

# PROPAGATION NON LINEAIRE DANS DES FIBRES OPTIQUES PAR RESEAUX DE NEURONES ARTIFICIELS

Sonia Boscolo <sup>1</sup> et Christophe Finot <sup>2</sup>

<sup>1</sup> *Aston Institute of Photonic Technologies, School of Engineering and Applied Science, Aston University, Birmingham B4 7ET, United Kingdom*

<sup>2</sup> *Laboratoire Interdisciplinaire Carnot de Bourgogne, UMR 6303 CNRS-UBFC - Dijon, France*

[christophe.finot@u-bourgogne.fr](mailto:christophe.finot@u-bourgogne.fr)

## RÉSUMÉ

Nous mettons en œuvre différents réseaux de neurones artificiels pour prédire l'évolution des profils temporels et spectraux d'intensité après propagation dans une fibre optique en présence de non-linéarité forte. Le problème inverse est également considéré.

**MOTS-CLEFS :** *apprentissage machine, fibre optique, optique non-linéaire.*

## 1. INTRODUCTION

Les techniques d'apprentissage machine transforment le paysage de la recherche traditionnelle avec l'utilisation d'outils algorithmiques avancés pour l'analyse de données massives offrant de nouveaux angles de vue. Les domaines de la photonique et de l'optique ultra-rapide n'échappent pas à cette révolution [1]. Nous nous intéressons dans cette contribution à la mise en œuvre de telles techniques appliquées à la mise en forme non-linéaire d'impulsions se propageant dans une fibre optique en présence de non-linéarités optiques. En effet, la combinaison de la dispersion et de la non-linéarité au cours de la propagation modifie profondément les profils temporels et spectraux de toute impulsion se propageant dans une fibre optique [2]. Le résultat dépend tout autant des propriétés de la fibre utilisée que des propriétés de l'impulsion initiale et des impulsions ultra-brèves, triangulaires, paraboliques, super-gaussiennes peuvent être générées, tout comme des spectres significativement élargis ou, au contraire, comprimés.

Dans tous ces processus, l'évolution du champ complexe lumineux dans une fibre monomode est prédite grâce à l'intégration numérique de l'équation de Schrödinger non-linéaire (ESNL). Nous montrons dans cette contribution qu'un réseau neuronal peut se substituer à cette approche et fournir fidèlement les profils temporels et spectraux d'intensité. Un réseau neuronal est également en mesure de résoudre le problème inverse, i.e. reconnaître à partir des profils d'intensité de l'impulsion, les conditions de la propagation.

## 2. PROPAGATION SANS-MODELE ET PROBLEME INVERSE

Notre approche repose sur l'utilisation d'un grand nombre de données initiales simulées par l'algorithme de la transformée de Fourier à pas divisés pour entraîner un réseau neuronal feed-forward à partir d'un algorithme de propagation inverse avec régularisation bayésienne. Les réseaux impliqués comprennent typiquement trois couches de 14 neurones. La bibliothèque d'apprentissage est formée de plusieurs milliers de résultats obtenus pour des combinaisons aléatoires de paramètres dispersifs et non-linéaires. Pour permettre à notre réseau de s'accommoder des différences possibles significatives au niveau des durées temporelles impliquées, nous avons appliqué un échantillonnage anamorphique du profil d'intensité. Après apprentissage, les réseaux neuronaux sont confrontés à d'autres ensembles de données générés par résolution numérique de l'ENSL.

Dans un premier temps, des impulsions initiales gaussiennes en limite de Fourier sont utilisées. Le nombre de paramètres physiques (durée initiale, puissance initiale, longueur de fibre,

dispersion et non-linéarité) peut se réduire à deux grâce à l'utilisation des lois d'échelle habituelles qui apparaissent dans le cadre de la normalisation de l'ESNL. Les deux paramètres pertinents sont alors la longueur de propagation normalisée  $\xi$  et le nombre soliton  $N$ . Un réseau neuronal convenablement entraîné permet de reproduire avec une très grande fidélité les détails des profils d'intensité temporels et spectraux obtenus en sortie de fibre, que ce soit en dispersion normale ou bien anormale. Le domaine de propagation anormal semble légèrement plus délicat à appréhender en raison des compressions rapides de type solitonique qui y existent.

