

Proposition d'une stratégie de segmentation d'images hyperspectrales

Hyperspectral images segmentation: a proposal

**Nathalie Goretta¹, Jean-Michel Roger¹, Fiorio Christophe²,
Véronique Bellon-Maurel¹, Gilles Rabatel¹ et Camille Lelong³**

¹ Cemagref, UMR ITAP Information et Technologie pour les agro-procédés, Montpellier FRANCE

² Lirmm, Montpellier FRANCE

³ Cirad, UMR TETIS, Montpellier FRANCE

Manuscrit reçu le 31 janvier 2008

Résumé et mots clés

Cet article présente une stratégie de segmentation d'images hyperspectrales liant de façon symétrique et conjointe les aspects spectraux et spatiaux. Pour cela, nous proposons de construire des variables latentes permettant de définir un sous-espace représentant au mieux la topologie de l'image. Dans cet article, nous limiterons cette notion de topologie à la seule appartenance aux régions. Pour ce faire, nous utilisons d'une part les notions de l'analyse discriminante (variance intra, inter) et les propriétés des algorithmes de segmentation en région liées à celles-ci. Le principe générique théorique est exposé puis décliné sous la forme d'un exemple d'implémentation optimisé utilisant un algorithme de segmentation en région type split and merge. Les résultats obtenus sur une image de synthèse puis réelle sont exposés et commentés.

Imagerie hyperspectrale, segmentation d'images, chimiométrie.

Abstract and key words

Hyper-Spectral Imaging (HSI) also known as chemical or spectroscopic imaging is an emerging technique that combines imaging and spectroscopy to capture both spectral and spatial information from an object. Hyperspectral images are made up of contiguous wavebands in a given spectral band. These images provide information on the chemical make-up profile of objects, thus allowing the differentiation of objects of the same colour but which possess make-up profile. Yet, whatever the application field, most of the methods devoted to HSI processing conduct data analysis without taking into account spatial information. Pixels are processed individually, as an array of spectral data without any spatial structure. Standard classification approaches are thus widely used (k-means, fuzzy-c-means hierarchical classification...). Linear modelling methods such as Partial Least Square analysis (PLS) or non linear approaches like support vector machine (SVM) are also used at different scales (remote sensing or laboratory applications). However, with the development of high resolution sensors, coupled exploitation of spectral and spatial information to process complex images, would appear to be a very relevant approach. However, few methods are proposed in the litterature. The most recent approaches can be broadly classified in two main categories. The first ones are related to a direct extension of individual pixel classification methods using just the spectral dimension (k-means, fuzzy-c-means or FCM, Support Vector Machine or SVM). Spatial dimension is integrated as an additionnal classification parameter (Markov fields with local homogeneity constraint [5], Support Vector Machine or SVM with spectral and spatial kernels combination [2], geometrically guided fuzzy C-means [3]...). The second ones combine the two fields related to each dimension (spectral and spatial), namely chemometric and image analysis. Various strategies have been attempted. The first one is to rely on chemometrics methods (Principal Component Analysis or PCA, Independant Component Analysis or ICA, Curvilinear Component Analysis...) to reduce the spectral dimension and then to apply standard images processing

technics on the resulting score images *i.e.* data projection on a subspace. Another approach is to extend the definition of basic image processing operators to this new dimensionality (morphological operators for example [1, 4]). However, the approaches mentioned above tend to favour only one description either directly or indirectly (spectral or spatial). The purpose of this paper is to propose a hyperspectral processing approach that strikes a better balance in the treatment of both kinds of information.

To achieve this, a generic scheme is proposed to associate more closely the spectral and spatial aspects symmetrically and conjunctively. This method, called butterfly, aims to perform an iterative and a cross analysis of data in the spectral and the spatial domains lead to the segmentation of the hyperspectral image. The strategy is based on two steps:

- Extraction of a spatial structure (topology) incorporating a spectral structure,
- Extraction of a spectral structure (latent variables) incorporating a spatial structure,

These steps are processed in a successive, iterative and inter-dependent way.

In this article, we will focus solely on specific notions of topology *i.e.* the notions of connectivity and adjacency. Thus, the first stage deals with the use of commonly used image processing tools (region segmentation algorithms) on a limited number of score images. This makes it relatively easy to process. To carry out the second step, we use chemometric tools to reveal a subspace (latent variables) enabling the characterization of heterogeneity of the obtained image partitions. However, the scheme can be applied on two different ways depending on the region segmentation strategy used *i.e.* top down approaches (splitting) or bottom-up approaches (merging). We have implemented this scheme by using a split and merge strategy based on the quadtree approach. Each phase is done over successive steps (iterations). At each iteration of the split phase, the data are projected on k_1 suitable latent variables. The split of each existing region (partition) into four disjoint quadrants is tested and the one maximising the Wilks Lambda parameter is chosen. At each iteration of the merge phase, the data are projected on k_2 suitable latent variables and all the merging of two adjacent regions are tested. The one maximising the Wilks Lambda parameter is chosen.

Lastly, we tested our approach on a simple synthetic image to show more precisely its characteristics and also on two real images at different scales (in field acquisition on crop, remote sensing image of urban zone). The results obtained on real images underline the benefit of the butterfly approach. However, further work will be undertaken to investigate the influence of various parameters. Moreover, other topology notions and image analysis algorithm could be also investigated.

Hyperspectral imaging, segmentation, chemometric.

References

- [1] J.A. BENEDIKTSSON, J.A. PALMASON, and J SVEINSSON. Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3):480-491, 2005.
- [2] G. CAMPS-VALLS, L. GOMEZ-CHOVA, J. MUNOZ-MARI, J. VILA-FRANCES, and J. CALPE-MARAVILLA. Composite kernels for hyperspectral image classification. *Geoscience and Remote Sensing Letters*, 3(1):93-97, 2006.
- [3] J. C. NOORDAM and W.H.A.M. VAN DEN. BROEK. Multivariate image segmentation based on geometrically guided fuzzy c-means clustering. *Journal of Chemometrics*, 16 :1-11, 2002.
- [4] J.A. PALMASON, J.A BENEDIKTSSON, and K. ARNASON. Morphological transformations and feature extraction for urban data with high spectral and spatial resolution. In *IGARSS*, volume 1, pages 470-472, Toulouse, France, 2003.
- [5] O. PRONY, X. DESCOMBES, and J. ZERUBIA. Classification des images satellitaires hyperspectrales en zone rurale et périurbaine. Rapport de recherche INRIA 4008, INRIA, septembre 2000.

1. Introduction

L'imagerie hyper-spectrale consiste à créer et à analyser des images acquises dans des centaines de bandes contiguës grâce auxquelles il est possible d'estimer un spectre de réflectance complet pour chaque élément de l'image. Quel que soit le domaine d'application, cette technique a apporté de véritables innovations dès lors qu'elle a permis de sortir du domaine spectral du visible (0,4-0,7 μm) et de construire des images infrarouges et proche infrarouges. De telles images apportent des informations sur la constitution chimique des objets et permettent ainsi de distinguer des objets de même couleur mais de compositions chimiques différentes.

Le premier facteur de développement de l'imagerie hyperspectrale a été indubitablement la disponibilité de détecteurs multicanaux sensibles aux rayonnements proche infrarouge (InGaAs avec différents dopages) ou infrarouge (micro-bolomètres). Il est intéressant de remarquer que l'imagerie hyperspectrale s'est développée à deux extrémités de l'échelle spatiale, à savoir pour l'imagerie satellitaire, avec des résolutions de 20 m environ et à l'échelle microscopique, notamment en imagerie Raman ou moyen-infrarouge, avec des résolutions de l'ordre de la dizaine de microns, et ceci sans que les communautés ne communiquent vraiment entre elles. Nos objets d'étude (les produits agro-alimentaires et les procédés agricoles) se situent à une échelle intermédiaire, appelée « échelle macroscopique » avec des champs variant de quelques centimètres à quelques mètres. À cette échelle d'étude, la vision hyper-spectrale s'est développée de manière beaucoup plus récente à cause du coût prohibitif des équipements pour les applications visées (agricoles et alimentaires). Aujourd'hui, les applications les plus avancées concernent la détection des contaminants dans des procédés alimentaires (corps étrangers, salissures ...) ou agricoles (mauvaises herbes), la cartographie de composants chimiques (répartition des matières actives dans des comprimés pharmaceutiques, répartition eau/matière grasse dans des produits alimentaires) ou encore la détection de défauts invisibles à l'œil (car ayant la même réflectance colorimétrique que la partie saine) comme par exemple, les meurtrissures sur les pommes avant brunissement. Ces différentes applications sont largement décrites dans [1].

