

Utilisation de réseaux de neurones pour la prédiction de la propagation modale en acoustique sous-marine

Arthur VARON^{1,2} Remi EMMETIERE¹ Julien BONNEL³ Jerome MARS²

¹ ROBOTIQUE & ACOUSTIQUE, ALSEAMAR, 13790, Rousset, France

² Univ. Grenoble Alpes, CNRS, Grenoble INP, GIPSA-lab, 38000, Grenoble France

³ Applied Ocean Physics & Engineering, Woods Hole Oceanographic Institution, Woods Hole, MA 02540, USA

Résumé – Les méthodes traditionnelles de simulation acoustique sous-marine sont coûteuses en temps de calcul. Le machine learning, notamment les réseaux de neurones, offre une alternative pour réduire ces coûts. Cependant, prédire le champ acoustique dans divers environnements est difficile en raison des échelles physiques variables et des phénomènes multiphysiques complexes. Les approches actuelles nécessitent souvent un ré-entraînement pour de nouveaux environnements. Notre méthode, basée sur la propagation modale utilise des réseaux de neurones pour prédire les paramètres modaux, tels que les nombres d’onde k_r et les fonctions modales Ψ , décrivant la physique du guide d’ondes. Ces paramètres sont plus faciles à prédire, permettant l’entraînement pour plusieurs environnements. De plus, notre modèle est entraîné sur des fréquences et un nombre de modes variables, ce qui permet d’effectuer des prédictions pour une grande diversité d’environnements.

Abstract – Traditional underwater acoustic simulation methods are computationally expensive. Machine learning, particularly neural networks, offers an alternative to reduce these costs. However, predicting the acoustic field in various environments is challenging due to varying physical scales and complex multiphysics phenomena. Current approaches often require retraining for new environments. Our method, based on modal propagation, uses neural networks to predict modal parameters, such as wavenumbers k_r and modal functions Ψ , describing the waveguide physics. These parameters are easier to predict, allowing training for multiple environments. Moreover, our model supports variable frequencies and a number of modes, enabling to predict for a wide range of environments.

1 Introduction

L’acoustique sous-marine s’est traditionnellement appuyée sur des théories physiques telles que les équations paraboliques, le tracé de rayons ou les modes normaux [6]. Bien que ces méthodes soient efficaces, elles peuvent rapidement devenir coûteuses en temps de calcul. En effet, en raison de la nature variable et du manque de mesures précises [5] des environnements, il est souvent nécessaire de répéter les simulations acoustiques. Cela s’applique notamment aux applications de type inversion pour la localisation de sources ou la connaissance des paramètres géoacoustiques. Ce problème est encore plus difficile lors de simulations de propagation de signaux large bande, où il est nécessaire de les effectuer pour chaque fréquence. C’est pourquoi les avancées récentes en machine learning, en particulier les réseaux de neurones, offrent une voie prometteuse pour améliorer le coût calculatoire de la simulation acoustique. Aussi, leur potentiel à simuler divers phénomènes physiques tout en réduisant substantiellement les coûts calculatoires est maintenant bien établi [2, 1].

Cependant, l’entraînement d’un réseau de neurones pour prédire les champs acoustiques dans différents environnements est difficile en raison des échelles physiques variables et des phénomènes multiphysiques complexes se produisant dans l’environnement sous-marin, notamment en environnement peu profond [9]. Ainsi, les approches proposées entraînent souvent un modèle pour approximer le champ acoustique dans un environnement donné, avec différentes positions de source ou pour différentes fréquences [4]. Cela limite les applications possibles, car le réseau de neurones proposé devrait alors être ré-entraîné à chaque fois que le milieu change.

Plusieurs travaux explorant cette direction ont été récemment proposés. Pour prédire le champ acoustique, la

théorie des modes normaux a été intégrée dans un modèle d’apprentissage automatique pour étendre la propagation à partir de points de mesure du champ acoustique [8]. Une méthode similaire a été proposée en se basant sur la théorie des rayons [7]. Divers modèles d’apprentissage ont aussi été entraînés pour discriminer rapidement des seuils de perte de transmission dans un environnement [10]. Cependant, l’ensemble ces approches se concentrent sur des environnements bien définis. L’extrapolation à des environnements non vus lors de l’entraînement reste toujours une question ouverte et non résolue.

