

Approche plug-and-play pour la reconstruction des cartes d'abondance en imagerie hyperspectrale mono-pixel

S er ena HARIGA¹ Nicolas DUCROS^{1,2} Audrey REPETTI³ J er emy COHEN¹

¹Univ Lyon, INSA-Lyon, Universit e Claude Bernard Lyon 1, UJM-Saint Etienne, CNRS, Inserm, CREATIS UMR 5220, U1294, F-69621, LYON, France

²Institut universitaire de France (IUF), France

³MACS, Heriot-Watt University & Maxwell Institute for Mathematical Sciences, Edinburgh, UK

R esum e – Nous  tudions dans cet article la reconstruction d'images hyperspectrales acquises par une cam era mono-pixel. Nous nous int eressons particuli erement   l'estimation des cartes d'abondance dans un cadre de d em elange spectral. Nous proposons d'utiliser un algorithme primal-dual d eclin e en deux versions, selon le type de r egularisation : (i) par variation totale et (ii) avec un r eseau de neurones d ebruit e (algorithme dit *plug-and-play*). Nous montrons sur des simulations que l'approche *plug-and-play* offre en g en eral de meilleures performances. Nous mettons  galement en  vidence l'impact de la pr esence d'un mat eriel en faible proportion sur la reconstruction de sa carte associ ee, et l'importance de bien choisir le param etre de r egularisation en cons equence.

Abstract – In this paper, we study the reconstruction of hyperspectral images acquired with a single-pixel camera. Our focus is on estimating abundance maps within a spectral unmixing framework. We propose a primal-dual algorithm in two versions, depending on the type of regularization: (i) total variation and (ii) using a denoising neural network (the so-called *plug-and-play* algorithm). Through simulations, we demonstrate that the *plug-and-play* approach generally yields better performance. We also examine the impact of a material's proportion on the quality of the reconstructed abundance map, highlighting the importance of selecting the appropriate regularization parameter.

1 Introduction

Une cam era mono-pixel mesure, au moyen d'un d etecteur ponctuel, une s erie de produits scalaires entre l'image d'une sc ene et les motifs lumineux charg es sur une matrice de micro-miroirs (DMD) [3]. Coupl ee   un spectrom etre, une cam era mono-pixel permet d'acqu erir un hypercube sur une large bande et avec une r esolution spatiale  lev ee   partir d'un nombre limit e de mesures [16]. La formation de l'image hyperspectrale n ecessite alors la r esolution d'un probl eme inverse, g en eralement mal pos e, o  l'objectif est de reconstruire l'hypercube   partir des acquisitions compress ees.

La reconstruction de l'hypercube ne suffit g en eralement pas   identifier les mat eriaux pr esents sur la sc ene, en particulier lorsque les pixels r esultent de m elanges spectraux complexes. Des m ethodes de d em elange spectral ont  t e d evelopp ees, dont le mod ele de m elange lin eaire qui est largement utilis e [1, 11]. Il suppose que chaque pixel est une somme pond er ee des signatures spectrales des mat eriaux pr esents. D es lors, il est possible d'extraire les cartes d'abondance des mat eriaux connaissant leur spectre [8]. Des m ethodes de factorisation de matrices peuvent  galement  tre mises en  uvre pour estimer   la fois les cartes d'abondance et les signatures spectrales des mat eriaux, lorsque ces derni eres ne sont pas connues [6]. Dans les deux cas, ces m ethodes supposent que l'image hyperspectrale est d ej a reconstruite et traite donc le probl eme en deux  tapes distinctes qui sont la reconstruction spatiale de l'hypercube et le d em elange spectral. Cette approche en deux temps permet de tirer parti des diff erents outils pr esents dans la litt erature   la fois en reconstruction mono-pixel et en d em elange spectral. Par ailleurs, elle reste sous-optimale et il est montr e dans [7] que le probl eme joint semble offrir de meilleures performances. Cependant, aucune r egularisation n'est appliqu ee ce qui peut limiter la qualit e des estimations, notamment en pr esence de bruit ou lorsque le nombre de mesures est r eduit.

