

# Segmentation Multi-phases d’Images Hyperspectrales Représentées par Graphes

Kaouther TABIA, Xavier DESQUESNES, Yves LUCAS, Sylvie TREUILLET

Laboratoire PRISME, Université d’Orléans  
12 rue de Blois BP 6744, 45067, Orléans cedex 2, France  
kaouther.tabia@univ-orleans.fr

**Résumé** – Dans cet article, nous proposons d’étudier l’adaptation et l’application des méthodes de level sets multi-phases sur graphes pondérés pour la segmentation d’images hyperspectrales. Nous abordons également les différentes constructions du graphe afin de représenter ce type d’image. L’approche présentée généralise le concept de propagation de front basé sur les EdP sur graphes. Initialement introduite pour la segmentation des images en niveaux de gris, elle est étendue aux images hyperspectrales. Des résultats expérimentaux montrent l’efficacité de notre méthode.

**Abstract** – In this paper, we propose to adapt and apply weighted graph based multiphase level set method for hyperspectral image segmentation. We also consider several graph structures to represent such image. Our method generalizes the PdE based front propagation concept initially introduced for gray image segmentation to images with huge wavelength dimension. Experimental results demonstrate the effectiveness of our method.

## 1 Introduction

Les capteurs hyperspectraux sont capables de détecter des centaines de bandes spectrales très fines dans la portion visible et infra-rouge du spectre des ondes électromagnétiques. Une image hyperspectrale (IHS) est donc considérée comme une série d’images de la même scène, chacune représentant une longueur d’onde. Ceci rend les IHS plus informatives comparées aux images RGB. Cependant, la grande dimensionnalité des images hyperspectrales complique leur traitement et rend difficile l’application des algorithmes classiques de traitement et d’analyse d’images notamment les approches de segmentation.

Les méthodes basées graphes, qui considèrent une image comme un graphe pondéré, permettent de s’affranchir de cette limitation et ainsi d’appliquer des traitements usuels aux images hyperspectrales grâce à l’utilisation simultanée d’informations spectrales et spatiales. En effet, dans ce mode de représentation, chaque pixel de l’image est représenté par un sommet du graphe connecté à ses voisins par une arête pondérée en fonction de leur similarité spectrale et/ou spatiale. Plusieurs méthodes basées graphes ont été appliquées sur des IHS pour la réduction de la dimensionnalité, la détection des anomalies [7], la classification et la segmentation [1]. Dans [5], la structure spatio-spectrale des graphes pondérés a montré son potentiel pour la segmentation d’IHS avec la méthode Graph-cut.

Dans cet article, nous proposons de poursuivre l’étude de l’utilisation des graphes pour la représentation des IHS, via une approche basée sur les level sets sur graphe et

leur extension aux level sets multi-phases. Cette approche s’appuie sur les travaux de Chan et Vese [9], ainsi que sur l’adaptation des level sets aux graphes [4].

Contrairement au modèle à deux-phases [2], le modèle multi-phases n’a pas encore été appliqué sur des graphes pondérés. Nous proposons donc d’étudier son application à la segmentation des IHS représentées avec différentes constructions du graphe.

## 2 Méthode proposée

Dans la première partie de cette section, nous rappelons la définition d’un graphe pondéré, ainsi que les différentes stratégies de constructions applicables aux IHS. Dans la seconde partie, nous présentons la méthode des level sets sur graphe, utilisée ensuite pour nos expérimentations.

### 2.1 Construction du graphe

Un graphe pondéré  $G = (V, E, \omega)$  est composé d’un ensemble de sommets  $V = (v_1, \dots, v_n)$  et d’un ensemble d’arêtes pondérées  $E = \{(u, v) \in V \times V | u \sim v\}$  où  $\sim$  signifie que  $u$  et  $v$  sont des sommets adjacents et  $\omega$  représente le poids de chaque arête dans  $G$ .

La première étape de l’approche proposée est la construction du graphe pondéré  $G(V, E, \omega)$  pour représenter une IHS. Un des avantages de l’utilisation de graphes est qu’ils permettent plusieurs représentations de l’image en fonction du problème posé. Pour notre méthode, nous avons

testé trois différentes constructions afin de représenter une IHS.

