

Segmentation par Ligne de Partage des Eaux avec Marqueurs Spatiaux et Spectraux

Sébastien LEFÈVRE

Laboratoire des Sciences de l'Image, de l'Informatique et de la Télédétection (UMR 7005 CNRS-UDS)
Université de Strasbourg, Pôle API, Boulevard Brant, BP 10413, 67412 Illkirch Cedex, France
lefevre@unistra.fr

Résumé – Du fait de son rôle majeur dans les systèmes d'analyse et de traitement des images, le problème de la segmentation a fait l'objet de nombreux travaux. Cependant il n'existe pas encore de méthode automatique apte à traiter correctement tout type d'image. Les méthodes semi-automatiques sont donc une solution appropriée pour résoudre ce problème lorsqu'une faible intervention de l'utilisateur est possible. Parmi ces méthodes, l'approche par ligne de partage des eaux avec marqueurs est certainement l'une des plus employées. Dans cet algorithme, l'utilisateur fournit des marqueurs, qui ne sont utilisés qu'en tant qu'initialisations spatiales des régions produites par le processus de segmentation. Nous proposons ici d'exploiter également le contenu (spectral) des marqueurs, au travers d'une classification supervisée floue. Les résultats obtenus dans différents domaines applicatifs (imagerie couleur, télédétection) démontrent l'intérêt et la pertinence de l'approche proposée, qui ne nécessite pas d'autre paramètre que les marqueurs fournis par l'utilisateur.

Abstract – Due to its great influence in image analysis and processing systems, the problem of image segmentation has been studied for years. However there is not yet any automatic method able to correctly process any kind of image. Semi-automatic methods are then an appropriate solution to solve this problem when a limited user intervention is possible. Among these methods, the marker-based watershed approach is certainly one of the most widely used. In this algorithm, the user provides some markers, which are used only as spatial initialisations of the regions to be produced by the segmentation process. We propose here to also rely on the (spectral) content of the markers, through a fuzzy supervised classification. The results we have obtained in several application domains (color imaging, remote sensing) underline the relevance of the proposed approach, which does not need any parameter apart from the markers provided by the user.

1 Introduction

L'analyse, le traitement et l'interprétation d'images nécessitent souvent l'emploi de différents algorithmes. Parmi ceux-ci, la segmentation, qui a pour but d'extraire d'une image un ensemble de régions pertinentes, est particulièrement critique puisque la qualité des régions produites aura une incidence majeure sur le résultat du processus global. Le problème de la segmentation d'image a donc fait l'objet de nombreux travaux, cherchant à proposer des méthodes les plus automatiques ou les plus génériques possibles (concevoir une méthode de segmentation apte à traiter correctement tout type d'image de façon automatique est aujourd'hui encore impossible, et le restera sans doute longtemps puisque le problème est mal posé).

Les méthodes de segmentation semi-automatique, impliquant une (faible) intervention de l'utilisateur, permettent de traiter une variété importante d'images. Cette intervention de l'utilisateur peut prendre la forme d'une initialisation spatiale de l'algorithme, d'une définition des classes d'intérêt dans l'image, d'une pondération des différentes caractéristiques (couleur, texture, forme) à prendre en compte, etc. Parmi ces méthodes, l'algorithme de segmentation par ligne de partage des eaux (LPE) avec marqueurs [11] (une extension très communément utilisée de la méthode de segmentation LPE [12]) peut faire appel

à l'utilisateur au travers d'une initialisation spatiale définie par la position des marqueurs. Dans cet algorithme, seule la position spatiale des marqueurs est utilisée, le contenu (spectral) des marqueurs étant complètement ignoré.

Nous proposons ici d'améliorer la performance de la segmentation LPE avec marqueurs en exploitant le contenu des marqueurs. Pour cela nous utilisons les marqueurs comme des ensembles d'apprentissage dans une classification supervisée floue, le processus de segmentation s'appuyant alors sur les cartes de probabilités d'appartenance des pixels aux classes.

2 Segmentation LPE avec marqueurs

Pour décrire notre méthode qui est une extension de l'algorithme de LPE avec marqueurs, nous rappelons tout d'abord ce dernier [11] et donnons sa formulation algorithmique selon le principe de l'immersion [12] utilisé ici. Nous détaillons ensuite quelques travaux qui cherchent à mieux exploiter l'information disponible au sein du processus de segmentation.

