

Modèle bayésien hiérarchique pour le démixage et la classification robuste d'images hyperspectrales

Adrien Lagrange¹

Mathieu Fauvel²

Stéphane May³

Nicolas Dobigeon¹

¹ IRIT/INP-ENSEEIH, Toulouse

² INP-ENSAT, UMR 1201 DYNAFOR

³ Centre National d'Études Spatiales (CNES), Toulouse

prenom.nom@{enseeih, ensat, cnes, seeeih}.fr

1 Introduction

L'interprétation des images hyperspectrales demeure un problème complexe qui a été abordée sous différents paradigmes. En particulier, les techniques de classification supervisée [1, 2] et de démixage spectral [3] sont deux familles de méthodes d'interprétation largement utilisées. Ces deux approches offrent des analyses complémentaires : le démixage spectral propose une modélisation basée sur une interprétation physique des images hyperspectrales, en supposant que chaque pixel est un mélange de spectres purs associés aux divers matériaux présents dans la scène, tandis que la classification supervisée cherche à identifier une classe unique par pixel en se basant sur un ensemble de classes sémantiques définies par l'utilisateur et sur un ensemble de données, labellisées par un expert, lui servant d'exemple. Si ces deux techniques ont été largement discutées dans la littérature, elles ont été rarement utilisées conjointement [4, 5].

L'interprétation d'images hyperspectrales pose des problèmes notamment dus à la grande dimension (fléau de la dimension). Une approche couramment utilisée est de réduire la dimension par des techniques de décomposition, comme l'analyse en composantes principales, ou bien encore par des méthodes de sélection de variables a priori ou durant l'interprétation des données. De ce point de vue, le démixage spectral peut être vu comme une méthode de décomposition sur une base réduite, supportée par une interprétation physique. D'autres problèmes surviennent également lors de la classification. En particulier, la multi-modalité des classes définies peut poser des problèmes notamment pour les approches bayésiennes. Par exemple, avec un classifieur bayésien gaussien, chaque classe est modélisée par une loi normale multivariée ce qui ne prend pas en compte le caractère potentiellement multi-modal des classes. Les approches faisant intervenir une modélisation sous forme de mélange de distributions pour chaque classe [6] prennent alors tout leur sens et permettent en plus de visualiser a posteriori les composantes du mélange, ce qui peut présenter un intérêt lors de l'interprétation des résultats.

Une autre problématique importante de la classification est le problème des erreurs dans les bases d'entraînement. Créées par des experts, elles peuvent contenir des ambiguïtés géométriques ou bien des erreurs dues à une obsolescence partielle de la vérité terrain. Il est donc important de disposer de méthodes robustes à ces erreurs. Des algorithmes bayésiens classiques tel que le modèle gaussien classique, où chaque classe est modélisée par une distribution gaussienne, sont généralement peu robustes à ce type d'erreurs.

Nous présentons dans ce papier un modèle permettant d'unifier les approches de classification et de démixage. Un tel modèle permet de pallier certaines limitations de la classification tout en introduisant le concept de démixage dans un contexte supervisé, tirant ainsi parti des données externes labellisées. Pour cela, un modèle bayésien hiérarchique est proposé permettant de relier les différents niveaux d'interprétation que sont le démixage hyperspectral (modélisation physique bas-niveau) et la classification supervisée (modélisation sémantique haut-niveau) via une étape de clustering (lien entre bas-niveau et haut-niveau).

2 Modèle bayésien hiérarchique

Le cadre de la modélisation bayésienne a été choisi pour profiter d'une part de sa flexibilité et d'autre part des travaux déjà réalisés pour le problème de démixage. Le modèle proposé est représenté par son graphe de dépendance à la




FIGURE 1 – Graphe direct acyclique de dépendance du modèle proposé. Les variables entourées de pointillés sont supposées connues ou estimées en amont.

la

Figure 1 et est décrit de manière détaillé dans [7]. Nous proposons de modéliser les données hyperspectrales par trois niveaux de représentation, chacun composé d’un ensemble de variables à estimer. Des lois a priori sont définies pour chacune des variables permettant une estimation à l’aide d’un algorithme de Monte Carlo par chaîne de Markov à travers l’échantillonnage des lois a posteriori. Nous décrivons dans ce qui suit les différents niveaux du modèle.

