

Déconvolution en ligne d’images hyperspectrales pour les imageurs de type pushbroom

Yingying SONG¹, El-Hadi DJERMOUNE¹, Jie CHEN², Cédric RICHARD³, David BRIE¹

¹CRAN, Université de Lorraine, CNRS, Vandœuvre-lès-Nancy, France

²Northwestern Polytechnical University, Xi’an, China

³Université Côte d’Azur, CNRS, OCA, Nice, France

yingying.song@univ-lorraine.fr, el-hadi.djermoune@univ-lorraine.fr
dr.jie.chen@ieee.org, cedric.richard@unice.fr, david.brie@univ-lorraine.fr

Résumé – Cet article s’intéresse à la conception d’une méthode séquentielle de déconvolution d’images hyperspectrales acquises par un imageur *pushbroom*. À partir de l’écriture sous forme séquentielle de l’image floutée, on propose un algorithme de type LMS (*least mean squares*) par bloc glissant qui inclut des termes de régularisation spatiale et spectrale. Les performances de l’algorithme sont illustrées sur des données réelles.

Abstract – This paper introduces a framework based on the least mean squares (LMS) algorithm for sequential deconvolution of hyperspectral images acquired by pushbroom imaging systems. Considering a sequential model of image blurring phenomenon, we derive a sliding-block regularized LMS algorithm with spatial and spectral regularizers. The performance of the algorithm is evaluated using real hyperspectral data.

1 Introduction

L’imagerie hyperspectrale permet de combiner les intérêts de l’imagerie numérique classique et de la spectroscopie puisque chaque pixel d’une image hyperspectrale caractérise localement le contenu spectral de l’échantillon analysé. Cette technique est utilisée dans différents domaines comme la télédétection et le contrôle industriel. Ces applications ont ouvert la voie à de nouveaux problèmes en traitement du signal et des images [1, 2]. Il existe essentiellement quatre techniques d’acquisition d’images hyperspectrales [3, 4] : whiskbroom (scan ponctuel), pushbroom (scan linéaire), filtre accordable (scan par longueur d’onde) et snapshot (acquisition en une seule passe de l’image hyperspectrale). Dans cette communication, nous nous focalisons sur les imageurs pushbroom qui sont utilisés dans de nombreuses applications telles que l’agroalimentaire [5, 6], le géoréférencement [7] et le tri de matériaux [8, 9]. Les pixels sont acquis ligne par ligne puis rangés séquentiellement pour former le cube de données en déplaçant, soit l’imageur au dessus de l’objet, soit l’objet sous l’imageur. Cet article est une première étape vers le développement de méthodes de traitement séquentiel d’images hyperspectrales qui sont nécessaires dans les applications visant à contrôler et à trier, après chaque balayage de ligne, les matériaux alimentant un processus industriel. Par exemple, c’est le cas pour les usines de papier et de panneaux de particules qui incluent des matériaux recyclés dans le processus de fabrication. Le but de cet article est de développer des algorithmes de déconvolution en ligne (séquentielle) adaptés aux imageurs pushbroom. La déconvolution d’images hyperspectrales consiste à restaurer une image à partir de mesures floutées et bruitées. Notons que l’algorithme de déconvolution séquentielle proposé peut être étendu

