

RESEAUX DE NEURONES CONVOLUTIFS POUR LA CARACTERISATION D'ANOMALIES MAGNETIQUES

CARDENAS J.¹, DENIS C.², MOUSANNIF H.³, CAMERLYNCK C.⁴, FLORSCH N.⁵

¹ UMMISCO - IRD, Bondy, France, julio.cardenas_chapellin@sorbonne-universite.fr

² LiP6 - SU, Paris, France, christophe.denis@lip6.fr

³ LISI - UCA, Marrakech, Maroc, mousannif@uca.ma

⁴ METIS - SU, Paris, France, christian.camerlynck@sorbonne-universite.fr

⁵ UMMISCO - IRD, Bondy, France, nicolas.florsch@sorbonne-universite.fr

RESUME

Cette contribution présente l'utilisation des réseaux de neurones convolutifs pour la détection d'anomalies magnétiques. L'approche développée permet la localisation de dipôles magnétiques, avec le comptage du nombre de dipôles, leur position géographique et la prédiction de leurs paramètres (moment magnétique, profondeur et déclinaison). Elle sera ensuite testée sur des données réelles, dans le cadre par exemple, d'une détection pyrotechnique pour la prospection de munitions non explosées, avant d'envisager une application vers d'autres méthodes géophysiques.

Mots clés : *apprentissage profond, réseaux de neurones convolutifs, géophysique, méthodes magnétiques*

CONVOLUTIONAL NEURAL NETWORKS FOR MAGNETIC ANOMALIES CHARACTERIZATION

ABSTRACT

This contribution introduces the use of convolutional neural networks for the detection of magnetic anomalies. The developed approach allows the localization of magnetic dipoles, including the counting of the number of dipoles, their geographical position and the prediction of their parameters (magnetic moment, depth and declination). Subsequently, it will be tested on real data, for example, in the framework of pyrotechnic detection for unexploded ordnance prospecting, before considering an application towards other geophysical methods.

Key words: *deep learning, convolutional neural networks, geophysics, magnetic methods*

INTRODUCTION

Bien que les idées de base des réseaux de neurones aient été étudiées de forme basique dès les années 1950, il a fallu des décennies pour mettre en place cette approche. Pendant longtemps, la pièce manquante était un moyen efficace d'entraîner les larges réseaux neuronaux. Cela a changé au milieu des années 1980 lors de l'application de l'algorithme de rétropropagation du gradient pour l'apprentissage des réseaux neuronaux. Ensuite, la performance de ces réseaux a progressé grâce à l'augmentation de la puissance de calcul et l'augmentation des données disponibles.

L'évolution de ces algorithmes ont progressivement conduit à leur application dans plusieurs domaines. Dans le cas de la géophysique, ces algorithmes ont été utilisés pour traiter les données ou pour se substituer aux méthodes inverses, par exemple pour l'identification des ondes ou le filtrage du bruit sismique (Baan et Jutten, 2000), ou pour obtenir une estimation de l'épaisseur globale de la croûte terrestre (Meier et al., 2007).

Au cours des dernières années, les algorithmes d'apprentissage profond se sont révélés très prometteurs, notamment dans le domaine de l'interprétation sismique, par exemple, avec la mise en évidence de failles dans les sections sismiques par la génération d'un attribut de probabilité (Ma et al., 2018), ou la prédiction par un réseau neuronal convolutif d'un modèle élastique du sous-sol directement à partir des données sismiques enregistrées (Das et al., 2018).

Dans cette présentation, nous appliquons les réseaux de neurones convolutifs (CNN) pour compter automatiquement le nombre de dipôles dans un modèle magnétique, prédire leurs positions respectives (x, y) et leurs paramètres (moment magnétique, profondeur et déclinaison). La réussite de cette application nous permettra de tester notre modèle dans un scénario réel, comme la détection de matériel non explosé enfoui dans le sol (UXO), avant d'envisager un transfert vers d'autres applications géophysiques, telles que les méthodes électriques.

