

Méthode plug-and-play pour des problèmes inverses sur signaux bivariés avec données synthétiques

Pierre PALUD¹ Eric CHASSANDE-MOTTIN¹

¹ Université Paris Cité, CNRS, Astroparticule et Cosmologie, F-75013 Paris, France

Résumé – L’approche plug-and-play (PnP) représente aujourd’hui l’état de l’art en restauration d’images. Elle repose sur un débruiteur gaussien, souvent défini par un réseau de neurones (RN) qui apprend les caractéristiques clés de l’image. Ce travail adapte l’approche PnP aux signaux bivariés. L’objectif principal est la restauration de la polarisation, c’est-à-dire la dépendance géométrique entre les deux composantes du signal. Il définit un RN débruiteur dans le domaine temps-fréquence en n’utilisant que des données synthétiques. L’intérêt de l’approche est démontré dans une application sur des signaux d’ondes gravitationnelles.

Abstract – Plug-and-play (PnP) approaches currently achieve state-of-the-art quality in image restoration. These methods rely on a Gaussian denoiser, often parametrized by an artificial neural network (ANN) that learns the image key features. This work adapts the PnP approach to bivariate time series. The main goal is to restore the polarisation, that is, the geometrical dependence between the two components of the signal. It designs an ANN denoiser in the time-frequency domain, using exclusively a synthetic dataset. The interest of the approach is demonstrated with an application to gravitational wave astronomy.

1 Introduction

Les dernières années ont vu les méthodes plug-and-play (PnP) [1] atteindre des performances de restauration remarquables dans des problèmes inverses sur des images naturelles. Ces méthodes relient les approches classiques de problèmes inverses aux techniques de l’apprentissage statistique et aux réseaux de neurones (RN). Le RN est entraîné comme débruiteur sur des données réalistes pour apprendre des caractéristiques clés. Il remplace l’opérateur proximal classiquement associé à la régularisation dans l’algorithme de restauration. Pour des images naturelles, l’entraînement exploite de grands ensembles de données. Pour beaucoup de systèmes d’imagerie, de tels ensembles n’existent pas ; des ensembles synthétiques sont alors utilisés, construits en transformant des images de référence [2] ou à partir de données purement synthétiques [3].

Les séries temporelles ont reçu moins d’attention que les images pour l’apprentissage profond. Cependant, des RN ont été utilisés pour traiter celles-ci dans les domaines temporel [4] et temps-fréquence [5]. Des méthodes récentes utilisent des spectrogrammes complexes avec des RN convolutionnels et des UNet [6].

Ce travail se concentre sur des séries temporelles bivariées, qui apparaissent dans divers champs de la physique, dont l’optique et l’électromagnétisme [7], l’océanographie avec les vitesses de courants [8] la sismologie [9], ou l’astrophysique avec les ondes gravitationnelles [10]. Dans de tels signaux, la relation entre les deux composantes, appelée la polarisation, porte une information physique importante [11]. Ce travail propose une approche PnP pour 1) des séries temporelles bivariées générales avec une attention sur la préservation de la polarisation, 2) en n’utilisant que des données synthétiques pour entraîner le RN profond débruiteur.

La Section 2 présente les signaux bivariés et la notion de polarisation. La Section 3 introduit le problème inverse et la méthode PnP proposée. La Section 4 décrit une application aux ondes gravitationnelles. La Section 5 en analyse les résultats.

2 Signaux bivariés et polarisation

Dans un signal bivarié $\mathbf{h}(t) = (h_1(t), h_2(t))$, la relation entre les deux composantes porte une information physique clé. Cette relation, appelée polarisation par les physiciens, peut être décrite avec les quatre paramètres de Stokes, notés de S_0 à S_3 [11]. S_0 quantifie l’amplitude du signal, les autres décrivent la géométrie elliptique de la polarisation. La représentation temps-fréquence des Stokes [11] est définie avec les produits des transformées de Fourier à court terme (TFCT) des deux composantes, H_1 et H_2

$$\begin{aligned} S_0(\tau, \nu) &= |H_1(\tau, \nu)|^2 + |H_2(\tau, \nu)|^2 \\ S_1(\tau, \nu) &= |H_1(\tau, \nu)|^2 - |H_2(\tau, \nu)|^2 \\ S_2(\tau, \nu) &= 2 \operatorname{Re} \left\{ H_1(\tau, \nu) \overline{H_2(\tau, \nu)} \right\} \\ S_3(\tau, \nu) &= 2 \operatorname{Im} \left\{ H_1(\tau, \nu) \overline{H_2(\tau, \nu)} \right\} \end{aligned} \quad (1)$$

