

COMPARAISON ENTRE LES MÉTHODES J-SEG ET MEANSHIFT : APPLICATION SUR DES DONNÉES THRS

Rabia Sarah Cheriguene¹, Habib Mahi¹

¹ : Centre des Techniques Spatiales, Algérie – sarah.cheriguene@yahoo.fr

Résumé

L'avènement des données à Très Haute Résolution Spatiale (THRS) rend les méthodes de classification basées pixels inadéquates. En effet, la résolution spatiale fine offerte par ces capteurs engendre une forte variabilité intra-classes. Afin de pallier cette carence, les méthodes de classification actuelles visent à traiter non pas le pixel individuellement mais à opérer sur les objets (ensemble de pixels) qui composent l'image, on parle alors de classification orientée objets. Généralement, elles sont composées de trois étapes : (1) Segmentation ; (2) Caractérisation des objets ; et enfin (3) La classification. Dans ce travail, on s'intéresse seulement à la segmentation des données à THRS à travers deux algorithmes de segmentation d'images couleur à savoir : l'algorithme J-SEG et l'algorithme MeanShift. Une étude comparative entre les deux algorithmes a été conduite à la fois sur des données synthétiques et des données réelles acquises par le satellite Quick-Bird sur une région urbaine de la ville d'Alger (Algérie). L'analyse quantitative des résultats de segmentation en utilisant les critères d'évaluation non supervisés de Levin-Nazif et de Borsotti ainsi qu'une évaluation supervisée basée sur un ensemble de référence montre que la segmentation obtenue par l'algorithme MeanShift est meilleure que celle obtenue par l'algorithme J-Seg. Une seconde comparaison a été menée entre l'algorithme MeanShift et la méthode de segmentation multi-échelles implémentée dans le logiciel ENVI Zoom 4.5. Les résultats comparatifs laissent apparaître l'efficacité de l'algorithme MeanShift.

Mots clés : Données à THRS, Segmentation, J-Seg, MeanShift, Critères d'évaluation, ENVI Zoom 4.5.

Abstract

With the emergence of commercial satellites with on-board sensors characterized by very High Spatial resolution (VHSR), the classification algorithms based on single pixel analyses do not give the desired result when applied to VHSR images. Indeed, the fine spatial resolution offers by this sensors makes the spectral discrimination between objects difficult and also due to the large within class spectral variations, it is therefore necessary to expend the object feature base to include geometrical characteristic in addition to spectral ones. Object-based classification approaches offer this possibility. Generally, these approaches comprise three steps : (1) the image is segmented into homogeneous objects based on the spectral and spatial information, (2) characterization of these objects, and, finally, (3) the classification. In this paper, we deal only the segmentation of VHSR data by applying two segmentations algorithms, named : J-SEG (J-Segmentation) and Meanshift. Comparative studies between the two algorithms and also with ENVI Zoom 4.5 commercial package were conducted using both synthetic gray-scale images and two sub-scenes of Quickbird images datasets of Algiers (northern Algeria). The quantitative assessment of the quality of the segmentation results based on Levin-Nazif and Borsotti criteria confirms the effectiveness of the Meanshift algorithm.

Keywords : VHSR data, J-Seg, Meanshift, Evaluation criteria, ENVI Zoom 4.5.

1. Introduction

La segmentation d'images est une étape fondamentale et importante dans beaucoup d'applications (Chan, 2007) telles que la médecine, la géophysique, etc. Elle se pose en préalable de la plupart des schémas d'interprétation et de décision. Formellement, la segmentation d'images consiste à diviser l'ensemble des pixels en régions connexes, homogènes et différentes de leurs voisines. Zuker (1976) définit la segmentation d'images de la manière suivante : soit I une image composée d'un ensemble des pixels P_{xy} , P_r un prédicat défini sur tout sous-ensemble de pixels connexes de I . Segmenter

l'image I en régions revient à réaliser une partition de I en N sous ensembles de pixels appelés R_1, R_2, \dots, R_N régions. La littérature recense une variété d'approches de segmentation (Gonzales and Wood, 2002; Pal and Pal, 1993). Les différentes techniques ont leurs avantages et leurs limites. Le choix d'une approche est fortement guidé par le type de problème à résoudre, les contraintes de mise en œuvre et enfin le type d'image à segmenter. L'objectif est donc de trouver la méthode la plus adaptée à une famille d'applications données. En effet, la complexité des images à traiter (texture, détails fins, ...) rend difficile la conception d'une méthode générale (Chabrier, 2005). Aussi, les objets existants

dans une image à segmenter peuvent être représentés soit par des vecteurs de mesures (plusieurs attributs) soit par des points (un seul attribut) dans un espace multidimensionnel (Lazar, 2008), ce qui est fonction de la méthode de segmentation utilisée.

