

Détection de l'eau dans les images radar du futur satellite SWOT

Sylvain LOBRY¹, Roger FJØRTOFT², Loïc DENIS³, Florence TUPIN¹

¹LTCI, Télécom ParisTech, Université Paris-Saclay, 75013, Paris, France

²Centre National d'Etudes Spatiales, 31400, Toulouse, France

³Univ Lyon, UJM-Saint-Etienne, CNRS, Institut d'Optique Graduate School, Laboratoire Hubert Curien UMR 5516, F-42023, Saint-Etienne, France

sylvain.lobry@telecom-paristech.fr, roger.fjortoft@cnes.fr
loic.denis@univ-st-etienne.fr, florence.tupin@telecom-paristech.fr

Résumé – Un des objectifs de la mission SWOT menée par le CNES et le JPL est d'obtenir une mesure globale des hauteurs des différentes surfaces d'eau. Pour pouvoir appliquer un traitement interférométrique aux images SWOT sur les continents, il est nécessaire d'obtenir une classification indiquant la présence d'eau. Nous présentons deux méthodes adaptées aux paramètres d'acquisition non usuels du capteur pour la détection des zones compactes (type lacs) et pour la détection des réseaux linéiques (rivières).

Abstract – One of the objectives of the SWOT mission conducted by CNES and JPL is to obtain a global measurement of water heights. In order to apply an interferometric processing on SWOT images over continents, a first step is to obtain a classification indicating the presence of water. We introduce two methods adapted to the unusual acquisition parameters of the sensor for the detection of compact areas (i.e. lakes) and linear networks (i.e. rivers).

1 Introduction

La mission SWOT menée par le CNES et le JPL a pour objectif d'obtenir une mesure globale des hauteurs des différentes surfaces d'eau sur la planète. L'instrument principal utilisé dans cette mission est un radar imageur interférométrique en bande Ka (35.75GHz, 0.84cm) nommé KaRIn (Ka-band Radar Interferometer) utilisant un angle d'incidence de 0.6° à 3.9° [1]. Ce capteur radar permettra des mesures régulières (tous les 22 jours) et relativement insensibles aux conditions météorologiques. Une des premières étapes vers la mesure des hauteurs d'eau à l'aide de KaRIn est de détecter la présence d'eau dans les images. La détection d'eau dans les images radar à synthèse d'ouverture (SAR) a été largement étudiée [2], mais le plus souvent dans le contexte de la recherche d'un faible signal. Les caractéristiques du capteur utilisé dans la mission SWOT permettent au contraire d'obtenir du signal dans les zones d'eau, et il est donc nécessaire de créer des méthodes dédiées. Nous présentons dans la section 2 une méthode adaptée aux paramètres d'acquisition du capteur pour la détection de surfaces compactes, et dans la section 3 une méthode adaptée aux réseaux linéiques. Enfin les performances de ces algorithmes sont évaluées dans le cas de SWOT dans la section 4.

2 Détection des surfaces d'eau compactes

2.1 Modèle considéré

Les images acquises par KaRIn représentent de très fortes fluctuations de l'amplitude des pixels à cause du phénomène de speckle propre aux techniques d'imagerie cohérente. Pour

prendre en compte ce phénomène, nous proposons d'utiliser une modélisation sous forme de Champs de Markov (MRF). À partir d'une observation \mathbf{v} , on cherche à obtenir une image binaire \mathbf{u} avec $u_i = 1$ si le pixel i contient de l'eau, et $u_i = 0$ sinon. Le calcul de l'estimation du maximum a posteriori conduit à la minimisation de l'énergie :

$$\mathcal{E}(\mathbf{u}) = \text{DT}(\mathbf{v}, \mathbf{u}) - \log(p(\mathbf{u})), \quad (1)$$

où le terme $-\log(p(\mathbf{u}))$ est l'a priori mis sur la solution cherchée. Dans le cas d'une classification binaire, on utilise un modèle d'Ising :

$$-\log(p(\mathbf{u})) = \beta_{det} \sum_{i \sim j} (u_i \neq u_j), \quad (2)$$

où $i \sim j$ indique que i et j sont des pixels voisins. Le terme $\text{DT}(\mathbf{v}, \mathbf{u})$ est l'attache aux données, définie comme la log-vraisemblance négative de \mathbf{v} par rapport à \mathbf{u} . En considérant les réalisations de speckle indépendantes d'un pixel à l'autre :