de manière simple aux imageurs whiskbroom. Différentes méthodes de déconvolution ont été proposées dans la littérature mais essentiellement dans un contexte hors ligne [10–15]. On cite également [16, 17] qui traitent spécifiquement de la calibration et de la déconvolution (hors ligne) pour imageurs hyperspectraux pushbroom. Considérons une image hyperspectrale $\mathbf{Y} \in \mathbb{R}^{N \times P \times K}$ acquise par un imageur pushbroom, où N , P et K représentent respectivement le nombre de mesures spatiales, spectrales et temporelles. Les échantillons à imager se déplacent à vitesse constante sur un convoyeur. L’image hyperspectrale est donc acquise tranche par tranche, chacune est notée $\mathbf{Y}_k \in \mathbb{R}^{N \times P}$. La taille de \mathbf{Y} augmente avec k qui n’est pas nécessairement fini. Les paramètres d’acquisition sont le pas d’échantillonnage spectral Δ_λ , le pas d’échantillonnage spatial Δ_s et le temps d’intégration T . Nous nous plaçons dans le cas où la réponse spectrale est suffisamment lisse pour choisir un échantillonnage spectral Δ_λ supérieur au support du flou spectral (pas de convolution spectrale) et un échantillonnage spatial Δ_s plus petit que le support de la réponse impulsionnelle de l’appareil, ce qui se traduit par un flou spatial. On considère également que T est petit (pour une acquisition rapide), ce qui conduit à un faible rapport signal à bruit (RSB). Il en résulte un modèle de dégradation impliquant uniquement un flou spatial (éventuellement dépendant de la longueur d’onde) de l’image hyperspectrale et un faible RSB. Ceci motive le développement d’un algorithme de déconvolution séquentielle permettant de restaurer en ligne une image hyperspectrale \mathbf{X} à partir de l’observation \mathbf{Y} floutée et bruitée. La contribution essentielle de ce travail est de poser le problème de déconvolution séquentielle dans un contexte LMS. Bien que l’algorithme proposé s’apparente aux algorithmes de type LMS utilisés en

identification [18–20] et en restauration adaptative d’images super-résolues [21, 22], la déconvolution séquentielle d’image par un algorithme de type LMS n’a jamais été rapportée dans la littérature. La prise en compte des spécificités du processus d’acquisition nous amène à proposer un algorithme LMS par bloc glissant qui permet de restaurer séquentiellement l’image hyperspectrale avec un retard Q . On introduit également des termes de régularisation favorisant la reconstruction d’objets constants par morceaux posés sur un fond à valeur nulle.

2 Noyau de convolution et causalité

On discute dans cette section de la causalité du noyau de convolution et des estimateurs associés. D’après [14], une image hyperspectrale floutée résulte de P convolutions spatiales simultanées. Pour chaque longueur d’onde λ_p , l’image spatiale floutée $\mathbf{Y}^p \in \mathbb{R}^{N \times K}$ s’exprime par la convolution 2D :

$$\mathbf{Y}^p = \bar{\mathbf{H}}^p * \mathbf{X}^p + \mathbf{Z}^p \quad (1)$$

où $*$ est l’opérateur de convolution 2D, $\mathbf{X}^p \in \mathbb{R}^{N \times K}$ l’image à restaurer, $\bar{\mathbf{H}}^p \in \mathbb{R}^{M \times L}$ le noyau de convolution, et \mathbf{Z}^p le bruit supposé additif et i.i.d. Le modèle (1) peut s’écrire sous une forme séquentielle causale. On se concentre sur le problème 2D et, sans perte de généralité, la dépendance par rapport à p est omise. L’image \mathbf{Y} acquise séquentiellement est représentée par une suite de vecteurs $\mathbf{y}_k := [y_{1,k}, \dots, y_{N,k}]^\top$, $k = 1, \dots, K$, où $^\top$ est l’opérateur de transposition matricielle. Les mêmes notations sont utilisées pour \mathbf{X} . On suppose également que le noyau de convolution est de longueur L finie selon la dimension temporelle, qu’il est centré sur 0, *i.e.* que les valeurs passées et futures de \mathbf{x}_k contribuent à l’observation \mathbf{y}_k . Pour rendre le noyau de convolution causal¹, il est nécessaire de décaler les observations de $(L-1)/2$ échantillons, *i.e.*, $\tilde{\mathbf{y}}_k = \mathbf{y}_{k-(L-1)/2}$. En posant $\bar{\mathbf{H}} = [\mathbf{h}_L, \dots, \mathbf{h}_1]$ avec $\mathbf{h}_\ell = [h_{M,\ell}, \dots, h_{1,\ell}]^\top$, le modèle (1) s’exprime selon :

$$\tilde{\mathbf{y}}_k = \mathbf{y}_{k-(L-1)/2} = \sum_{\ell=1}^L \mathbf{H}_\ell \mathbf{x}_{k-\ell+1} + \mathbf{z}_k \quad (2)$$

