

Méthodes parcimonieuses de déconvolution et démixage pour les images multispectrales « snapshot »

Kinan ABBAS Matthieu PUIGT Gilles DELMAIRE Gilles ROUSSEL

Univ. Littoral Côte d’Opale, LISIC – UR 4491, F-62219 Longuenesse Cedex, France

Résumé – Dans cet article, nous proposons une nouvelle méthode de démixage pour les systèmes d’imagerie spectrale « snapshot » (SSI) utilisant des filtres de Fabry-Perot. Ces caméras ne fournissent qu’une partie du contenu spectral observé et la stratégie classique consiste à réaliser le démixage après la restauration de l’image (ou dématricage). Dans cet article, nous proposons deux approches fondées sur la déconvolution des filtres de Fabry-Perot. Revisitant des concepts introduits pour les approches d’analyse en composantes parcimonieuses, ces méthodes étendent le cadre de « pixel pur » au niveau du patch de capteur SSI, que nous nommons hypothèse de « patch pur ». Nos expériences montrent qu’elles surpassent de manière significative les méthodes de la littérature, y compris une méthode de démixage et de dématricage conjoints fondée sur la complétion de matrice de faible rang que nous avons récemment proposée.

Abstract – In this paper, we propose a new unmixing method for snapshot spectral imaging (SSI) systems using Fabry-Perot filters. These cameras only provide a part of the observed spectral content, and a classical strategy consists of unmixing after image restoration (aka demosaicing). In this paper, we propose two approaches based on Fabry-Perot filter deconvolution. Revisiting concepts met in sparse component analysis, these methods extend the “pure pixel” framework to the SSI sensor patch level, that we name “pure patch” assumption. Our experiments show that our proposed approaches significantly outperform state-of-the-art methods, including our recently proposed low-rank-matrix-completion-based joint unmixing and demosaicing method.

1 Introduction

L’imagerie multispectrale « snapshot » (SSI pour *Snapshot Spectral Imaging* en anglais) permet l’acquisition d’un cube de données en une seule prise, comme une appareil photo RVB classique [8]. Cependant, la miniaturisation de ces caméras entraîne un compromis entre résolution spectrale et spatiale qui peut être levé par des approches de dématricage, utilisant la corrélation spatiale et/ou spectrale et basées sur l’interpolation (WB) [4], l’arborescence binaire (BTES) [9], la différence spectrale (ItSD) [11], une image pseudo-panchromatique (PPID) [10], la complétion de faible rang (GRMR) [14] ou l’apprentissage profond [7].

Par ailleurs, le démixage hyperspectral décompose la signature spectrale observée sur chaque pixel spatial du cube en une combinaison des signatures des matériaux (endmembers), pondérée par un poids proportionnel à leur surface sur le pixel (abondance). De nombreux algorithmes ont été proposés, dont des méthodes fondées sur l’hypothèse du « pixel pur » [3], la factorisation matricielle non-négative (FMN) [3], ou l’analyse en composantes parcimonieuses (SCA pour *Sparse Component Analysis* en anglais) [5].

Dans nos récents travaux [2], nous avons proposé une approche qui réalise conjointement le dématricage et le démixage, en combinant hypothèse de parcimonie des abondances et complétion de matrice de faible rang. Très performante pour des images SSI avec des filtres de Fabry-Perot idéaux, l’utilisation d’une « matrice de correction » [13] est nécessaire avec des filtres réalistes. Dans cet article, nous proposons une stratégie alternative où l’estimation des endmembers finaux est réalisée par déconvolution des filtres de Fabry-Perot à partir des images SSI. La structure de l’article est organisée ainsi : nous introduisons le problème à traiter dans la section 2. Nous




FIGURE 1 : Réponses spectrales des 25 filtres d’un patch SSI d’une caméra Photon Focus dans la gamme 400–1000 nm.

proposons ensuite deux nouvelles méthodes dans la section 3 et nous étudions leurs performances dans la section 4. Enfin, nous concluons en section 5.

