



HAL
open science

Un réseau neuronal pour explorer la diffraction par un bord d'écran

Christophe Finot

► **To cite this version:**

Christophe Finot. Un réseau neuronal pour explorer la diffraction par un bord d'écran. 2020. hal-02435880v1

HAL Id: hal-02435880

<https://hal.science/hal-02435880v1>

Preprint submitted on 11 Jan 2020 (v1), last revised 27 Feb 2021 (v2)

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.

Un réseau neuronal pour explorer la diffraction par un bord d'écran

Christophe Finot

christophe.finot@u-bourgogne.fr

Laboratoire Interdisciplinaire Carnot de Bourgogne, UMR CNRS – Bourgogne Franche-Comté
UFR Sciences et Techniques, Université de Bourgogne, 9 av. Alain Savary, 21800 Dijon

RESUME : Nous décrivons ici un projet visant à explorer avec un groupe d'étudiants en physique de niveau licence l'utilisation d'un réseau neuronal pour simuler un problème traditionnel de l'optique ondulatoire, i.e. la diffraction d'un bord d'écran dont la solution analytique est connue. Par cette première approche de l'intelligence artificielle, nous avons pu mettre l'accent sur les étapes essentielles nécessaires pour mettre en œuvre ces nouvelles technologies numériques.

Mots clés : diffraction de Fresnel ; apprentissage par réseau neuronal.

1 INTRODUCTION

L'optique ondulatoire et l'étude de la diffraction font partie des sujets les plus stimulants pour un étudiant de physique de niveau Licence 3. Mais il s'avère également exigeant, reposant sur des prérequis mathématique, d'électro-magnétisme et de physique ondulatoire. Des problèmes apparemment aussi basiques que l'image d'un bord d'écran éclairé par une lumière cohérente [1-4] n'ont ainsi rien d'intuitif à résoudre et la solution mathématique fait appel à des fonctions intégrales spécifiques connues sous le nom d'intégrales de Fresnel [5].

Dans ce contexte et profitant de la célébration du bicentenaire des travaux d'Augustin Fresnel [6, 7] consacrés en 1819 par le grand prix de l'Académie des Sciences, nous avons voulu tester avec un groupe de trois étudiants de physique, l'apport éventuel de l'utilisation de l'intelligence artificielle. Ce sujet est en effet actuellement particulièrement porté sur le devant de la scène médiatique [8] à travers ses utilisations dans les réseaux sociaux, dans les entreprises innovantes ou bien pour la reconnaissance et le traitement d'images.

Nous décrivons ainsi le problème physique que nous avons abordé dans le cadre d'un travail encadré de recherche de licence 3 et son traitement académique, avant de décrire la solution adoptée basée sur un réseau neuronal. Nous testerons ensuite la capacité du réseau neuronal à prédire efficacement la figure de diffraction, ainsi que la possibilité d'extraire d'une figure de diffraction inconnue la distance de l'objet diffractant.

2 LE PROBLEME ETUDIÉ : LA DIFFRACTION PAR UN BORD D'ECRAN

2.1 Situation analysée

La figure 1a représente le problème de diffraction très classique que nous avons étudié : la formation de l'image d'un bord d'écran opaque éclairé en incidence normale par une onde plane monochromatique de longueur d'onde λ . Nous observons la figure de diffrac-

tion à une distance z de l'écran. Les coordonnées transverses dans le plan de l'écran sont notées x et y alors que dans le plan d'observation, elles sont notées x' et y' . L'écran semi-infini correspond donc à une transmission optique nulle pour $x < 0$. Cette configuration était connue des étudiants qui ont eu l'occasion de la travailler à la fois en cours magistral et en travaux dirigés.