$$\text{DT}(\mathbf{v}, \mathbf{u}) = \sum_i -\log(p(v_i | \mu_{u_i})), \quad (3)$$

où μ_{u_i} est un paramètre de la classe u_i . Dans le cas d'images d'intensité, les variables suivent la loi Gamma [3] de paramètre μ :

$$p(v|\mu) = \frac{1}{\Gamma(L)} \frac{L}{\mu} \left(\frac{Lv_i}{\mu} \right)^{L-1} e^{-\frac{Lv_i}{\mu}}, \quad (4)$$

où L est le nombre de vues de \mathbf{v} . Les paramètres des classes μ_0 et μ_1 ne sont pas connus. Dans les prochaines sous-sections, nous allons nous intéresser au calcul de ces paramètres.

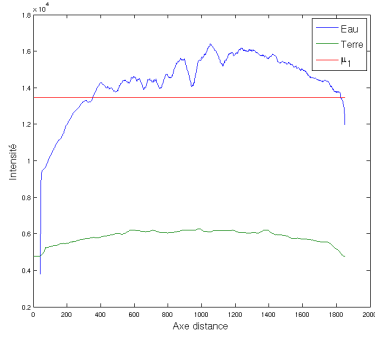


FIGURE 1 – Évolution moyenne des paramètres de classe le long de la fauchée. La courbe rouge indique la valeur de μ_1 lorsqu'il est calculé sur la totalité de l'image (Équation 5).

2.2 Paramètres de réflectivité constants

En la présence d'une précédente classification u , les paramètres μ_0 et μ_1 sont obtenus par l'estimateur au sens du maximum de vraisemblance :

$$\hat{\mu}_0 = \frac{1}{\#(u_i = 0)} \sum_{i \setminus u_i=0} v_i \quad \hat{\mu}_1 = \frac{1}{\#(u_i = 1)} \sum_{i \setminus u_i=1} v_i. \quad (5)$$

Dans le cas de SWOT, la réflectivité moyenne évolue le long de la fauchée, comme montré sur la Figure 1. Cette évolution est due au diagramme d'antenne du rapport signal sur bruit et du coefficient de rétrodiffusion pour les classes eau et terre. Comme la réflectivité moyenne n'évolue pas de la même façon pour les deux classes, elle ne peut être compensée. De plus, des variations locales peuvent apparaître à la suite de variations topographiques (terre) ou de vitesse de vent (rugosité de l'eau). Dans la prochaine sous-section nous présentons deux modèles permettant de prendre en compte la variabilité de ces paramètres.

2.3 Paramètres de réflectivité variables

En s'inspirant du travail effectué dans [4], les deux paramètres de classe sont représentés dans la suite de ce document par deux images μ_0 et μ_1 de même taille que l'image d'entrée et contenant des valeurs variables. Pour estimer ces images de paramètres, nous utilisons une méthode itérative présentée dans la Figure 2.

On rappelle que le speckle dans une image d'intensité est décrit par un modèle multiplicatif [3] : $v = \mu \times \xi$ où ξ est distribué selon une loi Gamma indépendante de μ . Ainsi, lorsque l'on considère le logarithme de l'intensité $\tilde{v}_i = \log(v_i)$, on peut faire l'approximation que le bruit est additif Gaussien (un modèle plus précis est donné par la distribution de Fisher-Tipett [3]) :

$$\tilde{v} = \tilde{\mu} + \log(\xi) \approx \tilde{\mu} + \eta \quad (6)$$

On peut alors décrire un nouveau champs de Markov sur les deux images de paramètres. Prenant en compte le diagramme d'antenne, on peut s'attendre à une évolution de la réflectivité

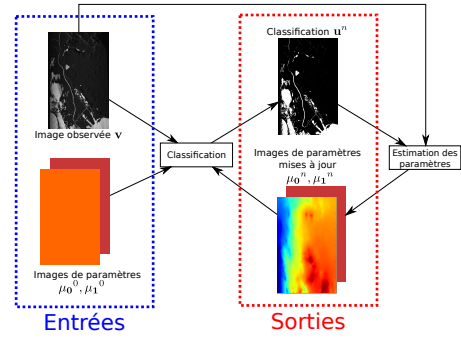


FIGURE 2 – Principe général des méthodes avec paramètres variables

des classes plus importante selon l'axe distance. De plus, on peut utiliser le diagramme d'antenne théorique (ou une estimation lorsque celui-ci n'est pas disponible), ce qui donne l'a priori suivant (le modèle pour μ_0 est similaire) :