**Graphe complet** : Un graphe complet est un graphe pondéré, dont chacun de ses sommets correspondant aux pixels de l'image, est connecté à tous les autres par une arête pondérée. L'ensemble des arêtes est défini par  $E = \{V \times V\}$ . Chaque arête dans  $E$  a un poids  $\omega_{uv}$  qui représente la similarité spectrale entre les deux sommets  $u$  et  $v$ . Comme son nom l'indique, ce graphe possède l'information la plus complète sur l'IHS mais le nombre trop élevé d'arêtes le rend difficilement exploitable.

**Graphe  $k$ -adjacences** : Soient  $k \in \mathbb{N}$  et  $d$  la distance euclidienne entre deux pixels. Le graphe des  $k$ -adjacences est un graphe pondéré dont chaque sommet représente un pixel de l'image. Chaque sommet de ce graphe est relié à ses  $k$  plus proches voisins, selon la distance  $d$ , par une arête pondérée.

**Graphe d'adjacence de région** : Cette construction se base sur une partition de l'image en régions connexes appelées superpixels. Chaque région de la partition est représentée par un unique sommet. Les sommets de deux régions adjacents sont connectés par une arête, dont le poids dépend de la similarité entre les deux régions. Pour cet article, les partitions ont été obtenues via les approches [6] et [8], qui produisent des régions homogènes et préservent les contours de l'image originale.

L'utilisation d'un RAG permet de réduire fortement le temps de traitement d'IHS grâce à la diminution de nombre de sommets du graphe.

### Similarité spectrale

Dans cet article, et indépendamment de la construction du graphe, nous utilisons une similarité basée sur la mesure de l'angle spectrale et dont l'intérêt a déjà été démontré dans [5]. Pour un graphe de  $k$ -adjacences, la mesure de similarité peut être exprimée ainsi :

$$\omega(u, v) = e^{-\theta(u, v)} \times \begin{cases} e^{-\frac{d^2(u, v)}{\sigma^2}} & \text{si } d^2(u, v) < r^2 \\ 0 & \text{sinon} \end{cases} \quad (1)$$

où  $\theta(u, v) = \cos^{-1}\left(\frac{\langle u, v \rangle}{\|u\| \cdot \|v\|}\right)$  est l'angle spectral (mesuré en degrés) entre le spectre de  $u$  et  $v$ , et  $d(u, v)$  est la distance euclidienne entre la position spatiale de  $u$  et  $v$ . Les paramètres  $r$  et  $\sigma$  sont des paramètres à ajuster.

Cette métrique utilise à la fois l'information spectrale et spatiale de l'image.

## 2.2 Level set multi-phases sur graphe

Nous proposons dans cet article d'étudier l'intérêt de level sets multi-phases pour la segmentation des IHS. Cette approche, initialement introduite pour une image en niveau de gris dans [9], consiste à diviser une image en  $2^n$

régions grâce à  $n$  level sets. Si on note  $\phi_n$  la fonction d'un de ces level sets, l'équation de propagation de  $\phi_n$  sera définie comme suit :

$$\frac{\partial \phi_n}{\partial t} = \delta_\epsilon(\phi_n) \left\{ \mu \operatorname{div} \left( \frac{\nabla \phi_n}{|\nabla \phi_n|} \right) - F_n \right\} \quad (2)$$

où  $\operatorname{div} \left( \frac{\nabla \phi_n}{|\nabla \phi_n|} \right)$  représente la courbure de contour évolutive  $\phi_n$ . Le terme  $F_n$  représente la vitesse de propagation de  $\phi_n$ .

En nous basant sur les travaux présentés dans [4], qui généralisent le principe des level sets sur graphe, nous proposons une adaptation de cette approche multi-phases sur graphe.

Par analogie avec le cas continu, chaque level set est représenté par une fonction  $\phi_n$ , dont le niveau zéro de cette fonction représente un contour partitionnant le graphe.

