

Segmentation hyperspectrale adaptée au démixage spectral au moyen d'un arbre de partition binaire

Guillaume TOCHON¹, Miguel. A. VEGANZONES¹, Mauro DALLA MURA¹, Antonio. J. PLAZA², Jocelyn CHANUSSOT¹

¹GIPSA-lab

11 rue des Mathématiques, 38400 Saint Martin d'Hères, France

²Hyperspectral Computing Laboratory

Avda. de la Universidad S/N, E-10003 Cáceres, Espagne

guillaume.tochon@gipsa-lab.grenoble-inp.fr,

miguel-angel.veganzones@gipsa-lab.grenoble-inp.fr,

mauro.dalla-mura@gipsa-lab.grenoble-inp.fr, aplaza@unex.es,

jocelyn.chanussot@gipsa-lab.grenoble-inp.fr

Résumé – Aujourd'hui, l'imagerie hyperspectrale a pris une place prépondérante en télédétection, mais est toujours le théâtre d'actives recherches. Dans cet article, une méthode originale combinant segmentation hyperspectrale et démixage spectral via l'utilisation d'un arbre de partition binaire est proposée. L'introduction d'un nouveau critère d'élagage de l'arbre permet l'obtention d'une carte de segmentation minimisant l'erreur de reconstruction, et donc optimale vis-à-vis du démixage spectral. La méthode proposée est validée sur l'image hyperspectrale de l'université de Pavia.

Abstract – Nowadays, hyperspectral imagery is widely used in remote sensing field but still at the heart of active researches. In this article, an original method combining hyperspectral segmentation and spectral unmixing by means of a binary partition tree is addressed. The introduction of a new pruning tree criterion allows to obtain a segmentation map minimizing the reconstruction error, consequently optimal with respect to spectral unmixing. The method is validated on the Pavia university hyperspectral image.

1 Introduction

De nos jours, l'imagerie hyperspectrale est communément utilisée en télédétection. Grâce aux progrès technologiques, les capteurs sont aujourd'hui en mesure d'acquérir des images possédant des résolutions spectrales et spatiales de plus en plus fines, permettant une meilleure identification spectrale des matériaux présents dans la scène et une meilleure reconnaissance des objets la composant [1]. C'est pourquoi les opérations de démixage spectral et de segmentation sont au cœur des travaux de recherche en télédétection.

Dans cette étude, nous proposons de combiner ces deux aspects afin de produire une segmentation optimale vis-à-vis du démixage spectral et de l'erreur de reconstruction qui en découle. Pour se faire, et contrairement au cas classique où l'opération de démixage est effectuée sur l'image entière, nous proposons une approche locale au moyen d'un arbre de partition binaire (APB). Ainsi, nous présentons dans un premier temps les aspects de démixage et d'arbre de partition binaire. Puis nous introduisons notre méthode en décrivant la stratégie de construction et d'élagage de l'APB. Enfin, les résultats de la méthode proposée et appliquée sur des données réelles, sont présentés, puis des pistes d'amélioration sont évoquées.

2 Démixage spectral

Il est communément admis en imagerie hyperspectrale qu'un pixel peut s'exprimer comme une combinaison linéaire de spectres de références, appelés *pôles de mélanges* (représentant bien souvent des entités macroscopiques telles que l'eau, la végétation, l'herbe, le bitume... etc) et dont les coefficients multiplicatifs correspondent aux abondances fractionnelles des pôles en question sur le site correspondant au pixel, plus un bruit additif [2]. Si $\mathbf{E} = [\mathbf{e}_1, \dots, \mathbf{e}_m]$ est la matrice formée des m pôles de mélange $\mathbf{e}_i \in \mathbb{R}^N$ présents dans l'image, N étant le nombre de bandes spectrales, alors la signature spectrale du pixel $\mathbf{r} = [r^{(1)}, \dots, r^{(N)}]$ peut s'exprimer comme

$$\mathbf{r} = \sum_{i=1}^m \mathbf{e}_i \phi_i + \mathbf{b} \quad (1)$$

avec $\phi = [\phi_1, \dots, \phi_m]$, ϕ_i étant l'abondance fractionnelle du pôle de mélange \mathbf{e}_i en \mathbf{r} , et \mathbf{b} représentant un bruit additif indépendant. Bien souvent, les contraintes de non-négativité : $\phi_i \geq 0, \forall i = 1, \dots, m$ et de sommation à 1 : $\sum_{i=1}^m \phi_i = 1$ sont requises pour ϕ . Étendue à toute l'image \mathbf{H} , l'équation 1 devient $\mathbf{H} = \mathbf{E}\Phi + \mathbf{B}$ avec Φ la matrice des abondances fractionnelles et \mathbf{B} un bruit additif indépendant.