2 Position du problème

Une caméra SSI acquiert une image en 2 dimensions de $m \times n$ pixels, où m et n sont respectivement le nombre de pixels selon l’axe horizontal et vertical. Chacun de ces pixels est associé à une longueur d’onde parmi les k acquises par la caméra, ce qui signifie qu’une image SSI peut être vue comme une projection 2D d’une image 3D théorique de taille $m \times n \times k$ que nous allons maintenant modéliser. La technologie « snapshot » fait appel à une mosaïque de filtres de Fabry-Perot [8] qui bloquent

la lumière en dehors d'une bande spectrale limitée propre à chaque filtre. Cette mosaïque est organisée sous forme de « patches » de taille $\sqrt{k} \times \sqrt{k}$ (typiquement 4×4 ou 5×5) qui sont répétés sur la surface du capteur. Ces filtres présentent des harmoniques autour des longueurs d'onde d'intérêt (voir figure 1) qui sont fournis par le fabricant de la caméra [8].

Nous considérons ci-dessous un unique patch de filtres de Fabry-Perot. En notant $y_i(\lambda_i)$ le i -ème pixel SSI du patch – observant la réponse spectrale à λ_i nm – on obtient

$$y_i(\lambda_i) = \sum_{j=1}^k h_i(\lambda_j) \cdot x_i(\lambda_j) + \omega_i, \quad (1)$$

où $h_i(\lambda)$ est le filtre de Fabry-Perot associé au pixel i , $x_i(\lambda)$ est le spectre « complet » sensé être observé au niveau du pixel i et ω_i du bruit additif. En supposant que le modèle de mélange est linéaire, le spectre observé peut alors s'écrire sous la forme d'un mélange d'endmembers :

$$x_i(\lambda) = \sum_{l=1}^p g_{il} f_l(\lambda), \quad (2)$$

où p est le nombre d'endmembers présents dans la scène observée, $f_l(\lambda)$ est le l -ème endmember et g_{il} l'abondance qui lui est associée dans le pixel i avec des contraintes de non-négativité et de somme à 1 des paramètres g_{il} (pour $l = 1, \dots, p$). En combinant les équations (1) et (2), on obtient

$$y_i(\lambda_i) = \sum_{l=1}^p g_{il} \left(\sum_{j=1}^k h_i(\lambda_j) \cdot f_l(\lambda_j) \right) + \omega_i. \quad (3)$$

Dans cet article, nous introduisons des méthodes pour estimer les termes g_{il} et $f_l(\lambda)$ à partir de l'équation (3).

3 Méthodes proposées

Nous introduisons maintenant les concepts et méthodes pour résoudre le problème explicité dans la section précédente. A partir de l'éq. (1), l'ensemble des k valeurs SSI observées et des k spectres complets du patch peuvent alors être respectivement exprimés sous forme vectorielle et matricielle :

$$\underline{y} \triangleq \begin{bmatrix} y_1(\lambda_1) \\ \vdots \\ y_k(\lambda_k) \end{bmatrix}, \quad X \triangleq \begin{bmatrix} x_1(\lambda_1) & \dots & x_1(\lambda_k) \\ \vdots & & \vdots \\ x_k(\lambda_1) & \dots & x_k(\lambda_k) \end{bmatrix}. \quad (4)$$

Le problème (1) étant mal posé, nous considérons un ensemble d'hypothèses que nous présentons ci-dessous.

Hypothèse 1 (Patch pur). *Pour chaque endmember, il existe au moins un patch où seul cet endmember est présent.*

Cette hypothèse est extrêmement classique en SCA [5] et étend au niveau du patch l'hypothèse de pixel pur rencontrée en démixage hyperspectral [3]. Dans un patch où l'hypothèse 1 est vérifiée, la matrice X est de rang-1 et peut être remplacée par un vecteur $\underline{x} = [x(\lambda_1), \dots, x(\lambda_k)]$ correspondant à un endmember. En notant $\underline{\omega} \triangleq [\omega_1, \dots, \omega_k]^T$ le vecteur associé

au bruit dans le patch et

$$H \triangleq \begin{bmatrix} h_1(\lambda_1) & \dots & h_1(\lambda_k) \\ \vdots & & \vdots \\ h_k(\lambda_1) & \dots & h_k(\lambda_k) \end{bmatrix} \quad (5)$$

la matrice de filtres de Fabry-Perot, l'équation (1) s'écrit alors

$$\underline{y} = H \cdot \underline{x}^T + \underline{\omega}, \quad (6)$$

où le symbole T est la transposée. Comme cette matrice H peut être mal conditionnée pour certains filtres, nous estimons \underline{x} en résolvant un problème pénalisé de déconvolution

$$\min_{\underline{x} \geq 0} \frac{1}{2} \|\underline{y} - H \cdot \underline{x}^T\|_2^2 + \frac{\alpha}{2} \|D \cdot \underline{x}^T\|_2^2, \quad (7)$$

où D est la matrice carrée modélisant la dérivée discrète du spectre \underline{x} et α le poids associé au terme de pénalisation.