2.1 Algorithme original de LPE avec marqueurs

Notons f l'image initiale à niveaux de gris définis dans l'intervalle $[h_{\min}, h_{\max}]$ que l'on va représenter comme un relief

topographique, et M l'ensemble des marqueurs fourni au titre de l'initialisation spatiale. Ces marqueurs vont permettre de localiser les minima que l'on souhaite imposer à la fonction f , et on définit alors le nouveau relief g comme :

$$g(p) = \begin{cases} h_{\min-1} & \text{si } p \in M \\ f(p) & \text{sinon} \end{cases} \quad (1)$$

où p représente les coordonnées d'un pixel, et $h_{\min-1}$ une nouvelle valeur spécifique aux marqueurs initiaux. La segmentation de l'image correspond à l'ensemble $X_{h_{\max}}$ des bassins de retention de la fonction g , calculé d'après le schéma de récursion suivant :

$$\begin{aligned} X_{h_{\min-1}} &= T_{h_{\min-1}}(g) \\ X_{h+1} &= IZ_{T_{h+1}(g)}(X_h), \quad h_{\min-1} \leq h < h_{\max} \end{aligned} \quad (2)$$

où T_h est la fonction seuil de niveau h (c'est-à-dire $T_h(f) = \{p \mid f(p) \geq h\}$), et $IZ_A(B)$ est l'union des zones d'influence géodésique des composantes connexes de B avec $B \subseteq A$. Nous faisons donc appel également aux définitions suivantes :

$$IZ_A(B) = \bigcup_{j=1}^l iz_A(B_j) \quad (3)$$

$$iz_A(B_j) = \{p \in A \mid \forall k \in [1, l] \setminus \{j\} : d_A(p, B_j) < d_A(p, B_k)\} \quad (4)$$

$$d_A(a, B) = \min_{b \in B} d_A(a, b) \quad (5)$$

où $d_A(a, b)$ représente la distance géodésique entre a et b dans A . Une définition complète est donnée dans l'article original [12].

2.2 Approches LPE exploitant des informations a priori

Beare [3] exploite des connaissances spatiales disponibles a priori et introduit un moyen pour contraindre la croissance des marqueurs via l'utilisation de fonctions de distances basées sur des éléments structurants. La méthode proposée est capable de traiter des frontières d'objets incomplètes ou bruitées.

Li et Hamarneh [6] considèrent un ensemble d'images d'apprentissage avec des segmentations de références pour construire des histogrammes de forme et des descripteurs d'apparence (la moyenne et la variance des intensités des pixels des objets). Leur segmentation guidée par des connaissances s'appuie sur un algorithme de LPE classique suivi par un algorithme de clustering k-means, mais la forme et l'apparence ne sont pas prises en compte dans l'étape de segmentation par la LPE.

Dans un travail précédent [4], nous avons proposé d'introduire la connaissance sous forme de pixels étiquetés lors d'une segmentation par LPE d'images multispectrales en télédétection. Plus précisément, un ensemble de c classes prédéfinies (par exemple les toits des bâtiments, la végétation, les routes) est considéré et des pixels exemples sont donnés pour chaque classe. Une classification floue basée pixels est alors appliquée en utilisant les signatures spectrales afin de générer des cartes de probabilité représentées sous la forme d'une seule image à c bandes. Un gradient morphologique est appliqué sur cette

image et la norme euclidienne permet ensuite d'obtenir une image à niveaux de gris, sur laquelle est finalement appliquée l'algorithme de LPE. La connaissance est donc ici uniquement liée à l'information spectrale, ne tenant pas compte de la position spatiale des pixels donnés en exemple.

A la connaissance de l'auteur, la seule tentative d'utilisation des marqueurs comme source de connaissances dans la segmentation par LPE a été effectuée par Grau et al dans [5], où une hypothèse très restrictive est faite quant à la distribution normale des intensités au sein des objets de l'image. Chaque marqueur ou classe étant représenté par la moyenne et la variance des valeurs de ses pixels, les auteurs considèrent un cadre bayésien et modélisent les corrélations locales entre pixels à l'aide de champs de Markov. Le processus de segmentation est donc relativement coûteux en temps de calcul.

3 Méthode proposée

Dans la définition de l'algorithme de segmentation par LPE avec marqueurs donnée précédemment, l'ensemble des marqueurs M a été utilisé seulement pour générer l'ensemble initial $X_{h_{\min-1}}$ impliqué dans l'algorithme récursif. Nous proposons ici d'exploiter non seulement la position mais aussi le contenu des marqueurs. Notre méthode offre l'avantage de ne pas nécessiter d'autre paramètre à régler outre ces marqueurs.