Quel que soit le domaine d'application, la plupart des méthodes développées pour le traitement des images hyperspectrales analysent les données sans prendre en compte l'information spatiale. Les pixels sont alors traités individuellement comme un simple tableau de mesures spectrales sans arrangement particulier. Les méthodes de classification classiques (k-means, fuzzy-C-Means, classification hiérarchique, par graphe ...) sont ainsi largement exploitées. Les méthodes de modélisation linéaires, telles que la régression PLS (Partial Least Squares) ([14], [10]) ou non linéaire telle que les vecteurs supports (Support Vector Machine ou SVM) sont aussi utilisées, en télédétection comme dans les laboratoires de chimie analytique ou les analyses industrielles ([22]).

Cependant, l'exploitation conjointe de l'information spectrale et spatiale disponibles, du fait entre autres, de l'apparition d'imageurs spectraux de meilleure résolution, apparaît aujourd'hui essentielle. Un champ nouveau de développement de méthodes d'analyses d'images hyper-spectrales a donc été ouvert : il consiste à élaborer des méthodes combinant de manière relativement symétrique (en particulier par des approches itératives) les paramètres spectraux et spatiaux des pixels de l'image. À notre connaissance, une des plus anciennes est due à Landgrebe et Kettig [11, 12] et est connue sous le nom d'ECHO pour « Extraction and Classification of Homogeneous Objects ». C'est une approche supervisée qui comporte une première étape de segmentation type croissance de région basée sur les statistiques des classes (fonction de densité de probabilité) puis une étape de classification par maximum de vraisemblance. Les approches plus récentes peuvent être classées grossièrement en deux catégories :

La première concerne les approches relevant davantage d'une extension de la classification individuelle des pixels telle que la proposerait une approche purement spectrale. L'information spatiale y est intégrée en tant que paramètre supplémentaire de classification. Dans [21], des contraintes d'homogénéité locale (énergie de clique) sont combinées à la classification spectrale selon le formalisme des champs de Markov, déjà largement éprouvé en imagerie classique. Camps-Valls [5] utilise un classifieur basé sur les SVM avec des noyaux composites intégrant un terme spatial. On peut également citer les travaux de Noordamm ([16, 17]) qui propose un algorithme des C-moyennes floues (Fuzzy-C means ou FCM [3]) guidé spatialement (Spatially Guided FCM) en introduisant dans la fonction d'objectif une information spatiale sous la forme d'un modèle d'objet.

La seconde concerne des approches visant à combiner les disciplines propres à chacune des dimensions à prendre en compte (spatial, spectral) développées depuis plusieurs décennies et reposant sur des outils théoriques bien établis. Il s'agit de la chimiométrie d'une part, dédiée initialement à l'analyse de données issues de spectromètres, et du traitement d'image. La difficulté à lier ces deux disciplines tient au fait que le traitement d'image concerne des données qui, au niveau du pixel, ont un contenu relativement pauvre, à savoir une valeur scalaire ou, au mieux, un vecteur de quelques composantes (images couleur). Face à cette incompatibilité initiale, plusieurs démarches peuvent être envisagées. La première consiste à s'appuyer sur des techniques issues pour la plupart de la chimiométrie visant à réduire la dimension spectrale des images, pour ensuite appliquer des procédures de traitement d'image « classiques ». Parmi ces méthodes de réduction, on peut citer l'analyse en composantes principales ou ACP, les algorithmes génétiques qui sélectionnent des variables [4], l'analyse en composantes principales ajustée au bruit, la poursuite de projection, l'analyse en composantes indépendantes ou ICA ([13]) et certaines projections non-linéaires comme l'analyse en composantes curvilinéaires (Curvilinear Component Analysis) ou en distance curvilinéaire (Curvilinear Distance Analysis) ([15]). Une autre démarche

consiste au contraire à étendre la définition de certaines opérations ou notions élémentaires du traitement d'image à cette multi-dimensionnalité nouvelle. Un exemple est la morphologie mathématique, où la redéfinition des opérations de base (érosion et dilatation), ouvre l'accès à une panoplie d'outils de traitement : filtrage morphologique, gradient morphologique, algorithme de partage des eaux, etc. Toutefois, cette redéfinition suppose d'établir une relation d'ordre dans l'espace des spectres. Dans [20], les auteurs évoquent diverses techniques d'ordonnement (D-ordre, R-ordre,...), mais des difficultés conceptuelles persistent. Dans [18], la solution finalement adoptée revient à réduire la dimension spectrale à une composante principale à l'aide d'une PCA et à construire un profil morphologique sur celle-ci. Benediktsson ([2]) propose d'utiliser deux composantes principales et construit ainsi un profil morphologique étendu (combinaison des profils morphologiques obtenus sur chacune des composantes principales). Dans [7], c'est la notion de gradient différentiel qui est étendue, en reprenant la définition de Di Zenzo ([6]). Les auteurs l'utilisent dans le cadre de l'algorithme de diffusion anisotrope de Perona-Malik [19], appliqué ici directement sur l'image hyperspectrale initiale. Le résultat est une réduction du bruit spectral dans les zones homogènes de l'image, sans perte des discontinuités.



Cet article présente une approche originale qui n'appartient à aucune des deux catégories évoquées ci-dessus. Le principe générique théorique de celle-ci est présenté dans la section 2.1. Nous illustrons ce principe section 2.2 par un exemple d'implémentation. La section 3 est dédiée à la présentation des résultats obtenus sur des images synthétique et réelle.

2. Théorie

2.1. Notations et conventions

Les lettres majuscules grasses sont employées pour désigner des matrices, p.e. \mathbf{Z} . En cas de besoin, la dimension des matrices peut être indiquée par un indice multiple entre parenthèses, p.e. $\mathbf{Z}_{(n,p)}$ indique que la matrice \mathbf{Z} a n lignes et p colonnes. Tant que le contexte sera suffisamment clair pour éviter toute confusion, les matrices de dimension 2 ou 3 ne seront pas différenciées par une notation particulière. Les lettres minuscules grasses désignent des vecteurs colonnes, p.e. \mathbf{z}_j désigne la $j^{\text{ème}}$ colonne de \mathbf{Z} ; les lettres minuscules non grasses désignent des scalaires, p.e. des éléments de matrice z_{ij} ou des indices i .

Lorsque l'aspect spatial est privilégié, une image hyperspectrale est vue comme une fonction de \mathbb{R}^2 dans \mathbb{R}^p qui, à un point de coordonnées (x,y) associe un spectre $\mathbf{s}(x,y)$, vecteur de signaux mesurés à p longueurs d'onde. Lorsque l'on s'intéresse à sa topologie, l'image est vue comme un ensemble rectangulaire de $n \times m$ points, muni d'une partition \mathcal{P} de k régions connexes.

Lorsque l'aspect spectral est privilégié, une image hyperspectrale est une matrice 3D notée $\mathbf{Z}_{(n,m,p)}$, où n est le nombre de lignes et m le nombre de colonnes de l'image et p le nombre de longueurs d'onde mesurées. Pour des raisons calculatoires, cette image pourra être dépliée (indifféremment en lignes ou en colonnes), pour devenir une matrice 2D, de $(n \times m, p)$ de $n \times m$ spectres par p longueurs d'onde. À toute partition \mathcal{P} d'une image on associe une matrice d'appartenance $\mathbf{Q}_{(n \times m, k)}$ qui contient, pour chaque pixel, les k degrés d'appartenance binaires aux k régions (codage disjonctif).