En pratique, l'erreur $\|\underline{y} - H \cdot \hat{\underline{x}}\|_2$ – où $\hat{\underline{x}}$ est le spectre estimé à partir de l'éq. (7) – fournit une mesure de la qualité d'approximation de rang-1 de la matrice X puisque cette erreur sera élevée si X est de rang supérieur à 1. A cette étape, nous avons presque une mesure d'activité mono-source – au sens des approches de SCA – et nous devons poser une hypothèse supplémentaire. Dans cet article, nous proposons deux hypothèses alternatives conduisant à deux méthodes différentes.

Hypothèse 2. *Lorsque plusieurs endmembers sont présents dans un même patch, leurs abondances varient significativement dans ce patch.*

Cette hypothèse est similaire à celle rencontrée en SCA [5]. Si elle est vérifiée, cela signifie que l'erreur $\|\underline{y} - H \cdot \hat{\underline{x}}\|_2$ devient un critère permettant de discriminer les patches purs des autres patches. Ainsi, chacun des vecteurs estimés dans les patches purs est associé à un endmember unique et leur estimation finale peut être réalisée par classification non-supervisée [5]. Dans cet article, nous choisissons la méthode K-means et la méthode proposée est appelée FPKmeans (pour *Filtered Patch and K-means-based approach*) par la suite.

Hypothèse 3. *Lorsque plusieurs endmembers sont présents dans un même patch, leurs abondances peuvent varier ou ne pas varier dans ce patch.*

Cette hypothèse est beaucoup moins restrictive que la précédente : elle implique que chaque vecteur $\hat{\underline{x}}$ associé aux plus faibles erreurs $\|\underline{y} - H \cdot \hat{\underline{x}}\|_2$ est soit un endmember soit un mélange linéaire d'endmembers. En pratique, nous considérons l'ensemble de ces vecteurs dans une matrice notée \mathbb{X} . Cette matrice est liée à la matrice des endmembers – notée F – par la relation

$$\mathbb{X} \approx \mathbb{G} \cdot F, \quad (8)$$

où \mathbb{G} est la matrice des abondances dans ces patches de rang-1. Grâce à l'hypothèse 1, l'éq. (8) décrit un problème séparable de FMN, pour laquelle de nombreuses méthodes ont été proposées. Dans cet article, nous considérons la méthode VCA [12] pour estimer F et nommons la méthode proposée associée FPCVA (pour *Filtered Patch and VCA-based approach*).

Une dernière étape consiste alors à estimer les abondances dans chacun des pixels de l'image SSI. Nous adoptons ici le formalisme de complétion de matrice de faible-rang proposé dans [2]. Au niveau d'un patch, nous considérons que

les valeurs observées $y_i(\lambda_i)$ font partie d'une matrice Y de dimension $k \times k$ partiellement observée. En notant S la matrice des endmembers convolués par H , nous obtenons la relation

$$H \circ Y \approx H \circ (G \cdot S), \quad (9)$$

où G est la matrice d'abondances dans le patch considéré. En pratique, nous initialisons G par régression au sens des moindres carrés à partir de F et du patch dématricié par une approche de la littérature [4]. Puis, nous regroupons l'ensemble de ces matrices Y pour mettre à jour globalement la matrice d'abondances, via une approche EM de FMN pondérée [6].

La structure globale des méthodes proposées est donc similaire à celle des approches de SCA [5] : (i) détection des patches purs où un seul endmember est présent, (ii) estimation des endmembers déconvolués dans ces patches et (iii) estimation des abondances. Par contre, fondée sur les mêmes hypothèses que FPKmeans, KPWNMF [2] utilise un formalisme de FMN pondérée et nécessite l'application d'une matrice de correction [13] pour estimer les endmembers finaux.

