

Détection d'objets enterrés par apprentissage profond sur imagerie géoradar

Minh-Tan Pham

Sébastien Lefèvre

IRISA - Université Bretagne Sud, UMR 6074, F-56000, Vannes, France

minh-tan.pham@irisa.fr

1 Introduction

L'imagerie géoradar est l'un des techniques géophysiques les plus utilisées pour la détection des objets enfouis tels que les mines terrestres, les canalisations d'eau ou de gaz, les artefacts archéologiques, etc. Un système géoradar transmet une onde électromagnétique dans le sol à plusieurs positions spatiales et reçoit le signal de réflexion pour former une image haute résolution appelée radargramme. Dans de tels radargrammes, les objets enfouis apparaissent sous forme d'hyperboles. Détecter des objets enfouis par imagerie géoradar revient donc à détecter des signatures hyperboliques dans les radargrammes associés.

La détection automatique des hyperboles a déjà été étudiée dans la littérature en reconnaissance de forme et vision par ordinateur, par exemple avec la transformée de Hough généralisée [1], la méthode d'appariement de forme (ou *template matching*) [2], l'utilisation de dictionnaire de formes [3], etc. Des méthodes supervisées ont également été proposées, en utilisant l'algorithme d'apprentissage en cascade de Viola & Jones [4] basé sur des caractéristiques d'histogramme de gradients orientés (ou HOG) ou des caractéristiques s'approchant des ondelettes de Haar [5, 6]. Cependant, les résultats de ces techniques ne sont pas pleinement satisfaisants, avec encore trop de fausses alarmes et cibles manquées. Récemment, et suite au succès croissant rencontré en vision par ordinateur, l'apprentissage profond avec des réseaux de neurones convolutifs (CNNs) a été également adopté en imagerie géoradar. Les applications concernent la classification binaire des profils (classes menace et non-menace) [7], ou la détection des mines terrestres [8, 9]. Cependant, ces méthodes se focalisent principalement sur la classification des patches d'images. Pour la tâche de détection, une fenêtre glissante avec laquelle on parcourt l'image entière reste la solution usuelle.

Dans ce travail, notre objectif est de proposer une chaîne de traitement automatique (i.e. *end-to-end framework*) pour la détection d'hyperboles dans les images géoradar. Pour ce faire, nous appliquons le détecteur Faster-RCNN [10] dont les performances en vision par ordinateur sont amplement démontrées. En raison du manque de données réelles nécessaires à la phase d'entraînement, nous proposons de combiner ces données avec des radargrammes obtenus par simulation avec le logiciel gprMax [11]. Les résultats préliminaires en détection montrent que la méthode proposée peut fournir des améliorations significatives par rapport aux méthodes classiques de vision par ordinateur, et qu'il est possible de traiter des données géoradar par apprentissage profond et ce même avec peu d'images d'entraînement.

2 Méthode proposée

La chaîne de traitement proposée peut être observée sur la figure 1. Elle consiste en deux étapes :

- 1) pré-entraîner un CNN sur la base d'images Cifar-10 [12] en niveaux de gris ;
- 2) ré-entraîner le Faster-RCNN (par *fine tuning*, utilisant des poids pré-entraînés) sur la base de radargrammes extraits de données réelles et simulées. Une fois l'entraînement terminé, le réseau est utilisé comme détecteur d'hyperboles à partir des nouveaux profils géoradar.

La première étape a pour but de définir et pré-entraîner un CNN qui sert à transférer les poids vers le réseau Faster-CNN (cf. figure 1). Nous avons choisi ici un réseau contenant trois couches de convolution de 16, 32 et 64 filtres de taille 5×5 pixels (chaque couche est suivie par une fonction d'activation de type ReLU et une agrégation (max-pooling) de 2×2 pixels) et une couche entièrement connectée de 64 neurones. Pour l'entraînement du réseau, comme recommandé dans [9], la base d'images Cifar-10 en niveaux de gris a été sélectionnée puisque la taille des images est petite (32×32 pixels), ce qui permet d'approcher la taille des hyperboles dans les radargrammes étudiés.

Le réseau Faster-RCNN [10] comprend deux composantes principales : un RPN (ou *region proposal network*) qui génère un ensemble de régions proposées à partir de l'image d'entrée puis un deuxième composant (comprenant un classifieur

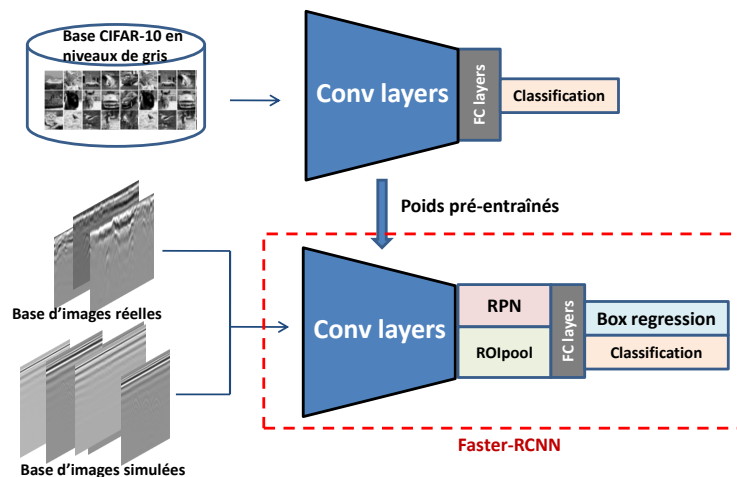


FIGURE 1 : Chaîne de traitement proposée.

et un opérateur de régression des patches) qui vérifie si chaque région proposée correspond à un objet recherché ou non. Ces étapes partagent toutes les deux les mêmes poids dans le réseau précédemment pré-entraîné (le lecteur intéressé par le fonctionnement d'un Faster-RCNN est invité à consulter l'article original [10]). Comme le montre la figure 1, les images géoradar réelles et simulées (par le logiciels gprMax [11]) sont utilisées pour entraîner le Faster-RCNN, qui sert à détecter des signatures hyperboliques de façon automatique.