Dans ce travail, nous abordons la r esolution du probl eme joint dans le cas o  le nombre de mesures est inf erieur au nombre de pixels de l'image afin de r eduire le temps d'acquisition. Il est alors crucial de choisir un terme de r egularisation appropri e. Nous proposons d'utiliser un algorithme primal-dual adapt e   une r egularisation

par variation totale (TV) des cartes d'abondance et admettant une version *plug-and-play* o  un r eseau de neurones d ebruit e se substitue   l'op erateur proximal de TV. Nous comparons ensuite finement les performances de ces deux approches. Pour cela, nous r ealisons des simulations dans diff erentes configurations et mettons en avant l'influence des hyperparam etres. Nous  tudions notamment l'impact de la pr esence d'un mat eriel en faible proportion sur la qualit e des estimations.

Notations : Soit A une matrice de dimension $P \times N$. On note $A[p, \cdot]$ la $p^{\text{ eme}}$ ligne de la matrice A , $A[\cdot, n]$ sa $n^{\text{ eme}}$ colonne et $A[p, n]$ le scalaire   la $p^{\text{ eme}}$ ligne et $n^{\text{ eme}}$ colonne. I_N repr esente la matrice identit e de taille N . A^T est la transpos ee de la matrice A .

2 Formulation du probl eme

2.1 Probl eme direct

Soit $Y \in \mathbb{R}^{B \times M}$ les mesures hyperspectrales issues de la cam era mono-pixel, o  M est le nombre de motifs projet es sur le DMD et B le nombre de bandes spectrales fournies par le spectrom etre. Ces acquisitions peuvent  tre mod elis ees par

$$Y \sim \mathcal{P}(\alpha X H^T), \quad (1)$$

o  \mathcal{P} repr esente la distribution de Poisson, utilis ee ici pour mod eliser le bruit inh erent au dispositif d'acquisition, $X \in \mathbb{R}_+^{B \times N}$ est l'hypercube aplati de la sc ene compos e de N pixels, $H \in \mathbb{R}^{M \times N}$ est la matrice de mesures o  chaque ligne correspond   un motif du DMD et $\alpha > 0$ est l'intensit e de la source lumineuse (en photons). Il est   noter que α d etermine le rapport signal-bruit des mesures, une valeur plus  lev ee indiquant une meilleure qualit e. En supposant de plus que l'hypercube r esulte de P mat eriaux distincts, nous consid erons le m elange lin eaire suivant

$$X = SA, \quad (2)$$

o  $S \in \mathbb{R}_+^{B \times P}$ contient les signatures spectrales de chaque mat eriel et $A \in \mathbb{R}_+^{P \times N}$ les cartes d'abondance correspondantes [11, 6].

2.2 Formulation variationnelle

Nous supposons dans ce qui suit que les signatures spectrales S sont connues. Dans ce cas, l'objectif est d'estimer les cartes d'abondance A à partir des données Y . On peut poser ce problème d'estimation comme le problème d'optimisation consistant à

$$\underset{A \in \mathbb{R}^{P \times N}}{\text{minimiser}} \text{KL}(Y, \alpha SAH^T) + R(A) + \iota_{[0,1]^{P \times N}}(A), \quad (3)$$

où KL est la divergence de Kullback-Leibler, $R: \mathbb{R}^{P \times N} \rightarrow]-\infty, +\infty]$ le terme de régularisation spatiale et $\iota_{[0,1]^{P \times N}}$ est la fonction indicatrice qui contraint les coefficients de A à appartenir à l'hypercube $[0, 1]^{P \times N}$. La fonction R est choisie de la forme

$$R(A) = \sum_{p=1}^P g(A[p, :]; L^T; \lambda_p), \quad (4)$$

où $g: \mathbb{R}^N \rightarrow \mathbb{R}$ est une fonction convexe non différentiable agissant sur les cartes d'abondance $A[p, :]$ composées avec un opérateur linéaire $L \in \mathbb{R}^{N' \times N}$ (typiquement l'opérateur de différences finies pour la variation totale [20] avec $N' = 2N$ dans ce cas). Les paramètres $(\lambda_p)_{1 \leq p \leq P} > 0$ représentent les paramètres de régularisation associés à chaque carte d'abondance.

