



HAL
open science

Apprentissage machine pour la propagation troposphérique

Thomas Bonnafont, Benjamin Chauvel, Abdelmalek Toumi

► **To cite this version:**

Thomas Bonnafont, Benjamin Chauvel, Abdelmalek Toumi. Apprentissage machine pour la propagation troposphérique. Journées d'études Propagation Radioélectrique 2023, Nov 2023, Rennes, France. hal-04291080

HAL Id: hal-04291080

<https://ensta-bretagne.hal.science/hal-04291080v1>

Submitted on 17 Nov 2023

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.

Apprentissage machine pour la propagation troposphérique

Thomas Bonnafont

Lab-STICC, UMR CNRS 6285

ENSTA Bretagne

Brest, France

thomas.bonnafont@ensta-bretagne.fr

Benjamin Chauvel

ENSTA Bretagne

Brest, France

benjamin.chauvel@ensta-bretagne.org

Abdelmalek Toumi

Lab-STICC, UMR CNRS 6285

ENSTA Bretagne

Brest, France

abdelmalek.toumi@ensta-bretagne.fr

Résumé—Dans ce résumé, nous proposons une méthode pour simuler la propagation longue distance basée sur un réseau U-Net. Nous nous focalisons ici sur la prise en compte du relief, et l’obtention du champ sur une verticale à la hauteur de l’émetteur, mais le cadre se veut général. Le réseau est entraîné sur des données artificielles, construite par la méthode split-step wavelet. Les reliefs synthétiques associés sont générés de façon aléatoire à l’aide d’un hypercube latin. Pour l’entraînement, une fonction perte basée sur une combinaison linéaire de la norme L2 et L1 est utilisée de façon à obtenir un estimateur robuste. Enfin des tests sont effectués sur des données IGN pour montrer la précision de la méthode. De plus, une stratégie de réglage fin sur les derniers blocs du réseau permet de l’adapter à d’autres types de reliefs.

Mots clés—propagation, apprentissage machine, U-Net, réglage fin, échantillonnage par hypercube latin

La modélisation précise et rapide de la propagation troposphérique sur de longues distances est importante pour de nombreuses applications, comme la prédiction de couverture de nouveaux systèmes (p.e. impact des structures humaines sur la propagation), ou pour l’optimisation du placement d’antennes (réseau 5G). Dans ce contexte il est important de prendre en compte différents effets comme le relief, de la composition du sol et de la réfraction.

Dans ce cadre, le modèle de l’équation d’onde parabolique (EOP) [1] est couramment utilisée. En effet, ce dernier tient compte uniquement de la propagation vers l’avant dans un cône paraxial, permettant de grands pas dans la direction de propagation. De plus l’EOP peut être résolu de manière efficace par la méthode split-step Fourier (SSF) [1], [2], ou par la méthode split-step wavelet (SSW) [3], [4]. La seconde permet un gain en taille mémoire et complexité en utilisant la transformée en ondelettes en lieu et place de la transformée de Fourier.

Depuis quelques années, les méthodes d’apprentissage machine se sont fortement développées dans le domaine de la modélisation de la propagation [5], [6]. En effet, elles permettent, une fois le réseau entraîné, d’inférer la propagation en ”temps réel”. Dans ce cadre, les réseaux ont été entraînés sur des données reflétant la situation à modéliser (p.e. des terrains urbains ou intérieurs), permettant une modélisation précise lorsque les nouvelles données sont proches des données d’apprentissage.

Ici nous proposons une méthode d’apprentissage machine

pour estimer la propagation longue distance à la hauteur de l’émetteur en tenant compte de reliefs ”ruraux”. Le cadre de la méthode se veut global, de façon à être facilement généralisable. Pour cela, un réseau de type U-Net est utilisée. Il est constitué de plusieurs blocs de convolutions et déconvolutions et a donné de bon résultats pour des applications connexes [5], [6].

L’objectif de la méthode d’apprentissage machine est d’approcher, par \hat{f}_θ , la fonction f (donnée par SSW ici) qui relie les paramètres physiques d’entrée ϕ (ici le terrain) au champ y . Dans cette définition θ représente les poids du réseau à optimiser pour obtenir une approximation la plus fidèle possible de f .

L’entraînement est fait sur des données artificielles de terrains dont le champ réel a été calculé par la méthode SSW. A la différence d’autres travaux [6], les données de terrains sont composées uniquement de terrain triangulaires et rectangulaires de façon à représenter la variété associée à l’opérateur de relief. Pour échantillonner de manière précise et uniforme cette dernière, une stratégie de l’hypercube latin est utilisée. Ainsi 4000 échantillons de terrain contenant entre 2 et 5 reliefs sont générés (réparti de façon équitable). Cette base de données est divisée en deux : 80% pour l’entraînement et 20% pour la base de test.