À partir des estimées $\hat{\mathbf{E}}$ de \mathbf{E} et $\hat{\Phi}$ de Φ , il est possible d'évaluer

la qualité du démixage en un pixel donné \mathbf{r} en calculant l'erreur quadratique moyenne (EQM) entre la signature théorique et la signature reconstruite $\hat{\mathbf{r}} = \sum_{i=1}^m \hat{\mathbf{e}}_i \hat{\phi}_i$:

$$\varepsilon(\hat{\mathbf{r}}, \mathbf{r}) = \sqrt{\frac{1}{N} \sum_{k=1}^N (\hat{r}^{(k)} - r^{(k)})^2} \quad (2)$$

3 Arbres de Partition Binaires

L'APB est une représentation hiérarchique d'une image sous la forme d'un arbre. Initialement proposés dans [3], les APBs ont depuis prouvé leur utilité en télédétection, notamment pour la segmentation d'images hyperspectrales [4]. Partant d'une partition initiale de l'image (qui peut être le niveau pixel ou une pré-segmentation de l'image), un algorithme itératif de fusion de régions est appliqué jusqu'à ce qu'il n'en subsiste plus qu'une. Cette dernière région, appelée *racine* de l'APB, représente l'image totale. Chaque région initiale correspond à une *feuille* de l'arbre, et chaque nœud situé entre les feuilles et la racine représente le résultat de la fusion de ses deux enfants. Les deux notions centrales pour la construction d'un APB sont le *modèle de région*, qui explicite sous quelle forme une région hyperspectrale est modélisée, et le *critère de fusion*, qui mesure la distance entre les modèles de deux régions voisines, et qui permet donc de quantifier leur similarité. Pour un modèle de région donné, il existe par conséquent une liste non exhaustive de critères de fusion [5].

L'étape d'*élagage* de l'APB intervient une fois sa construction terminée. Lors de cette étape, les branches de l'APB sont coupées selon un critère donné, de manière à ce que les feuilles de l'arbre élagué établissent la segmentation la plus pertinente possible. Ainsi, au contraire de la construction de l'APB qui est générique une fois les modèles de région et critères de fusion définis, la stratégie d'élagage à adopter dépend du résultats souhaité, et deux stratégies différentes produiront très probablement deux segmentations différentes. Un exemple de construction et d'élagage d'APB peut être vu sur la figure 1.

4 Méthode

4.1 Partition initiale

Dans cette étude, la partition initiale utilisée pour la construction de l'APB est obtenue après application d'un algorithme de partage des eaux hyperspectral sur l'image [6]. Cette méthode présente l'avantage de fournir une pré-segmentation largement sur-segmentée, avec des régions initiales dont les frontières sont pertinentes vis-à-vis des régions réelles présentes dans l'image. Cette partition initiale peut être observée sur la figure 2(b).

4.2 Construction de l'APB

Le modèle de région choisi pour cette étude est le spectre moyen. Ce modèle est couramment utilisé lors de la construction

d'un APB pour une image hyperspectrale [4]. Pour une région \mathcal{R} donnée, son modèle de région $\mathcal{M}_{\mathcal{R}}$ est par conséquent défini comme $\mathcal{M}_{\mathcal{R}} = \bar{\mathbf{r}} = [\bar{r}^{(1)}, \dots, \bar{r}^{(N)}]$ avec $\bar{r}^{(k)}$ étant la moyenne des pixels de la région \mathcal{R} pour la k^{ieme} bande spectrale :

$$\bar{r}^{(k)} = \frac{1}{|\mathcal{R}|} \sum_{j=1}^{|\mathcal{R}|} r_j^{(k)} \quad (3)$$

et $|\mathcal{R}|$ étant le nombre de pixels dans la région \mathcal{R} .

Le critère de fusion est une distance mesurant la similarité entre les modèles de deux régions voisines \mathcal{R}_i et \mathcal{R}_j . Le critère utilisé dans cette étude est l'angle spectral, défini entre deux régions \mathcal{R}_i et \mathcal{R}_j par :

$$\mathcal{O}(\mathcal{R}_i, \mathcal{R}_j) = \arccos \left(\frac{\langle \bar{\mathbf{r}}_i, \bar{\mathbf{r}}_j \rangle}{\|\bar{\mathbf{r}}_i\| \|\bar{\mathbf{r}}_j\|} \right) \quad (4)$$

avec $\langle \cdot, \cdot \rangle$ le produit scalaire Euclidien et $\|\cdot\|$ la norme Euclidienne.