Les paramètres de Stokes normalisés $s_i = S_i / (S_0 + \alpha)$ (avec $i \in \{1, 2, 3\}$ et $\alpha \ll 1$) permettent de simplifier la description de la polarisation [11]. Pour $\alpha = 0$, ces paramètres vivent sur la sphère unité en trois dimensions, appelée sphère de Poincaré. Ses pôles nord et sud ($S_3 = \pm S_0$) correspondent à une polarisation circulaire anti-horaire et horaire, respectivement. L’équateur décrit des polarisations linéaires. Fixer $\alpha > 0$ évite une division par 0 et ainsi garantit $s_i \simeq 0$ quand l’énergie S_0 tend vers zéro.

La Figure 1 montre un exemple typique d’onde gravitationnelle (OG), un signal bivarié avec ses deux composantes notées h_+ et h_\times . C’est un signal modulé en amplitude et fréquence en chirp avec une polarisation constante circulaire. Dans le domaine temporel, l’augmentation d’amplitude et de fréquence est visible sur chaque composante. La figure sur la gauche montre la polarisation circulaire, mais ne permet pas de déterminer si celle-ci évolue au cours du temps. La TFCT du signal (milieu) met en évidence l’évolution de la fréquence et de l’amplitude, mais ne montre rien de la relation entre

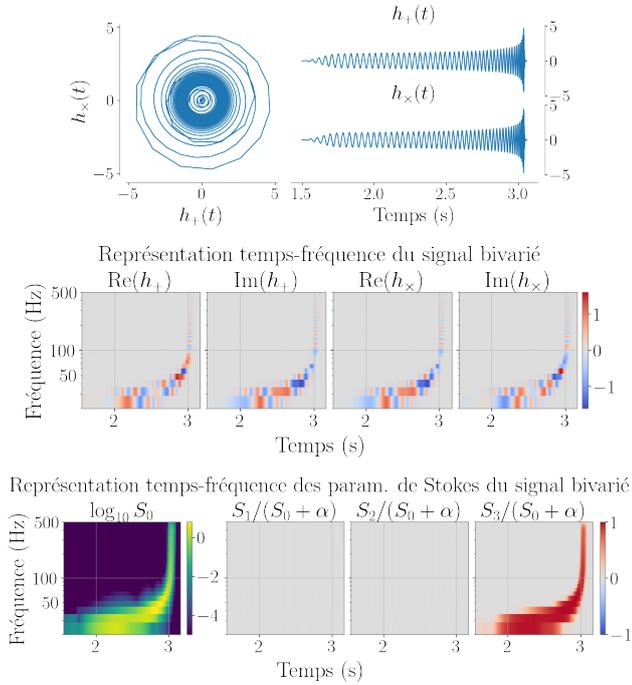


FIGURE 1 : Exemple de signal bivarié simulé (onde gravitationnelle) avec une polarisation constante circulaire. (Haut) domaine temporel, (Milieu) représentation temps-fréquence, (Bas) représentation temps-fréquence des paramètres de Stokes, avec $s_3 \simeq 1$ là où se situe l'énergie du signal.

les deux composantes. La représentation temps-fréquence des paramètres de Stokes (bas) donne une description complète de l'évolution de l'amplitude, de la fréquence et de la géométrie.

Le cas spécifique d'une OG avec une polarisation circulaire a été choisi comme exemple illustratif. Dans d'autres situations, les signaux peuvent être plus complexes, avec plusieurs modes, chacun avec une polarisation elliptique différente et potentiellement variable. Dans la suite, les signaux bivariés sont décrits avec la représentation temps-fréquence des Stokes, qui est suffisamment générale pour décrire ces cas plus complexes.