$$-\log p(\tilde{\mu}_1) = \beta_{az} \sum_{i \sim_{az} j} (\mu_{1,i} - \mu_{1,j})^2 + \beta_{dis} \sum_{i \sim_{dis} j} (\mu_{1,i} - \mu_{1,j})^2 + \beta_{th} \sum_i (\mu_{1,i} - \tilde{p}_i)^2, \quad (7)$$

où la notation $i \sim_{az} j$ est utilisée pour noter les pixels voisins sur l'axe azimuth, $i \sim_{dis} j$ les pixels voisins sur l'axe distance et \tilde{p} représente le logarithme de la réflectivité théorique donné par le diagramme d'antenne. Concernant l'attache aux données, on ne doit la prendre en compte que lorsque la classification précédente (la meilleur disponible à l'itération courante) indique que le pixel considéré appartient à la classe dont on cherche à obtenir la valeur. Cela nous donne le modèle suivant à optimiser :

$$\arg \min_{\tilde{\mu}_1} \sum_i u_i \cdot (\tilde{\mu}_i - \tilde{v}_i)^2 + \beta_{az} \sum_{i \sim_{az} j} (\mu_{1,i} - \mu_{1,j})^2 + \beta_{dis} \sum_{i \sim_{dis} j} (\mu_{1,i} - \mu_{1,j})^2 + \beta_{th} \sum_i (\mu_{1,i} - \tilde{p}_i)^2, \quad (8)$$

2.4 Optimisation

La minimisation des Équations 1 et 2 est un problème d'optimisation discrète largement étudié. Nous choisissons la méthode proposée par [5] s'appuyant sur une minimisation exacte via la recherche d'une coupe de coût minimal dans un graphe. Le problème modélisé dans l'Équation 8 est quadratique et continu. Il peut donc être optimisé à l'aide d'un algorithme de gradients conjugués.

3 Détection des réseaux linéiques

Les méthodes présentées dans la section précédente font l'hypothèse que les surfaces d'eau sont des objets compacts. Cette

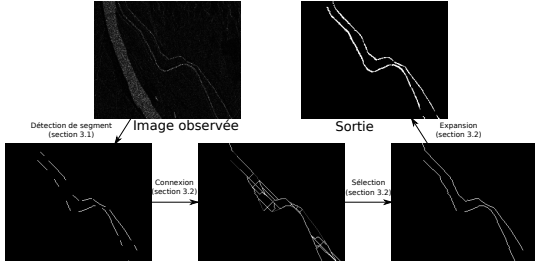


FIGURE 3 – Illustration sur un exemple du schéma général de la méthode de détection des rivières.

hypothèse est utile dans l’optique de détecter les objets de type « lac », néanmoins elle ne permet pas toujours la détection des éléments linéiques tels que les rivières. En s’inspirant du travail effectué dans [6], nous proposons une méthode dédiée à cette tâche. Le schéma général de la méthode est décrit dans la Figure 3.

3.1 Détection de segments

Le problème de la détection de segments a été largement étudié dans le cas des images SAR. Nous utilisons une approche similaire à [7] développée pour la détection de routes et [8] pour la détection de fissures dans les routes à partir d’images optiques. Pour chaque point, on cherche à évaluer son appartenance à une section de segment, modélisée par un rectangle. Plusieurs rectangles centrés en ce point (différentes largeurs et orientations) sont testés. L’intensité dans le rectangle ρ_1 est comparé à celle des deux rectangles connexes ρ_2 et ρ_3 . Ce test est illustré dans la Figure 4. Deux détecteurs sont combinés :

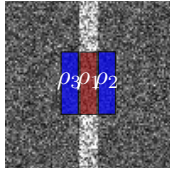


FIGURE 4 – Test pour la détection de segment.

D1 (le ratio de l’intensité moyenne de ρ_1 contre ρ_2 et ρ_3) et D2 (la corrélation croisée entre ρ_1 et ρ_2, ρ_3).

Les deux détecteurs sont ensuite fusionnés selon une somme associative :

$$l_i = \frac{D1_i D2_i}{1 - D1_i - D2_i + 2D1_i D2_i}, \quad (9)$$

En chaque point, on garde la meilleure réponse l_i parmi les différentes configurations testées. l est ensuite seuillée, en choisissant un seuil donnant un faible taux de fausse alerte. On obtient alors un ensemble de segments \mathcal{S} .