L’approche que nous proposons repose sur la prédiction des paramètres modaux (nombre d’onde horizontal k_{rm} et fonctions modales Ψ_m en large bande). Ces derniers étant plus simple à prédire, un modèle peut être entraîné à prédire et extrapoler pour des environnements non vus. Ces travaux sont une itération de travaux précédents présentés au GRETSI 2023 [11], où, nous avons proposé une preuve de concept sur trois modes en fréquence fixe, et en utilisant des environnements ou seuls les propriétés du fond marin pouvait varier. La méthode générale proposée reste proche, mais nous avons étendu l’étude au cas de plus de modes, en multi-fréquence, et sur diverses environnements de Pekeris (2 couches homogènes). Les fréquences et le nombre de modes considérés peuvent désormais être choisie au moment de l’inférence. Le modèle est également capable de rejeter les nombres d’onde évanescents (voir section 3.3). Les variabilités des environnements considérés a maintenant un effet nettement plus important sur les paramètres modaux.

2 Théorie des modes

L’environnement marin considéré dans notre étude (profondeur $D < 500$ m, $f < 500$ Hz : environnement peu profond), peut

être considéré comme un guide d’ondes où la propagation est décrite comme un filtre de l’environnement sur le signal propagé. Ce filtre est décrit par une somme de modes utilisant la théorie des modes normaux.

Dans le domaine fréquentiel, le signal reçu $Y(f)$ à la profondeur z_r et à la distance r est donné par :

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

où $S(f)$ est le signal source émis à la profondeur z_s , et où chaque mode m est caractérisé uniquement par son nombre d’onde k_r et sa fonction modale associée Ψ_m .

Le nombre d’onde k_r est une fonction de la fréquence f , ce qui signifie que l’environnement agit comme un guide d’ondes dispersif. Dans ce cas, à la fois le mode m et la fréquence f peuvent être utilisés pour l’inversion géoacoustique d’un signal large bande[3]. L’inconvénient majeur est que la simulation du signal large bande nécessite d’appeler de nombreuses fois et pour chaque fréquence, les codes traditionnels de propagation modale, ce qui est très coûteux en termes de temps de calcul.

3 Méthode proposée

Comme indiqué, l’objectif est de rendre plus rapide la simulation du champ acoustique sous-marin en remplaçant un modèle numérique traditionnel de propagation modale par un réseau de neurones. Pour accomplir cette tâche, le réseau de neurones doit être entraîné à prédire les paramètres modaux pour un environnement sous-marin spécifié. Les environnements utilisés ici sont des guides d’onde de Pekeris caractérisé par les paramètres géoacoustique suivant (profondeur d , célérité c_{water} et densité ρ_{wat} de la colonne d’eau, célérité c_{bas} et densité ρ_{bas} du sous-sol (substrat)). Introduisant donc une variation de célérité dans le guide d’onde par rapport au travaux précédent.

3.1 Architecture du réseau de neurones

Pour prédire les fonctions modales Ψ_m et les nombres d’onde k_r , deux réseaux de neurones séparés (NN_{Ψ} , NN_{k_r}) sont utilisés. Chacun de ces réseaux est composé de deux sous-réseaux. La première partie de ces réseaux, notée avec l’exposant “env”, prend en entrée les paramètres décrivant l’environnement sous-marin. La seconde partie de chacun des réseaux, notée avec l’exposant “out”, prend en entrée des valeurs telles que la fréquence f et le mode m , nécessaires pour calculer le paramètre modal approprié. Chaque sous-réseau est un réseau de neurones densément relié avec des fonctions d’activation tanh. Le nombre de couches et d’unités par couche sont présentés sous la forme d’une liste avec le nom du modèle associé, voir figure 1.

Nous avons prouvé que diviser le modèle en deux parties distinctes permet de prédire les paramètres modaux pour différents modes et fréquences sans avoir à réévaluer l’ensemble du modèle.

Pendant l’entraînement, l’optimiseur Adam a été utilisé avec un taux d’apprentissage de 4×10^{-3} , un taux d’apprentissage $\alpha = 1 \times 10^{-2}$, et des moments d’ordre un et deux valeurs par défaut, β_1 et β_2 , fixés respectivement à 0,9 et 0,999. Durant l’entraînement, si un modèle ne montrait aucun progrès sur l’ensemble de validation pendant 5 époques consécutives, alors le taux d’apprentissage du modèle effectif est divisé par deux.