Nous proposons de modifier la définition des marqueurs et considérons maintenant une collection $M = \{M_i\}_{1 \leq i \leq c}$ de c marqueurs. Chaque marqueur est un ensemble de pixels $M_i = \{p\}$, donnant ainsi lieu à une ou plusieurs composantes connexes. Ces pixels peuvent être décrits par différentes caractéristiques (intensité, couleur, signature spectrale, texture, etc). Nous associons à chaque marqueur M_i une classe C_i et appliquons une classification supervisée floue des pixels, en utilisant M_i comme ensemble d'apprentissage pour la classe C_i . La procédure de classification supervisée retourne un ensemble de probabilités $\{w_i(p)\}$ où $w_i(p)$ représente la probabilité pour que le pixel p appartienne à la classe i , avec la contrainte suivante : $\sum_{1 \leq i \leq c} w_i(p) = 1$. Le contenu d'un marqueur donné M_i permet de générer une nouvelle image w_i où les valeurs élevées représentent les pixels qui appartiennent le plus probablement à M_i . Comme le principe de LPE considère un niveau croissant h , nous définissons les fonctions

$$f_i = (1 - w_i) \cdot f \quad (6)$$

où les pixels de probabilité élevée w_i auront leur altitude initiale f réduite, alors que les pixels de faible probabilité resteront inchangés. Il est aussi possible de considérer seulement les cartes d'appartenances (soit $f_i = 1 - w_i$), voire de choisir un modèle de pondération, avec κ un coefficient à fixer :

$$f_i = \kappa \cdot (1 - w_i) + (1 - \kappa) \cdot f \quad (7)$$

Nous discuterons ces possibilités dans la prochaine section et avons opté ici pour le modèle de fusion multiplicative donné par l'équation (6). Les fonctions f_i vont être considérées comme les reliefs dans le processus de LPE par immersion.

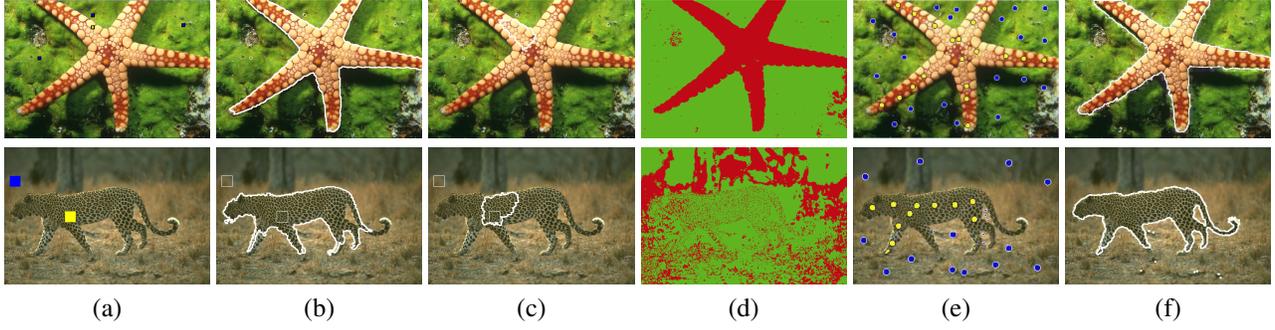


FIG. 1 – Segmentation d’images couleur : (a) image initiale avec marqueurs, (b) segmentation proposée, (c) segmentation par LPE avec marqueurs, (d) classification supervisée, (e) marqueurs et (f) résultats présentés dans [8].