Le problème de minimisation (3) peut admettre une infinité de solutions, notamment dans le cas où $M < N$. Le choix du terme de régularisation est alors crucial pour restreindre l'ensemble des solutions à l'ensemble des solutions souhaité. De plus, il fait intervenir plusieurs paramètres de régularisation qui peuvent être différent d'une carte à l'autre ce qui rend le choix de cet hyperparamètre plus difficile. Enfin, les cartes d'abondance peuvent avoir des échelles de valeurs différentes, ce qui rend leur estimation plus délicate.

3 Algorithmes d'optimisation

Le problème de minimisation (3) fait intervenir trois termes non différentiables, dont deux sont des fonctions composées avec des opérateurs linéaires. Pour résoudre ce problème, nous utilisons un algorithme primal-dual, basé sur la méthode proposée dans [2, 22], qui est particulièrement adaptée à ce type de formulation. Cette approche permet de traiter séparément chaque terme tout en alternant entre les mises à jour primales et duales, comme détaillé dans l'Algorithme 1.

Algorithme 1 : Primal-dual composite

```

1 Input :  $A_0 \in \mathbb{R}^{P \times N}$ ,  $V_0 \in \mathbb{R}^{B \times M}$ ,  $U_0 \in \mathbb{R}^{P \times N}$ 
2 pour  $k = 0, 1, \dots$  faire
3    $\tilde{V}_k = V_k + \tau_V \alpha SA_k H^T$ 
4    $V_{k+1} = \tilde{V}_k - \tau_V \text{prox}_{\tau_V^{-1} \text{KL}}(\tau_V^{-1} \tilde{V}_k)$ 
5    $\tilde{U}_k = U_k + \tau_U A_k L^T$ 
6   pour  $p = 0, \dots, P$  faire
7      $U_{k+1}[:, p] = \tilde{U}_k[:, p]$ 
8      $-\tau_U \text{prox}_{\tau_U^{-1} g(\cdot; \lambda_p)}(\tau_U^{-1} \tilde{U}_k[:, p])$ 
9   fin
10   $A_{k+1} = \text{proj}_{\iota_{[0,1]^{P \times N}}}(A_k - \gamma \alpha S^T (2V_{k+1} - V_k)H - \gamma (2U_{k+1} - U_k)L)$ 
11 fin

```

L'opérateur proximal de la divergence de KL admet la forme explicite suivante [5], pour tout $V \in \mathbb{R}^{B \times M}$, $\tau > 0$ et $1 \leq b \leq B$

$$\text{prox}_{\tau \text{KL}}(V) = \left(\frac{V[b, m]}{2} - \frac{\tau + \sqrt{(V[b, m] - \tau)^2 + 4\tau Y[b, m]}}{2} \right)_{1 \leq m \leq M}.$$

De plus, pour assurer la convergence des $(A_k)_{k \in \mathbb{N}}$ vers une solution du problème (3), les pas $(\gamma, \tau_U, \tau_V) > 0$ doivent satisfaire la condition suivante

$$\gamma(\tau_V \|\mathbf{H}\| + \tau_U \|\mathbf{L}\|) < 1 \quad (5)$$

où $\mathbf{H}: \mathbb{R}^{P \times N} \rightarrow \mathbb{R}^{B \times M}: A \mapsto \alpha SAH^T$, $\mathbf{L}: \mathbb{R}^{P \times N} \rightarrow \mathbb{R}^{P \times N'}: A \mapsto AL^T$ et $\|\cdot\|$ représente ici la norme spectrale.

Nous proposons deux versions de l'Algorithme 1 en fonction du choix du terme de régularisation R .

Variation totale – La première version consiste à considérer une régularisation de type TV anisotrope, avec $g = \lambda_p \|\cdot\|_1$ et L un opérateur de différences finies modélisant les gradients horizontaux et verticaux de l'image. Dans ce cas, les lignes 6 à 9 de l'Algorithme 1 prennent la forme suivante

Algorithme 1a : PD-TV

pour $p = 0, \dots, P$ **faire**

$$U_{k+1}[:, p] = \tilde{U}_k[:, p] - \tau_U \text{soft}_{[-\gamma_p; \gamma_p]}(\tau_U^{-1} \tilde{U}_k[:, p]),$$

fin

où $\text{soft}_{[-\gamma_p; \gamma_p]}$ est l'opérateur de seuillage doux de paramètre $\gamma_p = \tau_U^{-1} \lambda_p$.