3.2 Régularisation

Connexion À partir de l’image de segments détectés, une première étape de connexion est effectuée. En effet, l’étape de détection de segments donne peu de fausses alertes (pour le

seuil choisi), mais les segments ne sont pas détectés dans leur totalité. On utilise l’algorithme de Dijkstra pour effectuer la connexion. De par sa complexité, on restreint les connexions à des segments "compatibles" (la compatibilité étant définie par la proximité spatiale et une orientation similaire). Pour chaque paire de segments $(s_1, s_2) \in \mathcal{S}$ compatibles, l’algorithme de Dijkstra est appliqué sur un graphe orienté dont les nœuds correspondent aux pixels dans l’espace de recherche (une bande reliant les extrémités de s_1 et s_2 à connecter) afin de trouver un chemin d’un faible nombre de nœuds empruntant des pixels pour lesquels la probabilité d’appartenir à un segment est forte. Les arcs allant vers le nœud correspondant au pixel i ont un poids correspondant à l’opposé de la valeur de l’étape de bas-niveau l_i . Puisque la distance n’est pas normalisée par le nombre de pixels dans le chemin, les connexions longues sont pénalisées. Après cette étape, les connexions obtenues forment l’ensemble \mathcal{C}_D .

Sélection \mathcal{C}_D contient des connexions qui ne correspondent pas à des rivières dans l’image. Un certain nombre d’a priori sur la forme des rivières peuvent être énoncés : elles doivent avoir peu d’extrémités, d’intersections, les extrémités des segments ne sont généralement reliées qu’à un seul autre segment, les connexions sont généralement courtes (elles ne remplissent que des trous) et les segments longs sont un bon indicateur de la présence de rivières, et doivent donc être gardés. On cherche à assigner à chaque ensemble de pixels représentant une connexion $co \in \mathcal{C}_D$ un label x_{co} de valeur 1 si la connexion doit être gardée, et 0 sinon. Ainsi, on a le problème de minimisation suivant :

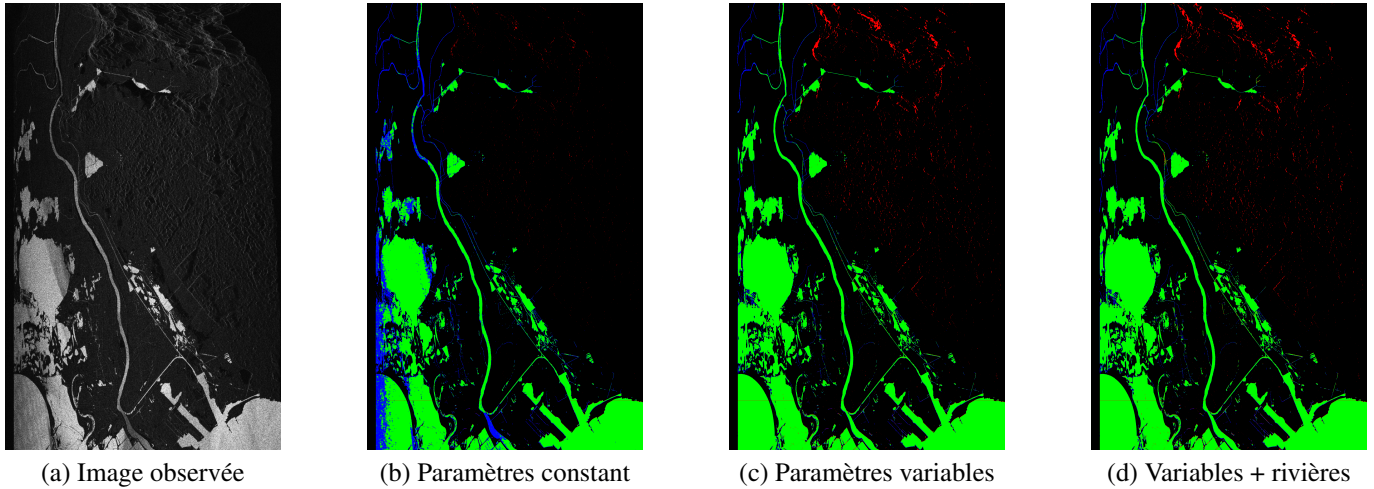
$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \sum_{co \in \mathcal{C}_D} U(x_{co}|l) + U_{forme}(\mathbf{x}), \quad (10)$$

où le terme de vraisemblance est $U(x_{co} = 1|l) = \frac{1}{|co|} \sum_{i \in co} l_i$ et $U(x_{co} = 0|l) = 0$. Enfin $U_{forme}(\mathbf{x})$ est un terme intégrant les propriétés souhaitées des rivières énoncées ci-dessus (détaillé dans [9]). À la fin de cette étape, l’ensemble des connexions tel que $x_{co} = 1$ est noté \mathcal{C} .