GENERATION DES MODELES SYNTHETIQUES

La précision des prédictions des réseaux de neurones dépend fortement de la complexité de l'architecture et de la quantité de données disponibles pour son apprentissage. Contrairement à d'autres domaines dans lesquels les réseaux de neurones ont connu un énorme succès, comme la classification des images, la disponibilité de données géophysiques labellisées est limitée. Pour surmonter ce problème, des données simulées ont été générées (figure 1) pour entraîner et valider le réseau neuronal convolutif. La perspective de ce travail est d'utiliser des données réelles pour tester la pertinence opérationnelle et l'adaptabilité de notre modèle.

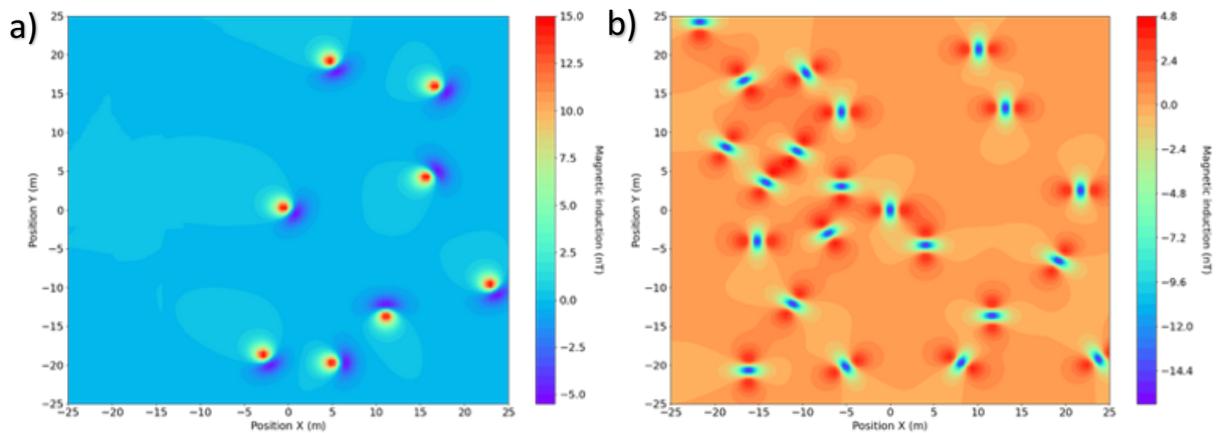


Fig. 1 – Cartes d'anomalies magnétiques induites incluses dans la base de données synthétiques utilisées pour l'apprentissage. Les anomalies de type dipolaire correspondent à des valeurs de déclinaison variées et à une inclinaison de 60° (a) et de 0° (b).

Les anomalies magnétiques dipolaires ont été générés selon une formule proposée par Scollar (1990):

$$\vec{B}_a = \frac{\mu_0}{4\pi} \left[\frac{3\hat{r}(\vec{m} \cdot \hat{r}) - \vec{m}}{r^3} \right] \cdot 10^9 \quad (1)$$

Avec :

\vec{B}_a : anomalie magnétique (en nT) ;

\vec{m} : moment magnétique du dipôle induit (en A.m²) ;

r : distance entre le dipôle magnétique et le point d'observation (en m) ;

\hat{r} : vecteur unitaire en direction du dipôle magnétique ;

μ_0 : perméabilité magnétique du vide (en H/m)

Les paramètres de chaque dipôle magnétique ont été utilisés comme données de labellisation de notre algorithme. Notre base de données, comportant 9600 exemples, a été divisée comme suit : 50% pour l'apprentissage, 25% pour la validation croisée et 25% pour le test. Cette répartition est considérée comme optimale par Collet (2018), lorsque la base de données est limitée (nombre d'exemples inférieur à 10⁶). Les caractéristiques de cette base de données sont décrites dans le tableau 1.

Caractéristiques de la base de données									
Cas magnétique	Aimantation rémanente	Grille		Caractéristiques physiques			Caractéristiques magnétiques		
		Taille	Espacement	Profondeur	Rayon	Hauteur du capteur	Champ local	Inclinaison	Déclinaison
Dipôles	Non	100 m	0.5 m	[1.0 – 1.6] m	[1.0 – 1.6] m	0.5 m	47.000 nT	[0, 30, 60, 90] degrés	[0-180] degrés

Tab. 1 – Caractéristiques utilisées pour générer la base de données simulées.

