

Post-segmentation d'image basée sur un apprentissage automatique par la méthode SVM

Ahmed Nasreddine BENAÏCHOUCHE, Hamouche OULHADJ, Patrick SIARRY

Laboratoire Images, Signaux et Systèmes Intelligents, LISSI (E.A. 3956)
122, rue Paul Armangot, 94400 Vitry sur Seine, France
ahmed.benaichouche@u-pec.fr, oulhadj@u-pec.fr
siarry@u-pec.fr

Résumé – Dans cet article, nous présentons une méthode de post-segmentation basée sur la détection et la reclassification de pixels potentiellement mal classés. Cette méthode peut être utilisée comme une étape de post-traitement ne dépendant que du résultat fourni par une méthode de segmentation basée-régions. Elle repose sur le constat que la majorité des erreurs de segmentation se produisent au niveau des frontières entre les différentes régions. Ces erreurs conduisent à une déformation des contours des objets détectés ou l'apparition d'artéfacts sous forme de grumeaux de pixels isolés dans des régions homogènes. Les pixels situés dans ces régions sont identifiés comme des pixels potentiellement mal classés à reconsidérer en se basant sur les autres pixels *de confiance*. Suite à ce partitionnement, un apprentissage automatique mettant en œuvre la méthode de machine à vecteurs de support (SVM) est effectué sur l'ensemble des pixels de confiance exploitant différents attributs. La réaffectation est effectuée en maximisant la probabilité d'appartenance en exploitant les attributs locaux des différentes classes présentes dans un voisinage immédiat du pixel considéré. La méthode proposée a été greffée aux différentes méthodes de segmentation basées sur la classification par logique floue (*FCM-based*) et testée sur une base d'images synthétiques contenant différents nombres de classes et affectées de plusieurs types et taux de bruits. Les résultats montrent une amélioration significative des performances, ce qui établit l'intérêt des idées développées.

Abstract – In this article, we present a post-segmentation method based on the detection and the reclassification of potentially misclassified pixels. This method can be used as a post-processing step that depends only on the result provided by a region-based segmentation method. The proposed method is based on the observation that the majority of segmentation errors occur at the boundaries between regions. These errors lead to object's contours deformations or the appearance of artifacts in homogeneous regions. Pixels present in these locations are considered as potentially misclassified pixels, while others are considered as high confidence pixels. After this, a training of a support vector machine (SVM) classifier on the high confidence pixels takes place based on different local features. Finally, the reallocation of the misclassified pixels is made, based on a maximisation of a probability function. The proposed method was used with different FCM-based segmentation methods and tested on a synthetic image database containing different numbers of clusters and affected by different types and levels of noise. The experimental results show a significant improvement of performances, which proves the interest of the presented ideas.

1 Introduction

La segmentation d'image est une étape importante dans le processus d'analyse d'image, et constitue l'un des sujets les plus étudiés dans le domaine. Plusieurs techniques de segmentation d'image ont été proposées dans la littérature. Ces techniques peuvent être regroupées dans deux familles : les techniques de segmentation basées-contours et les techniques de segmentation basées-régions. Dans cet article, nous nous intéressons à la segmentation basée-régions. Le travail présenté repose sur l'idée que la plupart des méthodes de segmentation sont à même de segmenter correctement la majorité des pixels qui se situent dans des zones homogènes. De ce fait, au lieu de concevoir des méthodes complexes dès le départ, nous proposons d'utiliser n'importe quelle méthode de segmentation relativement simple et efficace et de se focaliser sur la post-segmentation. Notre méthode se déroule, par conséquent, en deux étapes. La première étape est de segmenter l'image afin de partitionner ses pixels en deux ensembles : l'ensemble des

pixels de confiance (situés dans des zones homogènes) et l'ensemble des pixels ambigus, à reclasser. Cette approche de post-traitement est évidemment très répandue [1, 2]. L'intérêt de notre méthode est d'introduire un apprentissage automatique des caractéristiques des pixels de confiance en utilisant la méthode SVM. Ces caractéristiques sont ensuite exploitées pour reclasser les pixels ambigus.

Ce papier est organisé comme suit : dans la section 2, la méthode proposée est présentée en détaillant chacune de ses étapes. Puis, dans la section 3, nous exposons des résultats expérimentaux. Finalement, dans la section 3, nous donnons une conclusion de ce travail et des perspectives de développement.