Soit \mathbf{Z} une image hyperspectrale, munie d'une partition \mathcal{P} . Soit $\bar{\mathbf{z}}$ le spectre moyen de l'image, et $\tilde{\mathbf{Z}}$ l'image de même taille que \mathbf{Z} , dont tous les pixels valent $\bar{\mathbf{z}}$. Soit $\tilde{\mathbf{Z}}$ la matrice obtenue après centrage de \mathbf{Z} , i.e. $\tilde{\mathbf{Z}} = \mathbf{Z} - \bar{\mathbf{z}}$. La matrice d'inertie totale de l'image est définie par : $\mathbf{T} = \tilde{\mathbf{Z}}^T \tilde{\mathbf{Z}}$, la matrice d'inertie inter régions est donnée par $\mathbf{B} = \tilde{\mathbf{Z}}^T \mathbf{Q} (\mathbf{Q}^T \mathbf{Q})^{-1} \mathbf{Q}^T \tilde{\mathbf{Z}}$ et la matrice d'inertie intra classes est donnée par $\mathbf{W} = \mathbf{T} - \mathbf{B}$. Le Lambda de Wilks ([23]) de l'image \mathbf{Z} munie de la partition \mathbf{P} est défini par : $\Lambda(\mathbf{Z}, \mathbf{P}) = \text{trace}(\mathbf{B}) / \text{trace}(\mathbf{T})$. Cet indice varie entre 0 et 1 et mesure, de manière croissante, la séparation des régions dans l'espace spectral.

2.2. Description de la méthode

On propose de mêler les aspects spatiaux et spectraux d'une part de manière symétrique, de façon à ne pas privilégier un espace par rapport à l'autre, et de manière conjointe d'autre part de façon à ce que l'information spatiale se « nourrisse » de l'information spectrale et vice-versa pour avancer dans le processus de traitement de l'image.

Soit une image hyperspectrale Z , l'objectif est d'obtenir une segmentation de Z , i.e. une partition \mathcal{P} en k régions R_i , avec $i = 1 \dots k$ telle que :

$$Z = \bigcup R_i, i \in [1 \dots k]; \tag{1}$$

$$R_i \cap R_j = \emptyset \forall i \neq j, i, j \in [1 \dots k]; \tag{2}$$

$$Pr(R_i) = \text{vrai} \forall i \in [1 \dots k]; \tag{3}$$

$$Pr(R_i \cup R_j) = \text{faux} \forall R_i, R_j \text{ adjacentes}; \tag{4}$$

avec Pr: prédicat

Du point de vue spectral, nous nous intéressons à la construction de variables latentes, combinaisons linéaires des spectres, de façon à réduire la dimension de l'espace de travail tout en gardant l'information spectrale utile. La combinaison spectro/spatiale que nous proposons repose d'une part sur la construction de variables latentes dépendant de l'information topologique, et d'autre part sur la génération d'une topologie à partir de variables latentes. Ceci se traduit par les deux problématiques suivantes :

- Segmenter une image sur un espace réduit de variables latentes ;
- Construire des variables latentes prenant en compte l'information topologique ;

La première problématique est relativement aisée à traiter puisque elle s'apparente au traitement d'images couleur (trois plans) voire même au traitement d'image noir et blanc (un plan). De nombreuses méthodes sont ainsi disponibles dans la littérature.

Nous proposons de traiter le deuxième problème en limitant l'information topologique à la seule appartenance aux régions. La transposition de la notion de régions (qui concerne l'espace spatial) à celle de classes (qui concerne l'espace spectral) nous permet d'employer les outils de l'analyse discriminante. Ceux-ci sont utilisés pour construire les variables latentes. Pour déterminer ce sous espace, il est intéressant de remarquer qu'un grand nombre d'algorithmes de segmentation d'images en régions reposent sur deux opérations élémentaires appelées division et fusion. L'opération de division consiste à diviser tout ou partie de l'image pour diminuer l'hétérogénéité de chaque région au sens d'un critère défini au préalable. L'opération de fusion consiste à assembler les régions telles que leur union permette d'obtenir une nouvelle région uniforme au sens d'un prédicat d'homogénéité défini au préalable. Un algorithme classique en traitement d'images utilisant ce principe est l'algorithme de division-fusion ou SPLIT and MERGE [9]. Un algorithme type croissance de région tel que l'Union-Find par exemple [8], procède essentiellement en une étape de fusion ou d'union, l'étape de division pouvant être vue comme poussée à l'extrême, chaque pixel étant une région en début de processus. En utilisant les concepts de l'analyse discriminante, l'étape de division a donc pour objectif d'augmenter le nombre de régions en cherchant à diminuer l'hétérogénéité intra région (\mathbf{W}). L'étape de fusion a pour objectif de diminuer le nombre de régions (en supprimer) ceci étant réalisé en préservant l'hétérogénéité inter région (\mathbf{B}). Nous proposons donc la méthode suivante pour construire les variables latentes d'une image hyperspectrale Z avec la connaissance des régions (une partition \mathcal{P}):

- Pour l'étape de division: construction des variables latentes comme les premiers vecteurs propres (VP) de la matrice de variance intra région puis projection sur ces variables latentes:

$$\text{DIVISION : } \mathbf{Z}_{(m \times n, p)} \xrightarrow{\text{Calculer}} \mathbf{U} = VP(\mathbf{W}) \xrightarrow{\text{Projection}} \text{Scores} = \mathbf{ZU}$$

- Pour l'étape de fusion: construction des variables latentes comme les premiers vecteurs propres (VP) de la matrice de variance inter région puis projection sur ces variables latentes:

$$\text{FUSION : } \mathbf{Z}_{(m \times n, p)} \xrightarrow{\text{Calculer}} \mathbf{U} = VP(\mathbf{B}) \xrightarrow{\text{Projection}} \text{Scores} = \mathbf{ZU}$$

Le principe général évoqué ci-dessus peut être implémenté sous différentes formes en correspondance avec les algorithmes classiques de segmentation d'images régions. Nous présentons dans la section ci-dessous un exemple d'implémentation à partir d'un algorithme de segmentation en région type split and merge.

2.3. Exemple d'implémentation

2.3.1. Principe général

L'algorithme proposé repose sur une stratégie split and merge ([9]). La phase de split est réalisée par étapes successives. À chaque étape, l'image est projetée sur k variables latentes (calculées sur l'inertie intra), le split de chaque région en q régions est testé, et celui qui maximise le Lambda de Wilks est retenu. L'arrêt de cette première phase est contrôlé soit par le nombre de régions, soit par l'évolution du Lambda de Wilks. L'algorithme suivant décrit formellement la phase de split: Soit Z une image hyperspectrale et $\tilde{\mathbf{Z}}_{(n \times m, p)}$ sa matrice associée (supposée centrée), \mathcal{P} la partition réalisée, r le nombre de régions et *Arret* le prédicat d'arrêt de l'algorithme.

1. $r \leftarrow 1$; $\mathcal{P} \leftarrow \{Z\}$
2. $\mathbf{W} \leftarrow$ inertie intra de \mathbf{Z} , selon \mathcal{P}
3. $\mathbf{U}_{(p, k)} \leftarrow k$ variables latentes, k premiers vecteurs propres de \mathbf{W}
4. $\mathbf{S}_{(m \times n, k)} \leftarrow \tilde{\mathbf{Z}}\mathbf{U}$ scores sur les variables latentes
5. Pour chaque région R_i de \mathcal{P}
 - (a) split en q régions de $R_i \rightarrow \{A_1, A_2, \dots, A_q\}$
 - (b) création d'une partition $\mathcal{Q}_i \leftarrow \mathcal{P} - \{R_i\} + \{A_1, A_2, \dots, A_q\}$
 - (c) $\lambda_i \leftarrow \Lambda(\mathbf{S}, \mathcal{Q}_i)$
6. $I \leftarrow \text{ArgMax}_i(\lambda_i)$
7. $\mathcal{P} \leftarrow \mathcal{Q}_I$; $r \leftarrow r + q$
8. Si *Arret* = FALSE, GOTO 2

La phase de merge est elle aussi réalisée par étapes successives. De manière analogue au split, à chaque étape, l'image est projetée sur k' variables latentes (calculées sur l'inertie inter) et toutes les fusions de deux régions voisines sont testées. Celle qui maximise le Lambda de Wilks est retenue. Ainsi, l'ordre de regroupement des régions importe peu sur le résultat de la segmentation finale. Comme pour le split, l'arrêt peut être contrôlé par le nombre de régions désirées ou par l'évolution du Lambda de Wilks. Cette phase est décrite formellement par l'algorithme suivant:

\mathcal{P} est la partition de l'image en r régions, à l'issue de la phase de split.