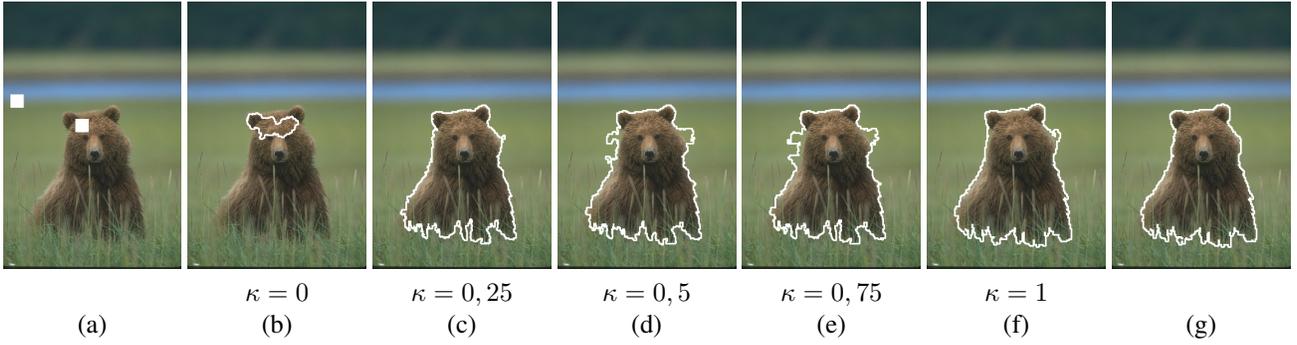


FIG. 2 – Influence du modèle de fusion entre relief initial f et probabilités d’appartenance w_i : (a) image initiale et ses deux marqueurs, (b) à (f) pondération des informations spatiales et spectrales selon l’équation (7) avec différentes valeurs de κ , et (g) fusion multiplicative adoptée ici.

L’algorithme initial de LPE nécessite une image à niveaux de gris f , tandis qu’ici la classification supervisée produit un ensemble de c images f_i . Au lieu d’imposer une étape de fusion pour combiner ces différentes images, nous considérons plutôt une image différente f_i pour chaque marqueur M_i , ce qui nécessite d’adapter l’algorithme original décrit précédemment. Nous définissons alors les fonctions g_i comme

$$g_i(p) = \begin{cases} h_{\min-1} & \text{si } p \in M_i \\ f_i(p) & \text{sinon} \end{cases} \quad (8)$$

et l’ensemble $X = \{X^i\}_{1 \leq i \leq c}$, modifiant ainsi la récursion :

$$\begin{aligned} X_{h_{\min-1}}^i &= T_{h_{\min-1}}(g_i) \\ X_{h+1}^i &= IZ_{\{T_{h+1}(g_i)\}_{1 \leq i \leq c}}(X_h), \quad h_{\min-1} \leq h < h_{\max} \end{aligned} \quad (9)$$

et considérant une définition adaptée des zones d’influence :

$$IZ_A^i(B) = \bigcup_{j=1}^l iz_A^i(B_j^i) \quad (10)$$

$$\begin{aligned} iz_A^i(B_j^i) &= iz_A(B_j^i) \cup \bigcap_{m=1}^c \{p \in A^i \cap A^m \mid \\ &\forall k \in [1, l] : d_{A^i}(p, B_j^i) < d_{A^m}(p, B_k^m)\} \end{aligned} \quad (11)$$

Autrement dit, chaque bassin de rétention est initialement défini par un marqueur donné et va s’étendre selon le relief construit à partir de ce marqueur. Plusieurs fonctions de relief f_i seront impliquées seulement dans le cas des pixels de bord qui pourraient être affectés à plusieurs bassins.

4 Résultats

Nous avons évalué notre méthode dans différents contextes applicatifs dont quelques exemples sont donnés ici. Nous avons calculé le relief initial par la norme euclidienne d’un gradient morphologique marginal sans changement d’espace couleur, et exploité les marqueurs au travers d’une classification par 5-plus proches voisins avec pondération de distances.

Nous présentons en figure 1 des exemples de résultats obtenus en quelques secondes sur la base d’images naturelles de Berkeley [7]. Nous avons naturellement comparé notre approche avec une classification supervisée et avec une segmentation LPE avec marqueurs classique, afin d’évaluer l’intérêt de notre approche sur ces deux techniques sur lesquelles elle s’appuie. D’autre part nous avons également comparé nos résultats avec ceux fournis par d’autres méthodes de segmentation, comme l’approche de Micusik et Hanbury [8] qui nécessite un plus grand nombre et un meilleur positionnement des marqueurs et qui s’appuie sur des caractéristiques plus évoluées (intensité, couleur et texture) que les seules valeurs RVB utilisées ici.

Nous pouvons observer dans la figure 2 l’intérêt du modèle de fusion multiplicative (équation (6)) par rapport à une fusion pondérée (équation (7)) et différentes valeurs de κ des informations spatiales et spectrales. La fusion proposée permet de conserver des frontières précises qui ne peuvent être obtenues même dans le cas d’une image où les objets sont spectralement

bien différenciés, et évite le problème délicat du réglage de κ .

La figure 3 présente quant à elle un exemple de résultat obtenu en télédétection à très haute résolution spatiale, où l'objectif est de fournir un outil d'aide à la localisation d'objets d'intérêt (trait de côte ici, mais aussi bâtiments par exemple). Les résultats obtenus ont convaincu des équipes de géographes d'utiliser cet outil dans leurs travaux en photo-interprétation [10].