Dans le cadre de ce travail, nous nous focalisons sur l'étude de deux algorithmes de segmentation d'images couleurs, à savoir, l'algorithme J-SEG (J-SEGmentation) et l'algorithme MeanShift. Le choix de ces deux méthodes est motivé par le fait qu'ils prennent en compte à la fois l'information d'intensité (information spectrale) et l'information de texture (information spatiale), et qu'ils opèrent dans d'autres espaces de représentation couleurs. Le reste de l'article est composé comme suit. Dans la section 2, nous donnons une brève description théorique des deux algorithmes J-SEG et MeanShift et nous présentons les critères d'évaluation non supervisés de la qualité de segmentation, notamment ceux de Levin-Nazif et de Borsotti. La section 3 est dédiée à la fois à la mise en application des deux algorithmes sur des images synthétiques et des images de Télédétection ainsi qu'à une étude comparative entre les résultats obtenus par les deux algorithmes. Des discussions ainsi que les conclusions inhérentes à ce travail feront l'objet de la section 4.

2. Aspects théoriques

Nous présentons ici une brève description théorique des algorithmes J-SEG et MeanShift pour ensuite évoquer les critères d'évaluations non supervisées.

2.1. Algorithme J-SEG

Développé par Deng et Manjunath (Deng, 2001), l'algorithme J-SEG est un algorithme de segmentation d'images couleurs opérant en deux étapes. La première étape ayant pour but de pratiquer une quantification couleur sur l'image à traiter, la seconde faisant une segmentation spatiale.

Quantification couleur

La quantification couleur a pour but de regrouper les pixels en quelques teintes dominantes tout en conservant une bonne représentation de l'image initiale. Dans un premier temps, un filtrage par un algorithme non linéaire PGF (Peer Group Filtering) (Deng et al., 1999) est appliqué afin de lisser l'image et réduire le bruit. L'algorithme remplace chaque pixel dans l'image par la somme pondérée de ses voisins en privilégiant ceux qui sont de couleur proche. Les paramètres statistiques locaux sont employés comme des poids affectant une valeur faible aux zones texturées et une valeur plus importante pour les zones lisses. Suite à cela, et afin de faire la quantification couleur la méthode utilise l'Algorithme de Lloyd Généralisé (GLA pour Generalized Lloyd Algorithm) qui exécute la quantification dans l'espace

couleur Lab après la conversion de l'image du système couleur RVB (Bourgoin, 2009).

Segmentation spatiale

La seconde étape de l'algorithme J-SEG est d'opérer une segmentation spatiale sur l'image filtrée et quantifiée pour générer l'image J . Le critère d'homogénéité utilisé et celui s'inspirant du critère discriminant de Fisher (Duda and Hart, 1970). Dans cette étape, on commence d'abord par une quantification de l'image I en plusieurs classes couleurs C_i , $i \in \{1, \dots, n\}$ pour un ensemble de pixel Z dans l'image, on considère $Z_i = \{z \in Z \cap C_i\}$ et on note m et m_i respectivement les centres de gravité de l'ensemble Z et de chacun de ces sous-ensembles Z_i . On calcule alors :

$$\begin{aligned} S_T &= \sum_{z \in Z} \|z - m\|; \\ J &= (S_T - S_w)/S_w; \\ S_m &= \sum_{z \in Z} \|z - m_i\|. \end{aligned}$$

Le critère J reflète l'homogénéité de l'ensemble Z . Ce dernier est défini par plusieurs masques circulaires afin de trouver les textures de différentes granularités. Ensuite, un seuillage est opéré sur les valeurs J afin de détecter les germes, la construction des différentes régions est alors réalisée en utilisant la méthode de croissance de régions. La figure 1 illustre les différentes phases de l'algorithme J-SEG.

