



HAL
open science

Approximation de modèle de propagation modale en acoustique sous marine à l'aide de réseaux de neurones

Arthur Varon, Julien Bonnel, Jérôme Mars

► To cite this version:

Arthur Varon, Julien Bonnel, Jérôme Mars. Approximation de modèle de propagation modale en acoustique sous marine à l'aide de réseaux de neurones. XXIXème Colloque Francophone de Traitement du Signal et des Images, Aug 2023, GRENOBLE (38000), France. hal-04885265

HAL Id: hal-04885265

<https://hal.science/hal-04885265v1>

Submitted on 14 Jan 2025

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.

Public Domain

Approximation de modèle de propagation modale en acoustique sous marine à l'aide de réseaux de neurones

Arthur VARON¹ Julien BONNEL² Jérôme MARS¹

¹ Univ. Grenoble Alpes, CNRS, Grenoble INP, GIPSA-lab, 38000 Grenoble, France

² Applied Ocean Physics & Engineering, Woods Hole Oceanographic Institution, Woods Hole, MA 02540, USA

Résumé – Les réseaux de neurones se sont avérés capable de simuler et d'accélérer la simulation de phénomène physique complexe. En entraînant un DNN à prédire les nombres d'onde et les vitesses de groupes pour une variété d'environnements marins, nous avons pu accélérer la résolution des modèles de propagation modale pour des signaux large bande. Afin de montrer le potentiel de notre approche, notre modèle est utilisé pour prédire la perte de transmission et le scénario d'inversion géoacoustique sur les données Shallow Water 2006.

Abstract – Neural networks have proven capable of simulating and accelerating the simulation of complex physical phenomena. By training a neural network to predict wavenumbers and group velocities for a variety of marine environments, we were able to speed up the resolution of modal propagation models for wideband signals. To demonstrate potential applications, our model is then used to predict transmission loss and on a geoacoustic inversion scenario based on Shallow Water 2006 data.

1 Introduction

Dans un contexte de détection de cible ou de connaissance du milieu marin en acoustique sous-marine, la propagation des ondes acoustiques complexifie fortement le problème. Cette propagation est en effet, influencée par les caractéristiques physiques de la colonne d'eau, mais également par les paramètres géoacoustiques du fond marin. Pour décrire cette propagation, des modèles établies à partir de la théorie des modes normaux ont été développés [19, 14]. Bien que ces modèles soient relativement efficaces en termes de ressource calculatoire, la nécessité de les exécuter de nombreuses fois pour résoudre le problème direct ou inverse, notamment dans le cas des signaux large bande reste problématique.

Ces dernières années, les réseaux de neurones ont suscité une attention significative en raison de leur capacité à approximer des fonctions non linéaires, à simuler divers phénomènes physiques [5, 2], ou à réduire les coûts de calcul de ces modèles [13, 1].

L'utilisation de ces réseaux de neurone ou de l'apprentissage automatique en acoustique sous-marine n'est pas nouveau [16]. Récemment, ils ont été utilisés pour la classification des sources d'opportunité[7] ou la classification des fonds marins [18]. Cependant, l'utilisation de réseaux de neurones n'a pas encore été largement étudiée pour la simulation du champ acoustique, pour la résolution du problème direct par exemple. Cela peut être dû à la grande variété de méthodes disponibles pour simuler le champ acoustique, et probablement à un manque de données réelles annotées et cohérentes pour évaluer les modèles entraînés. Plus récemment, quelques approches prometteuses ont été réalisées dans ce domaine. Par exemple, la possibilité d'étendre la simulation de la perte de transmission en utilisant un réseau de neurones pour différentes positions de source dans un environnement donné et connu [12]. Le réseau de neurones utilisé dans les travaux de Mallik *et al*, est entraîné à partir de données simulées venant d'un modèle de propagation par tracé de rayon.

