

Un modèle bayésien pour le démixage, la segmentation et la classification robuste d'images hyperspectrales

Adrien LAGRANGE¹, Mathieu FAUVEL², Stéphane MAY³, Nicolas DOBIGEON¹

¹University of Toulouse, IRIT/INP-ENSEEIH, France

²University of Toulouse, INP-ENSAT, UMR 1201 DYNAFOR, France

³Centre National d'Études Spatiales (CNES), French Space Agency

Travail soutenu par le CNES et la région Occitanie.

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

Résumé – La classification supervisée et le démixage spectral sont deux techniques permettant d'extraire de l'information d'images hyperspectrales. Cependant, malgré la complémentarité de ces techniques, il est rare de trouver des travaux les exploitant conjointement. Nous proposons donc un nouveau modèle bayésien hiérarchique pour mener de façon conjointes ces deux types d'analyse, de sorte à ce que chacune soit facilitée par l'autre. Pour cela, un modèle de mélange linéaire de spectres purs est utilisé pour décrire le mélange spectral puis l'image est segmentée en plusieurs groupes caractérisés par des pixels dont les abondances sont statistiquement proches. Une loi a priori est définie sur ces étiquettes de groupe sous la forme d'un champ aléatoire de Markov. Ce champ inclut classiquement un potentiel de Potts-Markov favorisant la cohérence spatiale de ces étiquettes. Il est complété par un potentiel local de site induit par la classification. Cette classification exploite la présence de données déjà labellisées par l'utilisateur. Les estimateurs bayésiens des paramètres du modèle (abondances, étiquettes de groupes, étiquettes de classes) sont approchés à l'aide d'un algorithme de Monte Carlo par chaîne de Markov. L'intérêt du modèle est illustré à l'aide d'expériences menées sur des données synthétiques et réelles.

Abstract – Classification and spectral unmixing are two methods to extract information from hyperspectral images. Nonetheless, it is very unusual to find a joint approach of this two complementary interpretations. In this work, a new Bayesian model is proposed to perform unmixing and classification jointly. The traditional linear mixing model is used to describe the spectral mixtures. A clustering is then performed to divide the image into spectrally coherent clusters, in which abundance vectors are statistically homogeneous. Cluster labels are assigned a Markov random field prior which assures first a spatial regularity with a Potts potential and secondly a coherence with estimated classification labels. Classification labels are finally dependent of labeled pixels provided by the user as encountered in traditional classification tasks. Performances of the model are finally assessed with synthetic and real data.

1 Introduction

L'analyse d'images hyperspectrales est principalement menée suivant deux approches que sont le démixage spectral [1], visant à déterminer la proportion des différents constituants élémentaires du spectre (appelé spectres purs) de chaque pixel, et la classification [2], cherchant à attribuer une classe unique à chacun des pixels suivant une nomenclature prédéterminée. Ces deux cadres d'analyse possèdent des avantages distincts qui les rendent complémentaires. En particulier, la classification supervisée permet une description sémantique de l'image hyperspectrale, en s'appuyant sur de l'information externe déjà labellisée. Au contraire, le démixage réalise une analyse non-supervisée de l'image reposant sur une description physique des observations. L'exploitation conjointe de ces approches haut-niveau (classification) et bas-niveau (démixage) n'a pour le moment que rarement été proposée [3, 4].

Dans cet article, nous proposons un nouveau modèle bayésien permettant d'estimer simultanément les classes et les vecteurs d'abondances dans le cas où l'utilisateur fournit un jeu

de pixels déjà labellisés mais potentiellement erronés, comme c'est le cas dans le cadre d'une classification supervisée. Ce modèle a également l'avantage de prendre en compte des erreurs éventuelles dans les données labellisées et d'en proposer une correction, réalisant implicitement une classification robuste de l'image. Pour cela, nous étendons les travaux de Echès *et al.* [5] qui propose un algorithme de démixage effectuant une segmentation spatiale selon l'homogénéité des coefficients d'abondances des pixels. Dans l'approche proposée dans cet article, le modèle de segmentation est complété de sorte à dépendre également des classes, supposées inconnues. La classification est donc intégrée au modèle et exploite la donnée supervisée et la segmentation, qui intègre l'information bas-niveau, obtenant ainsi un classifieur robuste aux erreurs sur les données externes [6]. L'algorithme fournit alors une description hiérarchique de l'image en termes d'abondances, de segmentation spatiale et de classification thématique.