2.2. Algorithme MeanShift

L'algorithme MeanShift est une méthode d'estimation itérative non paramétrique pour l'estimation des modes d'une densité de probabilité. Il est basé sur une montée du gradient de la densité de probabilité estimée (Comaniciu and Meer, 2002). La procédure MeanShift se résume comme suit. Soit un ensemble de données $\{x_i\}$, $i \in \{1, \dots, n\}$ dans \mathbb{R}^d , l'estimateur multidimensionnel de densité en tout point x est donné par :

$$\Delta \hat{f}(x) = \frac{C_{k,d}}{nh^d} \sum_{i=1}^n k \left(\left\| \frac{x - x_i}{h} \right\|^2 \right), \quad (1)$$

où k est le profil de la fonction noyau K et h la largeur de ce noyau.

La détermination des modes à l'aide de la méthode MeanShift revient à annuler le gradient de l'estimateur de la densité de probabilité, c'est-à-dire, $\Delta \hat{f}(x) = 0$. Après quelques simplifications et substitutions dans l'équation 2, annuler le gradient revient à annuler la quantité $M_h(x)$ donnée par l'équation (Mahi and Izabatene, 2010) :

$$M_h(x) = \frac{\sum_{i=1}^n \left(x_i g \left\| \frac{x - x_i}{h} \right\|^2 \right)}{\sum_{i=1}^n \left(g \left\| \frac{x - x_i}{h} \right\|^2 \right)} - x. \quad (2)$$

$M_h(x)$ désigne le vecteur MeanShift et g la dérivée de la fonction profil k . L'algorithme MeanShift est donné comme suit :

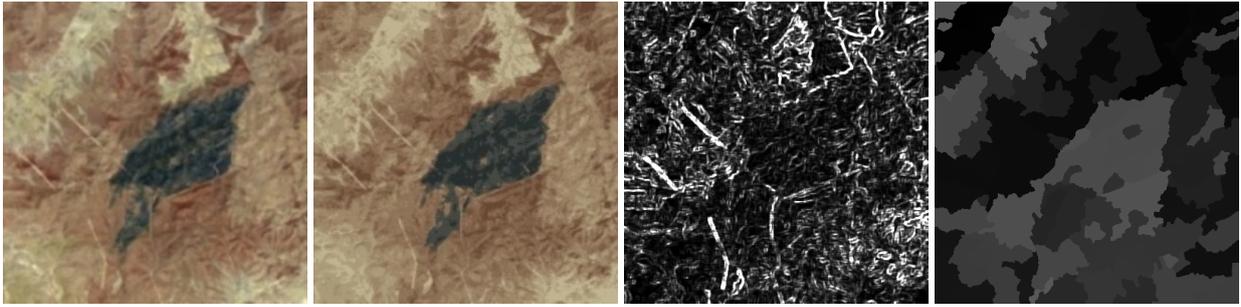


FIGURE 1 : Segmentation J-SEG : (a) image originale, (b) image quantifiée avec $q = 8$, (c) carte-j et (d) image segmentée avec $m = 0,2$.

1. Initialiser h , ϵ et le seuil de fusion.
2. Conversion des systèmes couleurs RVB vers Lab.
3. Construire un ensemble d'hypersphères de rayon h sur la totalité de l'image. Chaque centre de l'hypersphère est considéré comme un mode.
4. Pour chaque hypersphère :
 - 4.1 Calculer le vecteur $M_h(x)$;
 - 4.2 $x \leftarrow x + M_h(x)$;
 - 4.3 Tant que $x^{t+1} - x^t > \epsilon$, aller à l'étape 4.1.
5. Éliminer les modes dont la différence est inférieure au seuil de fusion.
6. Associer chaque pixel de l'image au mode associé suivant le critère de plus proche voisins au sens couleur.

Notons que la bande passante h est composée de deux bandes passantes, la première spatiale, qu'on notera h_s , et la seconde spectrale, qu'on notera h_r .

2.3. Évaluation de la qualité de segmentation

L'évaluation visuelle d'un résultat de segmentation étant difficile, il est nécessaire de faire appel à des critères d'évaluation quantitatifs. Dans cette étude, nous proposons d'utiliser trois critères d'évaluation non supervisées, à savoir, le critère d'uniformité intra-régions de Levin-Nazif, le critère d'uniformité inter-régions toujours de Levin-Nazif et en dernier le critère de Borsotti (Philipp et Guigues, 2006 ; Zhang, 1996). Les deux premiers critères opèrent sur des résultats de segmentation en niveaux de gris, tandis que le dernier opère sur des résultats de segmentation en couleurs.