4 Validation expérimentale

Nous présentons ici des résultats expérimentaux obtenus sur des simulations d'images SSI à partir de données synthétiques. Ces dernières sont issues de [2] et consistent en deux jeux d'images : l'une (image 1) où les hypothèses 1 et 2 sont vérifiées et l'autre (image 2) où les hypothèses 1 et 3 sont valides. Dans les deux cas, les images SSI, de taille 100×100 , correspondent à des mélanges de $p = 3$ endmembers (eau, métal, béton) dont les signatures sont extraites de [1]. Nous considérons des filtres de Fabry-Perot réels pour des patches de dimension 5×5 ($k = 25$) et la matrice de correction associée [13].

Nous analysons les performances fournies par les deux méthodes proposées (FPKmeans et FPVCA) et nous les comparons avec celles obtenues par KPWNMF [2], une approche « naïve » de FMN pondérée [2] et des stratégies en deux étapes (dématriciage puis démélange). Pour le dématriciage, nous considérons 5 approches de la littérature, c.-à-d. GRMR [14], BTES [9], WB [4], PPID [10] et ItSD [11] alors que le démélange est réalisé par la même technique de FMN que celle utilisée dans un formalisme EM par les approches KPWNMF et FPKmeans. Pour cela, nous analysons leur capacité à dématricier les images SSI – obtenues par le produit $G \cdot F$ pour KPWNMF, FPKmeans et FPVCA et l'approche naïve – que nous mesurons via le *Peak Signal-to-Noise Ratio* (PSNR). La qualité de démélange est mesurée par le rapport signal à interférence (SIR) et le *Spectral Angle Mapper* (SAM) pour chaque estimation d'endmember, et par le *Mixing Error Ratio* (MER) pour mesurer la qualité d'estimation des abondances. Le poids α du terme de pénalisation dans l'éq. (7) est fixé à $\alpha = 10^{-5}$. Cette valeur a été choisie sur la base de tests préliminaires réalisés avec des SNR élevés.

La figure 2 montre les valeurs de ces critères pour chaque méthode testée, par rapport au rapport signal à bruit (SNR) d'entrée. Les tracés en haut de la figure montrent les performances obtenues pour l'image 1 alors que ceux du bas montrent celles obtenues pour l'image 2. Rappelons que les hypothèses nécessaires au bon fonctionnement de FPKmeans et de KPWNMF ne sont pas satisfaites dans l'image 2. Au contraire, FPVCA et les approches en 2 étapes (qui ne font aucune hypothèse de parcimonie) peuvent la traiter.

Tout d'abord, nous notons que les approches en deux étapes fournissent toutes des performances faibles, pour tous les critères considérés. Cela s'explique par le fait que les erreurs de dématriciage vont avoir des conséquences sur les performances de démélange. Cependant, nous pouvons noter que l'approche faisant appel à PPID pour le dématriciage fournit les meilleures performances parmi ces approches en deux étapes. Par ailleurs, la méthode naïve de FMN pondérée – fondée sur un formalisme similaire à KPWNMF mais sans hypothèse de parcimonie des abondances – fournit elle-aussi des performances faibles. Cela démontre l'intérêt des hypothèses posées dans [2] et dans cet article. Enfin, nous notons que les approches proposées surpassent l'approche KPWNMF lorsque le SNR est élevé mais cette dernière est plus robuste au bruit additif dans ces tests. Les résultats obtenus avec les approches proposées pourraient sûrement être améliorés en jouant sur le paramètre α qui a été, rappelons-le, réglé via des tests où le niveau de bruit est faible.

La figure 3 montre les endmembers estimés par les méthodes FPKmeans, KWNMF, naïve et en deux étapes avec PPID, pour l'image 1 dans un cas sans bruit. Les endmembers estimés par FPVCA ne sont pas montrés pour des raisons de place mais sont similaires à ceux obtenus avec FPKmeans. Nous pouvons constater que même si elles font appel aux mêmes hypothèses, l'approche FPKmeans fournit de bien meilleures estimations que KPWNMF : les endmembers sont parfaitement estimés avec la première alors qu'il y a des différences significatives entre les spectres théoriques et estimés avec la seconde. Enfin, l'approche naïve et celle en deux étapes fournissent de mauvaises estimations des endmembers.

