

Hybridation de la classification par c-moyennes floues et de l'optimisation par essaim particulaire pour la segmentation d'image

Ahmed Nasreddine BENAÏCHOUCHE, Hamouche OULHADJ, Patrick SIARRY

Laboratoire Images, Signaux et Systèmes Intelligents, LISSI (E.A. 3956)

122, rue Paul Armandot, 94400 Vitry sur Seine, France

ahmed-nasreddine.benaichouche@univ-paris-est.fr, oulhadj@u-pec.fr

siarry@u-pec.fr

Résumé – L'algorithme de classification par c-moyennes floues (FCM) est largement utilisé en segmentation d'image. Néanmoins, il présente quelques inconvénients (blocage dans des minima locaux, absence d'information spatiale dans le critère de segmentation, la métrique utilisée est la distance euclidienne qui est sensible aux formes géométriques des classes). Dans la méthode que nous proposons, le problème du blocage dans les minima locaux est résolu en utilisant une métaheuristique d'optimisation à l'étape d'initialisation. Le critère de segmentation est amélioré en ajoutant une contrainte spatiale et en substituant à la distance Euclidienne la distance de Mahalanobis qui s'affranchit de la forme des classes. Comparativement à 6 méthodes concurrentes de la littérature, les résultats obtenus sont convaincants et montrent l'efficacité des idées mises en oeuvre.

Abstract – The fuzzy c-means classification algorithm (FCM) is widely used in image segmentation. Nevertheless, it has some inconvenients (local minimum trap, no spatial information in the segmentation criterion, the metric used is the Euclidean distance which is sensitive to the geometry of the classes). In our method, the local minimum trap problem is solved using the particle swarm optimization algorithm in the stage of initialization. The criterion of segmentation is also improved by taking into account the spatial and local informations in the image and the use of Mahalanobis distance to reduce the influence of the geometry of the different classes. Compared to six competing methods of the literature, the results are convincing and demonstrate the effectiveness of the implemented ideas.

1 Introduction

La segmentation d'image est une étape importante dans le processus d'analyse d'image, et représente l'un des sujets les plus étudiés dans le domaine. Plusieurs techniques de segmentation d'image ont été proposées dans la littérature [1]. Ces techniques peuvent être regroupées dans deux familles : les techniques de segmentation basées contours [2] et les techniques de segmentation basées régions [3]. Dans cet article, nous nous intéressons à la segmentation basée régions en utilisant la classification par logique floue. A l'inverse de la segmentation classique, où chaque pixel appartient à une seule classe, dans la classification floue chaque pixel appartient à toutes les classes avec des degrés d'appartenance différents. Cette propriété permet de mieux prendre en compte les faibles contrastes, le recouvrement de régions et le bruit présent dans l'image. Cela en minimisant l'effet du phénomène de propagation d'erreur au fil du processus de classification.

Suite à l'introduction de la théorie des ensembles flous par Zadeh (1965) [4], Bezdek a proposé un algorithme de classification floue basé sur cette théorie nommé "c-moyennes floues" [5]. Cet algorithme est largement utilisé dans le problème de segmentation d'image en raison de sa simplicité et son efficacité. Néanmoins, l'application aveugle de cet algorithme en

segmentation d'image ne donne pas souvent des résultats satisfaisants pour les raisons suivantes : 1) L'algorithme des c-moyennes floues est très sensible à l'étape d'initialisation et se trouve souvent bloqué dans des minima locaux. 2) Il ne tient compte d'aucune information spatiale de l'image, ce qui le rend très sensible aux bruits et artefacts. 3) Il se base sur la distance Euclidienne, ce qui le rend très sensible aux formes géométriques des classes dans l'espace des attributs (niveau de gris).

Afin de remédier au problème du blocage de l'algorithme des c-moyennes floues dans des minima locaux, plusieurs auteurs ont proposé l'utilisation des métaheuristicues d'optimisation, comme les algorithmes génétiques, le recuit simulé, la recherche tabou ou les algorithmes de colonies de fourmis [6]. Izakian et Abraham [7] ont utilisé l'algorithme d'optimisation par essaim particulaire flou [8] (Fuzzy PSO) afin de trouver l'optimum global. L'application de ces solutions dans le problème de segmentation d'image n'est pas souhaitée à cause de la grande dimension du problème.

