

# Segmentation d'images texturées par transformée en ondelettes et classification C-moyenne floue

Sahbani Mahersia Hela , Hamrouni Kamel

Ecole Nationale d'Ingénieurs de Tunis (ENIT)  
BP-37 le Belvédère 1004 Tunis, Tunisie

[Hela.mahersia@laposte.net](mailto:Hela.mahersia@laposte.net)

[kamel.hamrouni@enit.rnu.tn](mailto:kamel.hamrouni@enit.rnu.tn)

**Résumé:** Nous présentons dans ce papier une nouvelle méthode de segmentation d'images texturées basée sur l'application de la transformée en ondelettes au niveau du voisinage de chaque pixel et l'extraction d'un vecteur d'attributs caractérisant la texture existante suivie d'une classification réalisée dans l'espace des attributs au moyen de la méthode C-moyenne floue. Un post-traitement permet d'éliminer le bruit de la classification et d'étiqueter les composantes connexes pour déterminer les différentes régions composant l'image. La méthode a été testée sur des textures de l'album de Brodatz ainsi que sur des images médicales contenant des textures naturelles. .

**Mots clés:** Segmentation d'images, Texture, Ondelettes, Classification, C-moyenne floue

## 1. Introduction

La segmentation d'images est une étape incontournable dans tout processus d'analyse d'image. C'est un traitement de bas niveau qui précède l'étape de mesure, de compréhension et de décision. Son objectif consiste à partitionner l'image en régions connexes et homogènes au sens d'un critère d'homogénéité difficile à définir surtout dans le cas de régions texturées.

La texture, qui est presque omniprésente dans les images, joue donc un rôle important en analyse d'images non seulement dans les applications de segmentation mais aussi de classification et de caractérisation. Bien qu'elle ait intéressé de nombreux chercheurs et que de nombreux travaux aient été publiés ces dernières années, la texture continue à susciter l'intérêt des chercheurs surtout avec le succès réalisé par la transformée en ondelettes grâce à la possibilité d'effectuer une analyse spatio-fréquentielle des images.

Depuis les travaux de Haralick en 1979 sur la texture (Haralick, 1979), plusieurs approches ont été proposées: statistiques, structurelles, bancs de filtres de Gabor (Bovic et al., 1990) (Levesque, 2000), et

transformée en ondelettes (Unser, 1995). Cependant, la recherche de paramètres discriminants caractérisant la texture et l'utilisation de ces paramètres pour la segmentation des images texturées restent encore un problème délicat, sans solution universelle.

C'est dans ce contexte que nous proposons dans cet article une nouvelle méthode de segmentation d'images texturées. Cette méthode est basée sur une phase d'extraction des attributs par la transformée en ondelettes, caractérisant d'une manière fiable les différentes régions texturées ainsi qu'une phase de classification automatique des pixels de l'image à analyser, par la méthode de classification C-moyenne floue (« Fuzzy C-mean »).


Cet article est structuré en sections. La deuxième section présente l'état de l'art en matière d'analyse de texture. La troisième section présente l'analyse par la transformée en ondelettes. Le principe de la classification C-moyenne floue est présenté dans la quatrième section. La cinquième section est réservée à la présentation de notre méthode de segmentation d'images texturées. Les résultats obtenus par l'application de la méthode sur des textures de l'album de Brodatz et sur des images médicales présentant des textures naturelles seront présentés dans la sixième section.

## 2. Etat de l'art sur la texture

Bien que la notion de texture soit naturelle pour l'être humain, elle résiste depuis longtemps à toute tentative de définition. On peut s'en approcher en disant qu'une texture est une zone de l'image qui présente certaines caractéristiques d'homogénéité qui la font apparaître comme une zone unique. Nous pouvons aussi la décrire comme étant un ensemble de primitives de taille et de forme variables, présentant une organisation spatiale particulière. (Haralick, 1979) (Cocquerez et al., 1995) (Borges et al., 2000).