Des travaux pour étendre la prédiction du champ acoustique en basse fréquence à partir d'une zone de mesure ont également été réalisés [11]. Pour cela, Li et Chitre ont utilisé un réseau de neurone pour extraire les paramètres modaux du signal mesuré, avant d'effectuer la prédiction de propagation. Une approche similaire se basant sur un modèle de propagation par tracer de rayon a également été proposée par les mêmes auteurs[10]. Notre approche présentée dans cet article se place dans un contexte de propagation modale (UBF) et utilise la paramétrisation de l'environnement pour estimer les paramètres modaux (vitesse de groupe et nombre d'ondes) de la même façon que les modèles de simulation.

2 Propagation des modes normaux en acoustique sous-marine

Dans le cadre d'une propagation modale, l'environnement marin est décrit comme un guide d'onde dans lequel différents modes m se propagent. Ces modes sont décrits par leurs fonctions modales Ψ_m ainsi que leurs nombres d'ondes k_{rm} . Pour un signal source S placé à la profondeur z_s et connaissant le nombre de modes propagatifs N , le signal reçu Y , à la profondeur z_r et à une distance r de la source, peut être décrit par la théorie des modes normaux. Formellement, le champ acoustique reçu à la fréquence f est donnée par :

$$Y(f) = |S(f)| \sum_{m=1}^N \Psi_m(z_s, f) \Psi_m(z_r, f) \frac{e^{jrk_{rm}(f)}}{\sqrt{rk_{rm}(f)}} \quad (1)$$

le milieu marin se comportant comme un guide d'onde dispersif, la vitesse de groupe v_{gm} est dépendante à la fois de la fréquence f et du mode m . Parce que cette dispersion est dépendante de la colonne d'eau et du fond marin, on peut utiliser l'estimation de la vitesse de groupe, à partir d'une mesure pour estimer les paramètres géoacoustiques [4, 6]. Cette approche est détaillée en section 4.2.

3 Description de la méthode

L'objectif est d'étudier la possibilité de remplacer une simulation de propagation modale par un réseau de neurones (DNN). Cela permettra de diminuer les ressources calculatoires nécessaires à l'évaluation des modèles de propagation modales tout en conservant au maximum les différentes utilisations possibles de ce genre de modèle. Les paramètres nécessaires à la propagation modale sont les nombres d'ondes propagatifs k_{rm} et les fonctions modales Ψ_m . Les fonctions modales peuvent être obtenues à partir des nombres d'ondes propagatifs grâce à la méthode d'itération inverse [8]. La vitesse de groupe pouvant être utilisée pour effectuer l'inversion géoacoustique [6] est également calculée par les simulations. C'est pourquoi nous avons entraîné notre modèle à prédire les nombres d'ondes k_{rm} et les vitesses de groupes v_{gm} pour les trois premiers modes ainsi qu'un ensemble de quarante-et-une fréquences allant de 50 Hz à 250 Hz.

Le modèle a été entraîné sur les sorties du modèle Kraken [14], largement utilisé dans la communauté et effectue ses prédictions à partir d'une paramétrisation de l'environnement θ . La paramétrisation de l'environnement est composée du profil h_i de célérité c_i et de densité ρ_i du milieu. Un résumé de la méthode est présenté en figure 1




FIGURE 1 : Schéma résumé de la méthode et des applications proposées

3.1 Génération et prétraitement des données

Pour entraîner notre modèle, un jeu de donnée a été généré pour décrire un ensemble de paramétrisation d'environnement possible. Dans ce jeu de donnée, la vitesse du son (SSP) dans la colonne d'eau est présumée connue et fixée. Le profil de célérité est échantillonné à quatre profondeurs différentes de 0 m, 10 m, 25 m et 80 m, chacune avec une célérité respective de $1525 \text{ m} \cdot \text{s}^{-1}$, $1525 \text{ m} \cdot \text{s}^{-1}$, $1485 \text{ m} \cdot \text{s}^{-1}$ et $1490 \text{ m} \cdot \text{s}^{-1}$. La densité ρ est constante dans toute la colonne d'eau, avec une valeur de $1.03 \text{ kg} \cdot \text{m}^{-3}$. Ces profils de célérité et de densité sont issus des mesures de l'expérience SW06 en eau peu profonde [17]. Le modèle de fond marin est composé d'une couche de sédiments d'épaisseur h_1 , ayant une vitesse du son de c_1 et une densité de ρ_1 . Le substrat est considéré comme un milieu acoustique semi-infini ayant une vitesse du son de c_2 et une densité de ρ_2 .

