



Détection automatique de réseaux enterrés par imagerie géoradar

Guillaume Terrasse, Jean-Marie Nicolas, Emmanuel Trouvé, Émeline Drouet

► To cite this version:

Guillaume Terrasse, Jean-Marie Nicolas, Emmanuel Trouvé, Émeline Drouet. Détection automatique de réseaux enterrés par imagerie géoradar. RFIA, Jun 2016, Clermont-Ferrand, France. 2016. <hal-01351236>

HAL Id: hal-01351236

<https://hal.archives-ouvertes.fr/hal-01351236>

Submitted on 3 Aug 2016

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Détection automatique de réseaux enterrés par imagerie géoradar

Guillaume Terrasse¹ Jean-Marie Nicolas¹ Emmanuel Trouvé² Émeline Drouet²

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

² LISTIC, Polytech Annecy Chambéry, Université Savoie Mont-Blanc, 74944, Annecy-le-Vieux, France.

³ CRIGEN, ENGIE, Direction Recherche et Innovation, 93211, Saint-Denis La Plaine, France.

guillaume.terrasse@telecom-paristech.fr

1 Introduction

Afin d'améliorer la connaissance de l'existant et d'éviter l'endommagement d'ouvrages tiers au cours de travaux de voirie, la localisation des canalisations de gaz de manière non destructive est devenue un important domaine de recherche ces dernières années. Pour répondre à cette problématique, nous utilisons un géoradar. Cependant l'appareil ne fournit pas directement une position tridimensionnelle mais une carte des réflexions, appelée radargramme, que l'opérateur doit interpréter. La forme de l'ensemble des réflexions ainsi que leurs intensités donnent une indication sur la nature de l'objet. Une forme hyperbolique indique la présence d'un objet "ponctuel" situé au niveau de son aplomb. Cela pourrait être une pierre ou le franchissement perpendiculaire d'une canalisation. En revanche, une forme plane pourrait indiquer la limite entre deux couches. Ainsi la détection d'hyperboles dans le radargramme permet de localiser des canalisations. Plusieurs travaux ont porté sur le problème de détection automatique d'hyperboles dans les radargrammes. Ces travaux s'appuient principalement sur des algorithmes d'apprentissage supervisé. Notamment, dans [MS13] les auteurs utilisent l'algorithme *Viola Jones*. Cet algorithme calcule des caractéristiques à partir d'ondelettes de Haar en entrée d'un algorithme de boosting, *Adaboost*. Quant à [Bir10], il applique une classification par réseau de neurones. Il propose des vignettes à forme trapézoïdales pour limiter l'impact de l'arrière-plan au cours de l'étape d'apprentissage.

Dans cet article nous proposons un dictionnaire similaire aux *Physical Wavelet Frame (PWF)* décrites dans [ZU03] qui présente une nouvelle *frame* d'ondelette de forme hyperbolique construite sur trois paramètres influant sur la forme, l'épaisseur et l'aplatissement de l'hyperbole. Cependant, à la différence des PWF, les paramètres de nos atomes agissent indépendamment sur leur forme, épaisseur et aplatissement tout en conservant une position fixe.

2 Méthode proposée

2.1 Dictionnaire

Chaque atome du dictionnaire est construit à partir d'une *ondelette de Ricker* (Eq 2) traduite selon une fonction décrivant une forme hyperbolique (Eq 3). Chaque atome est paramétré par $\Theta = \{\alpha, \sigma, f, a, b, x_0, t_0\}$ selon :

$$h(x, t|\Theta) = e^{-\alpha \cdot A(x, t)} \cdot (r(t) \star \delta(t - g(x))) \quad (1)$$

$$r(t|\sigma) = \frac{2}{\sqrt{3\sigma} \cdot \pi^{1/4}} \cdot \left(1 - \frac{t^2}{\sigma^2}\right) \cdot e^{-\frac{t^2}{2\sigma^2}} \quad (2)$$

$$g(x|x_0, t_0, a, b, f) = a \cdot \sqrt{f^2 + \frac{(x - x_0)^2}{b^2}} + t_0 - f \cdot a \quad (3)$$

où $\delta(\cdot)$ est la distribution de Dirac. α et la fonction $A(x, t)$ assurent une faible énergie de l'atome aux frontières. σ contrôle l'épaisseur de l'atome. Les paramètres a et b impactent l'ouverture de l'hyperbole et f son aplatissement pour une localisation en (x_0, t_0) . On peut prouver que les atomes de notre dictionnaire sont intégrables sur $L_1(\mathbb{R}^2)$ et $L_2(\mathbb{R}^2)$ pour $\alpha > 0$. En pratique nous centrons nos atomes et faisons uniquement varier le paramètre a . À l'instar d'une ondelette notre dictionnaire est composé d'un même atome parent qui se décline en plusieurs ouvertures.

Les coefficients sont calculés par corrélation du radargramme avec chaque atome. Par conséquent, nous obtenons une pile d'images résultant de la corrélation entre un radargramme et chaque atome (Fig. 2 (1)). Chaque position (x, t) du radargramme est associée à un vecteur de coefficients $\mathbf{C}_{x,t} = (C(x, t|\Theta_1), \dots, C(x, t|\Theta_K))^T$, avec K le nombre d'atomes du dictionnaire.




FIGURE 1 – (a) Radargramme avec cinq hyperboles ; (b) Coefficients pour l'atome le plus corrélé aux cinq hyperboles. Les cinq "blobs" sont présentés dans les cadres en rouge.

