

# Utilisation d'images satellites haute résolution optique et radar pour la mise à jour de bases de données cartographiques

Vincent POULAIN<sup>1</sup>, Jordi INGLADA<sup>1</sup>, Marc SPIGAI<sup>2</sup>, Jean-Yves TOURNERET<sup>3</sup>, Philippe MARTHON<sup>3</sup>

<sup>1</sup>Centre National d'Études Spatiales  
18 av Edouard Belin, 31401 Toulouse Cedex 9, France

<sup>2</sup>Thales Alenia Space  
26 av J.F. Champollion, BP 1187, 31037 Toulouse Cedex, France

<sup>3</sup>IRIT  
2 rue Camichel, BP 7122, 31071 Toulouse Cedex 7, France  
vincent.poulain@these.cnes.fr, jordi.inglada@cnes.fr,  
marc.spigai@thalesaleniaspace.com, jean-yves.tourneret@enseeiht.fr,  
philippe.marthon@enseeiht.fr

**Résumé** – Ce travail présente une chaîne de traitement générique pour la mise à jour de bases de données cartographiques grâce à des images satellites haute résolution optique et radar en milieu urbain dense. La méthode est basée sur l'extraction de primitives dans les images pour vérifier les éléments de la base de données (routes et bâtiments) puis pour détecter de nouveaux éléments à ajouter dans cette base de données. Un vecteur d'attribut est associé à chaque objet et une classification par « SVM 1 classe » est utilisée pour décider de la nature de l'objet.

**Abstract** – This paper addresses the issue of cartographic database creation or update using high resolution SAR and optical images in dense urban environment. The approach is composed of two steps. First, the presence of each database object (roads and buildings) in images is checked. Then, we verify if objects coming from an image segmentation must be added in the database. The two steps are conducted by extracting relevant features from images in the neighborhood of the considered object. The object removal/inclusion in the database is then achieved by a classification using the one-class SVM.

## 1 Introduction

L'émergence de nouveaux capteurs d'imagerie satellitaire à haute résolution, comme dans le cadre du programme d'observation de la Terre ORFEO, requiert une automatisation croissante des méthodes de traitement du flux de données disponibles. L'une des principales applications à l'imagerie satellitaire est la mise à jour de bases de données (BD) cartographiques. La plupart des études dans ce domaine portent sur des applications souvent spécifiques à un capteur et à un type de base de données. Dans ce travail, nous développons une chaîne de traitement générique, permettant la prise en compte d'images optiques et/ou RSO (radar à synthèse d'ouverture) à différentes résolutions en milieu urbain dense, pour la mise à jour de base de données de bâtiments et de routes. Plusieurs scénarios sont envisageables en fonction des images disponibles en entrée. Le cas le plus favorable étant celui où l'on dispose d'une image optique à haute résolution (de type Quickbird ou Pléiades), d'une image radar à haute résolution (par exemple Cosmo-SkyMed ou TerraSAR-X) et d'une base de données vecteur. L'objectif est alors de mettre à jour la base de données à l'aide des images optique et radar. Cependant,

notre chaîne doit être en mesure de prendre en compte des scénarios moins favorables, comme par exemple l'utilisation d'une seule image en entrée (qu'elle soit optique ou radar), de deux images de même nature, ou d'une image de résolution plus basse (de type Spot-5 par exemple à 2.5m de résolution), avec ou sans base de données comme information a priori.

## 2 Chaîne de traitement

Notre chaîne de traitement pour la mise à jour de base de données routes et bâtiments est présentée sur la figure 1. Les entrées de la chaîne sont des images satellites optique et/ou RSO à haute résolution (comprise entre 0.6m et 2.5m). Le but est de mettre à jour une base de données (si disponible), ou de la créer. L'approche choisie consiste dans un premier temps à vérifier les éléments de la base de données, et ensuite à détecter des nouveaux éléments. Afin de vérifier si chaque élément de la base de données est toujours présent sur les images, des descripteurs basés sur des primitives sont extraits des images. À chaque objet considéré est associé un vecteur constitué des scores de chaque descripteur. Les objets sont classifiés en fonction de leur vecteur de paramètres. Pour la détection de nou-

veaux objets, des hypothèses (de routes ou de bâtiments) sont extraites des images. Dans le cas des bâtiments, ces hypothèses sont des régions issues d'une segmentation multi-niveaux. Pour les routes, les hypothèses proviennent à la fois d'une segmentation et d'algorithmes automatiques d'extraction de routes. Pour décider si chacune de ces hypothèses est un objet d'intérêt, leur vecteur de paramètres est déterminé en utilisant les descripteurs, et une classification est effectuée afin de sélectionner les éléments à ajouter dans la base de données.

