



Réseaux de Neurones Convolutifs pour la Caractérisation d'Anomalies Magnétiques

Julio José Cárdenas Chapellín, Christophe Denis, Hajar Mousannif, Christian Camerlynck, Nicolas Florsch

► To cite this version:

Julio José Cárdenas Chapellín, Christophe Denis, Hajar Mousannif, Christian Camerlynck, Nicolas Florsch. Réseaux de Neurones Convolutifs pour la Caractérisation d'Anomalies Magnétiques. CNIA 2021 : Conférence Nationale en Intelligence Artificielle, Jun 2021, Bordeaux (en ligne), France. pp.84-90. hal-03321334

HAL Id: hal-03321334

<https://hal.science/hal-03321334>

Submitted on 17 Aug 2021

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.

Réseaux de Neurones Convolutifs pour la Caractérisation d'Anomalies Magnétiques

J. Cárdenas Chapellín¹, C. Denis², H. Mousannif³, C. Camerlynck⁴, N. Florsch¹

¹ Sorbonne Université, UMMISCO

² Sorbonne Université, LIP6

³ Université Cadi Ayyad, LISI

⁴ Sorbonne Université, METIS

julio.cardenas_chapellin@sorbonne-universite.fr

Résumé

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

Abstract

This contribution introduces the use of convolutional neural networks for the characterization of magnetic anomalies. The developed approach allows one the localization of magnetic dipoles, including counting 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 prospection. Finally, an application to other geophysical methods will be considered.

Keywords

Deep learning, convolutional neural networks, geophysics, magnetic methods

1 Introduction

Les premiers réseaux de neurones ont été développés dans les années 1950. Cependant, jusque dans les années 1980, il n'existait pas à la fois une puissance de calcul et des algorithmes efficaces pour prendre en compte des topologies de réseaux de neurones plus complexes, permettant d'améliorer leurs capacités de prédiction. L'algorithme de rétropropagation du gradient couplé à une plus forte puissance de calcul a permis d'obtenir des résultats spectaculaires dans

le domaine de la reconnaissance des formes et de la perception.

De nombreuses disciplines scientifiques orientent également leurs activités de recherche vers l'apprentissage machine profond. C'est aussi le cas de la géophysique pour faciliter le traitement automatisé des données géophysiques et la résolution des problèmes d'inversion : par exemple pour l'identification des trains d'ondes ou le filtrage du bruit sismique [12], ou pour obtenir une estimation de l'épaisseur globale de la croûte terrestre [11].

Pendant la dernière décennie, les méthodes d'apprentissage profond se sont révélées très prometteuses, notamment dans le domaine de l'interprétation sismique, ou en mettant en évidence des failles dans les sections sismiques par la génération d'un attribut de probabilité [10], ou encore avec la prédiction par un réseau neuronal convolutif d'un modèle élastique du sous-sol directement à partir des données sismiques enregistrées [3].

L'inversion des données magnétiques par apprentissage machine profond est un sujet qui n'a été abordé que très récemment. Des modèles d'apprentissage profond ont récemment été utilisés pour réaliser l'inversion de structures magnétiques 3D [6]. Pour cela, un jeu de données contenant des millions de modèles géologiques annotés pour chaque structure géologique a été généré pour alimenter les réseaux de neurones convolutifs. Leurs modèles de réseaux de neurones permettent de classifier et de prédire les paramètres d'une structure géologique présente dans les cartes magnétiques. Cependant, cette approche est limitée à l'analyse d'une seule configuration et, le fait d'analyser l'ensemble des anomalies plutôt que chacune d'entre elles séparément, multiplie le nombre de cas à traiter et donc le temps de prédiction.

Le projet du présent article vise à caractériser des données magnétiques en comptant le nombre d'anomalies magnétiques dipolaires puis de prédire leurs positions (x,y) respectives ainsi que les paramètres associés (moment magnétique, profondeur et déclinaison).