L'évolution de ce contour est contrôlée par la fonction de vitesse  $F_n$ . Le contour s'étend lorsque  $F_n$  est positive et se rétracte lorsque  $F_n$  est négative :

$$\frac{\partial \phi_n(u, t)}{\partial t} = \begin{cases} F_n(u, t) \|(\nabla_\omega^+ \phi_n)(u, t)\|, & \text{si } F_n(u, t) > 0 \\ F_n(u, t) \|(\nabla_\omega^- \phi_n)(u, t)\|, & \text{si } F_n(u, t) < 0 \\ 0, & \text{sinon} \end{cases} \quad (3)$$

$(\nabla_\omega^+ \phi_n)(u, t)$  et  $(\nabla_\omega^- \phi_n)(u, t)$  sont les opérateurs externes et internes de gradients pondérés définis respectivement par :

$$(\nabla_\omega^+ \phi_n)(u) = (\sqrt{\omega_{uv}} (\phi_n(v) - \phi_n(u)))^+_{(u, v) \in E} \quad (4)$$

$$(\nabla_\omega^- \phi_n)(u) = (-\sqrt{\omega_{uv}} (\phi_n(v) - \phi_n(u)))^-_{(u, v) \in E} \quad (5)$$

avec  $(x)^+ = \max(0, x)$  et  $(x)^- = \min(0, x)$ .

Dans le cas multi-phases, chaque level set évolue indépendamment sous l'impulsion d'une fonction de vitesse spécifique.

Pour illustrer, prenons l'exemple de  $n = 2$  fonctions de level sets, les équations de  $\phi_1$  et  $\phi_2$  deviennent :

$$\frac{\partial \phi_1(u, t)}{\partial t} = \begin{cases} \delta_\epsilon(\phi_1) [F_1(u, t) \|(\nabla_\omega^+ \phi_1)(u, t)\|], & \text{si } F_1(u, t) > 0 \\ \delta_{\epsilon_1}(\phi_1) [F_1(u, t) \|(\nabla_\omega^- \phi_1)(u, t)\|], & \text{si } F_1(u, t) < 0 \\ 0, & \text{sinon} \end{cases}$$

$$\frac{\partial \phi_2(u, t)}{\partial t} = \begin{cases} \delta_\epsilon(\phi_2) [F_2(u, t) \|(\nabla_\omega^+ \phi_2)(u, t)\|], & \text{si } F_2(u, t) > 0 \\ \delta_{\epsilon_2}(\phi_2) [F_2(u, t) \|(\nabla_\omega^- \phi_2)(u, t)\|], & \text{si } F_2(u, t) < 0 \\ 0, & \text{sinon} \end{cases}$$

où  $F_1$  et  $F_2$  sont définies comme suit :

$$F_1(u, t) = \mu \operatorname{div} \left( \frac{\nabla \phi_1}{|\nabla \phi_1|} \right) - ((I(u) - c_{11})^2 - (I(u) - c_{01})^2) H(\phi_2) + ((I(u) - c_{10})^2 - (I(u) - c_{00})^2) (1 - H(\phi_2)) \quad (6)$$

$$F_2(u, t) = \mu \operatorname{div} \left( \frac{\nabla \phi_2}{|\nabla \phi_2|} \right) - ((I(u) - c_{11})^2 - (I(u) - c_{10})^2) H(\phi_1) + ((I(u) - c_{01})^2 - (I(u) - c_{00})^2) (1 - H(\phi_1)) \quad (7)$$

où  $I(u)$  est le vecteur spectral au sommet  $u$  et  $c_{00}$ ,  $c_{01}$ ,  $c_{11}$  et  $c_{10}$  (voir figure 1) sont les valeurs moyennes d'intensité des pixels dans les quatre régions respectives.  $H$  représente la fonction Heaviside définie par  $H(x) = 1$  lorsque  $x > 0$  et  $H(x) = 0$  lorsque  $x < 0$ .

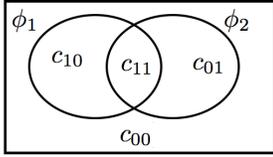


FIGURE 1 – 2 contours divisent l'image en 4 régions :  $c_{11} = \{\phi_1 > 0, \phi_2 > 0\}$ ,  $c_{10} = \{\phi_1 > 0, \phi_2 < 0\}$ ,  $c_{01} = \{\phi_1 < 0, \phi_2 > 0\}$ ,  $c_{00} = \{\phi_1 < 0, \phi_2 < 0\}$

### 3 Résultats expérimentaux

Les expériences ont été réalisées sur une IHS couramment utilisée dans la littérature. Cette image représentant l'université de Pavia, en Italie, a été acquise par le capteur optique ROSIS-03 (figure 2). Cette image contient  $610 \times 340$  pixels sur 103 bandes spectrales avec une résolution spatiale de 1.3 m/pixel.