2.2 Apprentissage supervisé

On remarque que lorsqu'un atome est proche d'une hyperbole d'un radargramme, ses coefficients situés au niveau du haut de l'hyperbole forment un *blob* (cf. Fig 1 (b)). Ce blob représente une partie de l'énergie de l'hyperbole concentrée en son apex. La détection de ces blobs permet de connaître la position de l'apex des hyperboles. À partir de ce constat, deux modèles sont appris par un algorithme d'apprentissage




FIGURE 2 – Structure de la méthode proposée ; 3 et 5 : Les pixels blanc représentent les positions conservées.

supervisé. Le premier modèle (Modèle Coefficients) est utilisé afin de prédire si un vecteur de coefficients à la position (x, t) se situe sur l’apex d’une hyperbole. Le second modèle (Modèle blobs) distingue les blobs de l’arrière plan. La méthode de détection d’hyperboles est décrite ci-dessous en suivant la Figure 2 : **(1.)** On calcule un vecteur de coefficients pour chaque position du radargramme $C_{x,t}$. **(2.)** Chaque vecteur $C_{x,t}$ est utilisé dans le *Modèle Coefficients*. **(3.)** À partir des résultats de la classification, une position reliée à un vecteur de coefficients est conservée ou rejetée. **(4.)** À partir des positions conservées, nous cherchons l’atome le plus corrélé, c’est-à-dire $j = \underset{i}{\arg \max}(C(x, t|\Theta_i))$ et utilisons une vignette centrée en (x, t) en entrée du *Modèle Blobs*. **(5.)** Ce second modèle décide si une vignette centrée en (x, t) à la position j de la pile d’images contient un blob ou non. Si c’est le cas alors la position est conservée comme étant le haut d’une hyperbole.

2.3 Estimation de la profondeur

Une fois qu’une hyperbole a été détectée, sa fonction mathématique est donnée par l’atome le plus corrélé à celle-ci. Sous l’hypothèse d’un milieu homogène et à partir de la forme de l’hyperbole, nous calculons une vitesse de propagation moyenne de l’onde et en déduisons une estimation de la profondeur.

3 Résultats

La Figure 3 présente les résultats de la détection automatique d’hyperbole et l’estimation de leur forme à partir de la méthode proposée.




FIGURE 3 – Résultat de la détection automatique d’hyperboles et de l’estimation de leurs formes illustrées en rouge (b) à partir d’un radargramme prétraité (a).

Nous avons comparé notre méthode avec différents descripteurs (Desc.) lors de l’apprentissage. Tout d’abord, à partir d’un ensemble d’apprentissage (EA) nous avons appris un modèle qui sépare les vignettes d’hyperboles des vignettes d’arrière-plans. Le Tableau 1 illustre ces résultats de détection sur un ensemble test à partir de modèles appris par algorithme d’apprentissage supervisé *Support Vector Machine (SVM)* sur un ensemble d’apprentissage com-

posé de vignettes (Vignettes). Les deux modèles proposés ont été appris à partir des descripteurs détaillés précédemment : des vecteurs de coefficients (Coef) et des vignettes de blobs (Blobs).

EA	Desc.	Noyau	Précision	Rappel	F-Score	Taux
Vignettes	Brutes	Linéaire	57.9	53.5	55.6	55.8
		RBF	80.2	80.5	80.3	79.6
	HOG	Linéaire	74.1	69.3	71.6	71.6
		RBF	78.1	80.3	79.2	78.2
	Canny	Linéaire	58.2	55.7	56.9	56.4
		RBF	71.0	71.0	71.0	70
Coef	Coef	Linéaire	66.7	75.5	70.9	69.2
		RBF	96.5	93.3	94.9	95.0
Blobs	Blobs	Linéaire	55.0	59.0	56.9	54.6
		RBF	96.7	95.9	96.3	96.3

TABLE 1 – Résultats (%) du modèle appris avec l’algorithme SVM à partir de la base de données test d’hyperboles

On constate que la méthode proposée obtient des résultats très satisfaisants et de meilleures performances comparées à une méthode basée sur des vignettes avec d’autres descripteurs.

4 Conclusion

Dans ce travail, nous avons proposé une méthode de détection automatique d’hyperboles sur des données géoradar afin de localiser des canalisations. Pour cela, nous utilisons un dictionnaire d’hyperboles théoriques qui va nous permettre de calculer deux descripteurs utilisés en entrée d’un algorithme de classification supervisé. Dans des travaux futurs, une étude complémentaire sur la mise en évidence des blobs devrait être faite ainsi que l’analyse plus appuyée de différents algorithmes d’apprentissage à appliquer.

5 Remerciements

Les auteurs souhaitent remercier BPI France et la région Île-de-France qui ont soutenu ces travaux dans le cadre du projet FUI/G4M (<http://g4m.fr>).

Références

- [Bir10] S. Birkenfeld. Automatic detection of reflexion hyperbolos in GPR data with neural networks. In *World Automation Congress*, pages 1–6, Kobe, Septembre 2010. IEEE.
- [MS13] C. Maas and J. Schmalzl. Using pattern recognition to automatically localize reflection hyperbolos in data from ground penetrating radar. *Computers and Geosciences*, 58 :116–125, Août 2013.
- [ZU03] R. Zhang and T. J. Ulrych. Physical wavelet frame denoising. *Geophysics*, 68(1) :225–231, 2003.