Plug-and-play – Dans la seconde version, nous considérons une approche dite *plug-and-play* [10, 18, 23, 19, 9]. L'idée est d'entraîner un réseau de neurones comme un débruiteur Gaussien, afin de remplacer le terme de régularisation variationnel (e.g., à la place de la TV). Plusieurs choix sont possible quant à l'endroit où introduire le réseau de neurones dans l'Algorithme 1. Dans [21], les auteurs utilisent le réseau sur la variable primale.

Ici, nous proposons de remplacer l'opérateur proximal de g dans l'Algorithme 1 par le réseau de neurones débruiteur. En considérant le cas $L = I_N$, nous créons la variable auxiliaire \tilde{U}_k sur laquelle le réseau est appliqué, puis nous ré-agrégeons les variables auxiliaires duales dans l'étape de mise à jour de A_k . Nous choisissons le réseau de neurones comme étant le DRUNet introduit dans [23]. Ce dernier est noté $D_\theta(\cdot; \lambda_p)$, où λ_p est un hyperparamètre représentant le niveau de bruit de l'image à débruiter [23, 19, 12] et θ sont les paramètres appris au cours de l'entraînement du réseaux, qui est effectué indépendamment du problème direct décrit dans la Section 2.1.

L'approche primale-duale-DRUNet (PD-DRUNet) revient à remplacer les lignes 6 à 9 de l'Algorithme 1 par :

Algorithme 1b : PD-DRUNet

pour $p = 0, \dots, P$ **faire**

$$U_{k+1}[:, p] = \tilde{U}_k[:, p] - D_\theta(\tilde{U}_k[:, p]; \lambda_p)$$

fin

Dans les deux cas (Algorithmes 1a ou 1b), la boucle sur P peut être évitée en pratique grâce à l'extension automatique des dimensions (broadcasting).

4 Simulations

Simulation de l'hypercube : Nous proposons de simuler un hypercube X contenant $P = 2$ matériaux distincts, en suivant le modèle linéaire (2). Les spectres sont générés à partir de distributions gaussiennes discrétisées sur $B = 100$ points correspondant au nombre de bandes spectrales. Plus précisément, $S[:, 1] = \mathcal{N}(40, 2)$ et $S[:, 2] = \mathcal{N}(60, 4)$. Les spectres sont ensuite normalisés par la norme ℓ_2 pour assurer qu'ils aient une énergie comparable. Pour simuler les cartes d'abondance, nous utilisons la base de données BSDS300 [15]. Ces cartes sont obtenues en convertissant les images en noir et blanc puis en extrayant des patches de taille $N = 64 \times 64$. Nous notons \bar{A} les cartes d'abondance normalisées entre 0 et 1. Afin d'introduire une variabilité dans la proportion du deuxième matériau, on

introduit le paramètre de pondération $\mu \in [0, 1]$, qui change l'échelle de la deuxième carte (i.e., $A[1, :] \in [0, 1]^N$ et $A[2, :] \in [0, \mu]^N$). Les cartes d'abondance sont alors simulées par $A[1, :] = \bar{A}[1, :]$ et $A[2, :] = \mu \bar{A}[2, :]$.

Opérateur de mesures : Un choix classique pour l'opérateur de mesures H consiste à considérer une matrice de Hadamard d'ordre N [17]. Afin de réduire les temps d'acquisition, nous acquérons uniquement les $M = N/4$ lignes de cette matrice correspondant aux coefficients de Hadamard dont la variance, calculée sur la base de données STL10, est la plus grande (cf. [13] et [4]). Les matrices de Hadamard contiennent des valeurs négatives, tandis qu'un DMD peut uniquement implémenter des motifs positifs. Pour contourner ce problème, la matrice H peut être construite en alternant entre les composantes positives et négatives des motifs retenus [14].