### 2.1. Types de textures

Il existe deux types de textures: les textures périodiques définies par la répétition d'un motif de base et les textures dites aléatoires qui ont un aspect anarchiques mais qui apparaissent homogènes vis-à-vis de leur environnement. Brodatz a établi un catalogue de texture à des fins de synthèse d'images texturées (Brodatz, 1966). Ce catalogue constitue aujourd'hui une référence en matière de base de test pour les chercheurs travaillant sur la texture. Il s'agit de 112 textures (sable, herbe, bulles, eau, bois, etc.) ayant chacune seize variantes différentes. Ces images sont classiquement utilisées pour valider les différentes méthodes d'analyse de texture. (Figure-1).



**Figure-1.** Exemples de textures issues de l'album de Brodatz

### 2.2. Analyse de la texture

L'analyse de texture regroupe un ensemble de techniques permettant de quantifier les différents niveaux de gris présents dans une image en terme d'intensité et de distribution dans le but de calculer un certain nombre de paramètres caractéristiques de la texture à étudier.

Les applications possibles de l'analyse de texture sont la segmentation, la classification ou la caractérisation de textures homogènes. Comme il existe deux grandes classes de textures, l'analyse peut se faire selon deux classes de méthodes: les méthodes structurelles et les méthodes statistiques (Haralick, 1979). Les méthodes structurelles permettent de décrire la texture en définissant les primitives et les "règles" d'arrangement qui les relient. Elles sont donc applicables sur les textures aléatoires. Alors que les méthodes statistiques étudient les relations entre un pixel et ses voisins et définissent des paramètres discriminants de la texture en se basant sur des outils statistiques. Généralement, elles sont utilisées pour caractériser des structures fines, sans régularité apparente. Plus l'ordre de la statistique est élevé et plus le nombre de pixels mis en jeu est important.

Les attributs souvent utilisés pour caractériser une texture, sont issus de l'histogramme de l'image, de l'image gradient, de la matrices de co-occurrence (Haralick, 1973), de la matrice des longueurs de plage (Xiaou, 1998), des coefficients des filtres de Gabor (Levesque, 2000), des coefficients de la transformée en ondelettes (Demaeyer, 2003) (Unser, 1995) (Sharma). Parmi les attributs statistiques du premier et du deuxième ordre, la matrice de co-occurrence donne de bons résultats (Weszka et al., 1976) (Connors et al., 1980).

Cependant, toutes les méthodes du premier et du second ordre prennent en considération l'arrangement spatial des pixels. Elles demandent donc un temps de calcul relativement long et manquent de précision lorsque l'ordre des attributs statistiques devient assez grand. Le filtrage de Gabor, quant à lui, convient pour les textures à forte périodicité. Mais un choix minutieux doit être fait pour fixer les paramètres du filtre, notamment la largeur de bande de fréquence et l'orientation.

## 3. L'analyse en ondelettes


Depuis les travaux de Grossman et Morlet (Grossman et al., 1984), la transformation en Ondelettes est apparue comme un outil performant pour résoudre des problèmes relevant de différents domaines d'application (Meyer, 1990). Très tôt, un intérêt soutenu s'est manifesté à l'égard de la Transformation en ondelettes en traitement d'images (Mallat, 1998),(Barlaud, 1995).

La transformée en ondelettes décompose le signal d'entrée en une série de fonctions d'ondelettes  $\psi_{a,b}(t)$  [1] qui dérivent d'une fonction mère  $\psi(t)$  donnée par des opérations de dilatation et de translation [2]. La figure-2 présente quelques exemples d'ondelettes.

$$C_{a,b} = \int_{-\infty}^{+\infty} x(t)\Psi_{a,b}(t)dt \quad [1]$$

Grossman et Morlet ont montré que les coefficients d'ondelette  $C_{a,b}$  résultant de cette transformation contiennent des informations concernant le signal  $x(t)$  étudié à différentes échelles.

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}}\Psi\left(\frac{t-b}{a}\right) \quad \text{avec } a \neq 0 \quad [2]$$



**Figure 2.** Exemples classiques d'ondelettes : ondelette de Haar(a), ondelette chapeau mexicain (b), ondelette de Morlet (c)

Le principal avantage de la transformée en ondelettes par rapport à la transformée de Fourier est la localisation dans le domaine temps-échelle.