Afin d'introduire l'information spatiale, plusieurs travaux ont été proposés dans la littérature [9–15]. Dans toutes ces méthodes, le critère de segmentation est reformulé en ajoutant des contraintes spatiales, afin que la classification de chaque pixel

soit guidée par son voisinage local dans l'image.

Le choix de la métrique de distance est primordial dans les algorithmes de classification. La distance Euclidienne est la plus utilisée en raison de sa simplicité. Son utilisation suppose la validité de l'hypothèse que toutes les classes ont des formes géométriques super-sphériques de diamètres égaux, ce qui n'est pas vrai, surtout en segmentation d'image. La distance de Mahalanobis peut remédier à ce problème [16–18].

Dans ce travail, nous proposons de remédier aux inconvénients de l'algorithme des *c*-moyennes floues, en utilisant l'optimisation par essaim particulaire à l'étape d'initialisation afin de résoudre le problème du blocage dans les minima locaux, et en améliorant le critère de segmentation par introduction de l'information spatiale et par substitution à la distance Euclidienne de la distance de Mahalanobis.

2 L'algorithme des *c*-moyennes floues appliqué à la segmentation d'image

L'algorithme des *c*-moyennes floues est un algorithme de classification non-supervisé à base de prototypes (chaque classe est représentée par son centre), basé sur la minimisation d'un critère de distance.

Pour une image X constituée de N pixels de niveaux de gris $\{x_1 \dots x_N\}$ et contenant C classes, l'algorithme des FCM permet de segmenter l'image en calculant les centres des classes (c_i) et les degrés d'appartenance (u_{ij}) de chaque pixel de niveau de gris x_j aux différentes classes c_i en minimisant la distance $d(x_j, c_i)$ entre le pixel j et le centre de la classe i (équations (1) et (2)) :

$$J = \sum_{j=1}^N \sum_{i=1}^C u_{ij}^m d^2(x_j, c_i) \quad (1)$$

Sous les contraintes :

$$\begin{cases} \forall j \in [1, N] : \sum_{i=1}^C u_{ij} = 1 \\ \forall j \in [1, N], \forall i \in [1, C] : u_{ij} \in [0, 1] \end{cases} \quad (2)$$

Le problème d'optimisation du critère (1) sous les contraintes (2) est résolu par la méthode des multiplicateurs de Lagrange qui permet de transformer le problème en un problème d'optimisation sans contraintes. Les centres des classes et les degrés d'appartenance ne peuvent être calculés simultanément, ainsi une procédure alternant ces deux étapes est utilisée. En première étape, Les centres des classes sont supposés constants afin de calculer les degrés d'appartenance. En deuxième étape, les degrés d'appartenance sont supposés à leur tour constants pour calculer les centres des classes.

3 Optimisation de l'étape d'initialisation

Les performances de l'algorithme des *c*-moyennes floues dépendent énormément de la configuration initiale des centres des classes. Ces derniers, souvent fixés aléatoirement, mènent au blocage de l'algorithme dans des minima locaux. Afin d'optimiser cette étape d'initialisation, on propose d'utiliser l'optimisation par essaim particulaire pour trouver la meilleure configuration initiale des centres des classes.