1. $\mathbf{B} \leftarrow$ inertie inter de \mathbf{Z} , selon \mathcal{P}
2. $\mathbf{U}_{(p, k')} \leftarrow k'$ variables latentes, k' premiers vecteurs propres de \mathbf{B}
3. $\mathbf{S}_{(m \times n, k')} \leftarrow \tilde{\mathbf{Z}}\mathbf{U}$ scores sur les variables latentes
4. Pour chaque couple de régions adjacentes (R_i, R_j)
 - (a) fusion de $(R_i, R_j) \rightarrow R$
 - (b) création d'une partition $\mathcal{Q}_i \leftarrow \mathcal{P} - \{R_i, R_j\} + \{R\}$
 - (c) $\lambda_i \leftarrow \Lambda(\mathbf{S}, \mathcal{Q}_i)$
5. $I \leftarrow \text{ArgMax}_i(\lambda_i)$
6. $\mathcal{P} \leftarrow \mathcal{Q}_I$; $r \leftarrow r - 1$
7. Si *Arret* = FALSE, GOTO 1

À l'issue de l'enchaînement de ces deux phases, on dispose d'une image segmentée et d'une courbe d'évolution du Lambda

de Wilks, qui retrace l'évolution de la structure de l'image au cours du traitement.

L'algorithme, tel que décrit ci-dessus, est très gourmand en temps de calcul. Implémenté sous Matlab™, sur un Pentium™ IV / 2 GHz, le split en 1000 régions d'une image (100 × 212 × 160) demande de nombreuses heures de calcul. Son optimisation était donc absolument nécessaire. Elle a été réalisée en s'intéressant à la partie la plus rentable à optimiser à savoir le calcul de λ_i . Cette étape d'optimisation permet de passer, pour ce calcul, d'une complexité $O(n^3)$ en $O(n)$ (voir annexe A).

3. Matériel et méthode

3.1. Images de synthèse

Afin de tester la méthode présentée, une image hyperspectrale de synthèse de taille $n = 32 \times m = 32 \times p = 256$ a été construite de la manière suivante. L'image couleur $n = 32 \times m = 32$ de la figure 1 a été dessinée manuellement à l'aide d'un logiciel de gestion d'images (type Le Gimp), en juxtaposant des régions rouge, verte et bleue. Ces zones étaient toutes dimensionnées et placées pour être complètement circonscrites avec un nombre de splits réduit. L'image a été dépliée pour former une matrice $\mathbf{X}_{(1024,3)}$. Un ensemble de 3 spectres de $p = 256$ bandes spectrales, $\mathbf{S}_{(3,256)}$ a été synthétisé par combinaison linéaire aléatoire de 5 gaussiennes de centre et de largeur aléatoires, comme reporté par la figure 2. L'image hyperspectrale a ensuite été calculée par $\mathbf{Z} = \mathbf{X}\mathbf{S} + \epsilon\mathbf{E}$, où ϵ est un coefficient d'atténuation et $\mathbf{E}_{(1024,256)}$ est une matrice de spectres synthétiques, chacun construit de manière indépendante des autres, avec la même méthode que précédemment. Une valeur de 0.10 a été choisie pour ϵ . L'algorithme de segmentation

d'images utilisé est l'algorithme de Split and Merge classique ([9]). Ainsi, le split correspond à la division de chaque région candidate en 4 quadrants. Comme l'image de synthèse ainsi générée avait une structure simple, permettant de prévoir le comportement de l'algorithme, l'arrêt des phases de split et de merge a été contrôlé au moyen du nombre de régions. Un maximum de 10 régions a été demandé à la phase de split (*i.e.* 3 itérations), tandis que la phase de merge a été arrêtée lorsqu'il ne restait que 3 régions, conformément à l'image RVB de départ. Le nombre de variables latentes a été fixé à 1, pour les deux phases de l'algorithme.




Figure 2. Spectres utilisés comme base des images de synthèse, par combinaison linéaire avec les composantes RGB des images couleurs.



Figure 1. Image RVB utilisée comme base des images de synthèse.

3.2. Images réelles

3.2.1. Présentation des images

La méthode présentée a été testée sur deux images réelles :
 - La première est une image qui a été acquise à l'aide d'une caméra ligne HYSPEX VNIR 1600 pixels (Hyspex, Norsk Elektro Optikk AS, Norway) montée sur un banc assurant la translation et donnant accès à la dimension spatiale manquante (x). L'acquisition s'effectue sur une bande spectrale allant du visible au très proche infrarouge (400-1000 nm) avec une résolution spectrale de 3.7 nm permettant d'acquérir 160 plans spectraux. L'image a été acquise avec une profondeur de 12 bits. Plusieurs optiques de focale fixe sont disponibles. Elles permettent de travailler à une distance variable allant de 30 cm à quelques dizaines de mètres et fixent la résolution spatiale de l'image acquise. Pour une focale minimale (30 cm) la résolution spatiale est de 0.15 mm par pixel dans la direction y et peut varier de 0.15 à $0.15 \times b$ dans la direction de la translation (x), avec b facteur de binning spatial. Un temps d'intégration variable permet de s'adapter aux conditions de prise de vue *i.e.*

d'éclairage. L'acquisition des images réelles a été réalisée en milieu extérieur par temps clair sur une cible d'environ $20 \times 15 \text{ cm}^2$ composée d'adventices en pots (deux variétés). La distance de prise de vue était de 30 cm, le binning spatial dans la direction x fixé à 2, le temps d'intégration réglé à 1000 ms. Afin de réduire les temps de calcul, les pixels des images acquises de taille initiale $n = 1600 \times m = 1120 \times p = 160$ ont été regroupés par bloc pour former des images finales de taille $n = 80 \times m = 169 \times p = 160$ (figure 3).

- La deuxième est une image DAIS (Digital Airborne Imaging spectrometer) mise à disposition par le département de télécommunication et de télédétection de l'université de Pavie en Italie. Cette image représente une vue aéroportée de la ville de Pavie en Italie et comporte 80 bandes de 496 nm à 20000 nm. Afin de réduire les temps de calcul, l'image de taille initiale $n = 400 \times m = 400 \times p = 80$ a été réduite pour former une image finale de taille $n = 144 \times m = 161 \times p = 92$ (figure 3). Le traitement des images décrites précédemment a été effectué à l'aide d'une implémentation utilisant un processus Split and Merge classique. La segmentation a été effectuée dans un premier temps volontairement avec un nombre de phase de split élevé *i.e.* 300 splits soit 901 régions générées. Ce nombre a été ensuite diminué en fonction de l'analyse des résultats (voir section résultats).

Pour la première image traitée (image Hypspx) comportant optimalement 5 régions à déterminer (à savoir 2 adventices de variété 1, 2 adventices de variété 2 et le fond), le nombre de régions finales a été fixé à 5. Le nombre de variables latentes a été fixé à 1 pour la phase de split et de merge. Pour la deuxième image (image DAIS), le nombre de régions optimal est difficile à estimer et dépendra très certainement des applications envisagées. De la même façon que pour la première image, nous l'avons fixé à 5. Le nombre de variables latentes a été fixé à 1 pour la phase de split et de merge.



Figure 3. Image couleur de la scène Hypspx (gauche) et de la scène DAIS (droite).