où \mathbf{z}_k est le bruit de mesure de moyenne nulle, statistiquement indépendant des autres signaux. \mathbf{H}_ℓ est la matrice Toeplitz de dimension $N \times N$ dont la première colonne et la première ligne sont $[h_{1,\ell}, \dots, h_{M,\ell}, 0, \dots, 0]$ et $[h_{1,\ell}, 0, \dots, 0]$, respectivement. La relation (2) introduit un retard dans les dimensions spatiale et temporelle car le filtre est rendu causal selon ces deux dimensions. Un autre aspect concerne la causalité de l’estimateur de \mathbf{x}_k . D’une part, \mathbf{x}_k intervient dans les observations passées et futures ($\mathbf{y}_{k-(L-1)/2}, \dots, \mathbf{y}_k, \dots, \mathbf{y}_{k+(L-1)/2}$). D’autre part, l’estimation optimale de \mathbf{x}_k nécessite de disposer des estimations passées et futures ($\dots, \hat{\mathbf{x}}_{k-2}, \hat{\mathbf{x}}_{k-1}, \hat{\mathbf{x}}_{k+1}, \hat{\mathbf{x}}_{k+2}, \dots$). Ceci interdit de pouvoir estimer \mathbf{x}_k de façon séquentielle. Pour pallier ce problème, nous proposons de produire une estimée de $\hat{\mathbf{x}}_k$ avec un retard Q . En d’autres termes, nous devons estimer \mathbf{x}_{k-Q+1}

connaissant ($\mathbf{y}_{k+(L-1)/2-Q+1}, \dots, \mathbf{y}_{k+(L-1)/2}$), les estimées postérieures ($\hat{\mathbf{x}}_k, \hat{\mathbf{x}}_{k-1}, \dots, \hat{\mathbf{x}}_{k-Q+2}$) ainsi que les estimées antérieures ($\hat{\mathbf{x}}_{k-Q}, \hat{\mathbf{x}}_{k-Q-1}, \dots, \hat{\mathbf{x}}_{k-Q-L+2}$). Le développement de l’algorithme LMS par bloc glissant repose essentiellement sur cette idée.

3 Déconvolution séquentielle d’images

Considérons tout d’abord le problème de la déconvolution séquentielle dans le cas d’images 2D. L’approche sera ensuite étendue au cas des images hyperspectrales. L’estimation séquentielle de \mathbf{x}_{k-Q+1} utilise les observations ($\mathbf{y}_{k+(L-1)/2-Q+1}, \dots, \mathbf{y}_{k+(L-1)/2}$) ou, de façon équivalente, les observations retardées ($\tilde{\mathbf{y}}_{k-Q+1}, \dots, \tilde{\mathbf{y}}_k$). Dans la suite, pour simplifier les notations, \mathbf{y}_k désignera l’observation retardée $\tilde{\mathbf{y}}_k$. Pour tenir compte de leur dépendance de $\mathbf{x}_k, \dots, \mathbf{x}_{k-Q-L+2}$, nous considérons le critère suivant :

$$\begin{aligned} \mathcal{J}(\mathbf{x}_k, \dots, \mathbf{x}_{k-Q-L+2}) = & \sum_{q=1}^Q \mathbb{E} \left\| \mathbf{y}_{k-q+1} - \sum_{\ell=1}^L \mathbf{H}_\ell \mathbf{x}_{k-q-\ell+2} \right\|_2^2 + \eta_z \|\mathbf{x}_{k-q+1}\|_1 \\ & + \eta_s \sum_{q=1}^Q \|\mathbf{D}_N \mathbf{x}_{k-q+1}\|_1 + \eta_t \sum_{q=1}^{Q-1} \|\mathbf{x}_{k-q+1} - \mathbf{x}_{k-q}\|_1 \end{aligned} \quad (3)$$