L'optimisation par essaim particulaire (OEP) est une métaheuristique d'optimisation, proposée pour la première fois par Eberhart et Kennedy [19], elle est inspirée de vols d'oiseaux et bancs de poissons. Le problème d'optimisation est appréhendé en considérant une population de particules où chacune d'elles est une solution potentielle du problème. Dans l'OEP classique, la position de chaque particule est mise à jour à chaque itération en tenant compte de sa meilleure position et de la meilleure position de ses voisins. L'évolution de l'essaim dans l'espace de recherche est gouvernée par les équations suivantes (équations (3) et (4)) :

$$V^{(k+1)} = w.V^{(k)} + c_1.rand_1.(pbest^{(k)} - X^{(k)}) + c_2.rand_2.(gbest^{(k)} - X^{(k)}) \quad (3)$$

$$X^{(k+1)} = X^{(k)} + V^{(k+1)} \quad (4)$$

où $X^{(k)}$ est la position de la particule à l'itération k , V est sa vitesse, w est un paramètre d'inertie, $pbest$ est la meilleure position de la particule, $gbest$ est la meilleure position de l'essaim, $rand1$ et $rand2$ sont des variables aléatoires $\in [0, 1]$ et c_1 et c_2 sont des constantes positives qui caractérisent respectivement l'impact de $pbest$ et $gbest$ dans le processus de recherche. L'utilisation des métaheuristicues d'optimisation est confrontée au problème du choix des paramètres. Les paramètres de l'équation (3) sont ceux proposés par Trelea [20]. Le paramètre d'inertie w est utilisé de manière adaptative afin de bien équilibrer la balance entre les phases de diversification et d'intensification des solutions au cours des itérations. Il varie ainsi de 0,9 jusqu'à 0,4 pour un nombre maximal d'itérations.

4 Amélioration du critère de segmentation

Dans les méthodes de segmentation d'image basées sur l'optimisation d'un critère, les performances sont conditionnées par le choix du critère. Afin de tenir compte de l'information spatiale dans l'algorithme des *c*-moyennes floues, Chen *et al* [9] proposent la fonction objectif suivante :

$$J = \sum_{j=1}^N \sum_{i=1}^C u_{ij}^m d^2(x_j, c_i) + \alpha \sum_{j=1}^N \sum_{i=1}^C u_{ij}^m d^2(\bar{x}_j, c_i) \quad (5)$$

Où \bar{x}_j est le niveau de gris du j^{eme} pixel de l'image \bar{X} qui est le résultat d'un filtrage médian de l'image X , α est un

paramètre fixe d'ajustement du critère et m est un paramètre contrôlant le degré de flou (fixé à 2).

Tenant compte de la fonction objectif (5), le calcul des centres des classes et des degrés d'appartenance se fait à l'aide des équations suivantes :

$$c_i = \frac{\sum_{j=1}^N u_{ij}^m (x_j + \alpha \bar{x}_j)}{(1 + \alpha) \sum_{j=1}^N (u_{ij})^m} \quad (6)$$

$$u_{ij} = \frac{(d^2(x_j, c_i) + \alpha d^2(\bar{x}_j, c_i))^{\frac{1}{m-1}}}{\sum_{l=1}^C (d^2(x_j, c_l) + \alpha d^2(\bar{x}_j, c_l))^{\frac{1}{m-1}}} \quad (7)$$

Afin d'améliorer davantage ce critère, nous proposons de substituer à la distance Euclidienne la distance de Mahalanobis. Comme proposée par [21], cette distance est calculée à l'aide des équations suivantes ((8), (9) et (10)) :

$$d^2(x_j, c_i) = (x_j - c_i)^T V_i (x_j - c_i) \quad (8)$$

$$V_i = \left| \sum_i \right|^{\frac{1}{p}} \sum_i^{-1} \quad (9)$$

$$\sum_i = \frac{\sum_{j=1}^N \sum_{i=1}^C u_{ij}^m (x_j - c_i) (x_j - c_i)^T}{\sum_{j=1}^N \sum_{i=1}^C u_{ij}^m} \quad (10)$$

5 Résultats expérimentaux

La méthode proposée a été évaluée sur une base d'images de test composée de deux types d'images : 1) Des images synthétiques contenant différents nombres de classes (2, 3, 4 et 5) et types de bruits (Gaussien, uniforme, sel et poivre) avec des taux différents. 2) Des images IRM simulées du cerveau issues de la base BrainWeb [22], contenant plusieurs taux de bruit et paramètres d'inhomogénéité. L'algorithme proposé a été confronté à six algorithmes de segmentation d'image de la littérature basés sur la classification floue (FCM, FCMS1, FCMS2, EnFCM, FGFCM, FLICM).