La suite de cet article est organisée de la manière suivante. La Section 2 présente le modèle et en particulier développe la manière dont les tâches de démixage, segmentation et classifica-

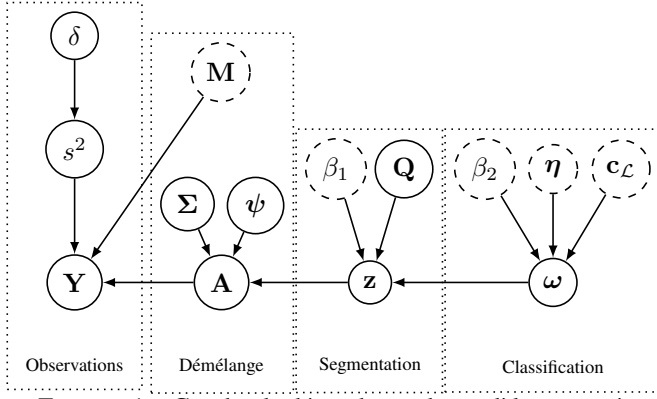


FIGURE 1 – Graphe de dépendance du modèle proposé.

tion sont modélisées. La Section 3 expose ensuite les résultats obtenus par des expériences réalisées à l’aide de données synthétiques et réelles. Finalement, la Section 4 conclut ce travail.

2 Du démixage à la classification

2.1 Formulation du problème

Dans ce travail, nous souhaitons réaliser conjointement le démixage et la classification supervisée d’une image hyperspectrale composée de P pixels dont les spectres $\mathbf{y}_p \in \mathbb{R}^D$ ($p \in \mathcal{P} \triangleq \{1, \dots, P\}$) sont observés dans D bandes spectrales. Les R spectres purs $\mathbf{M} = [\mathbf{m}_1, \dots, \mathbf{m}_R]$ associés aux composants élémentaires du mélange sont supposés connus. Il convient alors d’estimer à la fois une carte d’abondance $\mathbf{A} = [\mathbf{a}_1, \dots, \mathbf{a}_P]$ et une carte de classification $\omega = [\omega_1, \dots, \omega_P]$ où \mathbf{a}_p est le vecteur d’abondance associé au pixel p et $\omega_p \in \mathcal{J} \triangleq \{1, \dots, J\}$ est un label identifiant l’appartenance à une (label de classification), J étant le nombre total de classes. Chaque pixel est également muni d’une étiquette de groupe $z_p \in \mathcal{K} \triangleq \{1, \dots, K\}$ identifiant l’appartenance à un groupe de la segmentation. On peut noter qu’une classe est susceptible de contenir plusieurs groupes.

Dans un contexte supervisé classique, cette image est supposée être accompagnée d’une vérité terrain partielle. Formellement, certains des P pixels sont munis de labels $c_p \in \mathcal{J}$, potentiellement erronés. Par la suite, $\mathcal{L} \subset \mathcal{P}$ désigne l’ensemble des indices des pixels dont une étiquette de classe est fournie comme donnée externe et $\mathcal{U} = \mathcal{P} \setminus \mathcal{L}$ l’ensemble des indices des pixels ne bénéficiant pas de cette information.

Le modèle décrit par la suite est un modèle bayésien hiérarchique construit de manière à réaliser conjointement la tâche de bas niveau (e.g., le démixage) tout en exploitant l’information externe $c_{\mathcal{L}} \triangleq \{c_p, p \in \mathcal{L}\}$ de haut niveau (e.g., la classification). Les différents paramètres du modèle sont résumés dans le graphe de dépendance présenté sur la Figure 1. Ils seront estimés à l’aide d’un algorithme de Monte Carlo par chaîne de Markov (MCMC) non détaillé ici.

2.2 Modèle bayésien hiérarchique

Modèle de mélange Dans le cadre conventionnel d’un modèle de mélange linéaire, un pixel est décrit par une combinaison linéaire des R spectres purs à laquelle s’ajoute un bruit

$$\mathbf{y}_p = \mathbf{M}\mathbf{a}_p + \mathbf{n}_p \quad (1)$$

où \mathbf{n}_p est le bruit associé au pixel p et supposé gaussien, $\mathbf{n}_p | s^2 \sim \mathcal{N}(\mathbf{0}_D, s^2 \mathbf{I}_D)$, avec \mathbf{I}_D la matrice identité de taille $D \times D$. Suivant l’approche proposée dans [5], la variance inconnue s^2 de ce bruit est munie d’une loi a priori conjuguée inverse-gamma et une loi a priori non informative de Jeffreys est alors choisie pour l’hyperparamètre associé

$$s^2 | \delta \sim \mathcal{IG}(1, \delta), \quad \delta \propto \frac{1}{\delta} \mathbb{1}_{\mathbb{R}^+}(\delta). \quad (2)$$

Ces choix assurent une estimation aisée de ces paramètres de nuisance. Ce modèle d’observation est complété par des modèles de segmentation et de classification décrits dans les paragraphes qui suivent.