où \mathbb{E} est l’espérance mathématique, $\|\cdot\|_1$ désigne la norme ℓ_1 . On définit le filtre de dérivation de premier ordre \mathbf{D}_N comme une matrice Toeplitz de dimension $(N-1) \times N$ dont la première colonne et la première ligne sont données respectivement par $[1, 0, \dots, 0]$ et $[1, -1, 0, \dots, 0]$. Les termes de régularisation $\|\mathbf{D}_N \mathbf{x}_{k-q+1}\|_1$ et $\|\mathbf{x}_{k-q+1} - \mathbf{x}_{k-q}\|_1$ permettent de restaurer des signaux constants par morceaux selon les dimensions spatiale et temporelle, respectivement. Le terme de régularisation $\|\mathbf{x}_{k-q+1}\|_1$ (en anglais : *zero-attracting*) favorise la suppression de la réponse du tapis du convoyeur qui est idéalement nulle. Le choix de ces termes de régularisation est motivé par l’application visée, à savoir l’inspection d’objets posés sur un convoyeur. Pour une longueur d’onde donnée, la réponse du convoyeur après la suppression de l’arrière-plan est proche de zéro alors que celle des objets est supposée constante par morceaux. Les degrés de régularisation spatiale et temporelle (dérivées premières) sont contrôlés par les coefficients $\eta_s \geq 0$ et $\eta_t \geq 0$, respectivement. La régularisation *zero-attracting* est contrôlée par $\eta_z \geq 0$.

3.1 LMS régularisé par bloc glissant

L’algorithme LMS régularisé par bloc glissant (*Sliding-Block Regularized LMS* : SBR-LMS) est introduit dans cette section. Soient les données vectorisées $\mathbf{x}'_k \triangleq \text{col}\{\mathbf{x}_{k-q+1}\}_{q=1}^{Q+L-1}$ et $\mathbf{y}'_k \triangleq \text{col}\{\mathbf{y}_{k-q+1}\}_{q=1}^{Q+L-1}$, où $\text{col}\{\cdot\}$ est l’opérateur d’empilement lexicographique des vecteurs fournis en argument. Le sous-gradient de (3) s’écrit :

$$\nabla \mathcal{J}(\mathbf{x}'_k) \triangleq \text{col} \left\{ \frac{\partial \mathcal{J}}{\partial \mathbf{x}_k}, \dots, \frac{\partial \mathcal{J}}{\partial \mathbf{x}_{k-Q+1}}, \mathbf{0}_{(L-1)N \times 1} \right\} \quad (4)$$

1. Pour simplifier, L est supposé impair.

où $\mathbf{0}_{I \times J}$ est la matrice de dimension $I \times J$ contenant des 0. À noter qu'il est nécessaire d'inclure les variables $\hat{\mathbf{x}}_{k-Q}, \hat{\mathbf{x}}_{k-Q-1}, \dots, \hat{\mathbf{x}}_{k-Q-L+2}$ dans \mathbf{x}'_k car \mathbf{x}_{k-Q+1} en dépend. Comme elles sont fixées, le sous-gradient par rapport à ces variables est égal à 0. En approximant le sous-gradient (4) par sa valeur instantanée, on obtient :

$$\begin{aligned} \nabla \mathcal{J}(\mathbf{x}'_k) = & -2\Phi(\mathbf{y}'_k - \mathbf{G}\mathbf{x}'_k) + \eta_z \text{sign}(\mathbf{x}'_k) \\ & + \eta_s \mathbf{D}_s^\top \text{sign}(\mathbf{D}_s \mathbf{x}'_k) + \eta_t \mathbf{D}_t^\top \text{sign}(\mathbf{D}_t \mathbf{x}'_k) \end{aligned} \quad (5)$$

où Φ et \mathbf{G} sont des matrices de dimension $(Q+L-1)N \times (Q+L-1)N$. La matrice Φ est donnée par :

$$\Phi \triangleq \left[\begin{array}{ccc|ccc} \mathbf{H}_1^\top & & & & & \\ \vdots & & & & & \\ \mathbf{H}_Q^\top & & & & & \\ \hline & & & \mathbf{0}_{(L-1)N \times QN} & & \\ & & & & & \mathbf{0}_{(L-1)N \times (L-1)N} \end{array} \right],$$