2 La méthode proposée

La méthode de segmentation que nous présentons a pour objectif la correction des éventuelles erreurs de segmentation produites par les méthodes de segmentation basées-régions. Cette méthode ne nécessite aucune information sur la méthode de segmentation utilisée. En effet, elle n'utilise comme information que le résultat de la segmentation et l'image originale. Elle se déroule en trois étapes :

1. détection des pixels potentiellement mal classés et des pixels de confiance,
2. apprentissage d'un modèle de classification sur les pixels de confiance,
3. réaffectation des pixels potentiellement mal classés.

Le schéma global de la méthode est présenté dans la figure 1. Dans les sections suivantes, nous décrivons chacune des étapes de cette méthode.

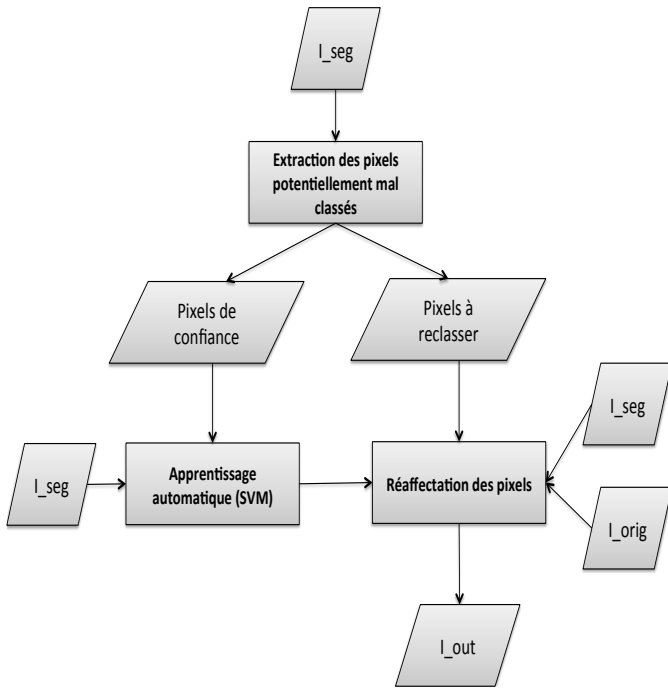


FIGURE 1 – Schéma global de la méthode proposée. I_{seg} représente l'image résultant d'une méthode de segmentation basée-régions. I_{orig} est l'image originale à segmenter. I_{out} est le résultat final de la post-segmentation.

2.1 Détection des pixels potentiellement mal classés

Cette détection repose sur le constat que la plupart des erreurs de segmentation se produisent au niveau des frontières entre les différentes régions dans l'image résultant d'une méthode de segmentation. Nous définissons un pixel potentiellement mal classé comme un pixel n'appartenant pas à la même

classe que tous ses voisins immédiats ($N_{3 \times 3}$) :

$$X^* = \{x_i \in I \mid \bar{I}(x_i) \neq \bar{I}(x_j), \forall i \neq j \in N_{3 \times 3}(x_i)\} \quad (1)$$

L'équation (1) exprime la définition de l'ensemble X^* des pixels à extraire, où I représente l'image originale à segmenter et \bar{I} représente un résultat de la segmentation.

La figure 2 montre un exemple de l'ensemble des pixels détectés à partir d'un résultat de segmentation par la méthode de classification par logique floue (FCM-S). On remarque dans cette figure qu'en plus des erreurs de segmentation, d'autres pixels sont détectés, qui doivent par la suite être réaffectés à leurs classes d'origine.




FIGURE 2 – Exemple d'extraction des pixels potentiellement mal classés. À gauche : le résultat de la segmentation via la méthode FCM-S. À droite : les pixels détectés comme potentiellement mal classés.

2.2 Apprentissage d'un SVM sur l'ensemble des pixels de confiance

Une fois que les pixels ambigus ont été détectés, les pixels restants sont considérés comme des pixels de confiance. Ces derniers sont utilisés comme une base d'apprentissage pour la méthode SVM. Dans le paragraphe suivant, nous présentons uniquement les principes de base de cette méthode. Pour plus de détails, le lecteur peut consulter les références [4, 5].