FIG. 3 – Segmentation avec 2 marqueurs (terre et mer) d'une image multispectrale pour l'extraction du trait de côte.

5 Conclusion

Dans cet article nous nous sommes intéressés au problème de la segmentation d'image, pour lequel l'algorithme de ligne de partage des eaux avec marqueurs est une des solutions les plus fréquemment utilisées. Cet algorithme nécessite une initialisation spatiale (automatique ou manuelle) pour définir les positions initiales des bassins de rétention (i.e. les marqueurs). Cependant, aussi pertinentes soient-elles, ces informations ne sont que partiellement utilisées.

Nous avons donc proposé ici d'utiliser les marqueurs comme des ensembles d'apprentissage dans un processus de classification supervisée floue des pixels. Pour chaque marqueur ou classe, nous obtenons alors en chaque pixel la probabilité d'appartenance à la classe donnée au travers d'une carte de probabilités. Il est ensuite possible de construire à partir de cette carte le relief qui sera nécessaire à l'algorithme de ligne de partage des eaux avec marqueurs, et d'utiliser à la fois les positions spatiales et le contenu (spectral) des marqueurs. Nous avons présentés des résultats prometteurs pour différentes applications (images couleur, télédétection).

Afin de mieux évaluer les résultats de segmentation produits par notre méthode, nous souhaitons mesurer leur pertinence et précision en utilisant la base d'images segmentées de Berkeley [7]. De plus, nous étudions l'intégration d'autres caractéristiques, liées par exemple à la texture [2] ou la couleur au travers d'autres espaces de représentation [1], et d'autres classificateurs (par exemple les SVM). La robustesse de notre méthode à la position initiale des marqueurs doit également être évaluée afin de déterminer la taille minimale des marqueurs.

Enfin, nous envisageons d'étudier l'automatisation de la méthode proposée. Pour cela, nous pourrions nous inspirer des travaux de Micusik et Hanbury qui ont construit une solution de segmentation complètement automatique [9] en itérant leur mé-

thode de segmentation semi-automatique [8], supprimant ainsi le besoin du réglage manuel des marqueurs.

Références

- [1] E. Aptoula and S. Lefèvre. A comparative study on multivariate mathematical morphology. *Pattern Recognition*, 40(11) :2914–2929, Novembre 2007.
- [2] E. Aptoula and S. Lefèvre. On morphological color texture characterization. In *International Symposium on Mathematical Morphology (ISMM)*, pages 153–164, Rio de Janeiro, Brésil, Octobre 2007.
- [3] R. Beare. A locally constrained watershed transform. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(7) :1063–1074, Juillet 2006.
- [4] S. Derivaux, S. Lefèvre, C. Wemmert, and J.J. Korczak. Segmentation par ligne de partage des eaux basées sur des connaissances texturales. In *Colloque GRETSI sur le Traitement du Signal et des Images*, Troyes, France, Septembre 2007.
- [5] V. Grau, A.U.J. Mewes, M. Alcaniz, R. Kikinis, and S.K. Warfield. Improved watershed transform for medical image segmentation using prior information. *IEEE Transactions on Medical Imaging*, 23(4) :447–458, Avril 2004.
- [6] X. Li and G. Hamarmeh. Modeling prior shape and appearance knowledge in watershed segmentation. In *Canadian Conference on Computer Vision*, 2005.
- [7] D. Martin, C. Fowlkes, D. Tal, and J. Malik. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. In *IEEE International Conference on Computer Vision (ICCV)*, pages 416–423, Juillet 2001.
- [8] B. Micusik and A. Hanbury. Steerable semi-automatic segmentation of textured images. In *Scandinavian Conference on Image Analysis (SCIA)*, 2005.
- [9] B. Micusik and A. Hanbury. Automatic image segmentation by positioning a seed. In *European Conference on Computer Vision (ECCV)*, 2006.
- [10] A. Puissant, S. Lefèvre, R. Desguée, and F. Levoy. Cartographie et suivi de l'évolution des schorres de la baie du mont-saint-michel (1986–2006) à partir d'images satellites haute résolution. *Photo-Interprétation*, 2009. A paraître, 17 pages.
- [11] J.F. Rivest, S. Beucher, and J. Delhomme. Marker-controlled segmentation : an application to electrical borehole imaging. *Journal of Electronic Imaging*, 1(2) :136–142, Avril 1992.
- [12] L. Vincent and P. Soille. Watersheds in digital spaces : An efficient algorithm based on immersion simulations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(6) :583–598, Juin 1991.