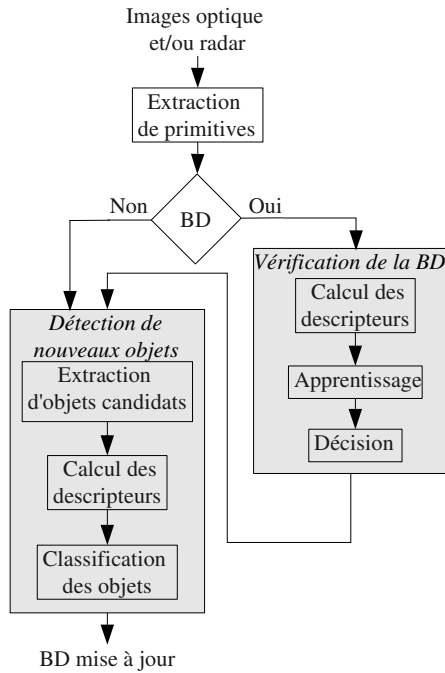


FIG. 1 – Chaîne de traitement générique.

### 3 Descripteurs

Les descripteurs ont pour objectif de caractériser les objets d'intérêt. Dans notre application, nous privilégions des descripteurs génériques, pouvant être adaptés aux différents scénarios envisagés. Ainsi pour les bâtiments nous utilisons les descripteurs suivants, que nous appliquons aux éléments de la base de données ainsi qu'aux hypothèses de bâtiments extraites lors de l'étape de détection :

- **Contours** : Caractérise le contraste entre l'hypothèse de bâtiment et son voisinage. Après une extraction de contours dans l'image optique [1], nous calculons la distance moyenne entre les murs du bâtiment et les contours extraits .
- **Lignes radar** : Dans une image RSO, le coin entre le sol et les murs orientés vers le capteur se caractérise par une ligne de forte intensité. Après avoir extrait les lignes brillantes de l'image [2], on vérifie pour chaque bâtiment la présence de lignes brillantes à proximité des murs orientés vers le capteur.

- **Ombres** : Comme un bâtiment est plus haut que son voisinage, il projette une ombre. Le descripteur consiste à quantifier la présence d'ombre du côté de l'hypothèse de bâtiment opposé au soleil.
- **Végétation** : Un masque de végétation est créé par seuillage du NDVI [3]. Nous calculons ensuite la proportion de végétation à l'intérieur de l'emprise du bâtiment.
- **Segments de ligne** : Les murs des bâtiments ayant une structure linéaire, la présence de segments de lignes [4] le long des contours de l'hypothèse est une preuve de présence de bâtiment.

Les descripteurs associés aux routes sont :

- **Radiométrie** : Dans une image optique, les routes sont de radiométrie assez homogène. Ce descripteur mesure la distance spectrale entre un pixel de route de référence et l'hypothèse de route.
- **Intensité RSO** : En imagerie RSO, le signal incident est en grande partie réfléchi de façon spéculaire par la route, donc l'intensité du signal reçu est très faible.
- **Végétation** : Utilisation d'un masque de végétation pour vérifier l'absence de végétation sur le tronçon de route.
- **Ombres** : Contrairement au descripteur ombre pour les bâtiments, celui-ci est utilisé pour vérifier que l'hypothèse de route ne projette pas d'ombre.

Ces descripteurs ne constituent pas une liste exhaustive, mais permettent tout de même d'obtenir des résultats intéressants pour notre application. De plus, de nouveaux descripteurs peuvent être aisément intégrés dans la chaîne de traitement afin d'améliorer les résultats, et notamment pour traiter les cas complexes qui ne peuvent être résolus avec ces descripteurs. Un vecteur de paramètres est associé à chaque élément considéré en fonction de son score obtenu avec chaque descripteur.

### 4 Classification

Pour décider si chaque hypothèse de bâtiment ou route doit être ajoutée/retirée de la base de données, une classification est effectuée sur la base de son vecteur de paramètres. Ainsi, dans le cas des bâtiments, le vecteur de paramètres contient les 5 variables associées aux descripteurs contours, lignes radar, ombres, végétation et segments de ligne. Les machines à vecteur support (SVM) [5] ont été utilisées avec succès pour des problèmes de classification supervisée. Le principe de cette technique de classification est de déterminer l'hyperplan séparant de façon optimale (avec une marge maximum) les données d'apprentissage labellisées. Or, dans notre application, nous ne disposons comme apprentissage que d'une base de données non à jour. En considérant que dans les bases de données routes et bâtiments des changements interviennent sur un faible nombre d'éléments, l'utilisation de la base de données comme apprentissage positif (classe « absence de changement ») est justifiée. L'algorithme One-Class SVM (aussi appelé OC-SVM ou 1-SVM) permet de s'affranchir de l'apprentissage négatif et semble donc approprié à notre problème de

classification. Dans notre application, l'apprentissage est effectué avec les vecteurs de paramètres des éléments de la base de données. La méthode 1-SVM nécessite en entrée un paramètre noté  $\nu$ , qui permet de régler le pourcentage d'anomalies présentes dans la base d'apprentissage. La classification permet de mettre en évidence les éléments marginaux pouvant alors être retirés de la base de données. Lors de l'étape de vérification de nouveaux objets, un vecteur de paramètres est associé à chaque objet candidat, et la classification est effectuée en utilisant comme apprentissage les éléments acceptés de la base de données.