avec $\mathbf{H}_\ell = \mathbf{0}_{N \times N}$ pour $\ell > L$, et \mathbf{G} la matrice bloc-Toeplitz dont le premier bloc-colonne est $[\mathbf{H}_1, \mathbf{0}_{N \times N}, \dots, \mathbf{0}_{N \times N}]$ et le premier bloc-ligne est $[\mathbf{H}_1, \dots, \mathbf{H}_L, \mathbf{0}_{N \times N}, \dots, \mathbf{0}_{N \times N}]$. Les filtres de dérivée première selon les dimensions spatiale et temporelle sont :

$$\begin{aligned} \mathbf{D}_s & \triangleq [\mathbf{I}_Q \otimes \mathbf{D}_N \quad \mathbf{0}_{Q(N-1) \times (L-1)N}] \\ \mathbf{D}_t & \triangleq [\mathbf{D}_Q \otimes \mathbf{I}_N \quad \mathbf{0}_{(Q-1)N \times (L-1)N}], \end{aligned}$$

où \otimes représente le produit de Kronecker et \mathbf{I}_J la matrice identité de dimension $J \times J$. La fonction $\text{sign}(\cdot)$ est définie selon $\text{sign}(x) = 0$ si $x = 0$, et $\text{sign}(x) = x/|x|$ sinon. L'algorithme SBR-LMS pour la déconvolution d'images 2D s'écrit :

$$\begin{aligned} \hat{\mathbf{x}}'_{k+1} & = \Omega \hat{\mathbf{x}}'_k - \frac{\mu}{2} \nabla \mathcal{J}(\hat{\mathbf{x}}'_k) \\ & = \Omega \hat{\mathbf{x}}'_k + \mu \Phi(\mathbf{y}'_k - \mathbf{G}\hat{\mathbf{x}}'_k) - \rho_z \text{sign}(\hat{\mathbf{x}}'_k) \\ & \quad - \rho_s \mathbf{D}_s^\top \text{sign}(\mathbf{D}_s \hat{\mathbf{x}}'_k) - \rho_t \mathbf{D}_t^\top \text{sign}(\mathbf{D}_t \hat{\mathbf{x}}'_k) \end{aligned} \quad (6)$$

où μ est le pas qui contrôle la vitesse de convergence et la stabilité de l'algorithme, $\rho_s = \mu\eta_s/2$, $\rho_t = \mu\eta_t/2$ et $\rho_z = \mu\eta_z/2$. La matrice Ω est donnée par :

$$\Omega \triangleq \begin{bmatrix} \mathbf{I}_{(Q-1)N} & \mathbf{0} & \mathbf{0} & \mathbf{0}_{(Q-1)N \times N} \\ \mathbf{0} & \mathbf{I}_N & \mathbf{0} & \mathbf{0}_{N \times N} \\ \mathbf{0} & \mathbf{0} & \mathbf{I}_N & \mathbf{0}_{N \times N} \\ \mathbf{0} & \mathbf{0} & \mathbf{I}_{(L-2)N} & \mathbf{0}_{(L-2)N \times N} \end{bmatrix}.$$

L'estimée finale $\hat{\mathbf{x}}_{k-Q+2}$ est obtenue par la sélection du Q^{e} bloc du vecteur $\hat{\mathbf{x}}'_{k+1}$, c'est-à-dire :

$$\hat{\mathbf{x}}_{k-Q+2} = \mathbf{S} \hat{\mathbf{x}}'_{k+1} \quad (7)$$

où $\mathbf{S} \triangleq [\mathbf{0}_{N \times (Q-1)N}, \mathbf{I}_N, \mathbf{0}_{N \times (L-1)N}]$. Quand $Q = 1$ et $\rho_s = \rho_t = 0$, l'algorithme (6) correspond au *Zero-Attracting LMS* (ZA-LMS) proposé par [19, 23] pour l'identification par-cimonieuse de systèmes dynamiques.