Modèle de segmentation Pour faire le lien entre la tâche de bas-niveau (i.e., le démixage) et la tâche haut-niveau (i.e., la classification), nous introduisons dans le modèle une tâche supplémentaire de segmentation. Précisément, comme dans [5], il est supposé que les pixels peuvent être répartis dans K groupes au sein desquels les vecteurs d’abondances sont statistiquement homogènes. Chaque pixel est donc muni d’une étiquette de groupe $z_p \in \mathcal{K} \triangleq \{1, \dots, K\}$ identifiant cette appartenance. Au sein de chaque groupe, les vecteurs d’abondance sont supposés être caractérisés par des moments d’ordre 1 et 2 identiques, justifiant une description par la loi a priori

$$\mathbf{a}_p | z_p = k \sim \mathcal{N}(\psi_k, \Sigma_k). \quad (3)$$

Les moyennes ψ_k et matrices de covariance Σ_k a priori sont des variables du modèle également à estimer. Pour cela, une loi de Dirichlet est choisie comme a priori sur ψ_k

$$\psi_{k,r} \sim \text{Dir}(\mathbf{1}) \quad (4)$$

permettant d’imposer sur le comportement moyen des vecteurs d’abondances les conditions de positivité et de somme-à-un classiquement rencontrées en démixage hyperspectral. La matrice Σ_k est choisie comme $\Sigma_k = \text{diag}(\sigma_{k,1}^2, \dots, \sigma_{k,R}^2)$ et $\sigma_{k,r}^2$ est munie d’une loi a priori conjuguée inverse-gamma

$$\sigma_{k,r}^2 \sim \mathcal{IG}(1, 0.1). \quad (5)$$

Les hyperparamètres de ces lois sont choisis de sorte à avoir des distributions peu informatives.

Le cœur de la méthode proposée réside dans le modèle a priori choisi pour décrire l’ensemble des étiquettes de groupes $\mathbf{z} = [z_1, \dots, z_P]$. Un champ de Markov aléatoire non-homogène est proposé pour favoriser deux comportements. Tout d’abord un potentiel de Potts-Markov de granularité β_1 est défini pour promouvoir la cohérence spatiale des étiquettes de groupe. Ensuite, un second potentiel, local et paramétré par une matrice \mathbf{Q} de taille $K \times J$, est introduit afin de promouvoir une cohérence

entre les étiquettes de groupe \mathbf{z} et les étiquettes de classes ω . La probabilité a priori conditionnelle de z_p est alors définie par

$$P[z_p = k | \mathbf{z}_{\mathcal{V}(p)}, \omega_p, q_{k, \omega_p}] \propto \exp \left(V_1(k, \omega_p, q_{k, \omega_p}) + \sum_{p' \in \mathcal{V}(p)} V_2(k, z_{p'}) \right) \quad (6)$$

où $\mathcal{V}(p)$ désigne l'ensemble des indices de pixels voisins du pixel p et $q_{k,j}$ est le k ième élément de la j ième colonne de \mathbf{Q} . Les quantités $V_1(\cdot)$ et $V_2(\cdot)$ sont respectivement le potentiel de cohérence avec la classification et le potentiel de Potts-Markov définis par

$$\begin{aligned} V_1(k, j, q_{k,j}) &= \log(q_{k,j}), \\ V_2(k, z_{p'}) &= \beta_1 \delta(k, z_{p'}), \end{aligned}$$

avec $\delta(\cdot, \cdot)$ la fonction de Kronecker. Dans les résultats préliminaires présentés par la suite, β_1 est choisi égal à 0 pour simplifier le processus d'échantillonnage, ce qui équivaut à ne pas régulariser spatialement la segmentation. Le cas $\beta_1 \neq 0$ est discuté dans [7]. La matrice \mathbf{Q} réunit un ensemble de coefficients traduisant la relation entre chaque couple possible $(k, j) \in \mathcal{K} \times \mathcal{J}$ d'étiquettes de groupes et de classes. Une grande valeur de $q_{j,k}$ aura tendance à favoriser un pixel dont l'étiquette de classe est $\omega_p = j$ à se voir attribuer une étiquette de groupe $z_p = k$. Une loi de Dirichlet est utilisée comme a priori pour chaque colonne \mathbf{q}_j de \mathbf{Q} supposée a priori indépendantes