Mallat (Mallat, 1989) montra que la transformée en ondelette discrète (TOD) peut être implémentée grâce à un banc de filtres comprenant un filtre passe-bas (PB) et un filtre passe-haut (PH). Dans la figure-3 qui illustre ces bancs de filtre, le signal d'entrée subit un filtre passe-haut et un filtre passe-bas. Après une opération de sous-échantillonnage, le filtrage reprend sur chaque sous-bande.




Figure 3. Décomposition d'un signal en approximation et détails

Pour le cas d'un signal 2D, la TOD est appliquée d'abord ligne par ligne, puis colonne par colonne. Quatre images sont alors générées à chaque niveau (Xianfeng, 2001). La figure-4 montre un exemple de décomposition de l'image sur deux niveaux.




Figure 4. Les 7 canaux résultant de la décomposition sur 2 niveaux.

La transformée en ondelettes admet une variante connue sous le nom de « transformation par paquet d'ondelettes » qui permet une analyse très fine des textures (Coifman et al., 1990) (Laine et al., 1993) (Chang et al., 1993). A chaque niveau, les sous-bandes sont sélectionnées pour la décomposition suivante. La différence entre la transformée en ondelettes et la transformée par paquet d'ondelettes réside dans le fait que cette dernière décompose récursivement les composantes haute fréquence en construisant ainsi une extension multi-échelle arborescente de la transformée en ondelettes.

#### 4. La classification C-moyenne floue

La méthode C-moyenne floue (ou fuzzy C-mean) est une méthode de classification itérative qui permet de classer les individus selon C classes (Chuai et al.,

2000) (Guillaume, 2001). Elle calcule à chaque fois les centres des classes et génère la matrice d'appartenance U des individus à ces classes.

Soient  $V_i$  le centroïde ou prototype de la classe  $i$ , U la matrice des coefficients  $\mu_{ik}$  et  $X_c$  celle des coordonnées des centres. Etant donné le nombre de classe C, le nombre d'individus n et l'exposant flou m ( $m > 1$ ), l'objectif de la méthode est de trouver U et  $X_c$  qui minimisent la fonction coût donnée par la relation [3] et [4].

$$J(U, V, m) = \sum_{i=1}^C \sum_{k=1}^n \mu_{ik}^m D_{ki}^2 \quad [3]$$

avec :

$$\sum_{i=1}^C \mu_{ik} = 1 \quad \forall k = 1, \dots, n \quad [4]$$

$D_{ki}$  est une métrique choisie au sens d'une norme. Généralement, il s'agit de la norme euclidienne. Ainsi  $D_{ki} = \|X_k - V_i\|_2$  : distance entre le vecteur  $X_k$  et le prototype  $V_i$ . La technique de classification par FCM repose sur l'algorithme présenté dans le tableau-1.

Tableau-1 : Algorithme de classification par C-moyenne floue

1. Soit  $X^i = (x_1, x_2, \dots)$  les vecteurs représentant les individus à classer
2. Fixer les paramètres
  - m : coefficient flou
  - C : le nombre de classes
  - $\epsilon$  : critère d'arrêt
3. Initialiser le vecteur V par C centres aléatoirement choisis
4. Calculer la matrice U de taille (C x n) par les équations :
 
$$\mu_{ik} = \frac{(D_{jk})^{-\frac{2}{m-1}}}{(\sum_{j=1}^C (D_{jk})^{-\frac{2}{m-1}})}$$


$D_{jk}$  est la distance entre l'individu k et le centre  $V_j$
5. Calculer le nouveau centre de chaque classe à l'aide de l'équation :
 
$$V_i = \frac{(\sum_{k=1}^n (\mu_{ik})^m x_k)}{(\sum_{k=1}^n (\mu_{ik})^m)}$$
6. Mettre à jour la matrice U et incrémenter le compteur t
7. Calculer la distance entre les nouveaux et les anciens centres par :
 
$$h = \|V^{t-1} - V^t\|$$
8. Répéter les étapes de 3 à 6 tant que  $h > \epsilon$

#### 5. méthode proposée

Notre méthode comporte deux phases principales : la sélection des attributs par la transformation en ondelettes et la classification floue dans l'espace des attributs par la méthode C-moyenne floue. Nous allons dans cette partie présenter chacune de ces deux phases ainsi que les problèmes rencontrés et les choix effectués.