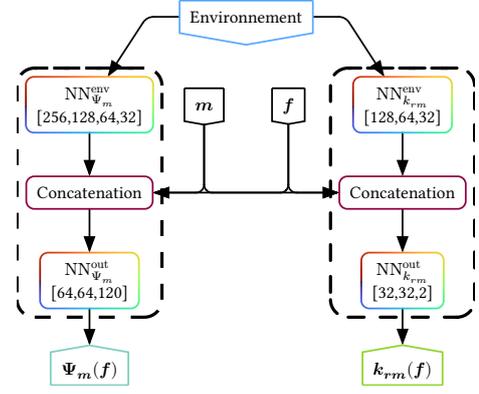


FIGURE 1 : Architecture du modèle. La taille des sous-réseaux est précisée par une liste ou chaque valeur correspond au nombre d’unités présentes dans la couche correspondante, la dernière couche étant la couche de sortie.

3.2 Génération de données

Les deux modèles sont entraînés sur un ensemble d’environnements générés aléatoirement en utilisant des valeurs aléatoires densément échantillonnées dans les limites définies par le tableau 1.

	Limites	Unité
Profondeur de la colonne d’eau : d	[80,100]	m
Célérité de la colonne d’eau : c_{wat}	[1475,1525]	m/s
Célérité du substrat : c_{bas}	[1525,2200]	m/s
Densité du substrat : ρ_{bas}	[1,2,2.5]	kg/m ³
Fréquence : f	[50,300]	Hz
Mode : m	[1,7]	

TABLE 1 : Paramètres utilisés pour générer les environnements et les paramètres modaux.

Pour chacun de ces environnements, à une fréquence donnée et un mode donné, le nombre d’onde ainsi que la fonction modale associée sont calculés. Chaque valeur d’entrée ainsi échantillonnée est ensuite normalisée dans le segment $[-1, 1]$.

3.3 Prétraitement du nombre d’onde

Nous savons que sa valeur réelle d’un nombre d’onde est définie entre $k_{\text{max}} = \omega/c_{\text{min}}$ et $k_{\text{min}} = \omega/c_{\text{max}}$. En tenant compte de ces limites et en connaissant la méthode basée sur l’interpolation HPIM [4] qui découle de la linéarisation de la relation de dispersion, nous redéfinissons l’espace des nombres d’ondes de sorte qu’il soit défini dans le segment $[0, 1]$.

La méthode proposée ainsi projette le nombre d’ondes $k_r(f)$ dans l’espace $k_{r_{\text{wat}}}(f)$, $k_{r_{\text{bas}}}(f)$:

$$\begin{pmatrix} k_{r_{\text{wat}}}(f) \\ k_{r_{\text{bas}}}(f) \end{pmatrix} = \begin{pmatrix} \sqrt{k_{\text{max}}^2 - k_{r_{\text{bas}}}(f)^2} \\ \frac{\Delta k(f)}{\sqrt{k_{r_{\text{bas}}}(f)^2 - k_{\text{min}}^2}} \\ \Delta k(f) \end{pmatrix} \quad (2)$$

où $\Delta k(f) = \sqrt{k_{\text{max}}^2(f) - k_{\text{min}}^2(f)}$.

Le modèle est ensuite entraîné à prédire $k_{r_{\text{wat}}}$ et $k_{r_{\text{bas}}}$, à partir desquels nous pouvons récupérer le nombre d’onde original $k_{r_{\text{m}}}$.

Nous savons également que si le $k_{r_{\text{m}}}$ prédit est inférieur à k_{max} , cela signifie que le mode peut être considéré évanescent dans la colonne d’eau à cette fréquence. Nous proposons une procédure pour écarter les modes évanescents de la simulation

en champ lointain.

3.4 Évaluation

Les deux modèles NN_{ψ} et NN_{k_r} sont évalués sur un jeu de données généré de 10 000 environnements créés en échantillonnant linéairement 10 fois les valeurs environnementales (c_{wat} , c_{bas} , d , ρ_{basement}) (voir tableau 1). Une fois généré, nous évaluons les environnements sur 50 fréquences comprises entre 50 et 300 Hz et pour 7 modes entraînés.