Pour l’apprentissage, nous proposons une combinaison de la norme L1 et L2 comme fonction perte¹. En effet, la norme L1 permet d’obtenir un estimateur lisse, quand la norme L2 privilégie une bonne précision point à point, mais est très sensible aux valeurs aberrantes. Ainsi, le risque empirique à minimiser s’écrit comme

$$\inf_{\theta \in \mathbb{R}^{|\Theta|}} \mathbb{E}_{\phi \in \mathcal{L}_\phi} \left(\alpha \|f(\phi) - \hat{f}_\theta(\phi)\|_1 + \beta \|f(\phi) - \hat{f}_\theta(\phi)\|_2^2 \right),$$

où \mathcal{L}_ϕ représente la stratégie d’échantillonnage sur ϕ (ici l’hypercube latin), et $\alpha \in [0, 1]$ et $\beta \in [0, 1]$ sont deux constantes permettant d’obtenir au maximum l’avantage des deux normes. Pour trouver la bonne combinaison de α, β , nous avons entraîné différents modèles avec différents couples et les avons testés sur des données à 6 reliefs ou IGN [7],

1. Il est à noter que la norme L1 agit comme une pénalisation de sur-apprentissage pour la norme L2.

en comparant l'erreur de chacun en norme L_2^2 . Dans le premier cas les valeurs sont proches pour tous les couples autour de 0.2 (sauf pour la norme L1 seule où l'erreur est de l'ordre de 0.35). Dans le second, nous donnons en Figure 1, les différents résultats obtenus. Nous pouvons voir que pour $\alpha = 0.4$ et $\beta = 0.8$, un optimum est obtenu dans ce cas.




FIGURE 1. Évolution de l'erreur en norme L2 pour différents couples α, β .

En utilisant ce modèle, nous avons simulé la propagation entre Paris et Chartres, $\simeq 80$ km. Les données IGN [7], normalisées, ont été utilisées pour générer le relief entre les deux villes. Le résultat est donné en Figure 2.

Nous pouvons voir que l'erreur en norme L2 est faible, et que les variations globales du champ sont bien représentées par la méthode basée sur l'apprentissage machine. Seules les

2. Cette dernière étant couramment utilisée dans la communauté.

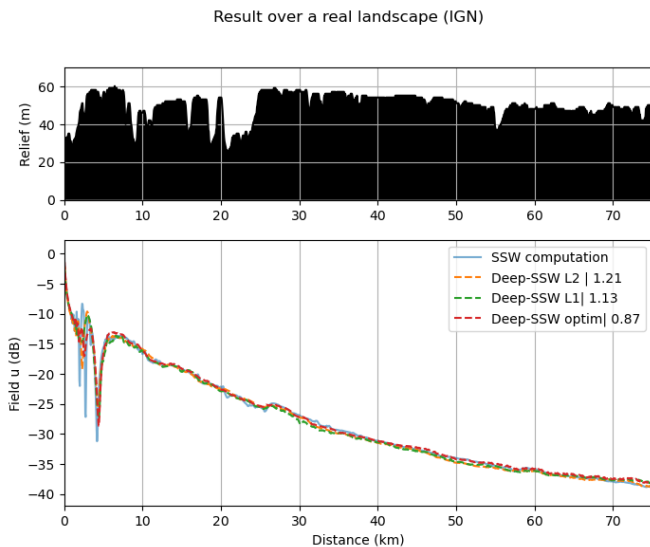


FIGURE 2. Propagation de Paris à Chartres modélisée par SSW et sa version apprentissage machine.

oscillations rapides sont moins bien prises en compte. Il est cependant à noter que ce résultat est obtenu en 1 ms, et que le terrain fourni en entrée est très différent de ceux présents dans la base d'apprentissage. Ainsi, la méthode permet d'obtenir une première approximation du champ et de la portée d'un équipement en temps réels.

Pour finir, nous proposons une stratégie de réglage fin pour réutiliser le réseau pré-entraîné lorsque les reliefs considérés en entrée sont très différents. Pour cela, seuls les poids des dernières couches du réseau sont modifiés sur une faible quantité de donnée (1500 échantillons gaussiens ici). Nous donnons en Figure 3 un exemple pour un terrain plus complexe (gaussien).




FIGURE 3. Propagation au dessus d'un relief Gaussien (aléatoire), SSW (bleu), Deep-SSW (vert), et la version réglée finement (orange).

Nous pouvons voir que la méthode entraînée par réglage fin du réseau général donne des résultats convenables même si l'ensemble d'apprentissage est petit. Ceci permet d'adapter le réseau à d'autres types de reliefs, et de le spécialiser pour les cas à traiter.

RÉFÉRENCES

- [1] M. Levy, Parabolic equation methods for electromagnetic wave propagation, IET, 2000.
- [2] D. Dockery, and J.R. Kuttler, "An improved impedance-boundary algorithm for Fourier split-step solutions of the parabolic wave equation", IEEE Transactions on Antennas and Propagation, 44(12), 1592-1599, 1996.
- [3] T. Bonnafont, R. Douvenot, and A. Chabory, "A local split-step wavelet method for the long range propagation simulation in 2D", Radio Science, vol. 56(2), pp 1-11, 2021.
- [4] H. Zhou, R. Douvenot, and A. Chabory, "Modeling the long-range wave propagation by a split-step wavelet method", Journal of Computational Physics, 402, 109042, 2020.
- [5] S. Bakirtzis, K. Qiu, J. Zhang, and I. Wassell, "DeepRay : Deep learning meets ray-tracing," in 2022 16th European Conference on Antennas and Propagation (EuCAP), pp. 1-5, IEEE, 2022.
- [6] C. Brennan and K. McGuinness, "Site-specific deep learning path loss models based on the method of moments," arXiv preprint arXiv :2302.01052, 2023.
- [7] "Elevation lines data of the "Institut nationale de l'informations Géographique et Forestière" (IGN)." <https://www.geoportail.gouv.fr/>. Accessed : 04-07-2023.