De plus, lors de la construction, les pôles de mélanges $\mathbf{E}_{\mathcal{R}}$ et leurs abondances fractionnelles sont estimés pour chaque région \mathcal{R} par le biais d'un algorithme VCA (Vertex Component Analysis) [7]. Pour chaque pixel appartenant à \mathcal{R} , son erreur de reconstruction est estimée par le biais de son EQM : $\varepsilon(\hat{\mathbf{r}}, \mathbf{r})$. De plus, l'erreur de reconstruction de la région \mathcal{R} est définie comme étant le maximum des EQMs des pixels constituant la région : $\varepsilon_{\mathcal{R}} = \max_{\mathbf{r} \in \mathcal{R}} \varepsilon(\hat{\mathbf{r}}, \mathbf{r})$. Pour s'affranchir du caractère stochastique de l'algorithme VCA, celui-ci est exécuté 20 fois par région, et les pôles de mélanges gardés sont ceux générant la plus faible EQM $\varepsilon_{\mathcal{R}}$ pour la région.

4.3 Élagage de l'APB

Nous introduisons ici une nouvelle stratégie d'élagage, basée sur la minimisation de l'EQM maximale sur l'ensemble de la partition. Si \mathcal{P} est une partition de l'image (un élagage particulier de l'APB correspondant), et Ω l'ensemble de toutes les partitions possibles pour une image donnée, alors la partition minimisant l'EQM maximale est définie comme

$$\mathcal{P}^* = \arg \min_{\mathcal{P} \in \Omega} \left(\max_{\mathcal{R}_i \in \mathcal{P}} \varepsilon_{\mathcal{R}_i} \right) \quad (5)$$

En d'autres termes, il s'agit de trouver la partition telle que la plus grande EQM de région dans la partition soit la plus faible parmi l'ensemble des partitions possibles. La partition obtenue est par conséquence optimale vis-à-vis de l'erreur de reconstruction.

De plus, il peut être intéressant de se limiter à des régions suffisamment grosses. On définit alors la partition optimale sous contrainte de taille C de la manière suivante : l'ensemble des partitions possibles est restreint aux partitions dont toutes les régions ont une taille supérieure à C , $\Omega^C = \{\mathcal{P}, \forall \mathcal{R} \in \mathcal{P}, |\mathcal{R}| \geq C\}$, et la partition optimale sous contrainte de taille devient

$$\mathcal{P}^{C*} = \arg \min_{\mathcal{P} \in \Omega^C} \left(\max_{\mathcal{R}_i \in \mathcal{P}} \varepsilon_{\mathcal{R}_i} \right) \quad (6)$$

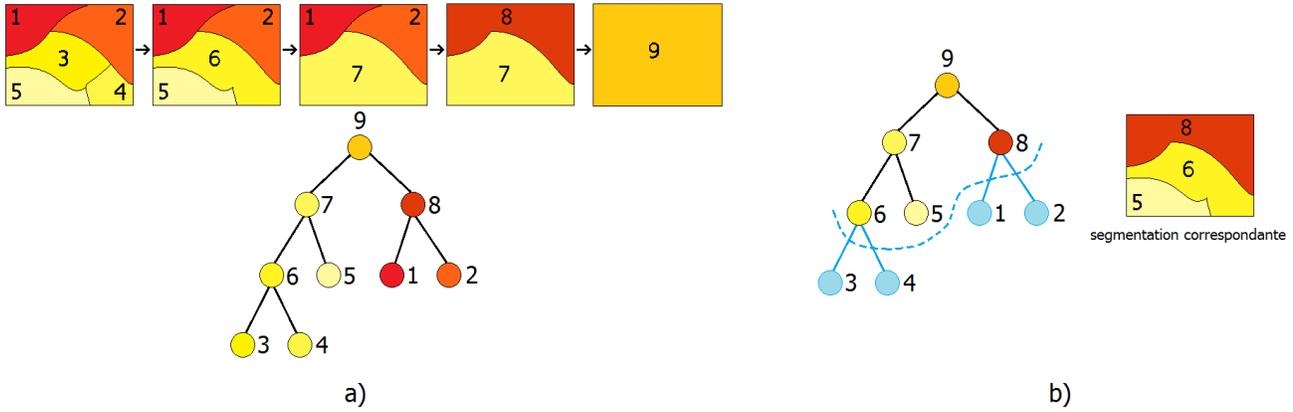


FIGURE 1 – Construction d’un APB (a) et son élagage (b).