Il s'avère également possible d'entraîner un réseau pour identifier, à partir de profils d'intensité temporels et spectraux (dont les puissances maximales ont été fixées à 1 pour donner puissance crête inconnue), les caractéristiques normalisées  $\xi$  et  $N$ . Notons que ce type de problème n'est pas accessible à partir de l'ESNL qui nécessite la connaissance complète du champ complexe de sortie pour envisager une propagation inverse. Le réseau entraîné se montre particulièrement performant pour répondre à cette identification, avec des erreurs très limitées en régime normal. Nous avons de plus testé la capacité de reconnaître convenablement ces paramètres pour différentes formes d'impulsions initiales : gaussienne, sécante hyperbolique, parabole, supergaussienne. Là, encore les résultats sont convaincants, même si la forme sécante hyperbolique est plus délicate en régime de dispersion anormale en raison de ses propriétés solitoniques.




Fig. 1 : Reconstruction des propriétés temporelles et spectrales (respectivement sous-panneaux 1 et 2) pour une impulsion initialement chirpée.

(a) Résultats pour une impulsion gaussienne après propagation dans une fibre à dispersion normale :  $\xi = 2.5$ ,  $N = 2.8$ , et  $C = -2.42$ , (b) Résultats obtenus avec  $\xi = 2.2$ ,  $N = 2$  et  $C = 2.42$ . Les prédictions du réseau neuronal (cercles bleus) sont comparés avec les résultats donnés par l'ESNL (courbes noires) et avec les propriétés initiales de l'impulsion (ligne rouge pointillée).

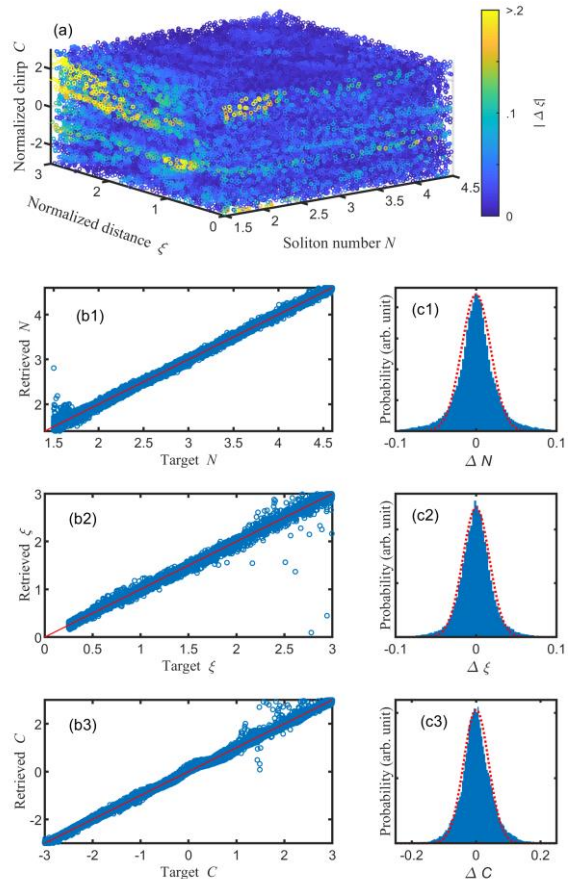


Fig. 2 : Problème inverse pour des impulsions initialement chirpées dans une fibre à dispersion normale. (a) Cartographie de l'erreur suivant  $N$ ,  $\xi$ ,  $C$ . (b) Comparaison des valeurs prédites par le réseau neuronal pour  $N$ ,  $\xi$  et  $C$  et des valeurs exactes. (c) Distributions statistique de l'erreur des erreurs sur  $N$ ,  $\xi$  et  $C$ . Les histogrammes sont comparés à une distribution normale (pointillés rouges).