1.1 Dynamique traditionnelle dans les méthodes magnétiques en géophysique et perspectives sur l'application de l'apprentissage profond

Dans les méthodes magnétiques en géophysique, les propriétés physiques d'intérêt sont la susceptibilité magnétique (aimantation induite) et la densité d'aimantation (cas rémanent). On s'intéresse ici au cas induit, le plus fréquent. L'aimantation induite permet de caractériser la quantité de matériau magnétisé dans un champ magnétique primaire. Le matériau magnétisé crée un champ magnétique secondaire (souvent appelé champ induit –mais en toute rigueur il faut parler d'induction magnétique) et les données mesurées lors d'une prospection sont la superposition du champ terrestre primaire et des champs induits secondaires. Ces données sont parfois interprétées en termes d'unités ou structures géologiques réelles (comme les failles ou les intrusions magmatiques), ou inversées pour obtenir la distribution de moments magnétiques induits sous la surface (figure 1).




FIGURE 1 – Éléments d'une prospection magnétique : un champ magnétique local, un corps magnétisable enfoui dans le sous-sol, un instrument de mesure (magnétomètre) et des cartes générées après traitement de données.

Afin d'interpréter les données magnétiques, les géophysiciens effectuent des corrections, fournissant les données traitées comme produit final. Ces corrections, en partie réalisées par des logiciels d'inversion classiques, permettent d'isoler le champ anomal causé par des éléments d'intérêt enfouis dans le sous-sol afin d'interpréter les données magnétiques en termes de caractéristiques et de structures en profondeur (Figure 2). Parfois la situation se complique pour les cartes magnétiques où les corps responsables ont des formes compliquées et des dimensions variables. Il est classique que ce processus implique un certain degré de subjectivité et dépendra de l'expertise du géophysicien. Notre approche de l'application de l'apprentissage profond (Figure 2) devrait d'une part pallier les faiblesses des algorithmes d'inversion, pour lesquels dans un problème multi-paramétré à grand nombre d'inconnues, la fonction objectif est souvent très aplatie autour de son minimum global. D'autre part, les différents bruits affectant les données réclament souvent un ajustement fin des paramètres d'amortissement en privilégiant un compromis entre la variance de la solution et la variance des erreurs d'ajustements.

Approche traditionnelle

- 1) Prospection magnétique
- 2) Obtention de données observées
(Cartes d'anomalies magnétiques)
- 3) Inversion des données
(logiciels traditionnels)
- 4) Interprétation géophysique
(paramètres de structures géologiques)

Nouvelle approche

- 1) Génération synthétique de :
Paramètres de structures géologiques
(Données de sortie)
↓
Cartes d'anomalies magnétiques
(Données d'entrée)
 - 2) Apprentissage du modèle
 - 3) Interprétation géophysique
- Données réelles

FIGURE 2 – Schéma de la dynamique traditionnelle suivie en géophysique (à gauche), et celui de la nouvelle approche proposée dans cette étude (à droite).

2 Méthodologie

Comme nous l'avons présenté précédemment, l'obtention d'une carte avec la distribution de la susceptibilité magnétique résulte d'une opération de prospection sur le terrain. Les cartes obtenues sont souvent imparfaites en raison de multiples facteurs, comme par exemple : le bruit instrumental, les conditions de régularité du terrain, les difficultés d'accès, etc. En conséquence, qualité et quantité des données géophysiques sont limitées.

Dans l'apprentissage profond, la précision des prédictions réalisées grâce aux réseaux de neurones dépend fortement de la complexité de l'architecture et de la quantité de données disponibles pour l'apprentissage. Contrairement à d'autres domaines dans lesquels les réseaux de neurones ont connu un énorme succès, comme pour la classification des images où le nombre de données disponibles est souvent supérieur à 1 million, la disponibilité de données géophysiques est un facteur limitant, car le nombre de cartes disponibles est faible (maximum d'un millier par exemple). Pour surmonter cette difficulté, on utilise des données simulées pour entraîner et valider le réseau neuronal convolutif. Par exemple, la figure 3 montre l'anomalie magnétique générée par une sphère de moment magnétique 52 A.m^2 , qui se trouve à 1.4 m de profondeur et en présence d'un champ primaire horizontal.