Expériences menées : Pour estimer les cartes, nous utilisons les deux versions de l'Algorithme 1 présentées dans la section précédente PD-TV et PD-DRUNet. Dans les deux cas, nous considérons deux expériences, chacune réalisée sur 10 couples de cartes.

- La première expérience consiste à faire varier les paramètres de régularisation (λ_1, λ_2) , associés aux cartes d'abondance $A[1, :]$ et $A[2, :]$ respectivement. Le but est d'évaluer l'influence de la nature des cartes d'abondance sur le choix du paramètre de régularisation optimal, et de ainsi déterminer si chaque carte nécessite un paramètre de régularisation distinct ou non.

- Nous répétons ensuite cette expérience pour différentes valeurs de $\mu \in \{0.1, \dots, 1\}$. L'objectif est d'analyser l'impact de cette proportion sur la reconstruction des cartes d'abondance et sur le choix de (λ_1, λ_2) , en particulier lorsque le matériau 2 est faiblement représenté (pour de faibles valeurs de μ).

Dans tous les cas, l'intensité des images, notée α et définie à l'équation (1), est fixée à 25 photons.

Choix des hyperparamètres : Les pas de l'algorithme ont été choisis de telle sorte à vérifier la condition (5) et ont les valeurs suivantes $\gamma = 10^{-3}$, $\tau_V = 5 \cdot 10^{-4}$ et $\tau_U = 10^{-1}$ pour PD-TV et $\gamma = 10^{-3}$, $\tau_V = 5 \cdot 10^{-4}$ et $\tau_U = 1$ pour PD-DRUNet. Pour les deux algorithmes, nous fixons le nombre d'itérations à 1200. L'initialisation se fait en attribuant aux matrices A_0 , V_0 et U_0 des valeurs nulles.

Métriques : La qualité de reconstruction des cartes d'abondance est évaluée à l'aide du PSNR. En notant λ_1^* et λ_2^* les paramètres de régularisation optimaux définis comme ceux maximisant le PSNR, nous analysons également l'écart entre ces deux valeurs afin d'évaluer la nécessité d'une régularisation différente pour chaque matériau.

5 Résultats expérimentaux

Résultats qualitatifs : La figure 1a montre un exemple de reconstruction des cartes d'abondance par les algorithmes PD-TV et PD-DRUNet dans le cas où $\mu = 1$, c'est-à-dire lorsque les matériaux sont présents en proportions similaires. Les cartes reconstruites par PD-DRUNet semblent de meilleure qualité, préservant certains détails qui sont perdus avec PD-TV. Sur la figure 1b, nous donnons les valeurs des PSNR des deux cartes en fonction des paramètres de régularisation λ_1 et λ_2 . Nous remarquons que pour les deux algorithmes, les paramètres de régularisation optimaux maximisant le PSNR sont obtenus lorsque $\lambda_1^* = \lambda_2^*$. Ainsi dans ce cas précis où les matériaux sont présents en proportions similaires, le choix des deux hyperparamètres peut se faire de façon indépendante sans risquer une perte de performance significative.

La figure 2a illustre la reconstruction de la carte d'abondance du deuxième matériau pour $\mu = 0.1$ (i.e., un cas où sa contribution est bien plus faible que celle du premier matériau). Nous constatons que, pour les deux algorithmes, la qualité des images reconstruites se dégrade par rapport à la configuration $\mu = 1$, avec une perte notable de détails. La figure 2b montre que, lorsque le matériau est faiblement représenté, le paramètre de régularisation optimal associé à sa

carte d'abondance est plus élevé que lorsque les deux matériaux sont présents en proportions similaires. En d'autres termes, les paramètres de régularisation optimaux diffèrent lorsque les composantes ont des amplitudes inégales ($\mu = 0.1$), mais deviennent presque identiques lorsque leurs amplitudes sont similaires ($\mu = 1$). Ainsi dans le cas où les cartes d'abondance ont des échelles de valeurs différentes, il est préférable d'ajuster spécifiquement les paramètres de régularisation pour chaque carte afin d'optimiser les performances des algorithmes.