3 Une méthode plug-and-play pour signaux bivariés

3.1 Description du problème

L'objectif de ce travail est de restaurer un signal bivarié $\mathbf{h} = (\mathbf{h}_1, \mathbf{h}_2) \in \mathbb{R}^{N \times 2}$ à partir d'observations dégradées $\mathbf{y} \in \mathbb{R}^{N \times D}$, avec N le nombre d'échantillons et D la dimension de chaque mesure. Cette tâche est généralement formulée par

$$\hat{\mathbf{h}} \in \arg \min_{\mathbf{h} \in \mathbb{R}^{N \times 2}} f_{\mathbf{y}}(\mathbf{h}) + \lambda g(\mathbf{h}), \quad (2)$$

où $f_{\mathbf{y}}$ est un terme de fidélité aux données, g est une fonction de régularisation favorisant des propriétés désirables de \mathbf{h} , et λ un poids de régularisation. À cause du faible rapport signal sur bruit (SNR) attendu en pratique ou de la complexité du terme de fidélité aux données, le maximum de vraisemblance – (2) avec $g = 0$ – est typiquement mal posé. Obtenir une bonne restauration requiert le choix d'une fonction de régularisation qui respecte les caractéristiques clés du signal.

3.2 L'approche plug-and-play

L'approche plug-and-play contourne le besoin d'une fonction de régularisation g explicite. Elle se base sur l'algorithme classique de descente de gradient proximal [12, chapitre 10] pour résoudre (2), où, à chaque itération t ,

$$\mathbf{h}^{(t+1)} = \text{prox}_{\lambda g} \left(\mathbf{h}^{(t)} - \eta \nabla f_{\mathbf{y}} \left(\mathbf{h}^{(t)} \right) \right), \quad (3)$$

avec un pas $\eta > 0$ et l'opérateur proximal

$$\text{prox}_{\lambda g}(\mathbf{h}) = \arg \min_{\mathbf{u} \in \mathbb{R}^{N \times 2}} [\|\mathbf{u} - \mathbf{h}\|_F^2 + \lambda g(\mathbf{u})]. \quad (4)$$

Cet opérateur est équivalent à un problème de débruitage gaussien avec une régularisation λg . L'approche PnP remplace l'opérateur $\text{prox}_{\lambda g}$ par un débruiteur appris qui contient implicitement les caractéristiques du signal [13]. À l'itération t , (3) devient

$$\mathbf{h}^{(t+1)} = D_{\sigma} \left(\mathbf{h}^{(t)} - \eta \nabla f_{\mathbf{y}} \left(\mathbf{h}^{(t)} \right) \right), \quad (5)$$

où D_{σ} est un débruiteur gaussien pour un niveau de bruit σ . Il apprend les caractéristiques du signal en minimisant la fonction de coût

$$\mathbb{E}_{\mathbf{h} \sim \pi_{\mathbf{h}}, \sigma \sim \mathcal{U}(0, \sigma_{\max}), \boldsymbol{\xi} \sim \mathcal{N}(0, \sigma^2 \mathbf{I})} [\|D_{\sigma}(\mathbf{h} + \boldsymbol{\xi}) - \mathbf{h}\|_2^2], \quad (6)$$

avec $\pi_{\mathbf{h}}$ la distribution de \mathbf{h} et $\mathcal{U}(0, \sigma_{\max})$ la distribution uniforme du niveau de bruit entre 0 et un niveau maximum σ_{\max} . Puisque l'entraînement d'un débruiteur gaussien est simplement une tâche prétexte pour remplacer un opérateur proximal (4), les équations (2) à (6) peuvent être utilisées avec d'autres représentations, comme Fourier ou temps-fréquence.