Les valeurs prédites par les réseaux de neurone sont notées \hat{X} . Les prédictions des modèles sont principalement évaluées sur 3 métriques adimensionnelles que nous présentons.

- La métrique différence relative du nombre d'onde est définie comme suit :

$$k_r \text{ différence relative} = \frac{k_{rm}(f) - \hat{k}_{rm}(f)}{k_{rm}(f)} \quad (3)$$

- Pour la fonction modale une différence relative n'aurait pas de sens, car les fonctions modales sont par définition orthonormales et leur valeur peut-être 0. Ainsi, la métrique proposée est la différence entre la valeur calculée et la prédiction. Elle peut être interprétée de manière similaire à une différence relative. Elle est définie :

$$\Psi_{\text{différence}} = \Psi_m(f) - \hat{\Psi}_m(f) \quad (4)$$

- La troisième métrique proposée est la différence inter-mode, qui sera la différence entre le nombre d'onde d'un mode et le nombre d'onde correspondant au mode suivant, à une fréquence donnée. Cette métrique est définie comme :

$$\delta k_r \text{ différence relative} = \frac{\delta k_{rm,m+1} - \hat{\delta k}_{rm,m+1}}{\delta k_{rm,m+1}} \quad (5)$$

avec $\delta k_{rm,m+1} = k_{rm} - k_{rm+1}$.

Les deux premières métriques servent principalement à vérifier si le modèle a correctement appris à prédire les paramètres modaux. La troisième métrique permet de voir si le NN est capable de modéliser avec précision la phase du signal une fois le signal propagé. Par exemple, une prédiction à une fréquence donnée pourrait avoir une grande erreur sur le nombre d'ondes, mais si l'erreur inter-mode est faible, cela signifierait que la phase du signal est correctement reconstruite à longue distance. Le signal reçu simulé serait alors simplement légèrement décalé en temps par rapport au signal réel reçu.

4 Résultats

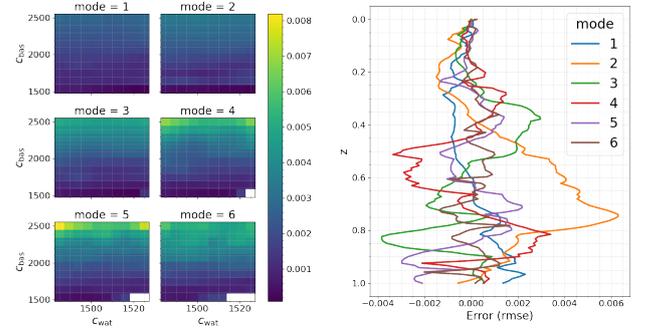
Pour chacune de ces métriques, nous calculons ensuite l'erreur en utilisant la racine de l'erreur quadratique moyenne (RMSE) selon différents paramètres, en fonction de l'observable souhaitée.

Par exemple, calculer la RMSE sur différents paramètres environnementaux permet de déterminer si le modèle rencontre des difficultés sur certains types d'environnements. Cela est illustré dans la figure 2 où deux erreurs sont proposées, l'erreur sur la fonction modale 2b, l'erreur sur le nombre d'onde 2a. Sur la figure 2a, la RMSE est calculée pour tous les points du jeu de données de test ayant la même vitesse du son dans la colonne d'eau et dans le substrat, et ce, pour chaque mode. On peut remarquer dans cette figure que l'erreur augmente lorsque la célérité est plus élevée dans le substrat. Cela peut être expliqué par le fait que la dispersion est plus importante

(moins linéaire), ce qui rend la prédiction plus difficile pour le modèle.

On observe également sur cette figure, au niveau des modes élevés, des erreurs très légèrement plus importantes lorsque la vitesse du son dans le substrat et dans la colonne d'eau sont proches. Pour ces environnements spécifiques, la fréquence de coupure de chaque mode est plus élevée que dans les environnements où le sous-sol a une célérité plus rapide. Ainsi, dans le jeu de données d'entraînement, moins de données ont été générées, principalement pour les modes plus élevés, ce qui a probablement conduit à une performance moindre pour ces environnements. Cependant, l'erreur reste raisonnable, montrant que le réseau a effectivement appris à prédire correctement le nombre d'ondes quel que soit l'environnement donné.