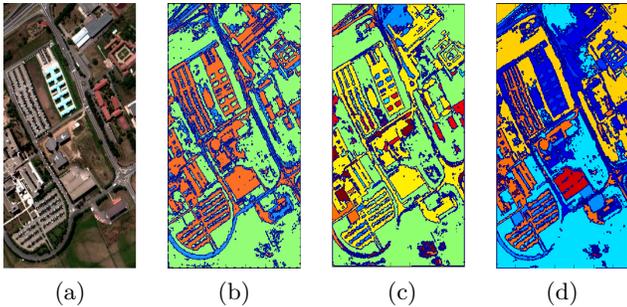


FIGURE 2 – Image de l'université de Pavia : (a) Image RVB, (b) Segmentation multi-phases (2 level sets), (c) Segmentation multi-phases (3 level sets), (d) Segmentation multi-phases (4 level sets)

La figure 2 présente les résultats obtenus à partir d'un graphe de 4-adjacences, avec 2, 3 et 4 level sets. Ces résultats ont été réalisés avec  $\sigma^2 = 50$  et  $r^2 = 2$ .

Comme on peut le voir à partir de ces résultats, l'augmentation du nombre de level sets produit une segmentation plus fine améliorant la classification du spectre.

Nous comparons notre méthode d'un seul level set avec la méthode de Graph-cut proposée dans [5]. Les figures 3(a) et 3(b), montrent l'image RVB et la vérité terrain de cette IHS. Les figures 3.c, 3.d et 3.e présentent les résultats obtenus avec notre méthode à deux-phases sur graphe à 4-adjacences, la méthode de Graph-cut sur graphe com-

TABLE 1 – L'évaluation des résultats de segmentation deux-phases

Méthode	deux-phases 4-adjacence graphe ( $r^2 = 2$ )	Graph-cut graphe complet	deux-phases graphe complet
OS	0.8209	0.8131	<b>0.9566</b>

plet et notre méthode à deux phases sur graphe complet, respectivement.

Pour évaluer ces résultats, nous avons utilisé le score de recouvrement (Overlapping Score = OS) qui compare l'image segmentée  $S$  et la vérité terrain  $G$ . Il est défini par :

$$OS = \frac{|S \cap G|}{\min(|S|, |G|)} \quad (8)$$

Le critère OS considère les valeurs les plus élevées près de 1 comme la meilleure segmentation.

L'évaluation des résultats de la segmentation est donnée dans le tableau 1. On constate que les résultats obtenus avec la méthode à deux-phases sur un graphe complet sont nettement supérieurs à toutes les autres.

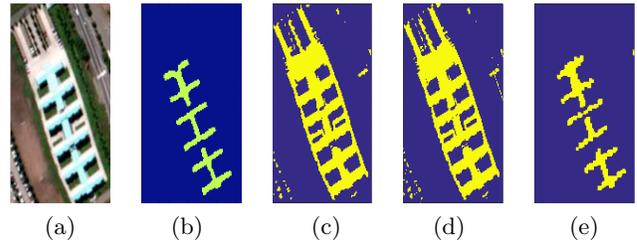


FIGURE 3 – Comparaison de notre approche avec Graph-cut : (a) Image originale, (b) Vérité terrain, (c) Level-sets ( $n = 1, r^2 = 2$ ), (d) Graph-cut (graphe complet), (e) Level-sets ( $n = 1$  graphe complet)

La figure 4 présente les résultats finaux de la segmentation multi-phases sur l'image Pavia à partir de sa représentation sous forme d'un RAG.

Les figures 4.a et 4.b, montrent la segmentation sur RAG basé respectivement sur l'extraction des régions avec l'approche TurboPixels [6] et l'approche de Ren et Malik [8].

Pour mieux visualiser l'extraction des régions et la construction du graphe, nous illustrons sur une partie formée de l'image (figure 5) la construction d'un RAG sur 100 régions.

Le tableau 2 compare la segmentation sur un RAG construit sur des superpixels de Ren et Malik et avec celle sur un RAG construit sur les TurboPixels et la segmentation sur graphe 4-adjacences en fonction du temps de calcul et du score de recouvrement.