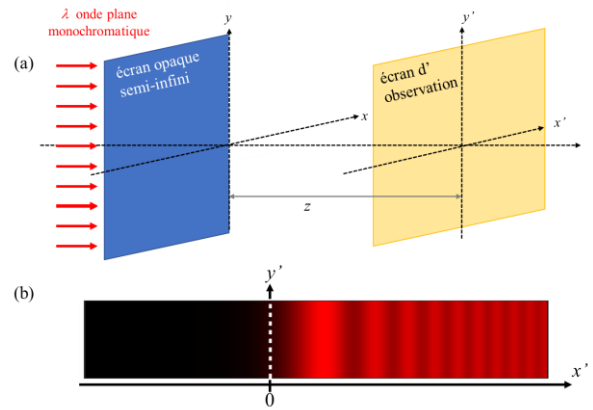


fig 1 : (a) Situation analysée lors de la diffraction par un bord d'écran. (b) Exemple de la figure de diffraction obtenue pour une illumination à 632.8 nm. La ligne pointillée blanche est l'image géométrique de l'arrêt de l'écran.

2.2 Solution analytique du problème

La situation étudiée correspond au cas d'école où les conditions simplificatrices habituellement utilisées en champ lointain (en diffraction de Fraunhofer) ne peuvent jamais être vérifiées. Il est dès lors impératif d'appliquer le formalisme de la diffraction de Fresnel. Compte tenu du bord d'écran suivant la direction x (la lumière n'étant pas limitée suivant la direction y), la diffraction opère suivant la direction x' et le champ optique alors obtenu dans le plan d'observation est donné par l'intégrale suivante [1-4] (pour simplifier, certains facteurs multiplicatifs n'influent pas sur la forme du profil d'intensité ont été ici omis) :

$$a(x', z) \propto \int_0^{\infty} e^{i \frac{\pi}{\lambda} \frac{(x'-x)^2}{z}} dx \quad (1)$$

Ce résultat se simplifie en introduisant la variable réduite u :

$$u = \sqrt{\frac{2}{\lambda z}} (x' - x) \quad (2)$$

conduisant à :

$$\begin{aligned} a(x', z) &\propto \int_{\sqrt{\frac{2}{\lambda z}} x'}^{-\infty} e^{i \frac{\pi}{2} u^2} du \\ &\propto C_f(-\infty) - C_f\left(\sqrt{\frac{2}{\lambda z}} x'\right) + i \left[S_f(-\infty) - S_f\left(\sqrt{\frac{2}{\lambda z}} x'\right) \right] \end{aligned} \quad (3)$$

avec $C_f(x)$ et $S_f(x)$ les intégrales de Fresnel définies par [5] :

$$\begin{aligned} C_f(x) &= \int_0^x \cos\left(\frac{\pi \omega^2}{2}\right) d\omega \\ S_f(x) &= \int_0^x \sin\left(\frac{\pi \omega^2}{2}\right) d\omega \end{aligned} \quad (4)$$

et dont les représentations graphiques sont données Fig. 2. Les intégrales de Fresnel sont des fonctions de parité impaire et $C_f(\infty) = S_f(\infty) = 1/2$.

L'image alors obtenue est donnée par :

$$\begin{aligned} I(x', z) &\propto a a^* \\ &\propto \left[C_f\left(\sqrt{\frac{2}{\lambda z}} x'\right) + \frac{1}{2} \right]^2 + \left[S_f\left(\sqrt{\frac{2}{\lambda z}} x'\right) + \frac{1}{2} \right]^2 \end{aligned} \quad (5)$$

et peut qualitativement être prédite en utilisant l'outil qu'est la spirale de Cornu (ou clothoïde) [3, 9]. Comme nous pouvons le voir Fig. 1b, la diffraction transforme l'échelon correspondant à l'image géométrique en une transition plus douce entre l'ombre et la partie lumineuse. Le point le plus marquant est l'apparition d'oscillations significatives à proximité de l'image de l'écran.




fig 2 : Évolution des intégrales de Fresnel C_f et S_f représentées respectivement par une courbe rouge et bleue.

3 LE RESEAU NEURONAL

3.1 Contexte et outils utilisés

Les méthodes d'intelligence artificielle constituent un sujet à découvrir complètement par nos étudiants, leur cursus de Licence n'incluant que les bases de programmation (en langage Octave). Pour leur introduire les notions rudimentaires d'apprentissage machine et de réseau neuronal, nous avons fait le choix de leur faire visionner les séquences vidéos du premier chapitre du MOOC « Deep Learning » de Nicolas Thome [10] du CNAM disponible sur la plateforme FUN. Au niveau implémentation logicielle, prenant en compte les compétences informatiques de nos étudiants et pour que cet aspect ne soit pas une difficulté en soi, nous avons opté pour l'environnement matlab et la toolbox proposée par cette société [11] qui dispose d'une interface graphique intuitive et conviviale. Les intégrales de Fresnel sont des fonctions incluses dans matlab et ses clones. Une solution en langage python et l'utilisation de ressources open-source sont bien évidemment totalement envisageables, d'autant plus que ce langage domine dans la communauté de l'intelligence artificielle.