Afin de quantifier les résultats de cette étude comparative, la mesure de cohérence entre l'image segmentée et l'image vérité terrain (Segmentation Accuracy, SA) a été utilisée. La mesure SA représente le taux de pixels bien classés par l'algorithme de segmentation.

La figure 1 montre un exemple de segmentation d'une image synthétique contenant 5 classes et affectée par un bruit Gaussien d'un taux de 10%. La figure 2 montre un exemple de segmentation d'une image IRM simulée affectée d'un bruit de taux 7% et d'un facteur d'inhomogénéité 20%. On remarque dans ces figures que la méthode proposée donne des résultats supérieurs à ceux des méthodes de comparaison.

Les tableaux 1 et 2 donnent la moyenne de la mesure SA pour la base d'images synthétiques et les images IRM simulées respectivement. Les résultats de cette étude comparative montrent que notre algorithme permet d'améliorer de manière significative les performances de la segmentation par rapport à l'ensemble des algorithmes concurrents.

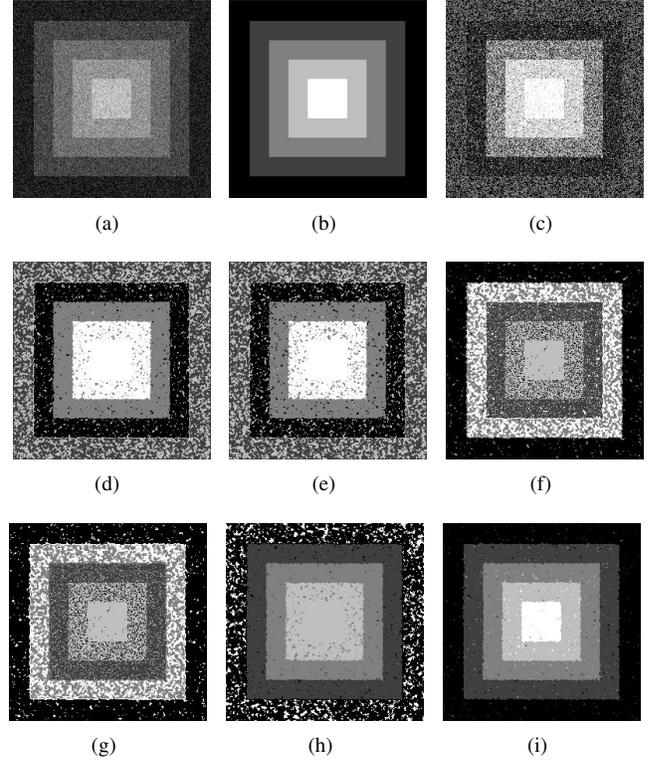


FIGURE 1 – Exemple de segmentation d'une image synthétique. (a) Image à segmenter. (b) Image référence. (c)–(i) résultats de segmentation par les algorithmes FCM, FCMS1, FCMS2, EnFCM, FGFCM, FLICM et la méthode proposée respectivement.

TABLE 1 – SA moyen (%) sur la base des images synthétiques.

| | FCM | FCMS1 | FCMS2 | EnFCM |
|---------------|-------|-------|------------------|-------|
| Gaussien | 47.48 | 85.16 | 78.68 | 78.07 |
| Uniforme | 42.40 | 83.06 | 74.30 | 76.31 |
| Sel et poivre | 75.81 | 81.02 | 90.05 | 79.69 |
| | FGFCM | FLICM | méthode proposée | |
| Gaussien | 88.92 | 91.99 | 92,13 | |
| Uniforme | 76.31 | 94.49 | 95,07 | |
| Sel et poivre | 72.50 | 58.39 | 91,11 | |

TABLE 2 – SA moyen (%) sur la base des images IRM simulées.