3.2.2. Comparaison des résultats

Les résultats obtenus par notre approche ont été comparés à ceux obtenus avec deux méthodes l'une prenant en compte l'information spatiale (croissance de région), l'autre non (k-means) et décrites succinctement ci-dessous :

- Une approche croissance de région utilisant un algorithme type Union-Find et implémenté sous sa forme linéaire (scanline [8]) précédé d'une analyse en composantes principales (nombre de variables latentes choisi en fonction du pourcentage de variance expliquée) et suivi d'une étape de regroupement des régions. Afin de garantir une équité de traitement entre cette méthode et notre approche, l'étape finale de regroupement des régions (fusion) a été réalisée en utilisant un procédé identique à celui développé dans notre approche, *i.e.* à chaque étape de fusion, test de toutes les fusions possibles et réalisation de la meilleure au sens de la plus petite variation de variance intra-région entre l'avant et l'après fusion.
- Une approche classique k-means, précédée d'une analyse en composantes principales (nombre de variables latentes choisi en fonction du pourcentage de variance expliquée).

4. Résultats

4.1. Sur image de synthèse

La figure 4 montre les spectres de l'image de synthèse. On voit clairement les trois groupes correspondant aux trois régions. La figure 5 montre le déroulement de l'algorithme. En 2 splits, les 3 régions initiales sont complètement cernées (le troisième n'était pas nécessaire). Puis, les 7 phases de merge font passer la partition de 10 régions à 3, correspondant aux régions de

l'image RVB. La figure 6 montre la variable latente utilisée pour le premier split, en superposition avec les spectres purs associés aux composantes R, V et B. Cette variable latente a été calculée sur l'inertie intra région de l'image de départ, qui ne comportait qu'une seule région. De fait, cette variable latente est identique à la première composante d'une ACP de l'image de départ. Ainsi, on peut constater que la variable latente est très proche du spectre associé au bleu, ce qui traduit la forte proportion de bleu dans l'image. À la première itération, c'est donc l'information prédominante (le bleu) qui a été prise en compte dans la première variable latente. La deuxième variable latente est représentée en figure 7. Elle a été calculée sur l'inertie interne de l'ensemble des 4 quadrants de l'image. Dans cette partition, l'inertie du bleu a disparu. C'est le quadrant bas-gauche qui présente la plus grande inertie, due à la présence de deux régions rouge et verte. On remarque bien que la variable latente est devenue quasiment indépendante du bleu. Elle est très proche du spectre associé au rouge, lorsque celui associé au vert est faible (par exemple entre les variables 125 et 200). En superposant la variable latente à la différence des spectres associés au rouge et au vert, comme représenté par la figure 8, on constate logiquement qu'elle réalise une séparation entre les deux directions spectrales associées au rouge et au vert. Cet exemple, volontairement simpliste dans lequel les « zones objets » correspondent parfaitement aux quadrants de la segmentation Split and Merge, montre bien la faculté de la méthode à utiliser l'information de manière incrémentale et ce de façon naturelle. À chaque itération, c'est une information complémentaire de celle utilisée lors de l'itération précédente qui est prise en compte.

4.2. Sur image réelle

La figure 9 montre l'évolution du Lambda de Wilks pour l'image Hypspx, au cours des deux phases de l'algorithme, avec deux modes de calcul : sur l'espace spectral complet (que nous




Figure 4. Spectres de l'image de synthèse.




Figure 5. Déroulement de l'algorithme sur l'image de synthèse.




Figure 6. Variable latente utilisée pour le premier split, en superposition aux spectres purs.




Figure 7. Variable latente utilisée pour le deuxième split, en superposition aux spectres purs.




Figure 8. Variable latente utilisée pour le premier split, en superposition au spectre de différence entre le spectre pur associé au rouge et celui associé au vert.

dénommerons Lambda complet) et sur l'espace des variables latentes (que nous nommerons Lambda partiel). On remarque que la valeur du Lambda complet est nettement plus faible que celle du Lambda partiel. Ceci montre bien qu'une grande partie de l'espace spectral n'est pas concernée par la segmentation, et qu'il est donc *a priori* plus optimal de travailler sur des variables latentes. On remarque également que les deux courbes ont approximativement le même profil, et que celle du Lambda partiel est beaucoup plus régulière. Le profil croissant/décroissant, obtenu pour le Lambda complet, est tout à fait naturel. Par contre, rien ne garantit que celui du Lambda partiel suive la même tendance. En effet, il convient de rappeler ici que le Lambda partiel est optimisé à chaque pas de l'algorithme sur un espace différent. La succession de ces espaces est bien cohérente avec l'évolution de la partition. Ceci confirme donc bien que les vecteurs propres de l'inertie intra classes et de l'inertie inter classes sont de très bons candidats pour définir un espace adapté aux opérations de split et de merge, respectivement.

De la même manière, la figure 10 montre l'évolution du Lambda de Wilk partiel pour l'image DAIS, au cours des deux phases de l'algorithme. Les profils des deux courbes est sensiblement le même que pour l'image Hypsplex avec, cependant une évolution plus lente de ce paramètre pour l'image DAIS.

La figure 11-A montre les segmentations obtenues avec une phase de 300 splits et un nombre de régions finales respectivement de 5, 9 et 20 pour l'image Hypsplex. Il apparaît ainsi que 5 régions ne sont pas suffisantes pour discriminer fond et plantes : la région 1 correspond à un mélange plantes-fond, les régions 3, 4 et 5 correspondent au fond (mélange terre-contenant), la région 2 contient une partie de feuille. La segmentation comprenant 9 régions permet de mieux séparer végétal et fond, avec l'apparition de nouveaux détails, *i.e.* région 9 correspondant à un morceau de bois, région 7 correspondant à une feuille non visible avec la segmentation précédente. Enfin, la segmen-




Figure 9. Image Hypsplex : Évolution du λ de Wilks, en fonction du nombre de régions, pendant les deux phases de split et de merge. En gras, calculé sur l'espace spectral complet ; en maigre, calculé sur l'espace des variables latentes.




Figure 10. Image DAIS : Évolution du Λ de Wilks, en fonction du nombre de régions, pendant les deux phases de split (maigre) et de merge (gras pointillé) calculé sur l'espace des variables latentes.

tation comportant 20 régions montre une sur-segmentation évidente. Les figures 11-B et 11-C montrent respectivement les segmentations obtenues avec les techniques d'Union-Find (seuil de regroupement fixé à 0.74) et du k-means avec 5, 10 et 20 régions finales. L'approche Union-Find, si elle permet par principe même d'avoir accès à la notion d'objet, ne parvient pas à dégager les grands ensembles de l'image. Partant du pixel, cette approche a tendance à « s'intéresser » aux régions très hétérogènes de l'image et ne permet pas, de ce fait, de dégager une

vue d'ensemble de l'image. L'approche k-means ne prenant pas en compte l'information spatiale ne permet pas d'obtenir une segmentation correcte de l'image.

La figure 12-A montre les segmentations obtenues avec une phase de 300 splits et un nombre de régions finales respectivement de 5, 9 et 20 pour l'image DAIS. Les figures 12-B et 12-C montrent les segmentations obtenues avec respectivement la méthode union-find (seuil de regroupement fixé à 0.044) et la méthode k-means. La segmentation obtenue avec notre approche et cinq régions finales permet d'avoir un aperçu des grands ensembles de l'image à savoir (1) la zone fluviale, (2) une zone d'habitation, (3) une zone de bâtiments industriels, (4) une zone nue d'habitation (5) un bâtiment. En augmentant le

nombre de régions finales, on peut accéder plus en détail aux structures ou objets composants la scène (voir figures 12-A avec 10 et 20 régions finales).

L'approche union-find ne permet pas pour cette image d'avoir accès à une vue globale de la scène (faire ressortir les grands ensembles). Plus encore que dans le cas de l'image Hypspex, elle s'intéresse aux détails et à donc tendance à privilégier les zones très hétérogènes de la scène en les sur-segmentant (figure 12-B, 20 régions finales en haut à droite) et rassembler les zones moins hétérogènes (figure 12-B, 20 régions finales, grande région). L'approche k-means ne permet pas d'obtenir une segmentation correcte de l'image.