3.2 Concept du neurone

La brique essentielle du réseau neuronal est le neurone dont le concept est illustré Fig. 3. Un neurone dispose de plusieurs entrées, e_1, e_2, \dots, e_n qu'il va combiner linéairement en les pondérant par des valeurs w_1, w_2, \dots, w_n avec un biais éventuel b . La sortie s du neurone est le résultat de cette combinaison par une fonction d'activation f (par exemple une fonction sigmoïde) :

$$s = f\left(b + \sum_{k=1}^n w_k e_k\right) \quad (6)$$

La phase d'apprentissage consistera à rechercher les coefficients w et b optimaux à appliquer pour faire correspondre à un certain jeu de paramètres d'entrée e la sortie s souhaitée.




fig 3 : Principe d'un neurone artificiel

3.3 Structure d'un réseau neuronal

Le réseau neuronal résulte de l'agencement de plusieurs neurones [12]. La configuration la plus simple consiste en une couche de N neurones faisant le lien

entre les n entrées e et les m sorties s (fig. 4a). Des structures plus riches et plus performantes sont réalisables lorsque les neurones se répartissent sur plusieurs couches (Fig. 4b). Le nombre de connections est alors augmenté ce qui nécessite des algorithmes puissants pour déterminer la structure optimale à adopter pour faire correspondre les entrées et les sorties.




fig 4 : Réseau neuronal impliquant une seule couche (a) ou bien à plusieurs couches totalement connectées (3 couches, b)

4 LE RESEAU UTILISÉ POUR PRÉDIRE LA FIGURE DE DIFFRACTION

4.1 Principe

Dans un premier temps, les étudiants ont évalué la capacité d'un réseau neuronal à prédire la figure de diffraction d'un écran semi-opaque. La première phase est l'apprentissage du réseau neuronal. Pour cela, il faut tout d'abord créer une collection de données permettant cet apprentissage. Autrement dit, il a fallu générer les profils diffractés $I(x')$ obtenus pour différentes distances et pour différentes longueurs d'onde. $I(x')$ est discrétisé sur une centaine de points régulièrement espacés I_m . Les paramètres d'entrée du réseau neuronal sont alors constitués par λ_n et z_n et les sorties seront la figure de diffraction discrétisée. L'apprentissage vise à adapter les poids et biais des différents neurones pour minimiser l'erreur entre le profil obtenu prédit par le réseau et le profil de référence. Les étudiants ont alors pu comparer plusieurs algorithmes et observer les différences en termes de précision et de rapidité. Ils ont également pu mesurer l'influence du nombre de neurones et du nombre de couches. Plus le nombre de neurones est élevé, plus les résultats sont fidèles, mais plus l'apprentissage requiert du temps. Il faut de plus demeurer vigilant face aux situations de sur-apprentissage : dans ce cas, le

résultat semble parfait sur les données utilisées pour l'apprentissage, mais le réseau n'est pas pour autant en mesure de prédire convenablement de nouvelles configurations. Finalement, après différents tests, une configuration satisfaisante semble être un réseau composé de trois couches de 12 neurones et l'algorithme retenu pour le réseau à propagation avant est la méthode *Bayesian regularization backpropagation*.