Nous avons ensuite cherché à étendre les capacités de nos réseaux en considérant des impulsions initiales présentant une dérive de fréquence (chirp) linéaire et évoluant dans une fibre à dispersion normale. Ce nouveau paramètre augmente la dimension du problème à résoudre à 3, avec comme nouvelle dimension le paramètre de chirp normalisé  $C$ . La figure 1 montre deux exemples illustrant la diversité des dynamiques non-linéaires façonnant l'impulsion durant sa propagation. Suivant le chirp initial appliqué, il sera possible d'observer la formation d'impulsions paraboliques avec un spectre élargi ou aplati ou bien un processus de compression spectrale [3]. Dans les deux cas, le réseau neuronal entraîné est capable de prédire avec une grande fidélité les propriétés des impulsions de sortie. La précision est suffisante pour pouvoir estimer les propriétés telles que la largeur à mi-hauteur ou bien l'excès de kurtosis donnant une indication de la forme. Il est dès lors envisageable d'utiliser des représentations graphiques à trois dimensions pour explorer l'ensemble des configurations et trouver la combinaison optimale répondant simultanément à un ensemble de contraintes [4]. L'avantage fondamental du réseau neuronal est alors un gain très conséquent sur le temps de calcul nécessaire pour couvrir l'espace de recherche : une fois entraîné, le réseau neuronal est à même de générer les résultats pour plusieurs millions de combinaisons en quelques minutes seulement alors que la résolution traditionnelle de l'ESNL nécessitait plusieurs dizaines d'heures.

Concernant le problème inverse impliquant une impulsion initiale à dérive de fréquence linéaire, les résultats sont résumés sur la figure 2. Encore une fois, la capacité du réseau neuronal à trouver les paramètres normalisés associés à un spectre et un profil temporel donnés est validée. Comme la dérive de fréquence initiale conduit à une chute de la puissance initiale, des erreurs plus prononcées peuvent intervenir pour les valeurs faibles du paramètre soliton. Ainsi, nous restreignons l'analyse statistique des erreurs aux données de test obtenues pour  $N > 1.5$ . Nous constatons sur les panneaux (b) que les valeurs des paramètres  $N$ ,  $\xi$ ,  $C$  retrouvées par le réseau neuronal sont totalement cohérentes avec les résultats attendus, avec seulement quelques points s'écartant d'un accord parfait sur plusieurs dizaines de milliers de réalisations. L'analyse statistique de l'erreur mesurée (panneaux (c)) indique que la partie centrale de l'histogramme peut être ajustée convenablement par une distribution normale d'écart-types 0.017, 0.018 et 0.039 pour  $\xi$ ,  $N$  et  $C$ .

### 3. CONCLUSIONS

Nous avons mis en œuvre un apprentissage machine supervisé reposant sur des réseaux neuronaux pour résoudre aussi bien les problèmes directs qu'inverses associés à la remise en forme non-linéaire d'une impulsion lors de sa propagation dans une fibre optique. Les détails de ce travail sont fournis dans la référence [5]. Nous avons été également en mesure d'étendre notre approche pour inclure l'impact de pertes ou de gains distribués le long d'une fibre à dispersion normale. Les résultats nous ont confirmé la robustesse des réseaux neuronaux [6] qui permettent ainsi d'étendre la panel des outils numériques existant pour la conception de façonneurs non-linéaires.

### REFERENCES

- [1] G. Genty, L. Salmela, J. M. Dudley, D. Brunner, A. Kokhanovskiy, S. Kobtsev, and S. K. Turitsyn, "Machine learning and applications in ultrafast photonics," *Nat. Photon.* **15**, 91-101 (2021).
- [2] S. Boscolo and C. Finot, *Shaping Light in Nonlinear Optical Fibers* (2017).
- [3] C. Finot and S. Boscolo, "Design rules for nonlinear spectral compression in optical fibers," *J. Opt. Soc. Am. B* **33**, 760-767 (2016).
- [4] C. Finot, I. Gukov, K. Hammani, and S. Boscolo, "Nonlinear sculpturing of optical pulses with normally dispersive fiber-based devices," *Opt. Fiber Technol.* **45**, 306-312 (2018).
- [5] S. Boscolo and C. Finot, "Artificial neural networks for nonlinear pulse shaping in optical fibers," *Opt. Laser Technol.* **131**, 106439 (2020).
- [6] S. Boscolo, J. M. Dudley, and C. Finot, "Modelling self-similar parabolic pulses in optical fibres with a neural network," *Results in Optics*, 100066 (2021).