3 Résultats préliminaires


Une base composée de 60 radargrammes réels et 40 radargrammes simulés a été créée pour la phase d'entraînement. Les profils réels ont été récemment acquis dans différents sites en France par un géoradar avec une antenne de 300 MHz qui peut pénétrer sur une profondeur de 7 mètres avec un temps de réponse de 100 ns. Pour les profils simulés, nous les avons d'abord générés en utilisant le logiciel gprMax [11] selon différents scénarios, avant d'ajouter un bruit préalablement estimé à partir des profils réels (nous permettant ainsi de disposer de données simulées plus réalistes) [13].

Dans la figure 2, nous présentons les résultats de détection d'un radargramme réel (qui n'appartient pas à la base d'entraînement). Ces résultats ont été obtenus par la méthode proposée et sont comparés à ceux produits par la méthode de Viola & Jones [4] basée sur des descripteurs de HOG et pseudo-Haar. Notons que les résultats présentés ici n'ont fait l'objet d'aucun post-traitement. Comme nous pouvons l'observer, le Faster-RCNN (cf. (c) et (d)) fournit de meilleurs résultats que la méthode de référence (cf. (a) et (b)), cette dernière ayant détecté des objets instables (i.e. avec des boîtes englobantes de taille très variée) et davantage de fausses alarmes. En outre, nous pouvons voir que l'ajout de profils simulés permet d'améliorer les résultats avec davantage de bonnes détections et moins de fausses alarmes (cf. 2(d) par rapport à 2(c)). Ces observations valident notre démarche et illustrent l'intérêt de l'algorithme proposé.


Notre travail actuel se focalise maintenant sur l'évaluation quantitative de nos résultats afin d'assurer une validation plus solide. De plus, nous nous intéressons également à la détection des paramètres des hyperboles (i.e. sommet et pente) pour la localisation fine et précise des objets détectés.

Références


- [1] C. G. Windsor, L. Capineri, and P. Falorni, A data pair-labeled generalized Hough transform for radar location of buried objects, *IEEE Geosci. Remote Sens. Lett.*, vol. 11, no. 1, pp. 124–127, 2014.
- [2] F. Sagnard and J.-P. Tarel, Template-matching based detection of hyperbolas in ground-penetrating radargrams for buried utilities, *J. Geophys. Eng.*, vol. 13, no. 4, p. 491, 2016.
- [3] G. Terrasse et al., Détection automatique de réseaux enterrés par imagerie géoradar, *RFIA*, 2016.
- [4] P. Viola and M. Jones, Rapid object detection using a boosted cascade of simple features, *CVPR*, 2001.
- [5] P. A. Torrione et al., Histograms of oriented gradients for landmine detection in ground-penetrating radar data, *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 3, pp. 1539–1550, 2014.
- [6] C. Maas and J. Schmalzl, Using pattern recognition to automatically localize reflection hyperbolas in data from ground penetrating radar, *Computers & Geosciences*, vol. 58, pp. 116–125, 2013.




(a) Algorithme Viola-Jones avec HOG



(b) Algorithme Viola-Jones avec Haar-like



(c) Faster-RCNN entraîné sur des profils réels



(d) Faster-RCNN entraîné sur des profils réels + simulés

FIGURE 2 : Résultats de détection sur un radargramme réel fournis par le Faster-RCNN (c et d) comparés avec la méthode Viola & Jones [4] (a et b). Pour le Faster-RCNN, les boîtes détectées avec un indice de confiance élevé ($> 0,7$) sont marquées en vert, tandis que celles avec un indice faible ($< 0,7$) sont en magenta.

- [7] L. E. Besaw and P. J. Stimac,, Deep convolutional neural networks for classifying GPR B-scans, *SPIE Defense+ Security*, pp. 945413–945413, 2015.
- [8] S. Lameri et al., Landmine detection from GPR data using convolutional neural networks, *EUSIPCO*, pp. 508–512, IEEE, 2017.
- [9] D. Reichman et al., Some good practices for applying convolutional neural networks to buried threat detection in Ground Penetrating Radar, *IWAGPR*, pp. 1–5, IEEE, 2017.
- [10] S. Ren et al., Faster R-CNN : Towards real-time object detection with region proposal networks, *NIPS*, pp. 91–99, 2015.
- [11] C. Warren et al., gprMax : Open source software to simulate electromagnetic wave propagation for ground penetrating radar, *Computer Physics Comm.*, vol. 209, pp. 163–170, 2016.
- [12] A. Krizhevsky and G. Hinton, Learning multiple layers of features from tiny images, 2009.
- [13] M. T. Pham and S. Lefèvre, Buried object detection from B-scan ground penetrating radar data using Faster-RCNN, *IGARSS*, 2018.