La variation des données générées provient des cinq paramètres définis dans le fond marin. Ces paramètres sont générés aléatoirement à l'aide d'une distribution uniforme dans des limites spécifiées décrites dans le tableau 1.

Paramètre	Unité	Limites
Épaisseur de couche de sédiment : h	m	[1,25]
Vitesse du son du sédiment : c_1	$\text{m} \cdot \text{s}^{-1}$	[1500,2500]
Densité du sédiment : ρ_1	$\text{kg} \cdot \text{m}^{-3}$	[1.2,2.5]
Vitesse du son du substrat : c_2	$\text{m} \cdot \text{s}^{-1}$	[1500,2500]
Densité du substrat : ρ_2	$\text{kg} \cdot \text{m}^{-3}$	[1.2,2.5]

TABLE 1 : Variabilité du jeu de données utilisé pour l'entraînement du modèle

Pour chaque environnement, le modèle Kraken [14] permet d'obtenir les nombres d'ondes k_{rm} et les vitesses de groupes v_{gm} utilisées comme label pour l'entraînement du réseau.

Ainsi, 500 000 paramétrisations et labels seront générés et répartis en deux jeux de données, 400 000 pour l'entraînement, et 100 000 pour les tests.

Afin d'améliorer l'entraînement, les profondeurs du profil h_i ainsi que les valeurs de célérité c_i et de densité ρ_i seront normalisées pour rester dans l'intervalle [0,1]. Les vitesses de groupes v_{gm} subiront la même transformation que les célérités. Le nombre d'ondes se verra soustraire sa tendance linéaire $2\pi f c_{\text{water}}$, où c_{water} représente la somme pondérée de la célérité dans la colonne d'eau.

3.2 Modèle et entraînement

L'architecture du DNN utilisé est composée de quatre couches densément reliées de 80 unités avec une dernière couche densément reliées donnant les sorties des nombres d'ondes et des vitesses de groupes. Chacune de ces couches est suivie d'une fonction d'activation linéaire rectifiée.

Pour l'entraînement, l'optimiseur adam [9] est utilisé avec un taux d'apprentissage $\alpha = 10^{-2}$ et nous prenons la racine de l'erreur quadratique moyenne comme fonction de perte.

3.3 Résultats




FIGURE 2 : Comparaison entre estimations du DNN et sortie du programme de mode normaux Kraken pour les vitesses de groupes (a) et les nombres d'ondes (d) sur un environnement. Erreur du modèle entre les vitesses de groupes (b) et les nombres d'ondes (e). Histogramme d'erreur moyenne relative par environnement pour le jeu de données de test sur les vitesses de groupes (c) et les nombres d'ondes (f).

Lors de l'évaluation, le modèle montre une bonne capacité à estimer la dispersion des différents milieux du jeu de données

de test, comme cela est mis en avant sur les figures 2(a) et 2(d). La majorité des prédictions effectuées ont une erreur relative moyenne inférieure à 0,5% pour les nombres d’ondes et inférieur à 0,3% pour les vitesses de groupes, comme le montre les figures 2(c) et 2(f).

Les figures 2(a) et 2(b) montrent un maximum d’erreur important sur le dernier mode propagatif dans les basses fréquences. Cela peut être expliqué par le fait qu’une partie des environnements du jeu de données d’entraînement ont une fréquence de coupure légèrement supérieure à 50Hz. Pour de telle fréquence, la vitesse de groupe change brutalement, pour tendre vers la célérité maximale du milieu considéré. Cela affecte l’entraînement et explique également les milieux pour lesquels l’erreur relative moyenne est plus importante.

4 Applications

Deux applications sont proposées : Le cas du problème direct, où l’on simule le champ acoustique propagé à partir de la paramétrisation de l’environnement et d’une source impulsionnelle. Cela est illustré avec le calcul de la perte de transmission, (section 4.1). Le cas du problème inverse, où l’on cherche à retrouver les paramètres géoacoustiques du milieu, à partir d’une mesure du champ acoustique en un point (section 4.2).