En pratique, $\pi_{\mathbf{h}}$ est approchée par un ensemble de données. Ce travail utilise des données générées par un simulateur. Une fois entraîné, le débruiteur D_{σ} peut être utilisé pour résoudre tout problème inverse visant à reconstruire le signal bivarié considéré. Pendant l'inférence, l'écart quadratique σ peut être interprété comme un paramètre de régularisation [13] et ajusté. La qualité de restauration dépend de l'efficacité de D_{σ} , qui dépend elle-même de l'ensemble de données synthétique, de l'architecture du RN et de la méthode d'entraînement.

3.3 Vers un débruiteur pour signal bivarié

Dans la littérature, les méthodes classiques de débruitage de séries temporelles passent par de l'apprentissage de dictionnaires, des contraintes de parcimonie dans le domaine de Fourier ou d'ondelettes, ou la variation totale. Ces méthodes ont une expressivité limitée, ce qui implique une capacité limitée à apprendre les caractéristiques clés du signal bivarié. De plus, elles ne peuvent souvent traiter qu'une série temporelle à la fois, et ne peuvent donc pas préserver la polarisation.

Les réseaux de neurones (RNs) produisent aujourd'hui de meilleurs résultats grâce à leur plus grande flexibilité. Ils peuvent traiter les séries temporelles dans le domaine temporel [4] or temps-fréquence [5]. Une représentation temps-fréquence comme la TFCT contient une description plus simple et informative, au prix d'étapes supplémentaires de traitement. Les méthodes les plus récentes exploitent les spectrogrammes à valeurs complexes [6].

Dans ce travail, le débruiteur D_{σ} est un RN basé sur l'architecture convolutionnelle DRUNet, qui constitue l'état

de l'art [14]. L'architecture a été modifiée pour traiter les spectrogrammes à valeurs complexes des signaux bivariés $\mathcal{H} = (\mathbf{H}_1, \mathbf{H}_2) \in \mathbb{C}^{2 \times N_f \times N_t}$, avec N_f et N_t les dimensions fréquentielle et temporelle de la TFCT, respectivement. Le signal bivarié $\mathbf{h} \in \mathbb{R}^{N \times 2}$ est donc converti en $(\text{Re}\{\mathbf{H}_1\}, \text{Im}\{\mathbf{H}_1\}, \text{Re}\{\mathbf{H}_2\}, \text{Im}\{\mathbf{H}_2\})$.

Une différence importante entre les images et la représentation temps-fréquence est que le RN ne doit pas être invariant aux translations verticales pour un spectrogramme. Pour éviter cette invariance, le RN est systématiquement entraîné et utilisé avec des spectrogrammes complets, alors que les débruiteurs d'images sont entraînés avec des patches [14].

4 Application aux signaux d'ondes gravitationnelles

4.1 Modèle direct

Les OGs sont intrinsèquement des signaux bivariés dont les composantes sont notées h_+ et h_\times [10]. Cette application considère les sources les plus communément détectées d'OGs, les fusions de binaires de trous noirs. La Figure 1 montre un exemple d'un signal sans bruit d'une OG émise par une telle source, que l'on cherche à reconstruire à partir d'observations bruitées. Ce signal est reconnaissable à sa morphologie en chirp : les OGs émettent dans les fréquences basses dans la phase de spirale, quand les trous noirs sont loin l'un de l'autre. La fréquence dominante augmente au fur et à mesure que les trous noirs se rapprochent, jusqu'à la fusion.

L'observation \mathbf{y} combine un signal synthétique \mathbf{h} – ici généré avec un simulateur basé sur le modèle SEOBNR [15] – avec un segment de mesures réelles de bruit \mathbf{b} des détecteurs LIGO Livingstone, LIGO Hanford et Virgo, menant à $D = 3$. Le bruit \mathbf{b} est supposé gaussien coloré avec une densité de puissance spectrale connue. Chaque détecteur observe une combinaison linéaire de h_+ et h_\times qui dépend de la position de la source dans le ciel. Dans ce travail, la position de la source et la matrice de projection associée $\mathbf{F} \in \mathbb{R}^{2 \times D}$ sont supposées connues, ce qui donne le modèle d'observation suivant