Lorsque $C = 0$, l’équation 6 est alors équivalente à l’équation 5.

5 Résultats

Le jeu de données utilisé pour valider la méthode proposée est l’image hyperspectrale de l’université de Pavia, acquise par le capteur ROSIS-03. L’image a une dimension spatiale de 610×340 pixels, avec une résolution au sol de 1.3 m par pixel, et possède 103 bandes spectrales après correction des bandes bruitées. L’image est composée de diverses structures telles que des bâtiments, des routes, des parkings, des zones gazonnées ainsi que de la végétation. Dans un souci de lisibilité, les résultats sont affichés pour une sous-image de taille 475×265 , centrée sur l’image originale. Une composition en fausse couleur peut être vue sur la figure 2(a).

Les figures 2(b), 2(c) et 2(d) représentent respectivement la partition initiale obtenue par ligne de partage des eaux hyperspectrale, la partition optimale sans contrainte de taille, et la partition optimale lorsqu’une contrainte $C = 100$ est appliquée. Il peut être remarqué que les deux partitions optimales sont bien moins sur-segmentées que la partition initiale. Dans le cas sans contrainte, bien que plusieurs petites régions soient présentes dans la carte de segmentation, nous pouvons toutefois observer plusieurs régions sémantiquement cohérentes dans la partition, telle que les zones gazonnées autour du bâtiment bleu. Dans le cas où la contrainte de taille est appliquée, le nombre de régions dans la partition a fortement diminué (240 avec contrainte de taille, contre 5453 dans le cas sans contrainte et 11917 pour la partition initiale), mais ces régions restent sémantiquement consistantes.

Les figures 2(e), 2(f), 2(g) et 2(h) représentent respectivement les cartes d’EQM du démélangeage global, de la partition initiale et des partitions optimales sans et avec contrainte. L’échelle des couleurs a été saturée entre le bleu (0) et le rouge (200 et plus) afin de pouvoir faciliter une comparaison visuelle. Il peut être remarqué que le démélangeage engendre une quantité plus importante d’erreurs de reconstruction lorsqu’il est effectué glo-

balement plutôt que localement. La comparaison des erreurs moyennes et maximales des cartes d’EQM de la partition initiale et de la partition optimale sans contrainte permet de voir l’intérêt de la méthode proposée : en effet, si les erreurs moyennes sont du même ordre de grandeur (20.38 contre 20.85), l’erreur maximale est divisée par 2 dans le cas de la partition optimale (382.89 contre 762.46 pour la partition initiale). Enfin, lorsque la contrainte de taille est imposée, l’EQM moyenne s’en retrouve légèrement augmentée (43.04), mais l’EQM maximale (788.04) reste du même ordre de grandeur que la partition initiale, offrant cependant une segmentation de l’image bien plus précise. Pour comparaison, les EQMs moyenne et maximale dans le cas du démélangeage global sont respectivement de 146.70 et 1246.8. Ces résultats sont résumés dans la table 1.

TABLE 1 – EQM moyenne et maximale, et nombre de régions pour les quatre configurations utilisées.

	EQM moy	EQM max	régions
image entière	146.70	1246.8	1
part. initiale	20.38	762.46	11917
part. optimale (sans contrainte)	20.85	382.89	5453
part. optimale ($C = 100$)	43.04	788.04	240

6 Conclusion

En conclusion, nous présentons dans cette étude une nouvelle méthode de segmentation hyperspectrale, optimale au sens du démélangeage spectral. L’utilisation d’un arbre de partition binaire couplé à un démélangeage effectué localement dans l’image permet d’une part de réaliser une segmentation prenant en compte les propriétés spectrales locales de l’image, et d’autre part de minimiser l’erreur de reconstruction générale, via sa minimisation locale dans l’image, qualité hautement désirable