FIGURE 3 – Exemple d'une carte d'anomalie magnétique générée synthétiquement.

2.1 Génération des modèles synthétiques

En utilisant l'équation 8.16 proposée par [15] (cf. équation 1), nous avons pu générer des cartes d'anomalies magnétiques pour différentes configurations de corps magnétiques, qui sont ici assimilés à des dipôles magnétiques. Premièrement nous avons choisi une gamme de valeurs pour les paramètres de la profondeur et de l'amplitude magnétique. Ensuite, les dipôles ont été générés pour chaque combinaison de paramètres en faisant varier aléatoirement leurs positions (x,y). Pour finir et afin d'augmenter le nombre de dipôles, nous avons sommé les cartes générées avec la même distribution de paramètres, en respectant une distance minimum de 2 mètres entre les dipôles pour éviter toute coalescence des anomalies (figure 4a et 4b). Le choix d'utiliser les mêmes distributions pour sommer les cartes permet d'éviter l'occultation d'anomalies dont les amplitudes seraient trop différentes. Cette difficulté, qui est souvent observée dans les cas réels, fera l'objet d'une étude ultérieure.

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

Avec :

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

$\vec{m}$ = moment magnétique du dipôle induit (en $A.m^2$) ;

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

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

μ_o = perméabilité magnétique du vide (en H/m)




FIGURE 4 – Cartes d'anomalies magnétiques induites incluses dans le jeu de données synthétiques utilisés pour l'apprentissage. Les anomalies de type dipolaire correspondent à des valeurs de déclinaison variable et à une inclinaison de 30°(a) et 0°(b).

Les paramètres de chaque dipôle magnétique ont été uti-

lisés comme données de labellisation de notre algorithme. Notre jeu de données, comportant environ 10^4 exemples, a été divisé comme suit : 50% apprentissage, 25% validation croisée et 25% test. Cette répartition est considérée comme optimale par Chollet F. [2], lorsque le jeu de données est limité (nombre d'exemples inférieur à 10^6). Pour choisir la taille de la base d'apprentissage, nous avons testé différentes tailles de celle-ci. La meilleure stabilité du modèle a été observée à partir de 10^4 exemples. Les caractéristiques de ce jeu de données sont décrites dans le tableau 1.

Caractéristiques du jeu de données		
Cas magnétique	Aimantation rémanente	
Dipôles	Non	
Grille		
Taille	Espacement	
100 m	0.5 m	
Caractéristiques physiques		
Profondeur	Rayon	Hauteur du capteur
[1.0 – 1.4] m	[1.0 – 1.4] m	0.5 m
Caractéristiques magnétiques		
Champ local	Inclinaison	Déclinaison
47.000 nT	[0, 30, 60, 90] degrés	[0-180] degrés

TABLE 1 – Caractéristiques utilisées pour générer le jeu de données simulées.

2.2 Sélection d'architecture

Au début de notre recherche, en l'absence de bibliographie spécifique sur notre application magnétique, nous avons décidé d'utiliser les réseaux de neurones convolutifs (« CNNs ») en raison de la similitude entre la représentation classique de données magnétiques (sous forme de carte colorée) et les images couleur ou noir/blanc. Nous considérons que les images contiennent dans chaque pixel une valeur d'induction magnétique similaire à l'information de l'un des canaux RVB d'une image couleur.

Cette hypothèse nous a permis de considérer et d'évaluer plusieurs combinaisons de modèles CNNs, souvent appliqués aux images, avant de trouver celle qui s'adapte le mieux à nos objectifs. Le tableau 2 montre un résumé des architectures utilisées par ordre avec des commentaires sur les avantages et les limitations observées.