La méthode de machine à vecteurs de support ou séparateur à vaste marge est une technique d'apprentissage supervisé, qui, pour une base d'apprentissage $(X_i, y_i)_{i=1 \dots n}$ contenant n couples d'exemples $X_i \in \mathbb{R}^m$ et leurs labels $y_i \in \{-1, 1\}$, permet de définir un modèle de classification. Le modèle permet de trouver le label y_j d'un nouvel exemple X_j . Ce modèle est donné par l'équation suivante :

$$f(X_j) = \text{sgn} \left(\sum_{i=1}^n a_i y_i K(X_i, X_j) \right) \quad (2)$$

où a_i sont les paramètres maximisant la fonction :

$$W(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j K(X_i, X_j) \quad (3)$$

sous les contraintes :

$$\sum_{i=1}^n a_i y_i = 0 \text{ et } 0 \leq a_i \leq C \quad i = 1, 2, \dots, n \quad (4)$$

où C représente un paramètre de compromis entre la complexité du modèle et le nombre d'exemples mal classés et K représente une fonction noyau (*kernel*).

Dans notre méthode, nous avons utilisé la méthode C-SVC, avec le noyau à fonction de base radiale (*Radial Basis Function*, RBF) procurant des sorties probabilistes, présentes dans LIBSVM [3]. Pour ce qui concerne les attributs, nous avons utilisé trois mesures : le niveau de gris, la moyenne locale et la variance locale de chaque pixel.

2.3 Réaffectation des pixels potentiellement mal classés

La réaffectation des pixels potentiellement mal classés est effectuée en se basant sur le modèle de classification de SVM et des attributs concernant chaque classe dans le voisinage de ces pixels. La décision de réaffectation est basée sur la maximisation de la probabilité d'appartenance, en utilisant différents attributs locaux pour chaque pixel (équation (5)) :

$$y_j = \max_{i \in \Omega_j} N_i \text{prob}(X_i) \quad (5)$$

où :

y_j : représente le nouveau label du $j^{\text{ème}}$ pixel à reclasser,

Ω_j : est l'ensemble des indices des labels des différentes classes présentes dans le voisinage immédiat du $j^{\text{ème}}$ pixel à reclasser. Un pixel ne peut être réaffecté qu'aux classes présentes dans son voisinage immédiat,

X_i : représente les attributs de classe i après affectation du pixel à reclasser à cette classe et en prenant en compte uniquement les pixels de confiance,

$\text{prob}(\cdot)$: la probabilité d'appartenance fournie par le modèle de SVM,

N_i : la proportion des pixels de confiance de la classe i dans le voisinage local du pixel j .

3 Résultats expérimentaux

Afin d'évaluer les performances de la méthode proposée, nous avons utilisé une base de tests contenant des images synthétiques de taille 256×256 comportant 2, 3, 4 ou 5 classes. Pour chaque nombre de classes, les images sont affectées de bruit Gaussien, uniforme ou poivre et sel. Les variances des bruits uniforme et poivre et sel varient dans l'intervalle $[0,004 ; 0,02]$ avec un pas de 0,002 (après normalisation des images entre 0 et 1). Le taux du bruit poivre et sel varie de 2 à 10% avec un pas de 2%. La méthode proposée a été utilisée pour corriger les éventuelles erreurs de segmentation des méthodes

de segmentation par classification floue FCM [6], FCM-S1 et FCM-S2 [7], EnFCM [8], FGFCM [9] et FLICM [10].

La figure 3 montre des exemples des résultats des méthodes FCM-S, FLICM et FCM, avec et sans utilisation de la méthode de post-segmentation proposée. On remarque sur cette figure une nette amélioration des résultats de segmentation procurés par les deux premières méthodes. Par ailleurs, pour la méthode FCM, il y a une légère amélioration, mais non suffisante. Cela s'explique par le fait que le nombre de pixels potentiellement mal classés détectés est très important, et largement supérieur au nombre de pixels de confiance. Dans ce cas, la base d'apprentissage n'est plus représentative des différentes classes présentes dans l'image.

Afin d'évaluer quantitativement les performances de la méthode proposée, la mesure de cohérence de segmentation définie par l'équation suivante (équation (6)) a été utilisée :

$$SA = \frac{\sum_{i=1}^c \text{card}(A_i \cap C_i)}{\sum_{j=1}^c \text{card}(C_j)} \quad (6)$$

où c est le nombre de classes, A_i est l'ensemble de pixels appartenant à la classe i dans l'image résultant de la segmentation et C_j est l'ensemble des pixels de la classe j dans l'image vérité-terrain. Les résultats sont rassemblés dans le tableau 1. On remarque dans ce tableau que la méthode proposée permet d'améliorer les performances des différentes méthodes testées.