Critère d'uniformité intra régions de Levin-Nazif

Ce critère est basé sur la somme des variances des régions. Il doit donc être faible.

$$\sum_i \sum_{s \in R_i} \left[f(s) - \frac{1}{A_i} \sum_{s \in R_i} f(s) \right]^2 = \sum_i \frac{\sigma_{max}^2}{C}. \quad (3)$$

Avec :

$$\sigma_{max}^2 = \frac{(f_{max} - f_{min})^2}{2}, \quad (4)$$

où f est l'intensité du pixel s ou d'un autre attribut (couleur, texture,...). C'est le facteur de normalisation, égal à la variance maximale.

Critère d'uniformité inter régions de Levin-Nazif

Soit $C_{ij} = \frac{|m_i - m_j|}{m_i + m_j}$ le contraste entre deux régions R_i et R_j . Le contraste de la région R_i est $C_i = \frac{\sum_{R_j} P_{ij} C_{ij}}{\sum_{R_j} P_{ij}}$, les R_j sont les régions adjacentes à R_i . $P_{ij} = l_{ij}/l_i$ est le rapport longueur de la frontière commune entre R_i et R_j sur le périmètre de R_i . Le contraste global est alors :

$$C = \frac{\sum_{R_i} w_i C_i}{\sum_{R_i} w_i}. \quad (5)$$

w_i est un poids associé à chaque région qui peut être l'aire de la région (Levin and Nazif, 1985).

Critère d'évaluation d'une segmentation couleur

Afin d'évaluer les résultats de différentes segmentations d'une image couleur, Borsotti et al. (1998) proposent un critère qui ne nécessite aucun réglage de paramètres et qui correspond de manière assez proche au jugement visuel, ce critère est donné par :

$$Q = \frac{\sqrt{R}}{100000(N \times M)} \sum_{i=1}^R \left(\frac{e_i^2}{1 + \log A_i} + \frac{R(A_i)^2}{A_i} \right), \quad (6)$$

Où $N \times M$ est la taille de l'image, R est le nombre de régions reconstruites dans l'image segmentée, A_i est la surface de la i -ème région reconstruite. La quantité e_i désigne est la somme des distances euclidiennes entre les couleurs RVB de chaque pixel de la i -ème région reconstruite et la couleur moyenne de cette même région reconstruite, et enfin $R(A_i)$ est le nombre de régions reconstruites dans la surface est égale à A_i .

3. Expérimentation

Dans cette section nous proposons de tester, dans un premier temps, les deux algorithmes sur deux images de synthèses, la première est en niveaux de gris possédant 15 régions (Figure 2a) et la seconde en niveaux de gris texturés avec le même nombre de régions (Figure 2b). Les deux approches seront testées sur les deux images satellitaires. La première acquise sur une zone urbaine (Figure 2c) d'une résolution spatiale de 0,6 mètres et la seconde acquise sur une zone accidentée (Figure 2d) d'une résolution spatiale de 30

mètres. Les différents tests permettront de trouver les paramètres optimaux des deux algorithmes pour l'obtention d'une bonne segmentation en vue des critères d'évaluation cités précédemment, et par la suite de les comparer. Notons que les deux algorithmes ainsi que les critères d'évaluation ont été implémentés sous l'environnement Matlab.

3.1. J-SEG et MeanShift sur les images synthétiques

Afin d'étudier l'influence des deux paramètres qui pilotent l'algorithme J-SEG à savoir q pour la quantification et m pour la fusion, nous avons effectués plusieurs tests et ce en variant la valeur de q et en fixant m dans un premier temps puis en fixant la valeur q et en variant m dans un second temps. Pour chaque résultat de segmentation nous calculons les deux critères d'évaluations de Levin-Nazif. Sur la figure 3, on présente les résultats de l'algorithme J-SEG et MeanShift appliqués aux deux images synthétiques. Concernant l'algorithme J-SEG, la valeur de q a été variée de 50 à 200 par pas de 50. Pour chaque valeur de q , on a fait varier le seuil de fusion m de 0,1 à 0,9 par pas de 0,1. Le meilleur résultat de segmentation obtenu en vue des critères utilisés est celui dont les paramètres sont $q=50$, $m=0,2$ pour l'image synthétique en niveau de gris (Figure 3a) et $q=200$, $m=0,9$ pour l'image synthétique en niveau de gris texturés (Figure 3b). Ces résultats correspondent respectivement à une valeur de 0,587 pour le critère d'uniformité inter-régions et 0,282 pour le critère d'uniformité intra-régions pour la résultat de la figure 3a et une valeur de 0,426 pour le critère d'uniformité inter-régions et 0,251 pour le critère d'uniformité intra-régions pour la résultat de la figure 3b. Pour ce qui est de l'algorithme MeanShift, le meilleur résultat de segmentation obtenu est celui dont les paramètres sont $h_s=3$; $h_r=6$; $s=12$; correspondant à la valeur 0,569 (critère d'uniformité inter-régions) et 0,033 (critère d'uniformité intra-régions) pour la figure 3.c, et $h_s=8$; $h_r=4$; $s=8$, correspondant à la valeur 0,691 (critère d'uniformité inter-régions) et 0,17 (critère d'uniformité intra-régions) pour la figure 3d. Le paramètre ϵ a été fixé à 0,0005 dans tous les tests de l'algorithme MeanShift.