4.1 Calcul de la perte de transmission

L’information que donne la perte de transmission est cruciale dans l’environnement sous-marin. La perte de transmission est utilisée pour calculer la portée effective des systèmes de communication, ou optimiser le placement de capteur. Pour calculer la perte de transmission, il faut d’abord récupérer les fonctions modales pour les modes et fréquences considérées. Pour cela, la méthode d’itération inverse [8] est utilisée avec les nombres d’ondes k_{rm} prédits par le réseau. Après avoir fixé la profondeur de la source z_s , la perte de transmission est calculée grâce à l’équation (1). Les résultats sont présentés sur la figure 3 pour une source placée à 32 mètres de profondeur. Malgré une estimation globalement très correcte avec près de 95% des points prédits ayant une erreur inférieure à 3dB, la figure 3(c) montre qu’il existe des erreurs présentes au niveau des zones d’interférences s’expliquant en partie par les fortes variations présentes dans ces zones.




FIGURE 3 : Comparaison entre perte de transmission à 160Hz pour une source à 32 mètres. (a) Simulation physique (Kraken). (b) Prédiction par le DNN. (c) Erreur supérieure à 3dB.

4.2 Inversion Géoacoustique

Notre modèle peut également être utilisé pour accélérer un problème d’inversion géoacoustique. Pour cette problématique, les paramètres modaux sont estimés pour un grand nombre d’environnements décrits par leur paramétrisation θ . Ils sont ensuite comparés avec ceux obtenus lors d’une mesure terrain. Les paramètres géoacoustique sont déduits de la paramétrisation θ ayant donné le minimum d’erreur pour les paramètres modaux. Bien que de nombreux paramètres modaux puissent être utilisés, de nombreuses recherches se sont concentrées sur la dispersion modale en temps-fréquence [3, 4, 15] qui est intrinsèquement liée à la vitesse de groupe v_{gm} .

Pour cette comparaison, des vitesses de groupes de références v_{gm}^{ref} ont été simulées pour un environnement θ^{ref} . Puis différents environnements ont été générés en faisant varier les 5 paramètres de notre réseau ($h_1, c_1, \rho_1, c_2, \rho_2$). Pour chacun de ces environnements, les vitesses de groupes ont été évaluées à la fois par la simulation v_{gm}^{KraK} et par le modèle d’apprentissage v_{gm}^{DNN} . Les vitesses de groupes ainsi obtenu ont été comparées aux vitesses de groupes de références à l’aide de l’équation (2) :

$$RMSE_i(\theta) = \sqrt{\frac{1}{N} \sum_{m,f} (v_{gm}^{\text{ref}})^2 - v_{gm}^i(\theta)^2} \quad (2)$$

avec $i = \text{KraK}$ et $i = \text{DNN}$.

Les résultats de cette inversion sont présentés en figure 4 sous la forme de coupe présentant le minimum d’erreur pour chaque paramètre géoacoustique. Dans ce cas d’application, le modèle d’apprentissage a permis une division du temps de calcul nécessaire par 40 comparés au modèle d’origine avec des ressources calculatoires similaires. Cependant, les paramètres (c_2 et ρ_2) ayant le moins d’impact sur la dispersion dans cette bande de fréquence ont été incorrectement estimés.

5 Conclusion

L’utilisation de simulation pour la propagation modale en acoustique sous-marine peut être coûteux, en particulier lorsque ces modèles doivent être évalués de nombreuses fois, par exemple, pour de l’inversion géoacoustique à large bande. Nous proposons de remplacer ce modèle par un DNN déportant ainsi le temps de calcul lors de l’entraînement. Le modèle utilisé reste simple, mais permet cependant d’obtenir une précision intéressante ainsi qu’une amélioration importante du temps de calcul nécessaire à la simulation.

Remerciements

Ce travail est soutenu par le CNRS, l’Agence de l’Innovation de Défense (#2021-65003) et l’Office Naval Research.