Modèle de mélange Le démélange spectral correspond au premier niveau du modèle. Un modèle conventionnel de mélange linéaire est considéré. Une observation y_p , i.e., un pixel, est ainsi modélisé comme une combinaison linéaire de spectres purs \mathbf{M} corrompue par un bruit gaussien de variance s^2 . La tâche de démélange en elle-même revient donc à estimer les proportions de mélange décrites par un vecteurs de proportion \mathbf{a}_p , appelé vecteur d’abondances.

Clustering Le clustering intervient comme lien entre le démélange et la classification et permet en particulier de prendre en compte la multi-modalité des classes. L’hypothèse de départ, proposée dans [8], consiste à dire que, dans l’ensemble des vecteurs d’abondances, il existe des clusters statistiquement homogènes supposés gaussiens de moyenne Ψ_k et de matrice de covariance Σ_k diagonale. De plus, les loi a priori sur Ψ_k et Σ_k sont choisies de sorte à imposer une contrainte de *somme-à-un* sur Ψ_k (qui représente un vecteur de proportion) et à maintenir un a priori vague sur les deux variables. Le lien avec la classification se fait par la méthode de régularisation employée sur les labels de cluster z_p . Une régularisation est introduite par le biais d’un champ de Markov aléatoire (MRF) [9]. Elle inclut une régularisation spatiale, paramétrée par β_1 , ainsi qu’une régularisation par rapport aux labels de classification ω_p . Une matrice \mathbf{Q} est estimée de sorte que $E[q_{k,j}|\mathbf{z}, \omega]$ soit un estimateur empirique de la probabilité d’appartenir au cluster k sachant l’appartenance à la classe j .

Classification La dernière étape consiste à estimer les labels de classification connaissant l’ensemble d’entraînement et les labels de clusters. Un MRF est à nouveau utilisé comme loi a priori sur les ω_p . Ce MRF possède encore une fois deux potentiels de régularisation. Le premier est un potentiel de régularisation spatiale de paramètre β_2 fixé. Le second potentiel régularise par rapport aux labels fournis par les experts. Si un pixel appartient à l’ensemble d’entraînement, sa classe estimée aura tendance à être identique à celle proposée par l’expert. Cette tendance est pondérée par un paramètre η entre 0 et 1 mesurant la confiance que l’on a dans l’expert (probabilité a priori que l’expert ait raison). Si η vaut 1, on est toujours d’accord avec l’expert sinon on s’autorise avec un certain degré à corriger les labels de l’expert. L’estimation devient donc robuste aux erreurs dans la base d’entraînement et propose de plus une correction de celle-ci.

3 Expérimentations




FIGURE 2 – (a) Composition colorée de l’image réelle, (b) vérité terrain, (c) vérité terrain pour l’entraînement, (d) clusters estimés, (e) classification réalisée par le modèle proposé, (f) classification réalisée avec un modèle gaussien.

Nous avons conduit des expérimentations sur une image hyperspectrale de taille 1756×1522 pixels du jeu de données MUESLI composée de 321 bandes spectrales avec 12 spectres purs extraits a priori à l’aide de l’algorithme VCA. Les données sont présentées dans la Figure 2 avec la vérité terrain associée réalisée par des experts. Celle-ci contient 4 classes (cultures, prairies, zones arborées, zones artificielles (bâti, route,...)) qui sont par nature multi-modales. La Figure 2 présente également les résultats obtenus par la méthode proposée : les clusters estimés et la classification réalisée. De plus, la classification a également été réalisée à l’aide d’un modèle bayésien gaussien (GMM). Chaque classe est alors modélisée par une distribution gaussienne dont les paramètres sont appris sur les échantillons de la base d’entraînement. Les résultats obtenus sont en grande partie concordant entre les deux classifieurs.

TABLE 1 – Résultats de classification. Cas 1 : cas standard ; Cas 2 : 30% des labels d’entraînement corrompus

		Cohen’s kappa	Score-F1 moyen	Temps
Cas 1	Mod. proposé	0.46	0.52	41.4h
	GMM	0.62	0.66	5min
Cas 2	Mod. proposé	0.54	0.60	48.7h
	GMM	0.52	0.59	6min

Cependant, les résultats quantitatifs présentés dans le Tableau 1 montrent que le GMM obtient des résultats significativement meilleurs dans un cas classique (cas 1) mais beaucoup moins riches comme illustré par la suite.