Le graphe de la figure 4 illustre les différentes valeurs des deux critères de Levin-Nazif en fonction du nombre de régions obtenues et cela en variant q et m pour l'image de la figure 3a.

3.2. J-SEG et Meanshift sur les images satellitaires

De la même façon que sur les images de synthèse, nous avons cette fois ci testé les deux algorithmes sur deux images satellitaires couleurs. Dans ce qui suit, le critère de Borsotti a été utilisé pour sélectionner le meilleur résultat de segmentation. Pour l'algorithme J-SEG les meilleurs résultats de segmentation sont $q=7$ et $m=5$ correspondant à $Q=4$ pour l'image acquise sur une zone urbaine (Figure 5a) et $q=40$, $m=7$ avec $Q=1.012$

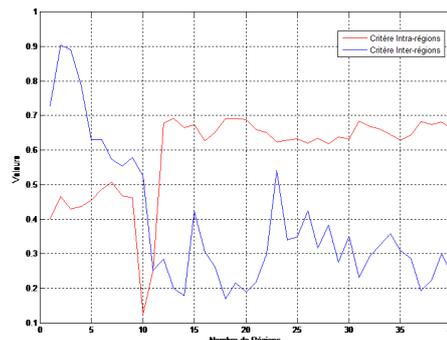


FIGURE 4 : Comparaison des résultats issus de la figure 2b.

e+005 pour l'image acquise sur une zone accidentée (Figure 5c). Pour ce qui est de l'algorithme MeanShift, les tests étaient comme suit :

- On a fixé h_r à 3, s à 5 et on a fait varier h_s de 3 à 7 par pas de 1.
- On a fixé h_s à 7, h_r à 3 et on a fait varier s de 4 à 10 par pas de 1.
- On a fixé h_s à 7 et s à 8 (meilleur résultat de segmentation dans le second jeu de tests), et on a fait varier de h_r de 4 à 10.

Ainsi nous obtenons dix-sept segmentations. Pour chacune d'elles, nous avons appliqué le critère d'évaluation non supervisé défini par Borsotti. Les meilleures segmentations pour l'algorithme MEANSHIFT $h_s=7$, $h_r=5$, $s=8$ avec $Q=1.028e-005$ pour l'image acquise sur une zone urbaine (Figure 5b) et $h_s=6$, $h_r=5$, $s=3$ avec $Q=1.138e-005$ pour l'image acquise sur une zone accidentée (Figure 5d).

4. Conclusion

Ce travail porte sur l'application des algorithmes J-SEG et MeanShift à des images en niveau de gris, urbaines et rurales. Les résultats obtenus par ces deux algorithmes ont été comparés en appliquant les algorithmes d'évaluation Levin-Nazif et Borsotti. Ces derniers sont encourageants et montrent clairement que J-SEG donne de bons résultats par rapport à MeanShift. Comme perspective à ce travail, il est intéressant de tester d'autres algorithmes d'évaluation comme l'algorithme de Kitchen et Rosenfeld (1982) basé sur la cohérence locale de contours ou celle de Tan, Gelfand et Delp (1992) qui combine les critères liés à l'image initiale et à la structure locales des contours.

Références

Ball J.E., Bruce L.M., 2007. Level set-Based Core Segmentation of Mammographic Masses Facilitating Three stage (Core, Periphery, Speculation) Analysis. In : Proceeding of the 29th annual international conference



FIGURE 2 : Les images de test.