Résultats quantitatifs : Nous observons en figure 3 que plus un matériau est représenté en faible proportion sur la scène (i.e., μ petit), plus la reconstruction de sa carte associée est complexe. En effet, pour PD-TV et PD-DRUNet, le PSNR des cartes estimées croît en fonction de l'amplitude μ de la deuxième composante. Cette augmentation est plus marquée pour PD-DRUNet qui passe d'un PSNR moyen d'environ 22 pour $\mu = 0.1$ à 27 pour $\mu = 1$ contre environ 22 à 25 pour PD-TV. On remarque que pour toutes les valeurs de μ , l'algorithme PD-DRUNet fournit de meilleurs résultats en termes de PSNR avec un écart croissant par rapport à PD-TV lorsque μ augmente. Pour $\mu = 0.1$, les deux algorithmes donnent des performances similaires, suggérant que PD-DRUNet rencontre davantage de difficultés lorsque les proportions des matériaux sont déséquilibrées.

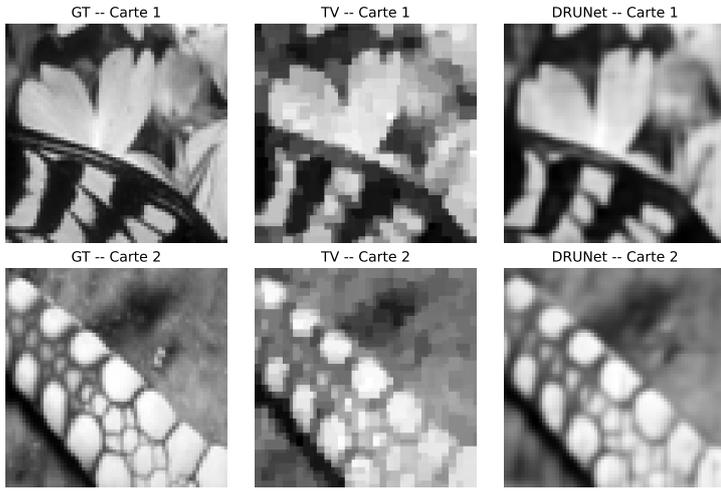
Enfin, nous constatons que pour de faibles valeurs μ , une régularisation plus forte des deux méthodes est nécessaire, accentuant l'écart entre les paramètres de régularisation optimaux des deux cartes.

6 Conclusion et perspectives

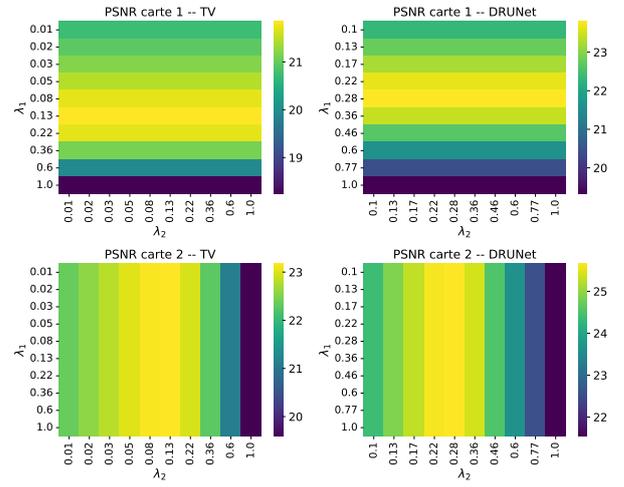
Nous avons montré sur des simulations que la version plug-and-play de l'algorithme primal-dual permet généralement d'obtenir de meilleures performances, en particulier pour les matériaux les plus représentés. De plus, la proportion d'un matériau sur la scène influence de manière significative la qualité de reconstruction des cartes d'abondance et le choix des hyperparamètres. Il serait pertinent d'adapter ces algorithmes, en particulier l'approche plug-and-play, afin d'améliorer la prise en compte des matériaux présents en faible proportion. Une autre piste de recherche consisterait à exprimer explicitement le terme de régularisation R dans le cadre de l'algorithme plug-and-play et à analyser sa convergence de manière théorique. Par ailleurs, nous souhaitons explorer le cas où les spectres des matériaux ne sont pas connus a priori, en adoptant une approche d'optimisation alternée. Enfin, une validation expérimentale sur des données réelles est essentielle pour évaluer les performances de notre méthode et en mesurer l'efficacité en conditions pratiques.