Modèle (prédictions)	Retour d'expérience
1) VGG16 (Paramètres)	- Prédiction limitée à un objet. - Pas d'information sur localisation.
2) VGG16 multi-objets (paramètres)	- Ralentissement de l'apprentissage lié à l'augmentation du nombre de neurones en sortie. - Pas d'information sur localisation.
3) VGG16 multi-objets (paramètres + position)	- Ralentissement de l'apprentissage lié à l'augmentation du nombre de neurones en sortie. - Diminution de la précision dû à la complexité des prédictions.
4) VGG16 multi-objets (paramètres) + U-Net	- Information précise des positions (x, y) mais imprécise de la largeur et de la longueur des objets.
5) YOLO + DenseNet multi-objets (paramètres)	- Information précise sur la localisation et la classification des objets. - Amélioration du temps d'apprentissage et de la prédictions des paramètres.

TABLE 2 – Ordre de sélection des architectures et les retours d'expériences correspondants.

Après plusieurs expérimentations, nous avons observé que la combinaison de deux modèles, «YOLO» [13] et «DenseNet» [7] (figure 5), 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.




FIGURE 5 – Schéma de notre architecture CNN combinant deux méthodes distinctes (YOLO et DenseNet).

"YOLO" 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 rectangles et les probabilités pour chacune. D'autre part, "DenseNet" est un type d'architecture CNN où chaque couche est connectée à toutes les couches suivantes. Cette idée permet d'atténuer le problème de l'évanescence de gradient et d'encourager la réutilisation des caractéristiques lors de l'apprentissage.

Pour améliorer la performance de notre modèle de régression et ainsi déterminer un bon ensemble d'hyperparamètres, nous avons utilisé l'algorithme "hyperband" [9]. Il consiste à accélérer la recherche aléatoire d'hyperparamètres grâce à une allocation adaptative des ressources et à un "early-stopping", ce qui offre une accélération d'un ordre de grandeur supérieur à celle d'autres algorithmes d'exploration. Parmi les hyperparamètres, nous avons utilisé «dropout» pour la régularisation. De multiples fonctions d'optimisation ont été comparées et "AdaGrad" a été sélectionné pour sa stabilité et sa convergence rapide. La fonction d'activation "tanh" a été choisie en raison de valeurs négatives et positives dans les quantités d'entrée. Il est important de préciser que cette fonction a été appliquée à toutes les couches sauf à la couche de sortie car, pour un modèle de régression, nous avons besoin de valeurs continues à la fin. Finalement, nous avons utilisé le coefficient de détermination R^2 pour calculer la précision et la fonction d'erreur quadratique moyenne (MSE) en guise de fonction coût. Le tableau 3 montre le nom du modèle de régression, les valeurs des hyperparamètres et celles de sa performance.

Model	Dropout	Learning rate
DenseNet	0.1	0.0003
Fonction d'activation	Précision	Perte
tanh	0.9998	0.0005

TABLE 3 – Combinaison d'hyperparamètres.

2.3 Étiquetage des données.

Nous avons procédé à un processus d'étiquetage suite à la génération des modèles géologiques. Vu que deux modèles d'apprentissage profond seront utilisés, les formats adoptés pour les données de sortie sont : le format d'étiquetage "YOLO" pour le modèle de détection et classification, et les valeurs réelles magnétiques pour le modèle de régression. Le format d'étiquetage "YOLO" consiste en la création d'un fichier.txt qui contient les annotations pour l'image correspondante, c'est-à-dire la classe et les valeurs du rectangle (« Bounding Box ») autour de chaque objet. "Bounding box" est un type d'annotation couramment utilisé en vision par ordinateur et il comporte les coordonnées, la hauteur et la largeur de l'objet.

Les CNNs sont particulièrement adaptés à l'analyse des données d'images. En plus de les utiliser pour la classification, on peut aussi les utiliser pour prédire des données continues. Dans notre recherche, ces données sont les paramètres des dipôles magnétiques (la déclinaison, la profondeur et l'amplitude du champ magnétique).