Références

- [1] Mohammad ABDOLRAZZAGHI, Soheil HASHEMY et Ali ABDOLALI : Fast-forward solver for inhomogeneous media using machine learning methods : Artificial neural network, support vector machine and fuzzy logic. *Neural Computing and Applications*, 29(12):1583–1591, 2016.
- [2] A. ADLER, M. ARAYA-POLO et T. POGGIO : Deep learning for seismic inverse problems : Toward the acceleration of geophysical analysis workflows. *IEEE Signal Processing Magazine*, 38(2):89–119, 2021.




FIGURE 4 : Comparaison de l’erreur entre la vitesse de groupe prédite et simulée. Les paramètres géoacoustiques non variables sont fixés pour présenter le minimum d’erreur.

[3] M. S. BALLARD, G. V. FRISK et K. M. BECKER : Estimates of the temporal and spatial variability of ocean sound speed on the new jersey shelf. *The Journal of the Acoustical Society of America*, 135(6):3316–3326, 2014.

[4] J. BONNEL, S. E. DOSSO et N. ROSS CHAPMAN : Bayesian geoacoustic inversion of single hydrophone light bulb data using warping dispersion analysis. *The Journal of the Acoustical Society of America*, 134(1):120–130, 2013.

[5] S. L. BRUNTON, B. R. NOACK et P. KOUMOUTSAKOS : Machine learning for fluid mechanics. *Annual Review of Fluid Mechanics*, 52(1):477–508, 2020.

[6] N. ROSS CHAPMAN et Er Chang SHANG : Review of geoacoustic inversion in underwater acoustics. *Journal of Theoretical and Computational Acoustics*, 29(03), 2021.

[7] M. GOLDWATER, J. BONNEL, A. CAMMARERI, D. WRIGHT et D. P. ZITTERBART : Classification of dispersive gunshot calls using a convolutional neural network. *JASA Express Letters*, 1(10):106002, 2021.

[8] F. B. JENSEN, W. A. KUPERMAN, M. B. PORTER et Henrik SCHMIDT : *Wavenumber Integration Techniques*, chapitre 4, pages 233–335. Computational Ocean Acoustics. Springer New York, 2011.

[9] D. P. KINGMA et J. BA : Adam : a method for stochastic optimization. *ArXiv*, 2014.

[10] K. LI et M. CHITRE : Data-aided underwater acoustic ray propagation modeling. *ArXiv*, 2022.

[11] K. LI et M. CHITRE : Physics-aided data-driven modal ocean acoustic propagation modeling. *The 24th International Congress on Acoustics (ICA 2022)*, 2022.

[12] W. MALLIK, R. K. JAIMAN et J. JELOVICA : Predicting transmission loss in underwater acoustics using convolutional recurrent autoencoder network. *The Journal of the Acoustical Society of America*, 152(3):1627–1638, 2022.

[13] b. MOSELEY, t. NISSEN-MEYER et a. MARKHAM : deep learning for fast simulation of seismic waves in complex media. *solid earth*, 11(4):1527–1549, 2020.

[14] M. B. PORTER : Kraken normal mode program. Rapport technique, Naval Research Lab Washington DC, 1992.

[15] G. R. POTTY, J. H. MILLER, J. F. LYNCH et Kevin B SMITH : Tomographic inversion for sediment parameters in shallow water. *The Journal of the Acoustical Society of America*, 108(3):973–986, 2000.

[16] Y. STÉPHAN, S. THIRIA et F. BADRAN : Application of multilayered neural networks to ocean acoustic tomography inversions. *Inverse Problems in Engineering*, 3(4):281–304, 1996.

[17] A. TURGUT : Validation of high-resolution inversion techniques for measuring seabed geoacoustic properties during the onr-sw06 experiment. Rapport technique, Naval Research Lab Washington DC acoustic div., 2007.

[18] D. F. VAN KOMEN, Tracianne B. NEILSEN, K. HOWARTH, D. P. KNOBLES et P. H. DAHL : A cnn for range and seabed estimation on normalized and extracted time-series impulses. *IEEE Journal of Oceanic Engineering*, 47(3):833–846, 2022.

[19] E. K. WESTWOOD, C. T. TINDLE et N. R. CHAPMAN : A normal mode model for acousto-elastic ocean environments. *The Journal of the Acoustical Society of America*, 100(6):3631–3645, 1996.