

Cofactorisation de matrices pour le démélange et la classification conjoints d'images hyperspectrales

Adrien LAGRANGE¹, Mathieu FAUVEL², Stéphane MAY³, José M. BIOUCAS-DIAS⁴, Nicolas DOBIGEON¹

¹IRIT/INP-ENSEEIH, 2 rue Camichel, 31000 Toulouse

²Centre d'Études Spatiales de la BIOSphère (CESBIO), 18 avenue Edouard Belin, bpi 2801, 31401 Toulouse cedex 9

³Centre national d'études spatiales (CNES), 18 avenue Edouard Belin, 31401 Toulouse cedex 9

⁴Instituto de Telecomunicações, Instituto Superior Técnico, Universidade de Lisboa, 1049-001 Lisbon, Portugal

prenom.nom@{enseeiht, inra, cnes, enseeiht}.fr, bioucas@lx.it.pt

TABLE 1 – Résultats de classification et démélange (moyenné sur 20 essais).

Model	Kappa	F1-moy	RMSE	RE	Time (s)
RF	0.882	0.922	N\A	N\A	0.1
FCLS	N\A	N\A	0.0448	0.155	0.04
CBPDN	N\A	N\A	0.127	0.314	0.05
D-KSVD	0.259	0.352	N\A	0.392	278
Cofact.	0.905	0.934	0.0210	0.227	152

Mots-clés : classification supervisée, démélange spectral, cofactorisation, images hyperspectrales.

Thématique(s) : méthodologie

Type de communication souhaitée : poster

La classification supervisée et le démélange spectral sont parmi les techniques les plus utilisées pour extraire l'information d'images hyperspectrales. Bien que ces deux méthodes sont couramment utilisées, elles n'ont que très rarement été envisagées conjointement. Au lieu d'utiliser ces méthodes de manière séquentielle, comme on le voit les travaux déjà réalisés [1], nous proposons ici d'introduire le concept de démélange et classification conjoints.

Méthodes proposées – La méthode proposée est formulée comme un problème de cofactorisation qui sont des modèles ayant prouvés leur efficacité dans d'autres domaines comme la séparation de source audio. Le concept général est de formuler classification et démélange comme des problèmes de factorisation de matrices puis d'ajouter un terme de couplage. En s'inspirant de [2], le terme de couplage est construit comme un terme de partitionnement qui sépare les vecteurs d'abondances en plusieurs groupes puis les vecteurs d'attribution aux groupes sont utilisés comme vecteurs de descripteurs pour la classification.




FIGURE 1 – Modèle de cofactorisation. Bleu : observations ou données annexes, vert : variables couplées, en pointillé : variable supposée connue.

Expérimentation – Une image hyperspectrale, présentée Figure 2, semi-synthétique est utilisée pour ces expérimentations. L'image a été générée en utilisant une image réelle qui a été démélangée de sorte à récupérer les cartes d'abondances qui ont été réutilisées pour recréer une image à partir de spectres réels connus. La vérité terrain associée à l'image d'origine a été réutilisée avec ces 4 classes. Les résultats de classification ont été comparés à ceux obtenus avec un algorithme de forêt aléatoire (RF) et ceux d'un K-SVD discriminatif, le premier étant reconnu pour son efficacité et le deuxième étant basé sur

une méthode de cofactorisation minimale. Les résultats du démélange sont comparés à deux algorithmes classiques que sont la méthode des moindres carrés entièrement contrainte (FCLS) et un débruitage de type *basis pursuit* (CBPDN).



FIGURE 2 – Image semi-synthétique : composition colorée de la HS Y (gauche), vérité terrain de la classification (droite).

Résultats – Pour réaliser l'évaluation quantitative présentée dans le tableau 1, la classification a été évaluée avec deux métriques conventionnelles que sont le kappa de Cohen et le score F1 moyen. Les résultats du démélange sont évalués en utilisant l'erreur de reconstruction (RE) et la racine de l'erreur quadratique moyenne (RMSE). Les résultats montrent que le modèle de cofactorisation proposé est plus performant autant en terme de classification que de démélange même s'il est plus lent que les autres qui ne réalisent cependant qu'une seule des deux tâches. Il est aussi important de noter que la cofactorisation génère de très intéressants produits annexes aidant à l'interprétation des résultats. Par exemple, il est possible de visualiser les centroïdes des partitions, comme montré figure 3, qui permettent de visualiser la multi-modalité de certaines classes.




FIGURE 3 – Centroïdes spectraux des différents clusters pour chaque classe.

- [1] 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. Top. Signal Process.*, vol. 5, no. 3, pp. 521–533, 2011.
- [2] A. Lagrange, M. Fauvel, S. May, and N. Dobigeon, "Hierarchical Bayesian image analysis : From low-level modeling to robust supervised learning," *Pattern Recognit.*, vol. 85, pp. 26–36, 2019.