S

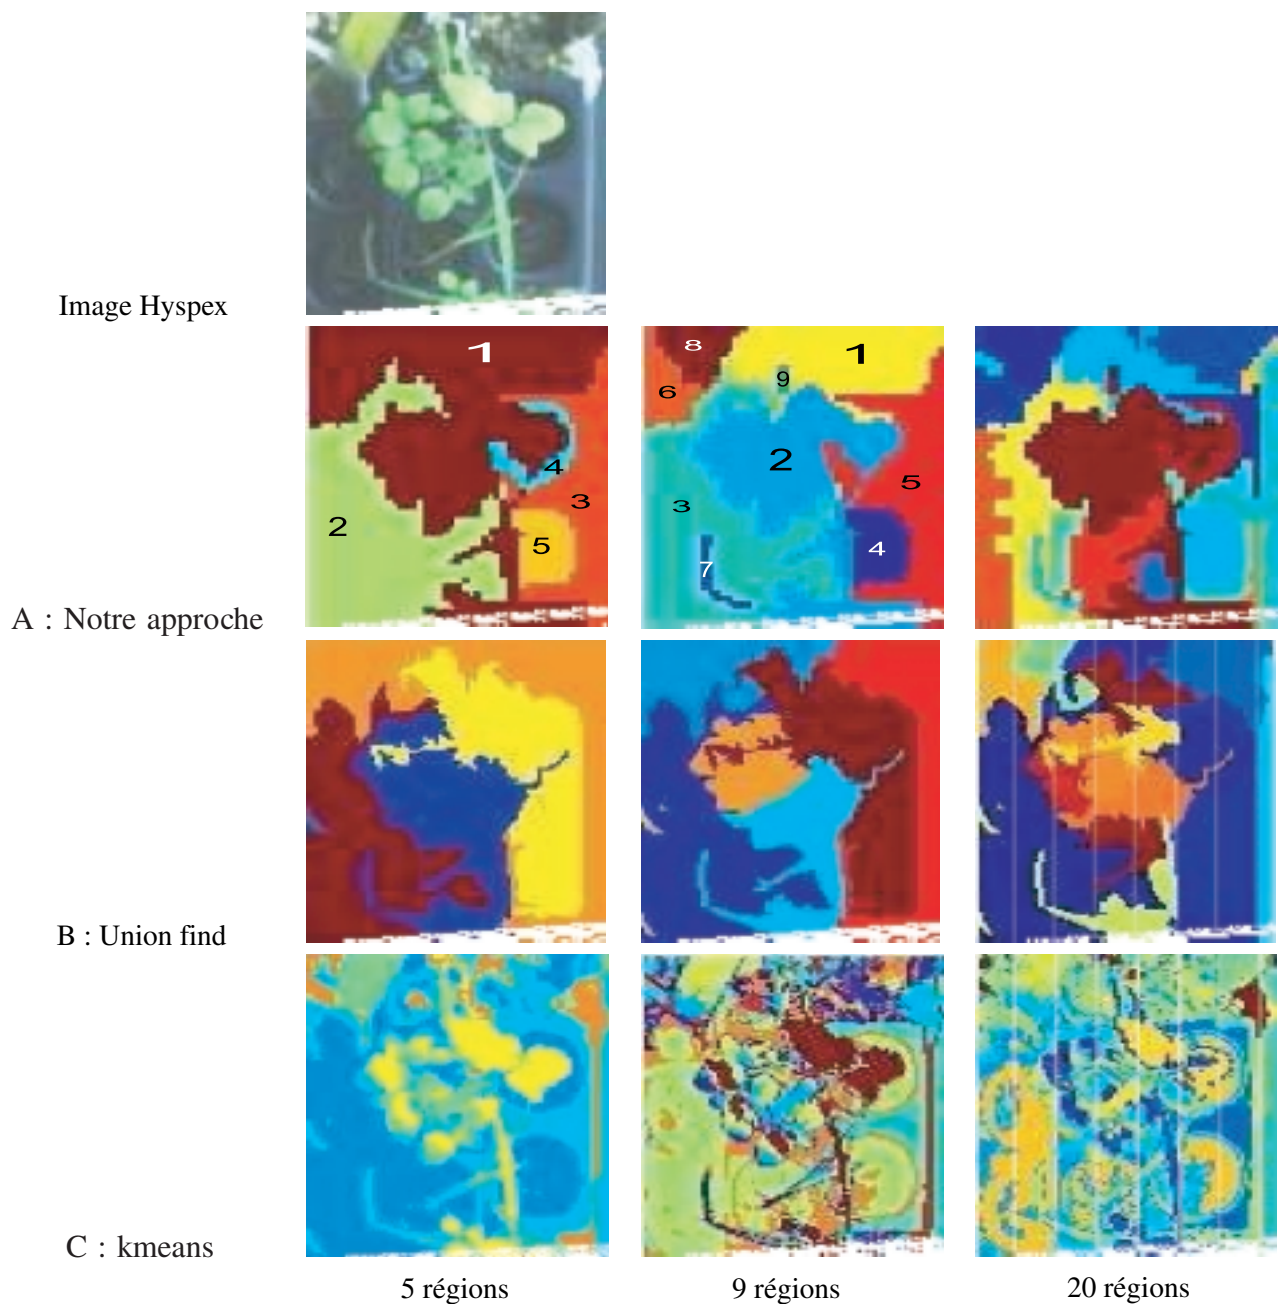


Figure 11. Segmentations de l'image Hypspex obtenues avec diverses approches et un nombre variable de régions finales.