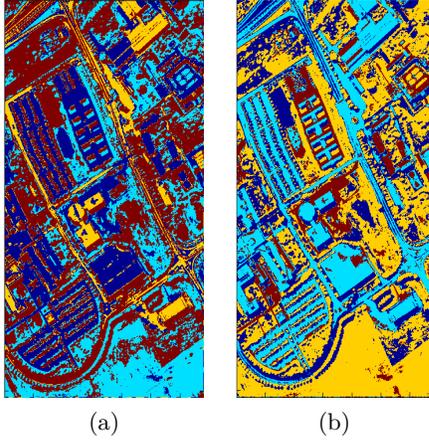


FIGURE 4 – Segmentation sur RAG avec deux level-sets : (a) Partition obtenue par la méthode TurboPixels (5000 régions), (b) Partition obtenue par la méthode Ren et Malik (10000 régions)

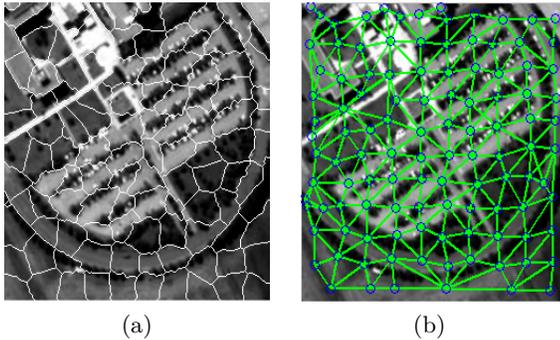


FIGURE 5 – Exemple de RAG : (a) L'image initiale avec les contours de la partition, (b) Le RAG correspondant. Les points bleus correspondent aux sommets et les arcs verts aux arêtes.

## 4 Conclusion

Dans cet article, nous avons présenté une adaptation des EdPs pour la méthode de level set sur des IHS en utilisant une propagation de front sur des graphes pondérés. Les résultats expérimentaux ont montré le potentiel de la méthode et son efficacité dans les modèles à deux phases et multi-phases avec différentes approches de construction du graphe.

Dans la suite de ces travaux, nous souhaitons nous focaliser sur d'autres constructions du graphe comme la construction non locale via l'utilisation des patches. Nous proposons aussi d'étudier l'impact d'autres métriques de similarité de spectres sur la segmentation d'IHS en se basant sur les travaux de [3].

TABLE 2 – Comparaison des résultats de segmentation multi-phases (2 level sets)

Méthode	RAG 5000 (Ren et Malik)	RAG 5000 (Levinshtein)	Pixels 4 adjacences
Temps de calcul	1.35 t	<b>t</b>	17.5 t
OS	0.7915	<b>0.8502</b>	0.8387

## Références

- [1] Gustavo Camps-Valls, Tatyana V Bandos Marsheva, and Dengyong Zhou. Semi-supervised graph-based hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10) :3044–3054, 2007.
- [2] Tony F Chan and Luminita A Vese. Active contours without edges. *Image processing, IEEE transactions on*, 10(2) :266–277, 2001.
- [3] Hilda Deborah, Noël Richard, and Jon Yngve Hardeberg. A comprehensive evaluation of spectral distance functions and metrics for hyperspectral image processing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6) :3224–3234, 2015.
- [4] Xavier Desquesnes, Abderrahim Elmoataz, and Olivier Lezoray. Pdes level sets on weighted graphs. In *Image Processing (ICIP), 2011 18th IEEE International Conference on*, pages 3377–3380. IEEE, 2011.
- [5] David B Gillis and Jeffrey H Bowles. Hyperspectral image segmentation using spatial-spectral graphs. In *SPIE Defense, Security, and Sensing*, pages 83901Q–83901Q. International Society for Optics and Photonics, 2012.
- [6] Alex Levinshtein, Adrian Stere, Kiriakos N Kutulakos, David J Fleet, Sven J Dickinson, and Kaleem Siddiqi. Turbopixels : Fast superpixels using geometric flows. *IEEE transactions on pattern analysis and machine intelligence*, 31(12) :2290–2297, 2009.
- [7] David W Messinger and J Albano. A graph theoretic approach to anomaly detection in hyperspectral imagery. In *Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS), 2011 3rd Workshop on*, pages 1–4. IEEE, 2011.
- [8] Xiaofeng Ren and Jitendra Malik. Learning a classification model for segmentation. In *ICCV*, volume 1, pages 10–17, 2003.
- [9] Luminita A Vese and Tony F Chan. A multiphase level set framework for image segmentation using the mumford and shah model. *International journal of computer vision*, 50(3) :271–293, 2002.