Références

- [1] J. BIOCAS-DIAS, A. PLAZA, N. DOBIGEON, M. PARENTE, Q. DU, P. GADER et J. CHANUSSOT : Hyperspectral Unmixing Overview : Geometrical, Statistical, and Sparse Regression-Based Approaches. *IEEE J-STARS*, 5(2), 2012.
- [2] L. CONDAT : A primal-dual splitting method for convex optimization involving lipschitzian, proximal and linear composite terms. *J. Optim. Theory Appl.*, 158(2):460–479, 2013.
- [3] M.F. DUARTE, M.A. DAVENPORT, D. TAKHAR, J.N. LASKA, Ting SUN, K.F. KELLY et R.G. BARANIUK : Single-Pixel Imaging via Compressive Sampling. *IEEE Signal Process. Mag.*, 25(2):83–91, mars 2008.
- [4] N. DUCROS : Une introduction à l'imagerie computationnelle monodétecteur. *ISTE Editions*, 2019. <https://hal.science/hal-03551730>.
- [5] F.-X. DUPÉ, J. FADILI et J.-L. STARCK : Linear inverse problems with various noise models and mixed regularizations. In *1st International Workshop on New Computational Methods for Inverse Problems*, 2011.
- [6] N. GILLIS : The Why and How of Nonnegative Matrix Factorization. *Mach. Learn. Pattern Recognit. Ser.*, 2014.
- [7] S. HARIGA, J. E. COHEN et N. DUCROS : Joint reconstruction and spectral unmixing from single-pixel acquisitions. *EUSIPCO*, 2024.
- [8] M.-D. IORDACHE, J. BIOCAS-DIAS et A. PLAZA : Sparse unmixing of hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 49(6):2014–2039, 2011.

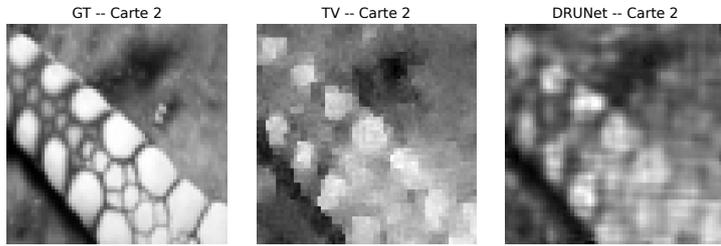


(a) Estimation des cartes d'abondance avec les paramètres de régularisation optimaux ($\lambda_1^* = \lambda_2^* = 0.13$ pour PD-TV et $\lambda_1^* = \lambda_2^* = 0.28$ pour PD-DRUNet).

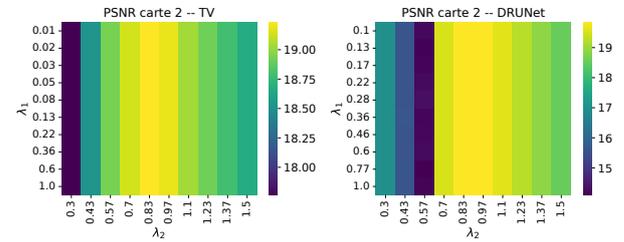


(b) PSNR en fonction des paramètres de régularisation λ_1 et λ_2 .

FIGURE 1 : Résultats pour $\mu = 1$, $\alpha = 25$ photons et $M = N/4$ mesures.



(a) Estimation de la deuxième carte d'abondance avec le paramètre de régularisation optimal ($\lambda_2^* = 0.83$ pour PD-TV et PD-DRUNet).



(b) PSNR en fonction des paramètres de régularisation λ_1 et λ_2 .

FIGURE 2 : Résultats pour $\mu = 0.1$, $\alpha = 25$ photons et $M = N/4$ mesures.