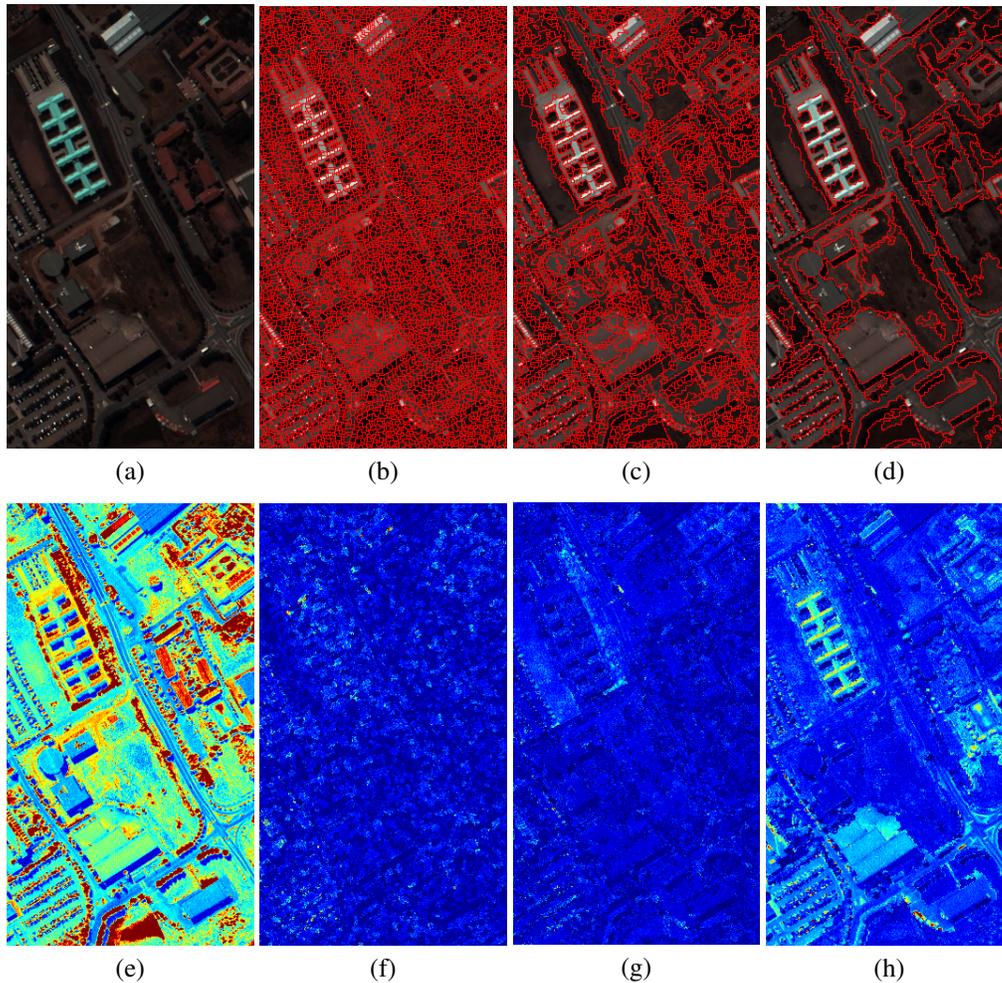


FIGURE 2 – Cartes de segmentation (ligne du haut) et cartes d’EQM correspondantes (ligne du bas) pour : (a)(e) l’image originale, (b)(f) la partition initiale, (c)(g) l’élitage optimal sans contrainte et pour (d)(h) l’élitage optimale avec contrainte de taille $C = 100$.

pour les applications du démelangeage hyperspectral. Les résultats obtenus démontrent l’intérêt de la méthode proposée, et les futurs travaux se focaliseront sur le traitement des pôles de mélanges générés par la partition optimale.

Références

- [1] A. F. Goetz, “Three decades of hyperspectral remote sensing of the earth : A personal view,” *Remote Sensing of Environment*, vol. 113, pp. S5–S16, 2009.
- [2] J. 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 Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, pp. 354–379, april 2012.
- [3] P. Salembier and L. Garrido, “Binary partition tree as an efficient representation for image processing, segmentation, and information retrieval,” *IEEE Transactions on Image Processing*, vol. 9, no. 4, pp. 561–576, 2000.
- [4] S. Valero, P. Salembier, and J. Chanussot, “Hyperspectral image representation and processing with binary partition trees,” *Image Processing, IEEE Transactions on*, vol. 22, pp. 1430–1443, april 2013.
- [5] S. Valero, P. Salembier, and J. Chanussot, “Comparison of merging orders and pruning strategies for binary partition tree in hyperspectral data,” in *Image Processing (ICIP), 2010 17th IEEE International Conference on*, pp. 2565–2568, IEEE, 2010.
- [6] Y. Tarabalka, J. Chanussot, and J. Benediktsson, “Segmentation and classification of hyperspectral images using watershed transformation,” *Pattern Recognition*, vol. 43, no. 7, pp. 2367–2379, 2010.
- [7] J. Nascimento and J. Dias, “Vertex component analysis : a fast algorithm to unmix hyperspectral data,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, pp. 898–910, april 2005.