Expansion Une dernière étape d’expansion doit être réalisée à ce stade. En effet, l’union de \mathcal{S} et \mathcal{C} indique la présence de segments, mais sous la forme de chaînes de largeur 1. Afin d’obtenir une couverture des rivières, une étape d’expansion est réalisée. Pour chaque composante connexe de $\mathcal{S} \cup \mathcal{C}$, on applique un algorithme de débruitage non-local [10] sur la boîte englobante. Enfin, un seuillage est effectué à l’aide de la radio-métrie estimée dans la section 2.

4 Résultats

Les résultats des différentes méthodes de détection des éléments compacts sont montrés dans la Figure 5 et analysés dans le Tableau 1 en utilisant les métriques suivantes :



Légende : Vrai positif Vrai négatif Faux positif Faux négatif

FIGURE 5 – Résultats visuel sur le jeu de donnée SWOT.

TABLE 1 – Évaluation des performances des algorithmes

	Simple	Paramètres variables	+ rivières
TPR	78%	92.98%	93.26%
FPR	0.27%	1.12%	1.17%
MCC	0.85	0.9236	0.9240
ER	23.65%	12.71%	12.66%

Matthews correlation coefficient (1 pour une solution parfaite) :

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

Taux d'erreur (0 pour une solution parfaite) :

$$ER = \frac{FP + FN}{TP + FN},$$

et les taux de vrais positifs (TPR) et de faux négatifs (FPR).

On peut noter une amélioration des résultats par rapport au MRF avec des paramètres constants lorsque les deux modèles proposés sont appliqués. Notons que les rivières contribuent peu à la surface eau globale donc leur détection a un faible impact sur les performances globales.

5 Conclusion

Dans ce papier, nous avons proposé deux méthodes pour la détection de surfaces d'eau continentales dans les images SWOT. La première est dédiée à la détection des zones compactes et la seconde aux réseaux linéiques. L'évaluation quantitative et qualitative montre une nette amélioration des résultats par rapport à une méthode classique de classification. Dans le futur, nous chercherons à intégrer l'information de cohérence afin d'améliorer les résultats.

Références

- [1] R. Fjørtoft *et al.*, "KaRIn on SWOT : Characteristics of Near-Nadir Ka-Band Interferometric SAR Imagery," *IEEE TGRS*, vol. 52, no. 4, pp. 2172–2185, April 2014.
- [2] C. Cazals *et al.*, "Mapping and characterization of hydrological dynamics in a coastal marsh using high temporal resolution sentinel-1a images," *Remote Sensing*, vol. 8, no. 7, 2016.
- [3] J. W. Goodman, *Speckle phenomena in optics : theory and applications*. Roberts and Company Publishers, 2007.
- [4] S. Lobry *et al.*, "Non-Uniform Markov Random Fields for Classification of SAR Images," in *EUSAR 2016 : 11th European Conference on Synthetic Aperture Radar, Proceedings of*. VDE VERLAG GmbH, 2016, pp. 1–4.
- [5] D. Greig *et al.*, "Exact maximum a posteriori estimation for binary images," *Journal of the Royal Statistical Society. Series B (Methodological)*, pp. 271–279, 1989.
- [6] F. Cao *et al.*, "Extraction of water surfaces in simulated Ka-band SAR images of KaRIn on SWOT," in *IEEE IGARSS*, 2011, pp. 3562–3565.
- [7] F. Tupin *et al.*, "Detection of linear features in SAR images : application to road network extraction," *IEEE TGRS*, vol. 36, no. 2, pp. 434–453, 1998.
- [8] R. Amhaz *et al.*, "A new minimal path selection algorithm for automatic crack detection on pavement images," in *2014 IEEE International Conference on Image Processing (ICIP)*, Oct 2014, pp. 788–792.
- [9] S. Lobry *et al.*, "Unsupervised detection of thin water surfaces in swot images based on segment detection and connection," in *IEEE IGARSS*, 2017, pp. 3362–3365.
- [10] C.-A. Deledalle *et al.*, "NL-SAR : A Unified Nonlocal Framework for Resolution-Preserving (Pol)(In)SAR Denoising," *IEEE TGRS*, vol. 53, no. 4, pp. 2021–2038, April 2015.