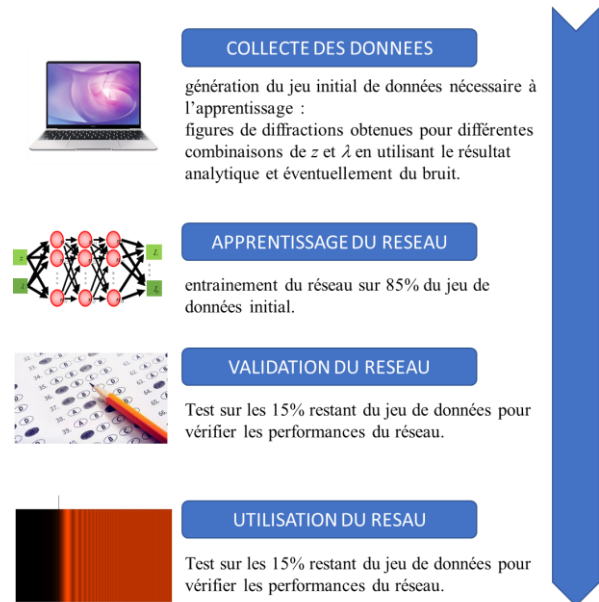


fig 5 : Différentes étapes de l'utilisation du réseau

4.2 Après un apprentissage sur des données parfaites

Nous avons tout d'abord testé le réseau neuronal sur un cas parfait, i.e. sur un ensemble de données constitué par des figures de diffractions non bruitées, i.e. la solution analytique donnée par l'Eq. (5). Le jeu initial de données est composé de profils obtenus pour 11 longueur d'onde différentes couvrant le domaine du visible, régulièrement espacées de 380 à 780 nm et pour 21 distances différentes (de 0.5 à 1 m). Nous comparons tout d'abord Fig. 6a les profils retrouvés pour des valeurs de z et λ correspondant au jeu de données initial. L'accord est tout à fait convaincant. De même, dans le cas d'une distance $z = .765m$ et $\lambda = 632.8$ non utilisés pour l'apprentissage, les prédictions du réseau et la solution analytique sont en parfait accord (Fig. 6b). Le réseau démontre donc sa capacité universelle d'interpolation. Le défi est bien plus marqué pour des données prises en dehors de l'espace de paramètres initialement utilisé pour l'apprentissage. Ainsi, pour une distance plus élevée et une longueur d'onde plus faible ($z = 1.2m$, $\lambda = 330$ nm), les résultats restent totalement consistants avec la solution analytique, soulignant que le réseau peut également être envisagé de manière pertinente pour une extrapolation.




fig 6 : Figure comparant données parfaites et données prédites par le réseau neuronal (a) pour $z = .75\text{m}$ et $\lambda = 580\text{ nm}$, (b) pour $z = 0.765\text{ m}$ et $\lambda = 632.8\text{ nm}$, (c) pour $z = 1.2\text{ m}$ et $\lambda = 330\text{ nm}$. Les résultats issus du réseau neuronal (courbe bleue) sont comparés avec le résultat analytique donné par l'Eq. (5) (cercles noirs).

4.3 Après un apprentissage sur des données bruitées

Dans un second temps, nous avons testé la capacité du réseau à manipuler des données bruitées. Nous avons ainsi utilisé comme données d'entrée un ensemble de 21 figures d'interférences obtenues pour différentes distances allant de 0.5 m à 1 m, à la même longueur d'onde de 632.8 nm (caractéristique du laser Hélium-Néon). Le bruit appliqué sur la trace analytique est un bruit blanc additif gaussien centré d'écart type 10% de l'intensité maximale et un bruit multiplicatif lui aussi d'écart type 10%. Cela nous permet de simuler un enregistrement expérimental tel qu'il aurait pu être obtenu par un barrette CCD de 100 pixels. Comme la complexité des données (λ désormais fixe) a diminué par rapport au problème précédent, nous avons réduit le réseau neuronal à trois couches de 8 neurones. Malgré la qualité imparfaite des données d'entraînement employées, le réseau est en mesure de prévoir efficacement les figures de diffraction (Fig. 7a). La figure 7b montre que le réseau se rend même capable de débruiter dans une certaine mesure les enregistrements expérimentaux, les rendant plus proches de la figure théorique.




fig 7 : (a) Comparaison du résultat analytique (Eq. (5)) avec les prédictions obtenues par le réseau entraîné sur des données bruitées pour une distance de 0.765 m et $\lambda = 632.8\text{ nm}$. (b) Evolutions de la figure de diffraction en fonction de la distance d'observation reconstituée à partir de données bruitées, des prédictions du réseau neuronal, de la théorie analytique (Eq. (5)) (panels 1, 2 et 3 ; une échelle de fausses couleurs a été utilisée pour mieux souligner les différences entre figures).