ARCHITECTURE DES RESEAUX DE NEURONES

Nos expérimentations ont montré que la combinaison de deux modèles "YOLO_DenseNet" (figure 2) est la plus performante pour atteindre nos objectifs de classification et de régression. Nous avons premièrement utilisé l'architecture "YOLO" pour localiser et classer chaque dipôle. Pour effectuer la régression sur les paramètres, nous avons ensuite mis en œuvre l'architecture "DenseNet" afin de prédire individuellement les paramètres de chaque dipôle détecté par le modèle YOLO.

"YOLO" (Redmon et al., 2016) est une architecture efficace de reconnaissance d'objets capable d'identifier la présence d'objets dans les images. Elle divise l'image en régions et prédit les boîtes et les probabilités pour chaque une. D'autre part, "DenseNet" est un type d'architecture CNN où chaque couche est reliée à une autre couche. Cette idée permet d'atténuer le problème du gradient de disparition et d'encourager la réutilisation des caractéristiques lors de l'apprentissage.

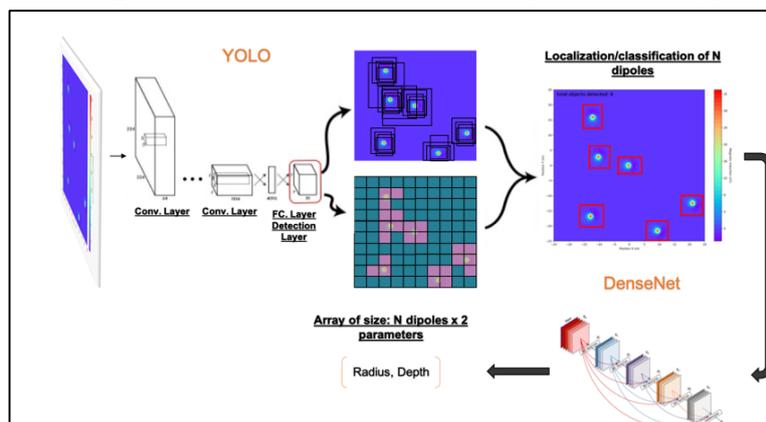


Fig. 2 – Schéma de notre architecture CNN combinant deux méthodes différents (YOLO et DenseNet).

RESULTATS ET DISCUSSION

Nous avons mis en place plusieurs expériences pour tester la robustesse de notre modèle et évaluer sa capacité de généralisation prenant en compte la variation des caractéristiques physiques et magnétiques des dipôles (tab. 1), le niveau de bruit et le nombre de dipôles présents dans le modèle.

Les résultats montrent que la méthode YOLO obtient de très bonnes performances. Bien que notre modèle ait été entraîné avec un nombre limité de dipôles (entre 1 et 8), sa capacité de généralisation lui permet d'identifier de 15 (figure 3a) à 30 (figure 3b) dipôles avec une confiance moyenne supérieure à 90%. A propos de l'évaluation de la performance de YOLO, chaque score de confiance reflète la probabilité qu'une boîte prédite contienne un objet ($Pr(\text{objet})$), ainsi que la précision de cette boîte en évaluant son chevauchement avec la boîte de délimitation de la vérité de terrain mesurée par le score IoU (« Intersection over Union »). Par conséquent, le score de confiance devient $Pr(\text{objet}) * IoU$. Dans cette étude, nous avons calculé la moyenne du score de confiance pour mesurer l'impact de l'augmentation des dipôles sur la précision de toutes les anomalies détectées.

Concernant la méthode DenseNet, on remarque une performance élevée (score de R^2 supérieur à 95%) (Figure 4). Ce résultat s'explique par le fait que le modèle analyse un dipôle à la fois, pour éviter l'influence sur la performance des zones où il n'y a pas de dipôles, et parce que le modèle YOLO localise précisément chaque anomalie d'intérêt.

Cependant, la performance des deux modèles diminue à partir de la présence de 10 dipôles (Fig. 4). Augmentant le nombre de dipôles, la possibilité d'avoir des objets qui se chevauchent augmente, ainsi que la probabilité d'avoir un dipôle proche des bords de la zone modélisée.