Il est possible de remarquer au travers des résultats de clustering que le caractère multi-modal des classes a bien été pris en compte. Par exemple, dans le zoom Figure 2 (d), il est possible de remarquer un cluster marron foncé correspondant aux champs labourés ou encore un cluster rose correspondant aux céréales à pailles, tous les deux appartenant à la classe culture. Les spectres moyens des clusters représentant au moins 5% de l'image sont présentés Figure 3. Les spectres moyens des clusters appartenant à la classe zones arborées sont présentés Figure 3. L'accès à ce type d'information est un des atouts majeurs de la méthode proposée. L'utilisateur peut par ce biais avoir une interprétation beaucoup plus fine des résultats au prix d'un temps de calcul accru comme le montre la Table 1. De même, la matrice Q , illustré Figure 4, contribue à la richesse d'interprétation en montrant la répartition des classes dans les différents clusters. La classe #3 est composée de 5 clusters dont le cluster #7 très majoritaire à plus de 40%.




FIGURE 3 – Spectres moyens de la classe zone arborée.




FIGURE 4 – Matrice Q estimée.

Afin de tester la robustesse aux erreurs dans la base d'entraînement, une deuxième expérimentation a été réalisée en corrompant les labels de vérité terrain. Dans ce deuxième cas, chaque label de la base d'entraînement a une probabilité de 30% d'avoir été changé en un autre label. Les résultats quantitatifs sur la base de test, présentés Table 1, montrent que la classification n'a souffert d'aucune dégradation avec le modèle proposé. Les performances du modèle bayésien classique ont par contre diminué significativement, ce qui est attendu, étant donné que l'estimation des paramètres des gaussiennes n'est pas robuste au bruit.

Références

- [1] M. Fauvel, Y. Tarabalka, J. A. Benediktsson, J. Chanussot, and J. C. Tilton, "Advances in spectral-spatial classification of hyperspectral images," *Proc. IEEE*, vol. 101, pp. 652–675, 2013.
- [2] M. Dalla Mura, A. Villa, J. A. Benediktsson, J. Chanussot, and L. Bruzzone, "Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis," *IEEE Geosci. Remote Sens. Lett.*, vol. 8, pp. 542–546, 2011.
- [3] J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader, and J. Chanussot, "Hyperspectral Unmixing Overview : Geometrical, Statistical, and Sparse Regression-Based Approaches," *IEEE J. Sel. Topics Appl. Earth Observ. in Remote Sens.*, vol. 5, pp. 354–379, 2012.
- [4] A. Villa, J. Li, A. Plaza, and J. M. Bioucas-Dias, "A new semi-supervised algorithm for hyperspectral image classification based on spectral unmixing concepts," in *Proc. IEEE GRSS Workshop Hyperspectral Image Signal Process. : Evolution in Remote Sens. (WHISPERS)*. IEEE, 2011, pp. 1–4.
- [5] I. Dópido, J. Li, P. Gamba, and A. Plaza, "A new hybrid strategy combining semisupervised classification and unmixing of hyperspectral data," *IEEE J. Sel. Topics Appl. Earth Observ. in Remote Sens.*, vol. 7, pp. 3619–3629, 2014.
- [6] C. Bouveyron and S. Girard, "Robust supervised classification with mixture models : Learning from data with uncertain labels," *Pattern Recognit.*, vol. 42, pp. 2649–2658, 2009.
- [7] A. Lagrange, M. Fauvel, S. May, and N. Dobigeon, "Hierarchical Bayesian image analysis : From low-level modeling to robust supervised learning," 2017. [Online]. Available : <https://hal.archives-ouvertes.fr/hal-01545393>
- [8] O. Eches, N. Dobigeon, and J.-Y. Tourneret, "Enhancing hyperspectral image unmixing with spatial correlations," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, pp. 4239–4247, 2011.
- [9] S. Z. Li, *Markov Random Field Modeling in Image Analysis*. Springer Science & Business Media, 2009.