5 LE RESEAU UTILISÉ POUR EXPLOITER UNE FIGURE DE DIFFRACTION

Après avoir validé la capacité d'un réseau à prédire une figure de diffraction connaissant la distance d'observation et la longueur d'onde, nous nous sommes intéressés au problème inverse, i.e. déterminer à partir d'une figure de diffraction enregistrée la distance et la longueur d'onde à laquelle la figure a été prise. Un tel problème nécessite a priori l'utilisation d'un autre réseau neuronal où l'entrée sera cette fois-ci constituée du profil d'intensité discrétisé en cent points, alors que les paramètres de sortie seront la longueur d'onde et la distance. Nous pouvons donc utiliser le même jeu de données précédemment créé, mais en intervertissant données d'entrées et données de sorties.

Dès leurs premières manipulations, les étudiants ont pu constater des soucis au niveau de l'apprentissage des données. Lorsqu'ils travaillaient avec des figures avec des longueurs d'onde et des distances inconnues, les résultats obtenus étaient loin des attentes avec des prédictions très erronées. Ce n'est qu'en se repenchant sur la théorie analytique que les étudiants ont pu déterminer l'origine de cette incertitude : comme le montre l'Eq. (2), la longueur d'onde et la distance de propagation tiennent un rôle similaire dans la variable normalisée u . Autrement dit, pour une figure de diffraction donnée, il existe une infinité de combinaisons λ et z possibles (i.e. les combinaisons conduisant à un produit λz donné). Ainsi, en raison de

la physique sous-jacente, si les deux paramètres λ et z sont inconnus, il ne sera pas possible de les déterminer sans ambiguïté quelle que soit la qualité du réseau neuronal employé.

Étant donnée la contrainte précédemment mise en lumière, nous avons considéré la longueur d'onde connue et fixe ($\lambda = 632.8$ nm) et nous avons évalué la capacité du réseau à retrouver la distance de propagation. Les données utilisées pour l'apprentissage sont une série de 20 enregistrements entre .5 et 1 m. Le réseau neuronal mis ici en œuvre est un réseau de trente neurones disposés sur une unique couche. Les étudiants ont tout d'abord considéré des enregistrements idéaux (i.e. sans bruit). L'erreur entre la distance prédite par le réseau et la distance réelle est résumée Fig. 8(a) et qualifie la qualité du réseau employé. Cette erreur est remarquablement faible (bien inférieure au mm), validant la reconnaissance de figures non-bruitées. Notons que l'erreur est plus marquée sur les extrémités de la zone entraînée.

Cette étude est complétée par une étude où les traces étudiées sont affectées par du bruit blanc additif de type gaussien (d'écart type 5% de la valeur max du profil d'intensité). L'écart entre les prédictions du réseau et la distance réelle est ici beaucoup plus significatif. Une étude statistique a été menée sur 2000 réalisations et la distribution des erreurs est résumée Fig. 8(b) où l'on constate une répartition gaussienne. Si l'erreur absolue moyenne n'est que de 4 cm, quelques enregistrements peuvent présenter des écarts dépassant 15 cm, ce qui limite la précision de cette approche simple pour le traitement d'enregistrements réels.




fig 8 : (a) Erreur commise sur la position z estimée à partir d'un enregistrement sans bruit. (b) histogramme de l'erreur sur z obtenue par l'analyse par le réseau neuronal d'enregistrement bruités (2000 réalisations).

6 CONCLUSION

Pour conclure, ce projet mené sur quelques jours avec des étudiants de licence de Physique n'ayant aucune connaissance a priori en intelligence artificielle a permis d'introduire sur l'exemple d'un problème optique connu l'intérêt de ces techniques. Sans aller dans le détail des algorithmes et sans chercher à optimiser les solutions retenues (l'utilisation d'un réseau convolutif serait un plus), ils ont ainsi pu cerner l'utilité potentielle pour la reconnaissance ou la prédiction d'un motif de diffraction. Ils ont également pu constater que parfois les limites ne sont pas liées à l'algorithme, mais plutôt à la physique sous-jacente et nécessite la compréhension analytique du phénomène modélisé. Ainsi, l'IA ne se place pas forcément en concurrente des approches traditionnelles. Le rôle crucial des données d'entrée a également été souligné.