3.2 Déconvolution séquentielle d'images hyperspectrales

On considère maintenant la déconvolution d'images hyperspectrales 3D qui vise à restaurer séquentiellement les tranches

spatio-spectrales $\mathbf{X}_k \in \mathbb{R}^{N \times P}$. On considère donc les tranches hyperspectrales vectorisées :

$$\mathbf{x}'_k \triangleq \text{col} \{ \mathbf{x}'_k{}^p \}_{p=1}^P, \quad \mathbf{y}'_k \triangleq \text{col} \{ \mathbf{y}'_k{}^p \}_{p=1}^P$$

où l'exposant p représente l'indice de la bande spectrale. Un terme de douceur spectrale est ajouté, ce qui conduit au critère :

$$\mathcal{C}(\mathbf{x}'_k) = \sum_{p=1}^P \mathcal{J}(\mathbf{x}'_k{}^p) + \eta_\lambda \|\Lambda_\lambda \mathbf{x}'_k\|^2 \quad (8)$$

où $\Lambda_\lambda \triangleq (\text{diag}(c_1, \dots, c_{P-1}) \mathbf{D}_P) \otimes \mathbf{I}_{(Q+L-1)N}$ est un opérateur de dérivée première selon la dimension spectrale pondéré par les coefficients $\{c_p\}_{p=1}^{P-1}$. Le paramètre η_λ contrôle le poids du terme de douceur spectrale. L'algorithme SBR-LMS final est donnée par :

$$\begin{aligned} \hat{\mathbf{x}}'_{k+1} & = \Gamma \hat{\mathbf{x}}'_k + \mu \Psi(\mathbf{y}'_k - \Upsilon \hat{\mathbf{x}}'_k) - \rho_z \text{sign}(\hat{\mathbf{x}}'_k) \\ & \quad - \rho_s \Lambda_s^\top \text{sign}(\Lambda_s \hat{\mathbf{x}}'_k) - \rho_t \Lambda_t^\top \text{sign}(\Lambda_t \hat{\mathbf{x}}'_k) \\ & \quad - \mu \eta_\lambda \Lambda_\lambda^\top \Lambda_\lambda \hat{\mathbf{x}}'_k \end{aligned} \quad (9)$$

avec : $\Gamma \triangleq \mathbf{I}_P \otimes \Omega$, $\Psi \triangleq \text{blkdiag}\{\Phi^p\}_{p=1}^P$ une matrice bloc-diagonale, $\Upsilon \triangleq \text{blkdiag}\{\mathbf{G}^p\}_{p=1}^P$, $\Lambda_s \triangleq \mathbf{I}_P \otimes \mathbf{D}_s$, et $\Lambda_t \triangleq \mathbf{I}_P \otimes \mathbf{D}_t$.

4 Résultats expérimentaux

Dans cette section, on présente un résultat de l'algorithme SBR-LMS appliqué sur une image hyperspectrale floutée réelle de dimension $121 \times 171 \times 16$ avec des longueurs d'onde variant entre 501.1 nm et 868.6 nm par pas de 24.5 nm. La réponse du convoyeur a été estimée dans une zone de dimension 120×120 puis soustraite à l'image réelle. L'échantillon imagé est une pièce métallique. Le noyau de convolution a été estimé à partir de données de calibration : un noyau gaussien de taille 21×21 et de largeur à mi-hauteur de 10 points. Toutes les opérations de convolution sont implantées dans le domaine de Fourier. Les coefficients c_p sont fixés à 1. La figure 1 montre le résultat obtenu par SBR-LMS appliqué sur toute l'image hyperspectrale (seules 3 bandes spectrales sont montrées : 501.1 nm, 672.6 nm, 844.1 nm). L'image originale est montrée sur la figure 1(a). L'image restaurée par SBR-LMS ($\mu = 0.009$, $Q = 21$, $\rho_s = \rho_t = 1 \cdot 10^{-4}$, $\rho_z = 3 \cdot 10^{-4}$, $\eta_\lambda = 0.001$) est montrée sur la figure 1(b). Celle-ci illustre le gain en termes de défloutage et de débruitage apportés par la déconvolution séquentielle. Le résultat du SBR-LMS est comparé à celui des algorithmes classiques de déconvolution hors ligne proposés dans [14]. La figure 1(c) correspond à une régularisation ℓ_2 spatiale et spectrale de type Tikhonov (RT) et la figure 1(d) correspond à une régularisation de Tikhonov sous contrainte de non-négativité (RTNN). Les résultats de la déconvolution séquentielle ont une résolution similaire à celle de RT et RTNN. Le niveau de bruit sur le fond est semblable à celui obtenu avec RTNN, mais le coût de calcul de SBR-LMS reste du même ordre que celui de RT et est beaucoup plus faible que celui de RTNN. Compte tenu du manque de place, d'autres

résultats permettant d'évaluer l'influence des différents paramètres (Q , ρ_s , ρ_t , ρ_z) sont disponibles dans [24] et seront présentés au colloque Gretsri.