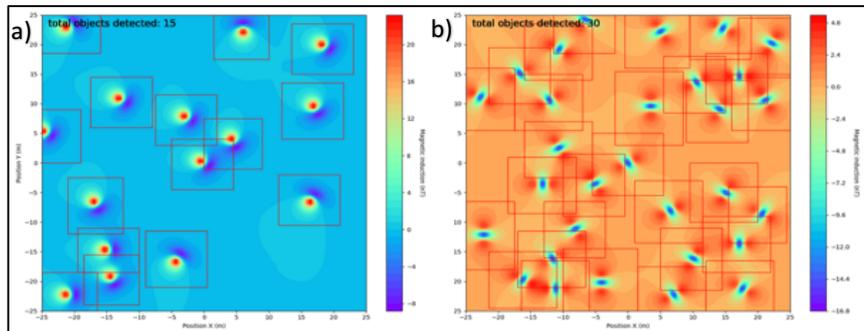


Fig. 3 – Prédiction du modèle YOLO pour 2 inclinaisons magnétiques de 60° (a) et 0° (b). L'algorithme localise chaque anomalie en l'identifiant dans une zone rectangulaire (boîte). Le total des dipôles détectés est 15 (a) et 30 (b) ; ces valeurs sont inscrites en haut à gauche de chaque figure.

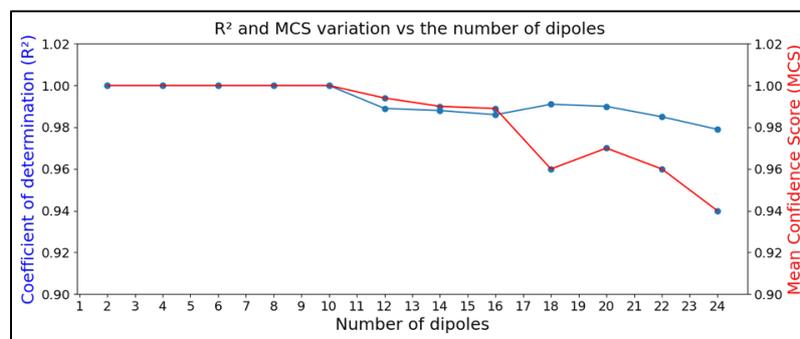


Fig. 4 – Variation du coefficient de détermination R^2 (DenseNet) à gauche et du score de confiance moyen (YOLO) en fonction du nombre de dipôles présents dans le modèle, à droite.

CONCLUSIONS ET PERSPECTIVES

Les résultats obtenus en appliquant les réseaux de neurones convolutifs sur une base de données magnétiques simulées nous permettent de valider leur utilisation pour ce niveau de complexité ; concernant les caractéristiques physiques et magnétiques des dipôles (tableau 1), le niveau de bruit et le nombre de dipôles. Le modèle YOLO détecte et localise chaque dipôle magnétique et le modèle DenseNet estime les paramètres de chaque dipôle identifié avec une précision supérieure à 90%.

Les perspectives de ce travail consistent à évaluer la robustesse de l'approche proposée en utilisant des données réelles. Un possible cas réel consiste à la détection de matériel non explosé enfoui dans le sol (UXO) considérant différents réglages de fond magnétique, e.g. des sites peu ou intensément bruités ou présentant des anomalies géologiques importantes. Il sera nécessaire d'expliquer les prédictions prises par nos modèles en comparant plusieurs outils informatiques. Ces explications seront évaluées en utilisant des résultats récents en philosophie des sciences.

REFERENCES BIBLIOGRAPHIQUES

COLLET F., 2018 – DEEP LEARNING with PYTHON. *Livre: Manning Publications Co, 1941–1945.*

DAS V. et al., 2018 – Convolutional neural network for seismic impedance inversion. *Article de conférence: SEG Technical Program Expanded Abstracts, 2071–2075.*

MA Y. et al., 2018 – A deep-learning method for automatic fault detection. *Article de conférence: SEG Technical Program Expanded Abstracts, 1941–1945.*

REDMON J. et al., 2016 – You Only Look Once: Unified, Real-Time Object Detection. *Article de conférence: IEEE Conference on Computer Vision and Pattern Recognition, 779–788.*

SCOLLAR I., 1990 – Archaeological prospecting and remote sensing. *Livre: Cambridge University Press.*