$$\mathbf{y} = \mathbf{h}\mathbf{F}^T + \mathbf{b}. \quad (7)$$

L'observation dure 6.56 s, dont 5 s de pur bruit, échantillonné à 4096 Hz, soit, $N = 26\,874$. Les observations blanchies $\tilde{\mathbf{Y}} = (\tilde{\mathbf{Y}}_1, \dots, \tilde{\mathbf{Y}}_D)$ sont calculées avec la densité spectrale de puissance du bruit. En utilisant la TFCT des observations blanchies $\tilde{\mathbf{Y}} = (\tilde{\mathbf{Y}}_1, \dots, \tilde{\mathbf{Y}}_D) \in \mathbb{C}^{D \times N_f \times N_t}$, avec $N_f = 257$ fréquences positives et $N_t = 424$, le modèle (7) devient

$$\tilde{\mathbf{Y}} = \mathbf{F}\tilde{\mathcal{H}} + \tilde{\mathbf{B}} \quad \text{avec} \quad \tilde{b}_{dij} \sim \mathcal{N}(0, 1) \quad \forall d, i, j. \quad (8)$$

La Figure 2 montre l'amplitude de la TFCT des observations blanchies $\tilde{\mathbf{Y}}$. Le SNR est de 28,6 dB pour LIGO Hanford, 33,8 dB pour LIGO Livingstone, et 14,0 dB pour Virgo. Ces valeurs sont assez basses, et les deux détecteurs LIGO assez proches (ils mesurent donc des projections similaires), ce qui rend le problème mal posé.

4.2 Estimateurs et métriques

L'estimateur PnP décrit dans la section 3 est entraîné avec un ensemble de 2048 OGs générées avec le simulateur

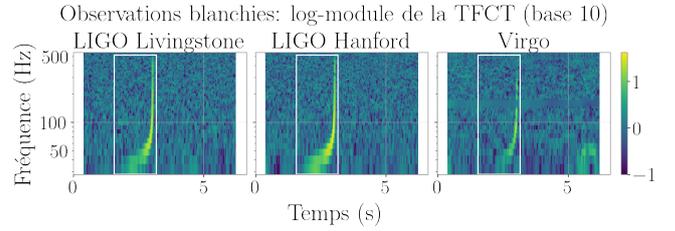


FIGURE 2 : Logarithme décimal du module de la TFCT des observations blanchies d'une OG $\tilde{\mathbf{Y}}$ pour chacun des $D = 3$ détecteurs. Pour chaque détecteur, l'observation contient une combinaison linéaire des deux composantes de l'OG et du bruit mesuré. Le rectangle blanc indique le support du signal vrai, c'est-à-dire la région représentée dans la Figure 1.

SEOBNR [15], couvrant une variété de cas physiques. Cet estimateur est comparé à deux estimateurs classiques en OGs : le maximum de vraisemblance (MLE) [10] et un maximum a posteriori (MAP) qui suppose une polarisation circulaire anti-horaire constante [10]. Les performances de ces estimateurs sont évaluées via la durée de calcul pour l'inférence et la qualité de restauration, quantifiée avec le mismatch et le SNR de reconstruction (R-SNR). Pour un signal vrai \mathbf{h}^* et un estimateur $\hat{\mathbf{h}}$, le mismatch est défini comme [10, chapitre 3]

$$\varepsilon(\mathbf{h}^*, \hat{\mathbf{h}}) = 1 - \max_{\tau} \frac{|\langle \mathbf{h}_1^* - i\mathbf{h}_2^*, (\hat{\mathbf{h}}_1 - i\hat{\mathbf{h}}_2) \cdot (-\tau) \rangle|}{\|\mathbf{h}_1^* - i\mathbf{h}_2^*\| \|\hat{\mathbf{h}}_1 - i\hat{\mathbf{h}}_2\|}, \quad (9)$$

avec τ un retard et le produit scalaire défini dans l'espace de Fourier

$$\langle g_1, g_2 \rangle = \int \mathcal{F}[g_1](\nu) \overline{\mathcal{F}[g_2](\nu)} d\nu. \quad (10)$$

Le R-SNR est défini dans le domaine temporel par R-SNR = $-20 \log_{10}(\|\hat{\mathbf{h}} - \mathbf{h}^*\| / \|\mathbf{h}^*\|)$.