TABLE 1 – La cohérence de segmentation SA (%) sur la base des images synthétiques. PS représente la méthode de post-segmentation proposée (ex. FCM+PS signifie une segmentation par la méthode FCM en utilisant la post-segmentation).

	FCM	FCM+PS	FCM-S1	FCM-S1+PS
Gaussien	80, 12	91,26	89, 74	94,26
Uniforme	81, 94	89,62	93, 35	96,52
Sel et poivre	85, 24	93,46	84, 03	92,18
	FCM-S2	FCM-S2+PS	EnFCM	EnFCM+PS
Gaussien	87, 25	94,62	85, 32	94,82
Uniforme	91, 37	95,19	89, 87	95,26
Sel et poivre	93, 85	97,04	82, 62	91,48
	FGFCM	FGFCM +PS	FLICM	FLICM +PS
Gaussien	85, 36	92,26	90, 47	96,52
Uniforme	87, 62	94,72	93, 24	97,21
Sel et poivre	75, 74	90,11	82, 36	91,53

4 Conclusion

Dans ce papier, nous avons présenté une méthode de post-segmentation d'image basée sur un apprentissage automatique à l'aide de la méthode SVM. La méthode présentée repose principalement sur trois étapes. La première étape est la détection des pixels potentiellement mal classés et des pixels de confiance. La deuxième étape est l'apprentissage d'un modèle de classi-




FIGURE 3 – Exemples de résultats avec et sans utilisation de la post-segmentation (images de gauche et de droite respectivement). (a) Image originale à segmenter. (b) Résultats de segmentation basés sur la méthode FCMS-S1. (c) Résultats de segmentation basés sur la méthode FLICM. (d) Résultats de segmentation basés sur la méthode FCM.

fication SVM sur la base des pixels de confiance. La dernière étape est la réaffectation des pixels potentiellement mal classés. Cette étape est basée sur la maximisation d'un critère qui dépend des probabilités d'appartenance fournies par le SVM et du nombre du pixels de confiance des différentes classes dans un voisinage local. La méthode proposée a été testée sur une base d'images synthétiques contenant différents nombres de régions, et affectées de plusieurs types et taux de bruits. Afin de montrer l'efficacité de cet algorithme de post-traitement, plusieurs méthodes de segmentation basées-régions ont été testées

avec et sans son utilisation. Les résultats expérimentaux montrent une nette amélioration des performances, ce qui prouve l'intérêt des idées présentées. Néanmoins, en dépit des performances de la méthode proposée, nous avons observé que les contours résultants sont, dans certains cas, irréguliers. Pour y remédier, nous comptons, en perspective, ajouter à l'étape d'affaiblissement un critère qui tient compte de l'information globale du contour. Les deux critères ainsi considérés peuvent être optimisés à l'aide d'une métaheuristique d'optimisation.

Références

- [1] Benaïchouche, A.N., Oulhadj, H., Siarry, P. : Improved spatial fuzzy c-means clustering for image segmentation using PSO initialization, Mahalanobis distance and post-segmentation correction. *Digital Signal Processing* **23**(5), 1390 – 1400 (2013).
- [2] Benaïchouche, A.N., Oulhadj, H., Siarry, P. : Multiobjective improved spatial fuzzy c-means clustering for image segmentation combining Pareto-optimal clusters. *Journal of Heuristics*, 1–22 (2014).
- [3] Chang, C.C and Lin, C.J. : LIBSVM : a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology* **2**(27), 1–27 (2011).
- [4] Vapnik, V. : *Statistical Learning Theory*. Wiley, New York (1988).
- [5] Burges, C.J.C. : A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*(2), 121–167 (1998).
- [6] Bezdek, J.C. : *Pattern recognition with fuzzy objective function algorithms*. Kluwer Academic Publishers (1981).
- [7] Chen, S., Zhang, D. : Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure. *Systems, Man, and Cybernetics, Part B : Cybernetics, IEEE Transactions on* **34**(4), 1907–1916 (2004).
- [8] Szilágyi, L., Benyo, Z., Szilágyi, S.M., Adam, H. : MR brain image segmentation using an enhanced fuzzy c-means algorithm. In : *Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE*, vol. 1, pp. 724–726. IEEE (2003).
- [9] Cai, W., Chen, S., Zhang, D. : Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation. *Pattern recognition* **40**(3), 825–838 (2007).
- [10] Krinidis, S., Chatzis, V. : A robust fuzzy local information c-means clustering algorithm. *Image Processing, IEEE Transactions on* **19**(5), 1328–1337 (2010).