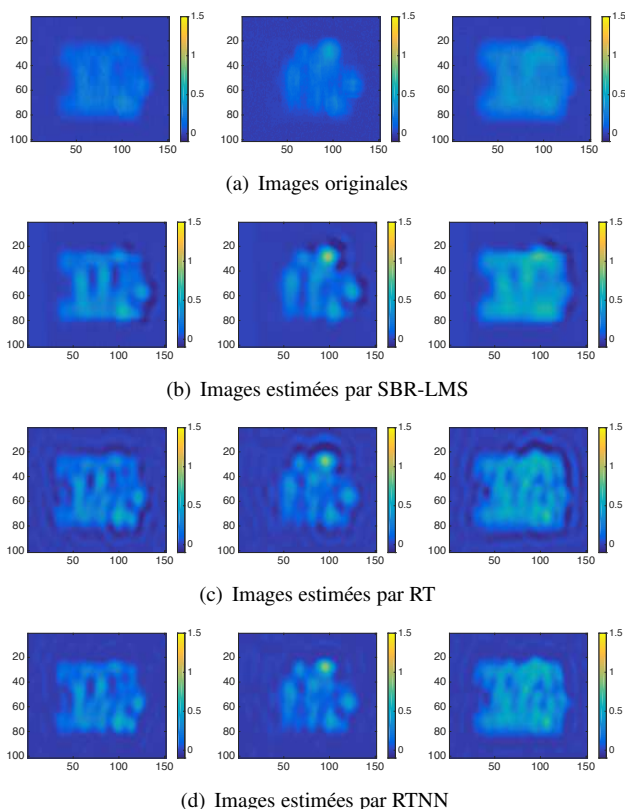


FIGURE 1: Image hyperspectrale restaurée

5 Conclusion

Nous avons considéré le problème de la déconvolution séquentielle d'images hyperspectrales collectées par un imageur pushbroom. Quelques problèmes relatifs à la non-causalité du modèle et des estimateurs ont été discutés. Pour y remédier, une approche originale a été proposée. Les performances de l'algorithme résultant (SBR-LMS) ont été illustrées sur une image hyperspectrale réelle. Nos travaux actuels concernent l'étude des propriétés de convergence de l'algorithme SBR-LMS et l'analyse de ses propriétés statistiques.

Références

- [1] J. Chen, C. Richard, and P. Honeine, "Nonlinear unmixing of hyperspectral data based on a linear-mixture/nonlinear-fluctuation model," *IEEE Transactions on Signal Processing*, vol. 61, no. 2, pp. 480–492, 2013.
- [2] R. Ammanouil, A. Ferrari, C. Richard, and D. Mary, "Blind and fully constrained unmixing of hyperspectral images," *IEEE Transactions on Image Processing*, vol. 23, no. 12, pp. 5510–5518, 2014.
- [3] R. M. Willett, M. F. Duarte, M. A. Davenport, and R. G. Baraniuk, "Sparsity and structure in hyperspectral imaging : sensing, reconstruction, and target detection," *IEEE Signal Processing Magazine*, vol. 31, no. 1, pp. 116–126, 2014.