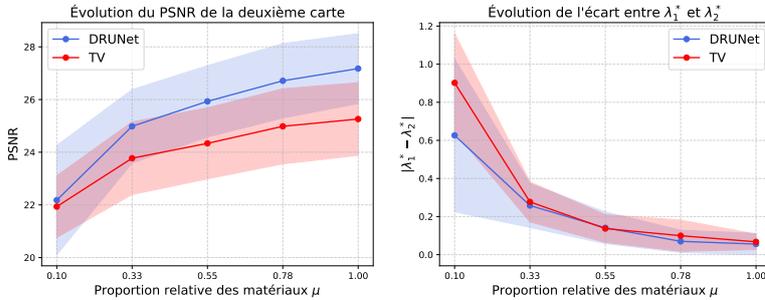


FIGURE 3 : Évolution des métriques en fonction de μ avec $\alpha = 25$ photons et $M = N/4$ mesures. À gauche : la valeur du PSNR de la carte d'abondance dont on fait varier sa proportion. À droite : l'écart entre les paramètres de régularisation optimaux.

- [9] U. S. KAMILOV, C. A. BOUMAN, G. T. BUZZARD et B. WOHLBERG : Plug-and-play methods for integrating physical and learned models in computational imaging : Theory, algorithms, and applications. *IEEE Signal Process. Mag.*, 40(1): 85–97, 2023.
- [10] U. S. KAMILOV, H. MANSOUR et B. WOHLBERG : A plug-and-play priors approach for solving nonlinear imaging inverse problems. *IEEE Signal Process. Lett.*, 24(12):1872–1876, 2017.
- [11] N. KESHAVA et J. F. MUSTARD : Spectral unmixing. *IEEE Signal Process. Mag.*, 19(1):44–57, 2002.
- [12] H. T. V. LE, A. REPETTI et N. PUSTELNIK : Unfolded proximal neural networks for robust image gaussian denoising. *IEEE Trans. Image Process.*, 2024.

- [13] A. LORENTE MUR, P. LECLERC, F. PEYRIN et N. DUCROS : Single-Pixel Image Reconstruction from Experimental Data Using Neural Networks. *Optics Express*, 29(11):17097, mai 2021.
- [14] A. LORENTE MUR, M. OCHOAB, J. E. COHEN, X. INTESB et N. DUCROS : Handling negative patterns for fast single-pixel lifetime imaging. *SIAM J. Optim.*, 2008.
- [15] D. MARTIN, C. FOWLKES, D. TAL et J. MALIK : A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. *ICCV*, 2:416–423, 2001.
- [16] G. B. MARTINS, L. MAHIEU-WILLIAME, T. BAUDIER et N. DUCROS : OpenSpiryt : an ecosystem for open single-pixel hyperspectral imaging. *Optics Express*, 31(10):15599, 2023.
- [17] N. RADWELL, K. J. MITCHELL, G. M. GIBSON, M. P. EDGAR, R. BOWMAN et M. J. PADGETT : Single-pixel infrared and visible microscope. *Optica*, 1(5):285–289, novembre 2014.
- [18] E. T. REEHORST et P. SCHNITER : Regularization by denoising : Clarifications and new interpretations. *IEEE Trans. Comput. Imaging*, 5(1):52–67, 2018.
- [19] A. REPETTI, M. TERRIS, Y. WIAUX et J.-C. PESQUET : Dual forward-backward unfolded network for flexible plug-and-play. *EUSIPCO*, 2022.
- [20] L. I. RUDIN, S. OSHER et E. FATEMI : Nonlinear total variation based noise removal algorithms. *Physica D : nonlinear phenomena*, 60(1-4):259–268, 1992.
- [21] C. SANTOS GARCIA, M. LARCHEVÉQUE, S. O'SULLIVAN, M. VAN WAEREBEKE, R. R. THOMSON, A. REPETTI et J.-C. PESQUET : A primal-dual data-driven method for computational optical imaging with a photonic lantern. *PNAS nexus*, 3(4):pgae164, 2024.
- [22] B.-C. VŪ : A splitting algorithm for dual monotone inclusions involving cocoercive operators. *Adv. Comput. Math.*, 38(3):667–681, 2013.
- [23] K. ZHANG, Y. LI, W. ZUO, L. ZHANG, L. VAN GOOL et R. TIMOFTE : Plug-and-play image restoration with deep denoiser prior. *IEEE Trans. Pattern Anal. Mach. Intell.*, 44(10):6360–6376, 2021.