Nous avons également montré, dans la figure 2b, que l'erreur de la fonction modale augmente avec la profondeur. Les données sont des guides d'onde de Pekeris avec une condition fixe à l'interface entre eau et air ($z = 0$), alors que la condition entre l'eau et le substrat ($z = 1$) est variable dans notre cas. Cela explique les erreurs croissantes sur la fonction modale en fonction de la profondeur.



(a) Erreur sur les nombres d'ondes (b) Erreur sur les fonctions modales en fonction de la célérité dans la colonne d'eau et du substrat

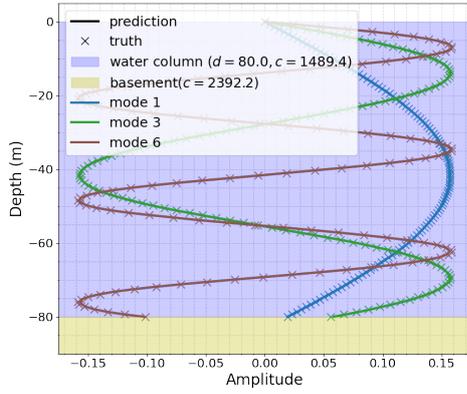
FIGURE 2 : Résultats sur le jeu de données de test

Pour illustrer les résultats obtenus, nous avons sélectionné un environnement représentatif du 9e décile des résultats après les avoir ordonnées à l'aide de la RMSE sur le nombre d'onde par environnement. Comme le montre la figure 3, les deux réseaux de neurones produisent toujours de bons résultats. Cela démontre que les réseaux ont effectivement appris à prédire avec précision les deux paramètres modaux pour lesquels ils ont été entraînés. Sur la figure 3a, on voit que le modèle NN_{ψ} est effectivement capable de prédire la fonction modale pour différents modes. Pour la figure 3b, même proche de la fréquence de coupure du mode, les nombres d'ondes sont non seulement correctement prédits, mais rejeté automatiquement grâce au traitement proposé en section 3.3 (rejet des ondes évanescentes).

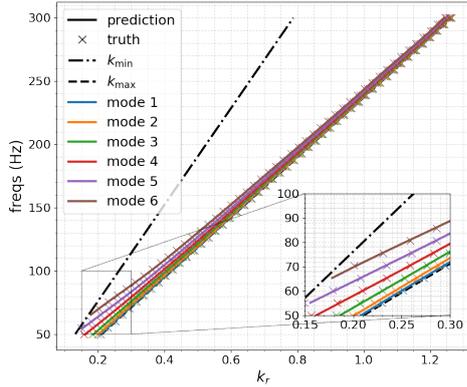
Toujours pour cet environnement, on calcule le champ de pression pour une source impulsionnelle située à une profondeur de 20 m, avec des positions de récepteur allant de 0 à 5 km. L'enveloppe du champ de pression $\Phi(r, z)$ est présentée en figure 4. L'enveloppe du champ de pression est défini comme :

$$\Phi(r, z) = p(r, z) / H_0^{(2)}(k_0 r) \quad (6)$$

avec $H_0^{(2)}$ la fonction de Hankel du deuxième type, d'ordre 0



(a) Comparaison des fonctions modales prédites et calculées



(b) Comparaison des nombres d'onde prédits et calculés

FIGURE 3 : Comparaison entre la simulation et la prédiction des NNs pour un environnement dans le 9ème décile des résultats par environnement

et $p(r, z)$ la pression à la distance r et la profondeur z .

On remarque figure 4 que le pattern d'interférence reste identique entre les valeurs calculées (label) et les prédictions de l'enveloppe du champ acoustique. On remarque également que malgré les résultats acceptables de la prédiction (figure 4), les petites erreurs sur le nombre d'onde s'accumulent rapidement sur la phase, notamment avec la distance.