| | FCM | FCM.S1 | FCM.S2 | EnFCM |
|------------------|-------|--------|-----------------|-------|
| LCR ¹ | 93.93 | 93.17 | 93.25 | 92.44 |
| Matière grise | 89.66 | 90.61 | 92.71 | 85.14 |
| Matière blanche | 88.81 | 92.46 | 92.75 | 90.92 |
| | FGFCM | FLICM | MP ² | |
| LCR | 91.64 | 90.52 | 94,16 | |
| Matière grise | 85.27 | 92.55 | 92,84 | |
| Matière blanche | 90.97 | 91.77 | 92,93 | |

¹ Liquide céphalo-rachidien

² Méthode proposée

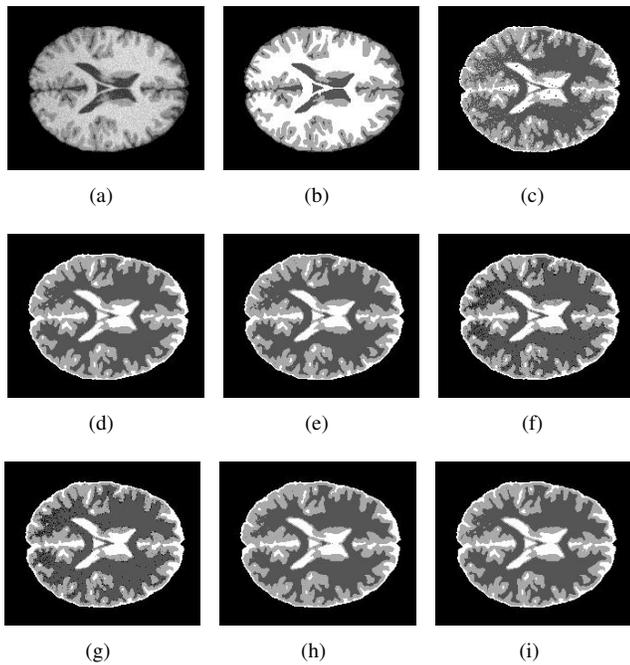


FIGURE 2 – Exemple de segmentation d’une image IRM simulée. (a) Image à segmenter. (b) Image référence. (c)–(i) résultats de segmentation par les algorithmes FCM, FCMS1, FCMS2, EnFCM, FGFCM, FLICM et la méthode proposée respectivement.

6 Conclusion

Nous avons proposé dans ce papier de combiner plusieurs idées pour remédier aux défauts de l’algorithme des *c*-moyennes floues appliqué à la segmentation d’image. La première amélioration consiste à résoudre le problème du blocage de l’algorithme dans des minima locaux en utilisant une méta-heuristique d’optimisation (optimisation par essaim particulier). La deuxième amélioration consiste à corriger le critère de segmentation en prenant en compte l’information locale et spatiale, et en substituant à la distance Euclidienne la distance de Mahalanobis qui s’affranchit de la forme géométrique des classes. La méthode proposée a été évaluée sur une base d’images de test contenant des images synthétiques et des images IRM simulées, et elle a été comparée à plusieurs méthodes compétitives de la littérature. Les résultats obtenus montrent une amélioration significative des performances. En perspective, nous envisageons d’améliorer davantage ces résultats en faisant appel à l’optimisation multiobjectif afin de faire coopérer les approches contours et régions au cours du processus de segmentation des images.

Références

[1] V. Dey, Y. Zhang, M. Zhong. *A review on image segmentation techniques with remote sensing perspective*. in : Wagner W, Székely B (ed), ISPRS TC VII Symposium – 100 Years ISPRS. vol.XXXVIII, pages 31–42. Vienna, Austria. 2010.

[2] G. Papari, N. Petkov. Edge and line oriented contour detection : State of the art. *Image and Vision Computing*. vol.29, pages 79–103. 2011.

[3] K. C. Ciesielski, J. K. Udupa. Region-based segmentation : Fuzzy connectedness, graph cut and related algorithms. T. M. Deserno (Ed.), *Biomedical Image Processing, Biological and Medical Physics*, Biomedical Engineering. Springer Berlin Heidelberg. pages 251–278. 2011.