Un faible mismatch indique que $\hat{\mathbf{h}}$ a la bonne forme, mais peut être décalé dans le temps, en phase ou en angle de polarisation. À l'inverse, atteindre un R-SNR élevé signifie que $\hat{\mathbf{h}}$ a la bonne position, phase et orientation. Idéalement, un estimateur devrait bien reproduire le signal tout en évitant de créer de faux signaux hors du support du signal vrai. Ce second point est critique pour un signal court inclu dans un long segment d'observation. Pour séparer ces deux aspects, le mismatch et le R-SNR sont calculés sur deux fenêtres : sur le segment complet, et sur le support du signal vrai, indiqué par un rectangle blanc dans la Figure 2.

5 Résultats

La Table 1 compare les estimateurs considérés avec les critères présentés dans la section précédente. La Figure 3 montre la représentation temps-fréquence des paramètres de Stokes de chaque estimateur – le vrai signal est montré dans la Figure 1. L'approche PnP est la plus lente puisqu'elle est itérative alors que les deux autres estimateurs ont des expressions analytiques. Cependant, elle converge en moins de trente itérations et donc garde une durée d'inférence inférieure à trois secondes, ce qui est raisonnable étant donnée la grande dimension du signal traité. Cette durée est comparable à celle du segment complet, ce qui permet une analyse proche du temps réel.

TABLE 1 : Performance des estimateurs sur l'application à une onde gravitationnelle.

méthode	mismatch		R-SNR (dB)		durée (s)
	complet	support	complet	support	
MLE	0.328	0.123	-0.3	11.3	0.001
MAP circ	0.063	0.019	8.7	28.3	0.002
MAP PnP	0.024	0.014	13.2	31.2	2.7

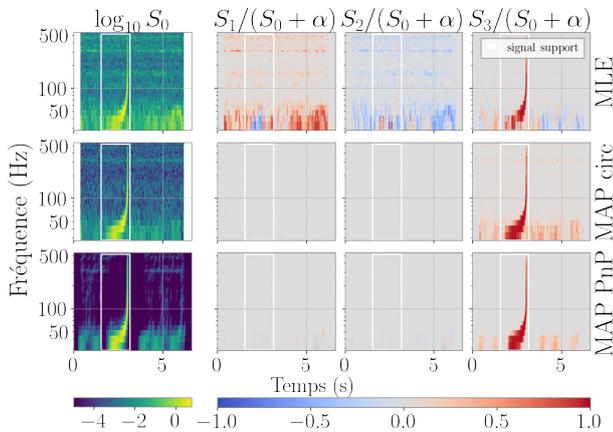


FIGURE 3 : Estimations représentées dans le domaine temps-fréquence des paramètres de Stokes (le signal vrai est montré dans la Figure 1). Le MLE (haut) reproduit la forme du chirp, mais conserve beaucoup de bruit. Le premier MAP (milieu) suppose une polarisation circulaire et parvient donc à la reproduire, mais restaure mal S_0 en incluant beaucoup d'énergie hors du support du signal vrai. L'estimateur PnP proposé (bas) ne suppose pas de polarisation particulière. Pourtant, il reproduit très bien S_0 et la polarisation sur le support du signal vrai et inclut moins d'énergie indésirable hors de ce support.

Concernant la qualité de restauration, le mismatch et le R-SNR montrent tous deux que le MLE produit de mauvais résultats, en particulier sur le segment complet. Le MAP basé sur l'hypothèse d'une polarisation circulaire améliore la reconstruction, mais crée des signaux hors du support du signal vrai. De plus, cette hypothèse est a priori trop forte pour une analyse d'OGs plus générales. Notre approche PnP ne requiert pas une telle hypothèse, et produit de bien meilleurs résultats : +2,9 dB pour le segment complet et +4,5 dB pour le support du signal vrai. Cela montre que le débruiteur préserve la polarisation, la forme de chirp et l'évolution de l'amplitude, le tout avec un temps de calcul raisonnable.