5 Conclusion et perspectives

Dans cet article, nous avons proposé deux approches de démélange dédiées aux images SSI issues de caméras multispectrales « snapshot ». Ces approches font appel au même formalisme de déconvolution dans des patches de rang-1 mais diffèrent par les hypothèses de parcimonie des endmembers et les étapes qui y sont associées. Nous montrons sur des données simulées que, lorsque le rapport signal-à-bruit est élevé, ces approches surpassent une approche proposée récemment qui fait appel à des hypothèses similaires mais utilise un formalisme de complétion de matrice. Dans nos futurs travaux, nous souhaitons pouvoir tenir compte de la variabilité spectrale et appliquer ces approches sur des données réelles.

Remerciements Les travaux de K. Abbas sont financés en partie par la région Hauts-de-France. Les expériences présentées dans cet article ont été réalisées sur la plate-forme de calcul scientifique CALCULCO de l'ULCO.

Références

- [1] USGS spectral library. <https://www.usgs.gov/labs/spectroscopy-lab/science/spectral-library>, Dernier accès : 24/10/2022.
- [2] K. ABBAS, M. PUIGT, G. DELMAIRE et G. ROUSSEL : Joint unmixing and demosaicing methods for snapshot spectral images. *In Proc. ICASSP*, 2023.




FIGURE 2 : De gauche à droite : Mesures de performance (PSNR, SAM, SIR et MER) des méthodes testées par rapport au SNR d'entrée. En haut / en bas : performances obtenues pour l'image 1 (Hypothèses 1 et 2) / l'image 2 (Hypothèses 1 et 3).




FIGURE 3 : Endmembers estimés pour l'image 1.

- [3] J. M. 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. Sel. Topics Appl. Earth Observ. Remote Sens.*, 5(2):354–379, avril 2012.
- [4] J. BRAUERS et T. AACH : A color filter array based multispectral camera. In German Color GROUP, éditeur : *12. Workshop Farbbildverarbeitung*, Ilmenau, October 5-6 2006.
- [5] Y. DEVILLE : Sparse component analysis : A general framework for linear and nonlinear blind source separation and mixture identification. In *Blind Source Separation*, pages 151–196. Springer, 2014.
- [6] C. DORFFER, M. PUIGT, G. DELMAIRE et G. ROUSSEL : Fast nonnegative matrix factorization and completion using Nesterov iterations. In *Proc. LVA/ICA'17*, volume 10169 de LNCS, pages 26–35, février 2017.
- [7] K. FENG, Y. ZHAO, J. C-W CHAN, S. KONG, X. ZHANG et B. WANG : Mosaic convolution-attention network for demosaicing multispectral filter array images. *IEEE Trans. Comput. Imaging*, 7:864–878, 2021.
- [8] B. GEELLEN, C. BLANCH, P. GONZALEZ, N. TACK et A. LAMBRECHTS : A tiny VIS-NIR snapshot multispectral camera. In *Advanced Fabrication Technologies for Micro/Nano Optics and Photonics VIII*, volume 9374. International Society for Optics and Photonics, 2015.
- [9] L. MIAO, H. QI, R. RAMANATH et W.E. SNYDER : Binary tree-based generic demosaicking algorithm for multispectral filter arrays. *IEEE Trans. Image Process.*, 15(11):3550–3558, novembre 2006.
- [10] S. MIHOUBI, O. LOSSON, B. MATHON et L. MACAIRE : Multispectral demosaicing using pseudo-panchromatic image. *IEEE Trans. Comput. Imaging*, 3(4):982–995, décembre 2017.
- [11] J. MIZUTANI, S. S. OGAWA, K. SHINODA, M. HASEGAWA et S. KATO : Multispectral demosaicking algorithm based on inter-channel correlation. In *Proc. IEEE VCIP'14*, pages 474–477, 2014.
- [12] J. M. P. NASCIMENTO et J. M. BIOCAS-DIAS : Vertex component analysis : a fast algorithm to unmix hyperspectral data. *IEEE Trans. Geosci. Remote Sens.*, 43(4):898–910, 2005.
- [13] J. PICHETTE, T. GOOSSENS, K. VUNCKX et A. LAMBRECHTS : Hyperspectral calibration method for CMOS-based hyperspectral sensors. In *Photonic Instrumentation Engineering IV*, volume 10110. International Society for Optics and Photonics, SPIE, 2017.
- [14] G. TSAGKATAKIS, M. BLOEMEN, B. GEELLEN, M. JAYAPALA et P. TSAKALIDES : Graph and rank regularized matrix recovery for snapshot spectral image demosaicing. *IEEE Trans. Comput. Imaging*, 5(2):301–316, juin 2019.