Les étudiants ont pu terminer le projet par la lecture de quelques articles de recherche réalisés dans l'équipe sur des configurations plus avancées où des réseaux neuronaux ont été employés comme outils prédictifs pour le design de nouvelles solutions optiques [13, 14]. En effet, que ce soit au niveau ingénierie photonique [15, 16], au niveau caractérisation d'impulsions complexes [17] ou bien de manière plus générale en physique [18], l'utilisation de l'intelligence artificielle connaît une utilisation grandissante.

Au final, les étudiants ont restitué leur compréhension des éléments découverts durant ce projet sous la forme d'un rapport synthétique et individuel de huit pages. Il est envisagé de faire évoluer ce projet de trois jours où les étudiants ont toute liberté d'explorer et tester par eux-même en un tp de quatre heures qui permettrait à l'ensemble d'une promotion d'avoir un premier contact avec ce domaine.

Remerciements

Nous remercions très sincèrement Leo Théodon, Nicolas Thevenot et Guillaume Jaskula, étudiants de Licence de Physique de l'Université de Bourgogne, pour leur investissement et la grande qualité de leur travail mené durant toute la durée de ce projet.

Bibliographie

- [1] Moen A K and Vander Meulen D L, "Fresnel Diffraction Using a He-Ne Gas Laser", *Am. J. Phys.*, Vol. 38, 1095-7 (1970).
- [2] Chu C C, Hey J D and Hoarau M, "An Optical Diffraction System for Industrial Application", *Phys. Scr.*, Vol. T97, 131 (2001).
- [3] Jenkins F A and White H E, "Fundamentals of optics - 4th edition", *McGraw-Hill Inc.,US* (1976).
- [4] Wolfers M F, "Diffraction par un bord rectiligne avec une source large", *J. Phys. Radium*, Vol. 6, 305-12 (1925).

- [5] Wikipedia contributors, "Fresnel integral".
- [6] "Œuvres complètes d'Augustin Fresnel", *Paris Imprimerie impériale (1866-1870)*.
- [7] Stepanov V I, "Auguste Fresnel. The 150th anniversary of his death", *J. Appl. Spectrosc.*, Vol. 27, 825-30 (1977).
- [8] Blayo F and Verleysen M, "Les réseaux de neurones artificiels", *Presses Universitaires de France (1996)*.
- [9] Wikipedia contributors, "Clothoïde".
- [10] Thome N, "Deep Learning".
- [11] Mathworks, "Deep Learning Toolbox".
- [12] Wikipedia contributors, "Réseau de neurones artificiels".
- [13] Finot C, Gukov I, Hammani K and Boscolo S, "Nonlinear sculpturing of optical pulses with normally dispersive fiber-based devices", *Opt. Fiber Technol.*, Vol. 45, 306-12 (2018).
- [14] Boscolo S, Finot C, Gukov I and Turitsyn S K, "Performance analysis of dual-pump nonlinear amplifying loop mirror mode-locked all-fibre laser", *Laser Phys. Lett.*, Vol. 16, 065105 (2019).
- [15] Chugh S, Gulistan A, Ghosh S and Rahman B M A, "Machine learning approach for computing optical properties of a photonic crystal fiber", *Opt. Express*, Vol. 27, 36414-25 (2019).
- [16] Pilozzi L, Farrelly F A, Marcucci G and Conti C, "Machine learning inverse problem for topological photonics", *Commun. Phys.*, Vol. 1, 57 (2018).
- [17] Zahavy T, Dikopoltsev A, Moss D, Haham G I, Cohen O, Mannor S and Segev M, "Deep learning reconstruction of ultrashort pulses", *Optica*, Vol. 5, 666-73 (2018).
- [18] Carleo G, Cirac I, Cranmer K, Daudet L, Schuld M, Tishby N, Vogt-Maranto L and Zdeborová L, "Machine learning and the physical sciences", *Rev. Modern Physics*, Vol. 91, 045002 (2019).