## 5 Résultats

Des tests ont été effectués pour évaluer la vérification de la base de données bâtiments et la détection de nouveaux bâtiments. D'abord, pour évaluer l'étape de vérification, nous utilisons une vérité terrain mise en place grâce à la BDTOPO de l'IGN. Des faux bâtiments sont également ajoutés à la base de données en déplaçant les bâtiments de la BD dans des zones non bâties de l'image. Les tests ont été effectués avec plusieurs jeux d'images en entrée, correspondant à divers scénarios possibles :

- Cas 1 : image multispectrale à 70cm de résolution et une image radar TerraSAR-X à 1m.
- Cas 2 : image panchromatique (niveaux de gris) à 70cm et une image radar TerraSAR-X à 1m.
- Cas 3 : image multispectrale à 2.5m et une image radar TerraSAR-X à 1m.

Les images optique et radar ont été acquises sur un quartier résidentiel de Toulouse, comprenant des bâtiments de taille, de forme et de radiométrie très variées. La base de données à vérifier est composée de 263 objets (116 bâtiments effectivement présents sur les images et 147 bâtiments ajoutés qui doivent être supprimés). L'évaluation des résultats au niveau objet est effectuée en calculant la précision et le rappel [6]. L'indice F-mesure correspond à la moyenne harmonique de la précision et du rappel. L'évaluation au niveau pixel consiste à calculer la probabilité de fausse alarme et la probabilité de détection. Ces deux évaluations sont complémentaires, compte tenu des tailles très diverses des bâtiments. En effet avec l'évaluation au niveau objet, chaque objet a le même poids dans les résultats, quelle que soit sa taille, ce qui n'est pas le cas au niveau pixel, qui présente par contre une plus grande sensibilité aux erreurs de recalage et aux approximations dans la forme des bâtiments. Les résultats de l'évaluation de la vérification de la base de données sont présentés sur la figure 2. Ces résultats montrent que le procédé de vérification de la base de données est performant pour l'application visée dans les différents scénarios envisagés. La figure 3 montre la position des fausses alarmes, des non détections, des bâtiments correctement détectés ou rejetés pour l'expérience de la figure 2 (scenario 1) qui correspond à une précision = 0.947 et un rappel = 0.922. Ces valeurs correspondent à une accepta-

tion de 107 bâtiments sur 116, et à 6 fausses alarmes pour 141 bâtiments correctement rejetés. Les couleurs sont choisies de la façon suivante :

- En mauve : vrais positifs
- En rouge : faux négatifs
- En bleu : faux positifs
- En blanc : vrais négatifs

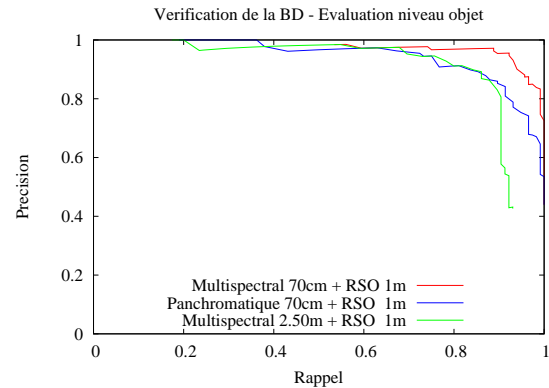


FIG. 2 – Courbes Précision-Rappel pour la vérification de la base de données bâtiments.



FIG. 3 – Résultats de la vérification de la BD bâtiments.

On remarque que les 6 faux positifs correspondent à des petits objets positionnés dans des zones hétérogènes (valeur élevée du descripteur basé sur les contours). Les faux négatifs sont soit des bâtiments de petite taille, soit des grands bâtiments de même radiométrie que la route adjacente.

