proches de l’état de l’art. Une limitation de ce modèle est qu’il n’autorise au plus qu’un changement par pixel, ce qui n’est pas réaliste lorsque l’on considère de longues séries temporelles (par exemple, Sentinel-1 a une durée de vie prévue de 7 ans). Il sera donc primordial d’enrichir le modèle actuel afin de considérer des scénarios plus complexes. Des seuils η différents devraient être fixés selon la date du changement t_c afin de garantir une probabilité de fausse alarme constante pour toutes les dates.

Références

[1] L. Bruzzone and D. F. Prieto. Automatic analysis of the difference image for unsupervised change detection. *Geoscience and Remote Sensing, IEEE Transactions on*, 38(3) :1171–1182, 2000.

[2] K. Conradsen, A. Nielsen, and H. Skriver. Change detection in polarimetric SAR data over several time points. *IGARSS*, pages 4540–4543, 2014.

[3] Loïc Denis, Florence Tupin, and Xavier Rondeau. Exact discrete minimization for TV+L0 image decomposition models. In *Image Processing (ICIP), 2010 17th IEEE International Conference on*, pages 2525–2528. IEEE, 2010.

[4] M. Horta, N. Mascarenhas, H. Sportouche, N. Seichepine, F. Tupin, and J.-M. Nicolas. Change detection

in multi-temporal HR SAR images : a hypothesis test-based approach. *IGARSS*, pages 374–377, 2012.

- [5] H. Ishikawa. Exact optimization for Markov random fields with convex priors. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(10) :1333–1336, 2003.
- [6] V. Krylov, G. Moser, A. Voisin, S.B. Serpico, and J. Zerubia. Change detection with synthetic aperture radar images by Wilcoxon statistic likelihood ratio test. In *IEEE International Conference on Image Processing 2012*, Orlando, United States, Sep 2012.
- [7] S. Lobry, L. Denis, and F. Tupin. Sparse + smooth decomposition models for multi-temporal SAR images. *MultiTemp, Annecy, France*, 2015.
- [8] P. Lombardo and C.J. Oliver. Maximum likelihood approach to the detection of changes between multitemporal SAR images. *IEEE Proceedings-Radar, Sonar and Navigation*, 148(4) :200–210, 2001.
- [9] P. Lombardo and T. Pellizzeri. Maximum likelihood Signal Processing Techniques to detect a Step Pattern of Change in Multitemporal SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, 40(4) :853–870, April 2002.
- [10] J-M Nicolas, Emmanuel Trouve, Renaud Fallourd, Flavien Vernier, Florence Tupin, Olivier Harant, Michel Gay, and Luc Moreau. A first comparison of Cosmo-Skymed and TerraSAR-X data over Chamonix Mont-Blanc test-site. In *Geoscience and Remote Sensing Symposium (IGARSS), 2012 IEEE International*, pages 5586–5589. IEEE, 2012.
- [11] J. Prendes, M. Chabert, F. Pascal, A. Giros, and J.-Y. Tournet. Change detection for optical and radar images using a bayesian nonparametric model coupled with a markov random field. In *Acoustics, Speech and Signal Processing (ICASSP), 2015 IEEE International Conference on*, pages 1513–1517. IEEE, 2015.
- [12] A. Singh. Digital change detection techniques using remotely-sensed data. *International journal of remote sensing*, 10(6) :989–1003, 1989.
- [13] X. Su, C.-A. Deledalle, F. Tupin, and H. Sun. NOR-CAMA : Change Analysis in SAR Time Series by Likelihood Ratio Change Matrix Clustering. *ISPRS Journal of Photogrammetry and Remote Sensing*, pages 247–261, May 2014.
- [14] X. Su, C.-A. Deledalle, F. Tupin, and H. Sun. Two-Step Multitemporal Nonlocal Means for Synthetic Aperture Radar Images. *IEEE Transactions on Geoscience and Remote Sensing*, 2014.