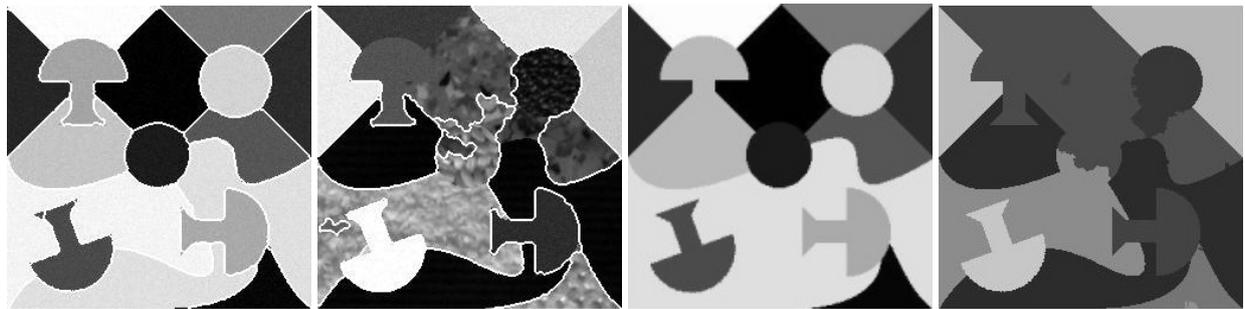


FIGURE 3 : Résultats obtenus par J-SEG et MeanShift sur des images synthétiques.



FIGURE 5 : Résultats obtenus par J-SEG et MeanShift en appliquant le critère de Borsotti.

- of the IEEE EMBS, Lyon, France, pp. 819–824.
- Bourgoin A., 2009. Segmentation d'images de tuffeau. Msc report, Orléans, France.
- Borsotti M., Campadelli P., Schettini R., 1998. Quantitative evaluation of color image segmentation results. *Pattern Recognition Letters* 19(8) :741–747.
- Chabrier S., 2005. Contribution à l'évaluation de performances en segmentation d'images. PhD thesis, Orléans, France.
- Chan D.M., 2007. Evaluation de la segmentation d'images. Institut de la francophonie pour l'informatique (IFI), Hanoi, Vietnam, pp. 5–36.
- Cocquerez J.P, Philipp S., 1995. Analyse d'images : filtrages et segmentation, Masson, Paris, France, 475p.
- Comaniciu D., Meer P., 1999. Distribution free decomposition of multivariable data. In : *Pattern Analysis and applications*, Vol. 2, pp. 22–30.
- Comaniciu D., Meer P., 2002. Meanshift : A robust Approach Toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 24(5) :603–619.
- Deng Y., Manjunath B.S., 2001. Unsupervised Segmentation of color texture regions in images and video. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 23(8) :800–810.
- Deng Y., Kenney S., Moore M., Manjunath B.S., 1999. Peer group filtering and perceptual color image quantization. In : *Proc. IEEE International Symposium on Circuits and Systems VLSI (ISCAS'99)*, Orlando, USA, vol. 4.
- Duda R.O., Hart P.E., 1970. *Pattern Classification and scene Analysis*. Wiley, New York, USA.
- Gonzales R., Wood R., 2002. *Digital Image Processing*, Addison Wesley, New-York, USA.
- Kitchen L., Rosenfeld A., 1982. Gray-level corner detection. *Pattern Recognition Letters* 1(2) :95–102.
- Lazar C., 2008. Méthodes non supervisées pour l'analyse des données multivariées. PhD thesis, Institut de formation Technique Supérieure, Charleville-Mézières, France.
- Levin M.D., Nazif A.M., 1985. Generated image segmentations. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 7(25) :155–164.
- Mahi H., Izabatene H.F., 2010. Les Moments invariants de Zernike et les SVM pour la Classification Supervisée des Formes d'Objets : Application aux Données Satellitaires à Très Haute Résolution. In : *International Conference on Information Systems and Technologies*, Tébessa, Algeria.
- Pal N.R., Pal S.K., 1993. A review on image segmentation techniques. *Pattern Recognition* 26(9) :1277-1294.
- Philipp S., Guigues L., 2006. Evaluation de la segmentation d'images : état de l'art, nouveaux indices et comparaison. *Traitement du Signal* 23(2) : 109–124.
- Tan H.L., Gelfand B., Delp E., 1992. A cost minimization approach to edge detection using simulated annealing. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 14(1) :3–18.
- Zhang, Y.J., 1996. A survey on evaluation methods for image segmentation. *Pattern Recognition* 29(8) :1335–1346.
- Zuker S.W., 1976. Toward a model of texture. *Computer Graphics and Image Processing* 5(2) :190–202.