- [4] Q. Li, X. He, Y. Wang, H. Liu, D. Xu, and F. Guo, "Review of spectral imaging technology in biomedical engineering : achievements and challenges," *Journal of biomedical optics*, vol. 18, no. 10, pp. 100901–100901, 2013.
- [5] Y. R. Chen, R. W. Huffman, B. Park, and M. Nguyen, "Transportable spectrophotometer system for on-line classification of poultry carcasses," *Applied Spectroscopy*, vol. 50, no. 7, pp. 910–916, 1996.
- [6] H. Huang, L. Liu, and M. O. Ngadi, "Recent developments in hyperspectral imaging for assessment of food quality and safety," *Sensors*, vol. 14, no. 4, pp. 7248–7276, 2014.
- [7] C. Cariou and K. Chehdi, "Automatic georeferencing of airborne pushbroom scanner images with missing ancillary data using mutual information," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 46, no. 5, pp. 1290–1300, 2008.
- [8] P. Tatzert, M. Wolf, and T. Panner, "Industrial application for inline material sorting using hyperspectral imaging in the NIR range," *Real-Time Imaging*, vol. 11, no. 2, pp. 99–107, 2005.
- [9] Pellenc Selective Technology, "Mistral product." <http://www.pellencst.com/products>. Accessed : 2016-09-01.
- [10] B. R. Hunt and O. Kubler, "Karhunen-Loeve multispectral image restoration, part I : Theory," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 32, no. 3, pp. 592–600, 1984.
- [11] N. P. Galatsanos, A. K. Katsaggelos, R. T. Chin, and A. D. Hillery, "Digital restoration of multichannel images," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 37, no. 3, pp. 415–421, 1989.
- [12] N. P. Galatsanos, A. K. Katsaggelos, R. T. Chin, and A. D. Hillery, "Least squares restoration of multichannel images," *IEEE Transactions on Signal Processing*, vol. 39, no. 10, pp. 2222–2236, 1991.
- [13] J. F. Giovannelli and A. Coulais, "Positive deconvolution for superimposed extended source and point sources," *Astronomy & Astrophysics*, vol. 439, no. 1, pp. 401–412, 2005.
- [14] S. Henrot, C. Soussen, and D. Brie, "Fast positive deconvolution of hyperspectral images," *IEEE Transactions on Image Processing*, vol. 22, no. 2, pp. 828–833, 2013.
- [15] X. Zhao, F. Wang, T. Huang, M. K. Ng, and R. J. Plemmons, "Deblurring and sparse unmixing for hyperspectral images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 7, pp. 4045–4058, 2013.
- [16] J. Jemec, F. Pernuš, B. Likar, and M. Bürmen, "Push-broom hyperspectral image calibration and enhancement by 2d deconvolution with a variant response function estimate," *Optics express*, vol. 22, no. 22, pp. 27655–27668, 2014.
- [17] J. Jemec, F. Pernuš, B. Likar, and M. Bürmen, "Deconvolution-based restoration of swir pushbroom imaging spectrometer images," *Optics express*, vol. 24, no. 21, pp. 24704–24718, 2016.
- [18] B. Widrow and S. D. Stearns, *Adaptive signal processing*. Englewood Cliffs, NJ, Prentice-Hall, Inc., 1985.
- [19] Y. Chen, Y. Gu, and A. O. Hero, "Regularized least-mean-square algorithms," *arXiv preprint arXiv :1012.5066*, 2010.
- [20] J. Chen, C. Richard, J.-C. M. Bermudez, and P. Honeine, "Nonnegative least-mean-square algorithm," *IEEE Transactions on Signal Processing*, vol. 59, no. 11, pp. 5225–5235, 2011.
- [21] M. Elad and A. Feuer, "Superresolution restoration of an image sequence : adaptive filtering approach," *IEEE Transactions on Image Processing*, vol. 8, no. 3, pp. 387–395, 1999.
- [22] G. H. Costa and J.-C. M. Bermudez, "Statistical analysis of the LMS algorithm applied to super-resolution image reconstruction," *IEEE Transactions on Signal Processing*, vol. 55, pp. 2084–2095, May 2007.
- [23] J. Chen, C. Richard, Y. Song, and D. Brie, "Transient performance analysis of zero-attracting LMS," *arXiv preprint arXiv :1608.07046*, 2016.
- [24] Y. Song, E.-H. Djerroune, J. Chen, C. Richard, and D. Brie, "Online deconvolution for pushbroom hyperspectral imaging systems : LMS algorithms and stochastic analysis," research report, CRAN, 2017.