$$\mathbf{q}_j \sim \text{Dir}(\mathbf{1}).$$

Il est important de remarquer qu'un tel choix a priori permet d'obtenir la loi conditionnelle a posteriori

$$\mathbf{q}_j | \mathbf{z}, \omega \sim \text{Dir}(n_{1,j}, \dots, n_{K,j})$$

où $n_{k,j} = \#\{p | z_p = k, \omega_p = j\}$ est le nombre de pixels ayant pour étiquette de groupe k et pour classe j . En particulier, l'espérance a posteriori de $q_{k,j}$ est $E[q_{k,j} | \mathbf{z}, \omega] = \frac{n_{k,j} - 1}{\sum_{i=1}^K n_{i,k} - K}$ qui est un estimateur empirique de $P[z_p = k | \omega_p = j]$.

Modèle de classification robuste La définition de la loi a priori sur les étiquettes de classes ω est similaire à celle des étiquettes de groupes \mathbf{z} et fait intervenir un champ de Markov aléatoire non-homogène constitué de deux potentiels. Le premier potentiel de régularisation spatiale est identique au potentiel $V_2(\cdot)$. Le second potentiel exploite l'information externe fournie par la carte partielle de vérité terrain $c_{\mathcal{L}}$ pour les pixels de \mathcal{L} et assure un potentiel non informatif pour les pixels de \mathcal{U}

$$P[\omega_p = j | \omega_{\mathcal{V}(p)}, c_p, \eta_p] \propto \exp \left(W_1(j, c_p, \eta_p) + \sum_{p' \in \mathcal{V}(p)} W_2(j, \omega_{p'}) \right) \quad (7)$$

avec

$$W_1(j, c_p, \eta_p) = \begin{cases} \begin{cases} \log(\eta_p), & \text{si } j = c_p \\ \log(\frac{1-\eta_p}{J-1}), & \text{sinon} \end{cases} & \text{si } p \in \mathcal{L} \\ -\log(J) & \text{sinon} \end{cases}$$

et

$$W_2(j, \omega_{p'}) = \beta_2 \delta(j, \omega_{p'}).$$

Le potentiel $W_1(\cdot)$ fait intervenir un paramètre $\eta_p \in (0, 1)$ fourni par l'utilisateur reflétant la confiance dans l'étiquette de classe fournie pour le pixel p a priori comme donnée supervisée. Dans le cas où la confiance dans la donnée externe c_p est totale, ce paramètre tend vers 1, ce qui conduit à $\omega_p = c_p$. Dans le cas où la confiance est par exemple de 90%, il est permis à la classification d'estimer un label de classes ω_p potentiellement différent de la donnée externe c_p et ainsi de la corriger, fournissant une classification robuste de l'image.

3 Expérimentation

Pour montrer l'intérêt du modèle proposé, des expériences ont été réalisées sur des images synthétiques et réelles. Les données synthétiques utilisées ont été générées en réalisant tout d'abord une carte de segmentation générée à l'aide d'un champ aléatoire de Potts-Markov. La carte de classification a ensuite été construite en réunissant un ou plusieurs groupes. Les vecteurs d'abondances ont été générés à partir d'une loi gaussienne avec une moyenne et matrice de covariance fixée pour chaque groupe. Enfin, les pixels de l'image hyperspectrale ont été générés suivant le modèle de mélange (1) avec des spectres purs comportant $D = 413$ bandes spectrales et un bruit gaussien fournissant un SNR= 30dB. Trois images présentées sur la Figure 2 ont ainsi été construites. La première de taille 100×100 fait intervenir $R = 3$ spectres purs, $K = 3$ groupes et $J = 2$ classes. La deuxième de taille 100×100 comporte $R = 9$ spectres purs, $K = 9$ groupes et $J = 5$ classes. La troisième est de taille 200×200 et est composée de $R = 9$ spectres purs, $K = 12$ groupes et $L = 5$ classes.




FIGURE 2 – Données synthétiques : (a), (b) et (c) représentent les cartes des classes des trois images utilisées et (d), (e) et (f) les cartes des étiquettes de groupe correspondantes.