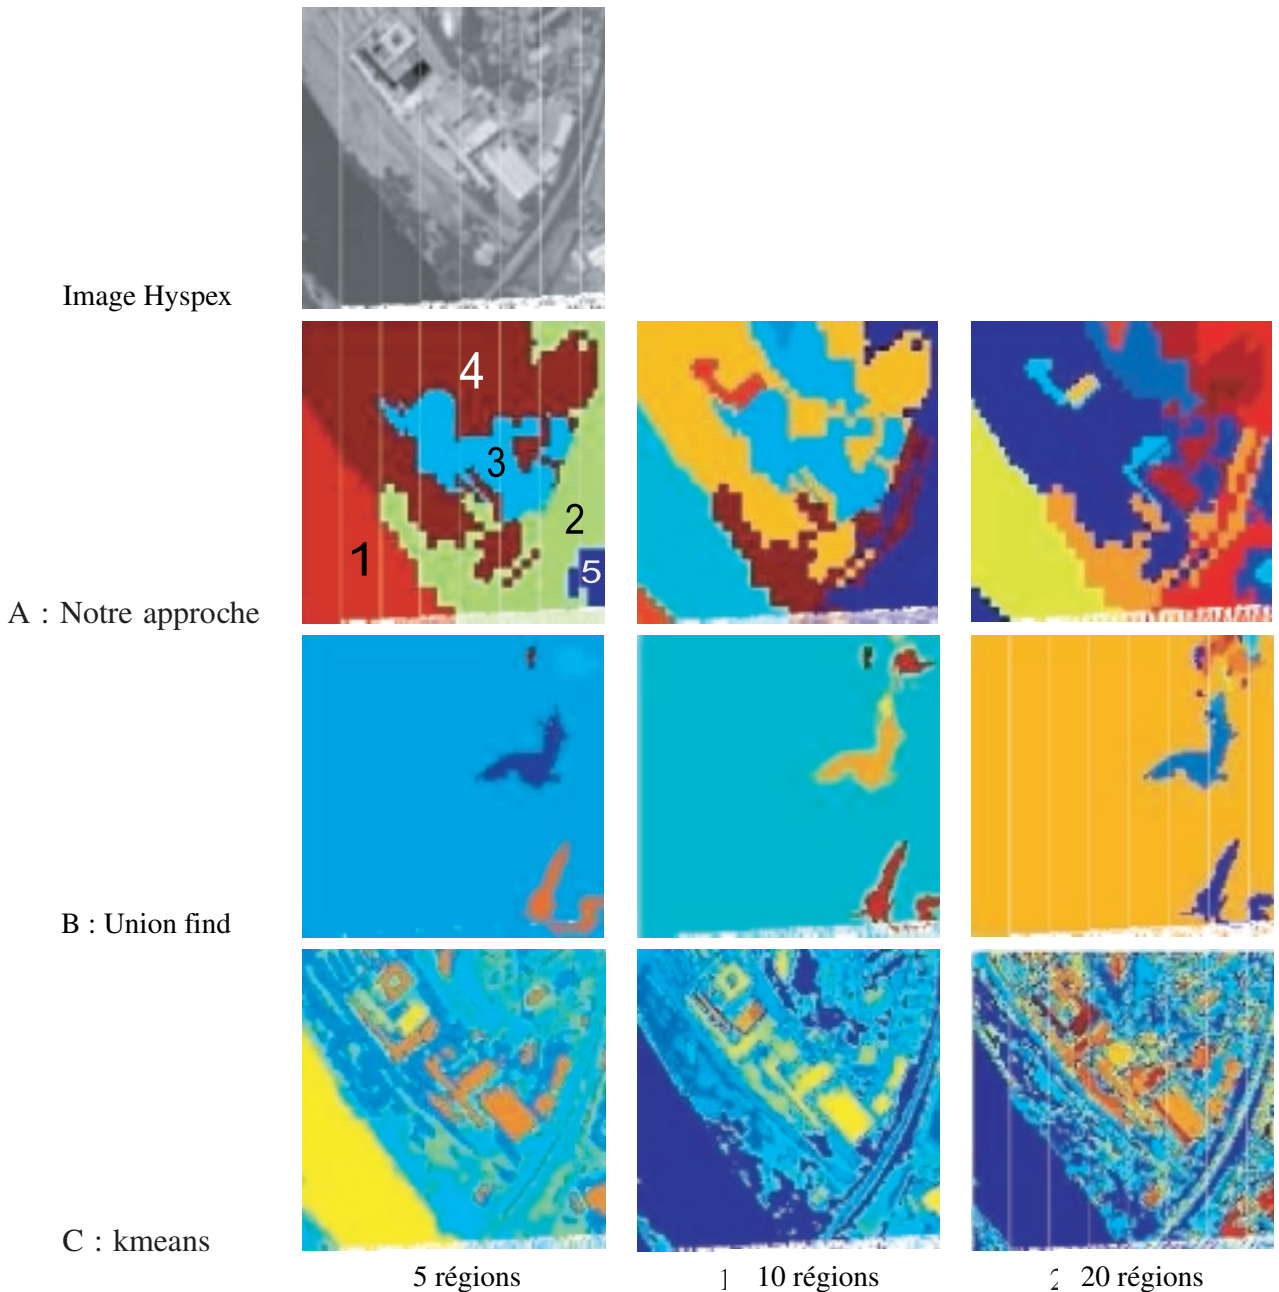


Figure 12. Segmentations de l'image DAIS obtenues avec diverses approches et un nombre variable de régions finales.

5. Conclusion

Cet article présente une stratégie de traitement des images hyperspectrales qui vise à combiner étroitement l'utilisation des informations spectrales et spatiales. Pour ce faire, nous proposons de construire des variables latentes spectrales en tenant compte de la topologie de l'image. Ceci est réalisé par le calcul des vecteurs propres des matrices d'inertie intra ou inter régions. La première est utilisée dans les phases de raffinement de la segmentation (phase de split), la deuxième lorsque la segmentation est dégradée (phase de merge). Ce principe a été utilisé dans un exemple d'implémentation mettant en oeuvre un

procédé de segmentation type division/fusion. L'algorithme a été appliqué à une image de synthèse pour illustrer son fonctionnement et à une image réelle de végétation et une image réelle de zone urbaine. L'objectif était de montrer la validité de notre approche dans son principe de fonctionnement tout en utilisant un algorithme de segmentation non optimal (segmentation split and merge). Des travaux ultérieurs seront entrepris afin d'utiliser des algorithmes de segmentation plus adaptés à savoir les méthodes de partitionnement de graphes (coupes minimales) ou une méthode de segmentation type ligne de partage des eaux modifiée. On s'intéressera également à l'étude de paramètres permettant de contrôler le déroulement de la segmentation (nombre de phase de division ou d'union) comme par

exemple le Λ de Wilks ou l'évolution des vecteurs propres. Cependant, la définition de ces paramètres sera très certainement liée à l'application envisagée.

6. Annexes

6.1. Annexe A

L'algorithme, tel que décrit ci-dessus (section 2. Théorie), est très gourmand en temps de calcul. Implémenté sous Matlab™, sur un Pentium™ IV/2 GHz, le split en 1000 régions d'une image (115 × 80 × 160) demande de nombreuses heures de calcul. Son optimisation est donc absolument nécessaire.

Dans les deux phases, la partie la plus rentable à optimiser, parce qu'elle est répétée souvent est le calcul de λ_i . Dans la boucle de recherche du meilleur split ou du meilleur merge, l'espace spectral est toujours le même, à savoir celui des variables latentes. Le dénominateur du Lambda de Wilks (la trace de l'inertie totale) est donc constant. Une première optimisation a donc consisté à ne calculer que le numérateur du Lambda de Wilks, c'est-à-dire la trace de l'inertie inter classes. Une deuxième optimisation a consisté à calculer la variation d'inertie inter classes due au split ou au merge. Soit $\mathbf{G}_{(r,p)}$ la matrice des centres de gravité (dans l'espace spectral) des r classes et $\mathbf{N}_{(r,r)}$ la matrice diagonale contenant les effectifs des r classes. On montre facilement que :

$$\mathbf{B} = \mathbf{G}^T \mathbf{N} \mathbf{G}$$

$$\mathbf{B} = \sum_{i=1}^p n_i \mathbf{g}_i \mathbf{g}_i^T$$

En d'autres termes, la contribution de la classe i à l'inertie inter classes est le produit externe de son vecteur centre de gravité par lui-même, pondéré par l'effectif de la classe. Comme la trace d'une somme de matrices est la somme des traces, on a :

$$\text{trace}(\mathbf{B}) = \sum_{i=1}^p n_i \text{trace}(\mathbf{g}_i \mathbf{g}_i^T)$$

$$\text{trace}(\mathbf{B}) = \sum_{i=1}^p n_i \mathbf{g}_i^2$$

La contribution de la classe i à la trace de l'inertie inter classes est donc le carré de la norme de son vecteur centre de gravité, pondéré par l'effectif de la classe. Partant de cette propriété, l'optimisation de l'algorithme a consisté (en reprenant les notations précédemment employées) :

- Pour le split, à remplacer le calcul de λ_i (5c), par :

$$\lambda_i = \sum_{j=1}^q n_{A_j} \mathbf{g}_{A_j}^2 - \sum_{j=1}^q n_{A_j} \mathbf{g}_{R_i}^2$$

- Pour le merge, à remplacer le calcul de λ_i (4c), par :

$$\lambda_i = n_R \mathbf{g}_R^2 - n_{R_i} \mathbf{g}_{R_i}^2 - n_{R_j} \mathbf{g}_{R_j}^2$$

où \mathbf{g}_X est le vecteur (de dimension p) du centre de gravité de la région X , dans l'espace spectral et n_X l'effectif de la région X .