Conclusion

Dans cet article, nous avons exploré les possibilités de remplacer un modèle numérique pour la propagation modale par un réseau de neurones. En comparaison avec la prédiction du champ acoustique, notre prédiction des seuls paramètres modaux est plus facile à prédire pour un réseau de neurones. Cette méthode permet à un modèle d'être entraîné sur plusieurs environnements différents, ce qui en fait une approche efficace, notamment en réduisant le temps de calcul d'un facteur 20 une fois le modèle entraîné, car évitant les recherches de racines coûteuses des modèles numériques. De plus, notre approche est plus générique, car elle prend en compte le caractère multi-fréquentiel du signal large bande et qu'elle fonctionne sur l'ensemble des modes. La prochaine étape sera d'incorporer les pertes en transmission du modèle et de le tester dans un cas réel de propagation acoustique dans un contexte de robotique sous-marine embarqué.

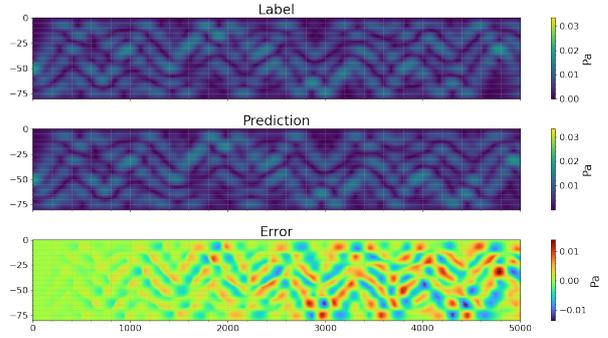


FIGURE 4 : Comparaison entre l'enveloppe du champ de pression obtenue avec la simulation et avec les NNs pour une source à 20m and et à 250 Hz

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". In : *Neural Computing and Applications* 29.12 (2018), p. 1583-1591.
- [2] Amir ADLER, Mauricio ARAYA-POLO et Tomaso POGGIO. "Deep Learning for Seismic Inverse Problems : Toward the Acceleration of Geophysical Analysis Workflows". In : *IEEE Signal Processing Magazine* 38.2 (2021), p. 89-119.
- [3] N. Ross CHAPMAN et Er Chang SHANG. "Review of Geoacoustic Inversion in Underwater Acoustics". In : *Journal of Theoretical and Computational Acoustics* 29.03 (2021).
- [4] Ziwei HUANG et al. "A Broadband Modeling Method for Range-Independent Underwater Acoustic Channels Using Physics-Informed Neural Networks". In : *The Journal of the Acoustical Society of America* 156.5 (21 nov. 2024), p. 3523-3533. ISSN : 0001-4966.
- [5] Kevin R. JAMES et David R. DOWLING. "Pekeris Waveguide Comparisons of Methods for Predicting Acoustic Field Amplitude Uncertainty Caused by a Spatially Uniform Environmental Uncertainty (L)a)". In : *The Journal of the Acoustical Society of America* 129.2 (11 fév. 2011), p. 589-592. ISSN : 0001-4966.
- [6] Finn B. JENSEN et al. *Computational Ocean Acoustics*. Springer New York, 2011.
- [7] Kexin LI et Mandar CHITRE. "Data-Aided Underwater Acoustic Ray Propagation Modeling". In : *IEEE Journal of Oceanic Engineering* 48.4 (oct. 2023), p. 1127-1148. arXiv : 2205.06066 [cs].
- [8] Kexin LI et Mandar CHITRE. "Physics-Aided Data-Driven Modal Ocean Acoustic Propagation Modeling". In : *The 24th International Congress on Acoustics (ICA 2022)* (2022).
- [9] Wrik MALLIK, Rajeev K. JAIMAN et Jasmin JELOVICA. "Predicting Transmission Loss in Underwater Acoustics Using Convolutional Recurrent Autoencoder Network". In : *The Journal of the Acoustical Society of America* 152.3 (2022), p. 1627-1638.
- [10] Ryan A. MCCARTHY et al. "Reduced-Order Machine-Learning Model for Transmission Loss Prediction in Underwater Acoustics". In : *IEEE Journal of Oceanic Engineering* (2023), p. 1-25.
- [11] A. VARON, J. BONNEL et J. MARS. "Approximation de Modèle de Propagation Modale En Acoustique Sous-Marine à l'aide de Réseaux de Neurones". In : GRETSI. Grenoble, France, sept. 2023.