Afin de vérifier l'intérêt d'inclure l'étape de classification et l'information externe dans le processus de démixage et de segmentation, les résultats ont été comparés au modèle proposé par Eches *et al.* dans [5] qui ne fait pas intervenir d'étape de classification. Les étiquettes de classes de la moitié supé-

rieure de la scène ont été fournies comme données supervisées et la confiance η_p ($p \in \mathcal{L}$) dans cette donnée supervisée a été fixée à une valeur proche de 1. Nous avons constaté que les erreurs d'estimation obtenues par ces deux modèles sont identiques. Cependant, la méthode présentée produit plusieurs résultats complémentaires pertinents pour l'analyse, comme l'estimation de la matrice \mathbf{Q} . Par exemple, la Figure 3 présente la matrice \mathbf{Q} estimée pour l'image correspondant aux cartes de groupe et de classe de la Figure 5 : synth-data (c). La structure de l'image est directement visible en lisant cette matrice qui détaille la répartition des groupes dans les classes. Par exemple, la classe 3 regroupe les groupes 1 et 10.




FIGURE 3 – Exemple de matrice \mathbf{Q} estimée pour l'image 3.

Ensuite, nous considérons le scénario où la donnée supervisée fournie comporte des erreurs. Précisément, sur cette expérience, les étiquettes de classes associées aux pixels de la moitié supérieure de l'image sont fournies comme donnée supervisée avec 40% d'erreur. La Figure 4 montre le résultat de classification obtenu par la méthode proposée lorsque la confiance dans la donnée supervisée a été fixée à $\eta_p = 0.8$ ($\forall p \in \mathcal{L}$). Il est possible de constater que ce modèle permet d'obtenir une classification très proche de la vérité malgré les informations erronées fournies, ce qui confirme la robustesse de la méthode.




FIGURE 4 – Classification avec données erronées : (a) vérité terrain sans erreur, (b) donnée supervisée fournie avec 40% d'erreur, (c) classification obtenue.

En dernier lieu, le modèle a été testé sur sur une image réelle de taille 600×600 issue de la mission MUESLI¹. Cette image comporte $D = 349$ bandes spectrales et $R = 10$ spectres purs ont été extraits à l'aide de l'algorithme VCA [8]. La vérité terrain associée à cette image comporte $L = 6$ classes (céréale à paille, culture d'été, zone arborée, bâtis, sol nu/fauché, prairie) et la moitié supérieure de celle-ci a été fournie comme donnée supervisée avec une confiance η_p tendant vers 1 ($\forall p \in \mathcal{P}$). La Figure 5 présente à titre illustratif les résultats obtenus en termes de segmentation et de classification qui apparaissent en accord avec la vérité terrain.




FIGURE 5 – Données réelles : (a) composition colorée de l'image, (b) vérité terrain, (c) segmentation obtenue et (d) classification obtenue (avec $\beta_2 = 1.2$).

4 Conclusion

Un nouveau modèle bayésien proposant de réaliser conjointement classification, segmentation et démixage spectral a été présenté. Le modèle proposé a été testé sur des images synthétiques et réelles. Une accélération de la convergence a été constatée et des résultats de classification cohérents ont été observés. La suite de nos travaux vise à poursuivre les tests sur données réelles pour évaluer les performances en terme de classification en se comparant notamment à d'autres classificateurs.

Références

- [1] 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 Observations Remote Sens.*, vol. 5, no. 2, pp. 354–379, April 2012.
- [2] 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, no. 3, pp. 652–675, March 2013.
- [3] A. Villa, J. Chanussot, J. A. Benediktsson, and C. Jutten, "Spectral unmixing for the classification of hyperspectral images at a finer spatial resolution," *IEEE J. Sel. Topics Signal Process.*, vol. 5, no. 3, pp. 521–533, 2011.
- [4] 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 Observations Remote Sens.*, vol. 7, no. 8, pp. 3619–3629, 2014.
- [5] O. Eches, N. Dobigeon, and J.-Y. Tourneret, "Enhancing hyperspectral image unmixing with spatial correlations," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 11, pp. 4239–4247, 2011.
- [6] C. Bouveyron and S. Girard, "Robust supervised classification with mixture models : Learning from data with uncertain labels," *Pattern Recognition*, vol. 42, no. 11, 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] J. M. Nascimento and J. M. Dias, "Vertex component analysis : A fast algorithm to unmix hyperspectral data," *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 4, pp. 898–910, 2005.

1. <http://fauvel.mathieu.free.fr/pages/muesli.html>