3 Explicabilité des algorithmes

L'utilisation de l'apprentissage machine engendre des interrogations de différentes nature concernant son fonctionnement. Dans le cadre de notre application en géophysique, il existe une pression forte sur l'explication des résultats produits par l'apprentissage machine. L'explication peut être destinée par exemple à des développeurs ou des ingénieurs en R&D qui utilisent le plus souvent l'apprentissage machine en mode "boite noire". L'explication peut être aussi destinée à des chercheurs académiques pour améliorer la connaissance scientifique en raison du caractère limité de la prédiction sans explication.

Dans le cadre de cette contribution, le besoin d'explication a été motivée pour sélectionner un modèle parmi d'autres ayant quasiment la même performance statistique. Nous avons utilisé les outils informatiques permettant d'obtenir des informations visuelles :

- La zone discriminatoire de notre réseau a été visualisée en utilisant l'outil Grad-Cam [14].
- L'outil t-SNE [8] a été utilisé pour réduire la dimensionnalité des données.

"Grad-Cam" est une technique permettant de produire des "explications visuelles" pour les décisions d'une grande classe de modèles basés sur CNN. Elle utilise les informations de gradient qui circulent dans la dernière couche convolutionnelle de la CNN pour comprendre chaque neurone en vue d'une décision d'intérêt. De l'autre côté, t-SNE est une autre technique de réduction de la dimensionnalité et est particulièrement bien adaptée à la visualisation d'un ensemble de données à haute dimension.

4 Résultats 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 (tableau 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 jusqu'à 20 dipôles (figure 6a et 6b) dipôles avec une confiance moyenne supérieure à 90%.




FIGURE 6 – Prédiction du modèle YOLO pour 2 inclinaisons magnétiques de 30° (a) et 0° (b). L'algorithme localise chaque anomalie en l'identifiant dans un rectangle. Le total des dipôles détectés est de 20 dans les deux cas ; ces valeurs sont inscrites en haut à gauche de chaque figure.

A propos de l'évaluation de la performance du réseau YOLO développé, chaque score de confiance reflète la probabilité qu'un rectangle contienne un objet ($Pr(objet)$), ainsi que la précision de ce rectangle en évaluant son chevauchement avec celui de la vérité de terrain mesurée par le score IoU (« Intersection over Union »). Par conséquent, le score de confiance devient $Pr(objet) * IoU$. 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 le réseau DenseNet, on remarque une performance élevée (score de R^2 supérieur à 95%) (Figure 7). Ce résultat s'explique par le fait que le réseau n'analyse que les zones

contenant une anomalie d'intérêt, localisée précédemment par le réseau YOLO. Cependant, on observe que la performance des deux réseaux diminue à partir de la présence de 10 dipôles (Figure 7). Cette diminution se produit parce qu'un plus grand nombre de dipôles augmente la coalescence d'anomalies, ainsi que la probabilité d'avoir une anomalie proche des bords de la zone modélisée. Le réentraînement du modèle avec ces cas dans le jeu de données doit surmonter ces limitations.




FIGURE 7 – 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.

D'autre part, il est important de mentionner que les résultats obtenus correspondent à un jeu de données d'une certaine complexité et sans bruit. La prise en compte de la détectabilité d'une anomalie en présence d'un bruit fond magnétique est beaucoup plus complexe que le simple dépassement d'un seuil constant [4]. Par conséquent, nous avons ajouté un bruit gaussien à notre jeu de données dans une première tentative pour simuler un bruit magnétique naturel. Bien que ce bruit soit basique en comparaison, son étude est importante pour évaluer la capacité de nos modèles à s'adapter correctement à de nouvelles données, tirées de la même distribution que celle utilisée pour leur création.

Pour évaluer les nouveaux modèles magnétiques bruités, nous avons utilisé notre modèle préalablement entraîné. Nous observons une altération de la forme des dipôles lorsque le niveau de bruit augmente et une variation considérable des valeurs d'induction magnétique. Ces changements pourraient baisser la performance de notre modèle parce qu'il dépend initialement de sa capacité à détecter chaque objet. Cependant, pour la détection, le modèle arrive à prédire le nombre exact et les rectangles correspondants à chaque dipôle (figure 8) avec une confiance supérieure à 92%. D'autre part, le modèle prédit les paramètres de chaque dipôle avec un coefficient de détermination supérieur à 96%. Ces résultats nous permettent de déduire que notre modèle est robuste jusqu'à ce niveau de bruit.