[4] L. Zadeh. Fuzzy sets. *journalInformation and Control*. vol.8. pages 338 – 353. 1965.

[5] J. C. Bezdek. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Kluwer Academic, Norwell, MA, USA, 1981.

[6] S. Das, A. Abraham, A. Konar. *Metaheuristic Clustering*. vol.178. *Studies in Computational Intelligence*. Springer. 2009.

[7] H. Izakian, A. Abraham. Fuzzy *c*-means and fuzzy swarm for fuzzy clustering problem. *Expert Systems with Applications*. vol.38, pages 1835 – 1838. 2011.

[8] W. Pang, K. Wang, C. Zhou, L. Dong. Fuzzy discrete particle swarm optimization for solving traveling salesman problem. *Proceedings of the The Fourth International Conference on Computer and Information Technology, CIT '04*, IEEE Computer Society, Washington, DC, USA. pages796–800. 2004.

[9] S. Chen, D. Zhang. *Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure*. *IEEE Transactions on, Systems, Man, and Cybernetics, Part B : Cybernetics*. vol.34, pages 1907–1916. 2004.

[10] M. Ahmed, S. Yamany, N. Mohamed, A. Farag, T. Moriarty. A modified fuzzy *c*-means algorithm for bias field estimation and segmentation of MRI data. *Medical Imaging, IEEE Transactions on*. vol.21, pages 193 –199. 2002.

[11] D. Pham. Fuzzy clustering with spatial constraints. *Image Processing, International Conference on*. vol.2, pages 65–68. New York, USA. 2002.

[12] L. Szilagyi, Z. Benyo, S. Szilagyi, H. Adam. MR brain image segmentation using an enhanced fuzzy *C*-means algorithm. *Engineering in Medicine and Biology Society, Proceedings of the 25th Annual International Conference of the IEEE*. vol.1, pages 724 – 726. Cancun, Mexico. 2003.

[13] J. Kang, W. Zhang. Fingerprint image segmentation using modified fuzzy *c*-means algorithm. *Bioinformatics and Biomedical Engineering, ICBBE 2009, 3rd International Conference on*. Beijing, P. R. China. pages1–4. 2009.

[14] W. Cai, S. Chen, D. Zhang. Fast and robust fuzzy *c*-means clustering algorithms incorporating local information for image segmentation. *Pattern Recognition*. vol.40, pages 825–838. 2007.

[15] S. Krinidis, V. Chatzis. A robust fuzzy local information *c*-means clustering algorithm *Image Processing, IEEE Transactions on*. vol.19, pages 1328 –1337. 2010.

[16] R. Krishnapuram, J. Kim. A note on the Gustafson-Kessel and adaptive fuzzy clustering algorithms. *Fuzzy Systems, IEEE Transactions on*. vol.7, pages 453 –46. 1999.

[17] D. E. Gustafson, W. C. Kessel. Fuzzy clustering with a fuzzy covariance matrix. *Decision and Control including the 17th Symposium on Adaptive Processes, IEEE Conference on*. vol.17, pages 761 –766. San Diego, CA, USA. 1978.

[18] I. Gath, A. Geva. *Unsupervised optimal fuzzy clustering*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. vol.11, pages 773–780. 1989.

[19] J. Kennedy, R. Eberhart. *Particle swarm optimization*. *IEEE International Conference on, Neural Networks*. vol.4, pages 1942–1948. Perth, Australia. 1995.

[20] I. C. Trelea. *The particle swarm optimization algorithm : convergence analysis and parameter selection*. *Information Processing Letters*. vol.85, pages 317–325. 2003.

[21] HC. Liu, BC. Jeng, JM. Yih, YK. Yu. *Fuzzy C-Means Algorithm Based on Standard Mahalanobis Distances*. *Proceedings of the 2009 International Symposium on Information Processing (ISIP'09)*. pages 422–427. Huangshan, P.R. China. 2009.

[22] <http://www.bic.mni.mcgill.ca/brainweb/>. 2012.