Références

- [1] V. BELLON-MAUREL and J. DUBOIS. *NIR Hyperspectral Imaging in Food and Agricultural Science in Infrared and Raman Spectroscopic Imaging*. Wiley Publ, 2008.
- [2] J.A. BENEDIKTSSON, J.A. PALMASON, and J. SVEINSSON. Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3):480-491, 2005.
- [3] J. BEZDEK. *Pattern recognition with fuzzy objective functions*. Plenum Press, New York, 1981.
- [4] L. BRIAN, A.L. STEWARD, R. P. KALEITA, and D.A.A EWING. Genetic algorithms for Hyperspectral Range and Operator Selection. In *ASAE Annual Meeting*, 2005.
- [5] G. CAMPS-VALLS, L. GOMEZ-CHOVA, J. MUNOZ-MARI, J. VILA-FRANCES, and J. CALPE-MARAVILLA. Composite kernels for hyperspectral image classification. *Geoscience and Remote Sensing Letters*, 3(1):93-97, 2006.
- [6] S. DI ZENZO. A note on gradient of a multi-image. *Computer vision, graphics, and image processing*, 33:116-125, 1986.
- [7] J.M DUARTE-CARVAJALINO, M. VÉLEZ-REYES, and P. CASTILLO. Scale-space in hyperspectral image analysis. *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XII*, Orlando (Kissimmee), FL, USA, SPIE, volume 6233-42, 2006.
- [8] C. FIORIO and J. GUSTEDT. Two linear time union-find strategie for image processing. In *Theoretical Computer Sciences*, 54:165-181, 1996.
- [9] S.L. HOROWITZ and T. PAVLIDIS. Picture Segmentation by a Directed Split and Merge Procedure. In *CMetImAly77*, pages 101-111, 1977.
- [10] Zhi HUANG, Brian J. TURNER, Stephen J. DURY, Ian R. WALLIS, and William J. FOLEY. Estimating foliage nitrogen concentration from HYMAP data using continuum removal analysis. *Remote Sensing of Environment*, 93(1-2):18-29, 2004.
- [11] R.L. KETTIG and D.A LANDGREBE. Classification of multispectral image data by extraction and Classification of homogeneous objects. *IEEE Transactions on geoscience Electronics*, GE-14(1):12-29, 1977.
- [12] D.A. LANDGREBE. The Development of a Spectral-Spatial Classifier for Earth Observational Data. *Pattern Recognition Letters*, 12(3):165-175, 1980.
- [13] M. LENNON, G. MERCIER, M.C. MOUCHOT, and L. HUBERT-MOY. Independent component analysis as a tool for the dimensionality reduction and the representation of hyperspectral images. In *IEEE Geoscience and Remote sensing symposium, IGARSS2001*, volume 6, pages 2893-2895, 2001.
- [14] S. MCDONALD, K.O. NIEMANN, D.G. GOODENOUGH, A. DYK, C. WEST, and M. Tian Han MURDOCH. Hyperspectral remote sensing of conifer chemistry and moisture. In *IEEE International Geoscience and Remote Sensing Symposium, IGARSS2003*, volume 1, pages 552-554, Toulouse, France, 2003.
- [15] G. MERCIER, S. DERRODE, and M. LENNON. Hyperspectral image segmentation with Markov chain model. In *IEEE International Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings.* 2003, volume 6, pages 3766- 3768, Toulouse, France, 2003.
- [16] J. C. NOORDAM, W. H. A. M. VAN DEN BROEK, and L. M. C. BUYDENS. Unsupervised Segmentation of Predefined Shapes in Multivariate Images. *Journal of Chemometrics*, 17:216-224, 2003.
- [17] J. C. NOORDAM and W.H.A.M. VAN DEN BROEK. Multivariate image segmentation based on geometrically guided fuzzy c-means clustering. *Journal of Chemometrics*, 16:1-11, 2002.
- [18] J.A. PALMASON, J.A BENEDIKTSSON, and K. ARNASON. Morphological transformations and feature extraction for urban data with high spectral and spatial resolution. In *IGARSS*, volume 1, pages 470-472, Toulouse, France, 2003.

- [19] P. PERONA and J. MALIK. Scale-Space and Edge Detection Using Anisotropic Diffusion. *Transactions on Pattern Analysis and Machine Intelligence, IEEE*, 12(7):629-639, 1990.
- [20] A. PLAZA. Morphological Hyperspectral Image Classification: A Parallel Processing Perspective. In Chein-I Chang, editor, *Hyperspectral Data Exploitation*, pages Pages353-378. John Wiley and Sons, Inc, 2007.
- [21] O. PRONY, X. DESCOMBES, and J. ZERUBIA. Classification des images satellitaires hyperspectrales en zone rurale et périurbaine. Rapport de recherche INRIA 4008, INRIA, septembre 2000.
- [22] W. H. A. M. VAN DEN BROEK, E. P. P. A. DERKS, E. W. VAN DE VEN, D. WIENKE, P. GELADI, and L. M. C. BUYDENS. Plastic identification by remote sensing spectroscopic NIR imaging using kernel partial least squares (kpls). *Chemometrics and Intelligent Laboratory Systems*, 35(2):187-197, 1996.
- [23] S. WILKS. *Multidimensional scatter*. Stanford Press, 1960.



Nathalie **Gorretta**

Nathalie Gorretta est diplômée de l'institut national des sciences appliquées (INSA) de Lyon spécialité traitement du signal et de l'image. Elle est actuellement ingénieur de recherche au sein de l'unité mixte de recherche ITAP du Cemagref de Montpellier et s'intéresse plus particulièrement au développement d'approches d'acquisition et de traitement de données hyperspectrales de proximité (acquisition au champ pour la caractérisation des cultures). Elle a obtenu récemment un doctorat en informatique.



Jean-Michel **Roger**

Jean-Michel Roger est professeur associé à SupAgro Montpellier et anime une équipe du Cemagref dont la recherche est axée sur les capteurs optiques et les systèmes d'aide à la décision. Son expertise scientifique est la chimométrie, notamment appliquée à la spectrométrie. Dans le cadre des recherches appliquées menées par le Cemagref, il a développé des méthodes originales pour répondre aux problèmes de robustesse des étalonnages multivariés. Il a assuré la présidence du congrès international de chimométrie CAC'2008 (www.cac2008.org).



Véronique **Bellon-Maurel**

Véronique Bellon-Maurel est professeur à Montpellier Supagro et directrice de l'UMR « Information et Technologies pour les Agro-Procédés ». Son expertise scientifique est la spectrométrie proche infrarouge et en particulier l'instrumentation pour les procédés de contrôle en ligne des produits agricoles ou alimentaires. Elle a reçu en 2008 le Thomas Hirschfeld Award, qui est la plus haute distinction scientifique de la communauté internationale en spectrométrie proche-infrarouge. Il y a 10 ans, elle a introduit l'imagerie hyperspectrale dans les thèmes de recherche de son unité et est responsable d'une colonne « hyperspectral imaging » dans le journal NIRNews.




Gilles **Rabatel**

Gilles Rabatel est Directeur de Recherche au Cemagref de Montpellier. Spécialisé en vision numérique et traitement d'image, il s'est intéressé plus particulièrement, tout au long de sa carrière, aux problématiques spécifiques de l'utilisation de ces techniques en environnement extérieur sur des objets biologiques (robotique agricole et caractérisation des cultures). Plus récemment, il a élargi son champ de recherche à l'imagerie hyperspectrale de proximité, et à son utilisation dans ce même type de conditions.



Christophe **Fiorio**

Christophe Fiorio a obtenu son doctorat en informatique à l'Université Montpellier 2 et est habilité à diriger les recherches depuis 2008. Il est responsable adjoint de l'équipe projet Arith du Laboratoire d'Informatique, de Robotique, de Microélectronique de Montpellier (LIRMM UMR CNRS-UM2) et directeur adjoint de l'École Polytechnique Universitaire de Montpellier 2. Ses recherches portent sur une approche discrète et combinatoire de l'imagerie. Plus précisément, il développe une approche algorithmique et combinatoire de l'analyse d'images et notamment la segmentation d'images. Il s'intéresse également aux modèles discrets de représentation des images et en particulier à la géométrie discrète. Il est membre de « IEEE Computer Society » et des comités de programme des conférences « International Symposium » on Visual Computing et « Discrete Geometry for Computer Imagery ».



Camille **Lelong**

Camille Lelong a obtenu son doctorat en physique, spécialité télédétection hyperspectrale, à l'Université Paul Sabatier de Toulouse en 1999. Depuis 2001, elle travaille au Centre de Coopération Internationale en Recherche Agronomique pour le Développement (CIRAD) à Montpellier, où elle recherche de nouvelles méthodes permettant l'extraction de l'information à partir des images de télédétection multi- et hyperspectrales à très haute résolution spatiale, à des fins d'évaluation des systèmes de culture agroforestiers tropicaux.