Comme indiqué dans la section 4, en plus d'utiliser les mesures statiques pour évaluer la performance de notre modèle, l'application d'outils visuels est important pour comprendre son fonctionnement et expliquer son principe de fonctionnement, indispensable pour son acceptabilité opérationnelle.




FIGURE 8 – Prédictions du modèle YOLO pour 2 inclinaisons magnétiques de 30°(a) et 0°(b) avec du bruit gaussien. Le total des dipôles détectés est a) 25 et b) 30.

Au début, l'application de l'outil Grad-Cam à la première version de notre modèle actuel nous a permis d'observer, dans la dernière couche de neurones, une carte de chaleur floue qui ne montrait pas la zone discriminatoire ciblée (Figure 9a). Cette carte nous a suggéré de supprimer plusieurs couches qui n'avaient probablement pas d'influence sur les prédictions. En suivant cette stratégie, nous avons trouvé une couche avec une zone discriminatoire cohérente (Figure 9b).

Ce changement a amélioré la stabilité de la courbe d'apprentissage, la performance des prédictions et a diminué considérablement le nombre de paramètres à entraîner du modèle, diminuant ainsi le temps de calcul de la phase d'apprentissage.

En plus de la capacité à discriminer, une autre caractéristique importante à évaluer est la capacité du modèle à différencier les paramètres utilisés pour créer le jeu de données. Pour cette évaluation, celui-ci était constitué par 16 combinaisons possibles entre les valeurs de profondeur et de rayon (tableau 1) et nous avons appliqué l'outil TSNE au jeu de données d'apprentissage (figure 10a), validation croisée (figure 10b) et test (figure 10c). Suite à cette application, nous observons que les prédictions de ces paramètres n'étaient pas aléatoires. Les graphiques générés confirment que le modèle parvient à différencier les 16 combinaisons. Bien que nous observons des petits clusters que le modèle n'arrive pas à rattacher à un groupe plus important (figure 10a) et des classifications ponctuelles erronées dans les données test (figure 10c), les résultats confirment la bonne capacité de notre modèle à différencier parmi les différentes combinaisons de paramètres.




FIGURE 9 – Identification des zones discriminatoires pour a) une ancienne version et b) une actuelle version du même modèle. Du haut vers le bas, on trouve premièrement le modèle géophysique analysé, deuxièmement les pixels d'activations identifiés par Grad-Cam, et troisièmement la zone discriminatoire.

Finalement, le temps de prédiction de notre modèle est d'une vingtaine de secondes, ce qui le rendrait compatible avec une utilisation temps réel pendant une prospection.

5 Conclusions et Perspectives

Nous avons présenté dans cette contribution une stratégie pour détecter, à l'aide de l'apprentissage machine, l'ensemble des dipôles présents dans une carte magnétique. Nous prédisons ensuite les caractéristiques physiques et magnétiques de chaque dipôle détecté. Il a été généré par simulation un jeu de données synthétique, ne disposant pas de mesures géophysiques labellisés en quantité suffisante. Nos expérimentations ont montré que la combinaison des modèles, YOLO et DenseNet, fournit les meilleures performances : le modèle YOLO permet de détecter chaque dipôle tandis que le réseau DenseNet estime les paramètres de chaque dipôle identifié avec une précision supérieure à 90%.

Au-delà de la performance statistique, nous avons optimisé le modèle pour que la zone discriminatoire, visualisée par l'outil Grad-Cam, soit conforme aux résultats escomptés pour éviter la création d'artefacts statistiques. Il est à noter que cela permet de faciliter l'explication des résultats obtenus. En particulier, nous avons optimisé le nombre de paramètres du modèle pour augmenter sa stabilité. Il s'agit donc d'une première étape de vérification fonctionnelle de la boîte noire de notre modèle.