6 Conclusion

Nous proposons une adaptation de la méthode plug-and-play (PnP) aux problèmes inverses visant la restauration d'une série temporelle bivariée. L'architecture DRUNet, état de l'art pour les images, est utilisée pour entraîner un débruiteur gaussien dans le domaine temps-fréquence. La méthode proposée est appliquée à un cas synthétique mais réaliste de restauration d'ondes gravitationnelles (OGs). Les résultats montrent qu'elle surpasse les estimateurs associés aux OGs en qualité de reconstruction, tout en maintenant une durée d'inférence raisonnable. En particulier, la méthode présentée préserve la polarisation, une propriété géométrique clé d'un signal bivarié.

Remerciements

Ce travail est soutenu par le projet ANR RICOCHET ANR-21-CE48-0013. Les auteurs remercient sincèrement Jérémie Boulanger, Pierre Chainais, Pierre-Antoine Thouvenin et Yusuf Yiğit Pilavci pour les échanges riches et fructueux.

Références

- [1] S. V. VENKATAKRISHNAN et al., "Plug-and-Play priors for model based reconstruction", in *2013 IEEE Global Conference on Signal and Information Processing*, Austin, TX, USA : IEEE, déc. 2013, p. 945-948.
- [2] M. XIAO et al., "A 1D Plug-and-Play Synthetic Data Deep Learning For Undersampled Magnetic Resonance Image Reconstruction", in *2024 IEEE International Conference on Image Processing (ICIP)*, oct. 2024, p. 2827-2832.
- [3] O. ORAL et al., "Plug-and-Play Regularization on Magnitude With Deep Priors for 3D Near-Field MIMO Imaging", *IEEE Transactions on Computational Imaging*, t. 10, p. 762-773, 2024.
- [4] Y. LUO et al., "TaSNet : Time-Domain Audio Separation Network for Real-Time, Single-Channel Speech Separation", in *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, avr. 2018, p. 696-700.
- [5] Y. ZHAO et al., "Single-channel noise reduction in the STFT domain from the fullband output SNR perspective", in *2016 24th European Signal Processing Conference (EUSIPCO)*, Budapest, Hungary : IEEE, août 2016, p. 1956-1959.
- [6] S.-W. FU et al., "Complex spectrogram enhancement by convolutional neural network with multi-metrics learning", *2017 IEEE 27th International Workshop on Machine Learning for Signal Processing (MLSP)*, p. 1-6, sept. 2017.
- [7] C. BROSSEAU, *Fundamentals of polarized light : a statistical optics approach*. New York : Wiley, 1998, xiv, 405.
- [8] J. GONELLA, "A rotary-component method for analysing meteorological and oceanographic vector time series", *Deep Sea Research and Oceanographic Abstracts*, t. 19, n° 12, p. 833-846, 1^{er} déc. 1972.
- [9] J. C. SAMSON, "Pure states, polarized waves, and principal components in the spectra of multiple, geophysical time-series", *Geophysical Journal International*, t. 72, n° 3, p. 647-664, 1^{er} mars 1983.
- [10] C. CANO, "Mathematical tools and signal processing algorithms for the study of gravitational waves polarization", thèse de doct., Univ. Grenoble Alpes, 28 oct. 2022.
- [11] J. FLAMANT, "A general approach for the analysis and filtering of bivariate signals", thèse de doct., Ecole Centrale de Lille, 27 sept. 2018.
- [12] A. BECK, *First-Order Methods in Optimization*. Philadelphia, PA : Society for Industrial and Applied Mathematics, 3 oct. 2017.
- [13] S. HURAUULT, "Convergent plug-and-play methods for image inverse problems with explicit and nonconvex deep regularization", thèse de doct., Univ. de Bordeaux, 27 nov. 2023.
- [14] K. ZHANG et al. "Plug-and-Play Image Restoration with Deep Denoiser Prior". (12 juill. 2021), prépubl.
- [15] S. OSSOKINE et al., "Multipolar effective-one-body waveforms for precessing binary black holes : Construction and validation", *Physical Review D*, t. 102, n° 4, p. 044 055, 31 août 2020.