Ensuite, la détection de nouveaux bâtiments est évaluée en utilisant la base de données comme apprentissage, et en classifiant toutes les régions issues de la segmentation multi-niveaux. Les résultats sont représentés grâce aux courbes précision-rappel pour l'évaluation au niveau objet (figure 4) et grâce aux courbes COR pour l'évaluation au niveau pixel (figure 5) pour les 3 scénarios indiqués précédemment. Les courbes sont obtenues en faisant varier un seuil correspondant à la distance à l'hyperplan séparateur. Les résultats au niveau pixel montrent que près de 65% des pixels de bâtiment sont détectés pour un taux de fausse alarme de 2%. Ceci correspond à une précision de 65% et un rappel de 63%. La figure 6 illustre les bâtiments détectés pour ces valeurs. On remarque que le cas où l'on dispose d'une image multispectrale à 2.5m (cas 3) fournit de meilleurs résultats au niveau objet que le cas image panchromatique (cas 2). Cependant ce n'est pas le cas pour l'évaluation au niveau pixel. En effet, avec une image optique moins résolue, l'extraction des bâtiments de très petite taille est très difficile, et par conséquent le taux de détection ne peut atteindre la valeur maximale des scénarios comportant une image à 70cm de résolution. Notons que la plupart des bâtiments de grande taille sont correctement détectés, montrant ainsi l'intérêt de cette chaîne de traitement pour l'application visée, c'est à dire traiter automatiquement les cas simples, un opérateur humain pouvant ainsi se focaliser uniquement sur les situations plus complexes.

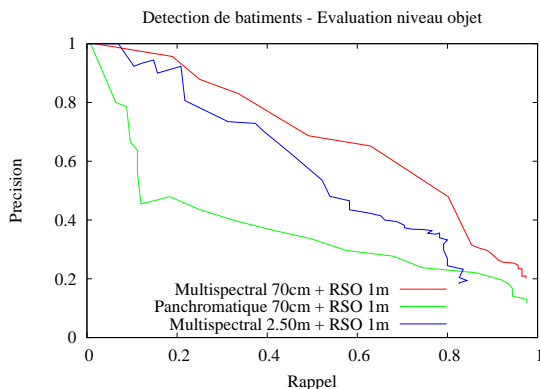


FIG. 4 – Courbes Précision-Rappel pour la détection de bâtiments.

## 6 Conclusion

Ce papier a détaillé une chaîne de traitement générique, utilisable dans plusieurs scénarios intégrant des images satellitaires optique et radar à haute résolution (dans l'intervalle 0.6m-2.5m) pour la mise à jour de bases de données cartographiques. L'utilisation de la méthode 1-SVM permet une classification des objets avec une seule classe d'apprentissage. Les résultats à la fois pour la vérification de la base de données et pour la détection de nouveaux éléments correspon-

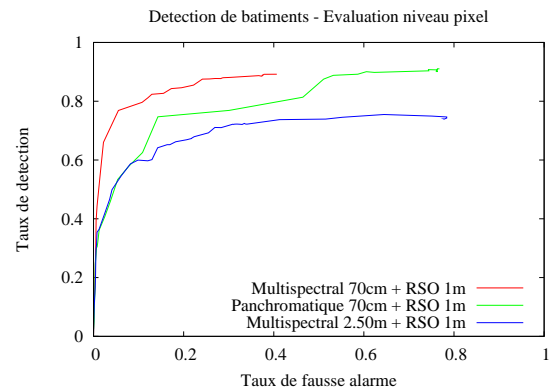


FIG. 5 – Courbes COR pour la détection de bâtiments.



FIG. 6 – Bâtiments détectés.

dent à l'application visée, et pourront de plus être améliorés en ajoutant des descripteurs pour traiter les cas complexes. La chaîne de traitement a été implémentée grâce à la bibliothèque libre de traitement d'image ORFEO Toolbox <http://www.orfeo-toolbox.org>.

## Références

- [1] D. Comaniciu and P. Meer, "Mean shift analysis and applications," in *The Proceedings of the Seventh IEEE International Conference on Computer Vision*, Kerkyra, Greece, 1999.
- [2] F. Tupin, H. Maitre, J. F. Mangin, J. M. Nicolas, and E. Pecher-sky, "Detection of linear features in SAR images : application to road network extraction," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 36, pp. 434–453, March 1998.
- [3] C. J. Tucker, "Red and photographic infrared linear combinations for monitoring vegetation," *Remote Sensing of Environment*, pp. 127–150, 1979.
- [4] R. Grompone Von Gioi, J. Jakubowicz, J. M. Morel, and G. Randall, "On straight line segment detection," *J. Math. Imaging Vis.*, vol. 32, no. 3, pp. 313–347, 2008.
- [5] B. Schölkopf and A. J. Smola, *Learning with Kernels : Support Vector Machines, Regularization, Optimization, and Beyond (Adaptive Computation and Machine Learning)*, The MIT Press, December 2001.
- [6] Jesse Davis and Mark Goadrich, "The relationship between precision-recall and roc curves," in *ICML '06 : Proceedings of the 23rd international conference on Machine learning*, New York, NY, USA, 2006, pp. 233–240, ACM.