FIGURE 10 – Exemple de graphiques obtenus grâce à l'utilisation de l'outil TSNE sur le jeu de données de a) apprentissage, b) validation croisée et c) test. Les axes n'ont pas d'unité spécifique et les couleurs des clusters représentent les 16 combinaisons possibles parmi les paramètres utilisés pour créer le jeu de données.

Enfin, l'utilisation de l'outil TSNE a permis d'évaluer la capacité du modèle à différencier parmi toutes les combinaisons possibles de paramètres présentes dans le jeu de données. Ces résultats montrent que ces outils de visualisation sont des alliés incontournables pour étudier la robustesse et la stabilité d'un modèle d'apprentissage profond en allant au-delà de la mesure de la précision statistique.

Les perspectives de ce travail consistent à évaluer la robustesse de l'approche proposée en utilisant des données réelles. Un possible cas d'étude consiste à détecter des munitions non explosées enfouies dans le sous-sol (UXO) en présence un bruit de fond magnétique naturel, 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 utilisant des techniques d'analyse post-hoc. Ces explications seront évaluées qualitativement par un panel d'expert en géophysique. Il sera aussi important de mettre en place des techniques d'adaptation de domaine, par exemple en utilisant une méthode d'apprentissage par transfert bien que les distributions statistiques des données synthétiques peuvent différer par rapport à celles des données réelles.

Références

- [1] BERKLEY D. et al., Overcoming Algorithm Aversion : People Will Use Imperfect Algorithms If They Can (Even Slightly) Modify Them, *Management Science*, pp. 1155-1170, 2018.
- [2] CHOLLET F., DEEP LEARNING with PYTHON *Manning Publications Co*, pp. 1941-1945, 2018.
- [3] DAS V. et al., Convolutional neural network for seismic impedance inversion, *SEG Technical Program Expanded Abstracts*, pp. 2071-2075, 2018.
- [4] DWAIN K. Butler, Potential fields methods for location of unexploded ordnance, *The Leading Edge*, pp. 890-895, 2001.
- [5] FLORSCH N., et al., Géophysique appliquée pour tous - Volume 2, Méthodes magnétiques et Slingram, *ISTE Editions*, 2019.
- [6] GUO J. et al., 3D geological structure inversion from Noddy-generated magnetic data using deep learning methods, *Computers and Geosciences*, pp. 104701, 2021.
- [7] HUANG G. et al., Densely Connected Convolutional Networks, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2261-2269, 2017.
- [8] LAURENS V. et GEOFFREY H., Visualizing data using t-SNE. *Journal of Machine Learning Research*, *Journal of Machine Learning Research*, pp. 2579-2605, 2008.
- [9] LISHA L. et al., Hyperband : A Novel Bandit-Based Approach to Hyperparameter Optimization, *Journal of Machine Learning Research*, pp. 1-52, 2018.
- [10] MA Y. et al., A deep-learning method for automatic fault detection, *SEG Technical Program Expanded Abstracts*, pp. 1941-1945, 2018.
- [11] MEIER U. et al., Fully nonlinear inversion of fundamental mode surface waves for a global crustal model : GLOBAL CRUSTAL MODEL, *Geophysical Research Letters*, pp. 706-722, 2007.
- [12] MIRKO V. et Christian J., Neural networks in geophysical applications, *GEOPHYSICS*, pp. 1032-1047, 2000.
- [13] REDMON J. et al., You Only Look Once : Unified, Real-Time Object Detection, *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 779-788, 2016.
- [14] SALVARAJU R. et al., Grad-CAM : Visual Explanations from Deep Networks via Gradient-based Localization, *Springer Science and Business Media LLC : International Journal of Computer Vision*, pp. 336-359, 2019.
- [15] SCOLLAR I., Archaeological prospecting and remote sensing, *Cambridge University Press*, Cambridge University Press, 1990.