## 5.1. Sélection des attributs

Comme toute méthode de segmentation d'images texturées, notre méthode commence par sélectionner un ensemble d'attributs caractérisant la texture locale (Hofmann, 1997) lors d'une analyse par transformée en ondelettes. L'analyse multi-échelle est effectuée dans une fenêtre d'analyse représentant la texture locale. La figure-5 illustre cette démarche.



**Figure 5.** Phase d'extraction des attributs de l'image originale

L'extraction des attributs se fait par la transformée en ondelettes. Après avoir appliqué l'algorithme de décomposition de l'image discrète  $A[N,M]$  sur  $J$  niveaux, nous nous retrouvons avec  $3J+1$  canaux de caractéristiques qui vont donner lieu à un vecteur d'attributs  $Y$  pour chaque pixel.

$$Y = \{a_j, (d_k^1, d_k^2, d_k^3), k = 1 \dots J\} \quad [5]$$

avec  $a_j$  est une approximation de basse résolution de l'image originale, et les  $d_k$  sont les sous-bandes contenant les détails de l'image à différentes échelles et orientations. Nous interpréterons les vecteurs transformés en ondelettes résultants comme une transformée linéaire locale des pixels d'entrées et nous pouvons ainsi caractériser une texture en regardant le comportement de ces vecteurs  $Y$ .

Toutefois, étant donnée que la texture, dans le sens le plus large, est caractérisée par son désordre et sa force, donc par une énergie interne, nous nous proposons de calculer l'énergie qui règne autour d'un pixel considéré à partir de son vecteur résultant  $Y$ , par la formule [6] (Haralick et al., 1973):

$$\text{Energie}(\text{canal}, \text{échelle}) = \frac{1}{n} \sum_{x,y \in R} d_{x,y}^2(\text{canal}) \quad [6]$$

avec  $n$  étant le nombre de pixels dans la région  $R$  considérée et  $d$  l'image détail à l'échelle considérée.

Le vecteur  $Y$  caractéristique de la texture du voisinage d'un pixel donne lieu à un vecteur  $X$  de même longueur ( $3J+1$ ) et dont les composantes sont des énergies [7]:

$$X = (e_1, e_2, \dots, e_{3J+1}) \quad [7]$$

L'ensemble des vecteurs associés à tous les pixels de l'image forment une matrice à deux dimensions composée de  $(3J+1)$  colonnes et d'autant de lignes que de fenêtres d'analyse.

## 5.2. Classification par la méthode C-moyenne flou

Après avoir sélectionné les caractéristiques discriminantes de chaque texture, il faut ensuite séparer distinctement les différentes régions de l'image. Pour cela, on applique l'algorithme de la méthode FCM (tableau-1) sur les individus représentés par les vecteurs  $X_k$ . La distance entre un individu et le centroïde d'une classe est calculée par une distance euclidienne :

$$D_{jk} = \|X_k - V_j\|^2$$

Le coefficient flou  $m$  qui est important dans la classification, fera l'objet d'un ensemble de test pour choisir la valeur optimale.

Les critères de proximité employés pour la classification, sont des distances entre les attributs et ne tiennent pas compte de la proximité entre pixels dans l'image. La classification doit donc être suivie par une opération d'étiquetage pour détecter les composantes connexes correspondant aux régions recherchées.

## 5.3 Ajustement des paramètres

La méthode de segmentation proposée admet quelques paramètres dont il faut ajuster les valeurs. Ces paramètres sont le type de la fenêtre d'analyse considérée autour de chaque pixel, le type d'ondelette et la valeur de l'exposant flou  $m$ .

### 5.3.1. Type de la fenêtre d'analyse

La fenêtre d'analyse peut être orientée pixel (« pixel-wise ») ou bien orientée bloc (« bloc-wise ») (Ying, 2003). Dans le premier cas, à chaque pixel est affectée une fenêtre d'analyse ce qui conduit à un découpage de l'image en blocs chevauchants. Dans le 2<sup>ème</sup> cas, l'image est découpée en blocs de taille fixe non chevauchants. La première approche est plus précise mais présente l'inconvénient d'exiger un temps de calcul plus long. Après avoir testé les deux solutions, nous avons opté pour le choix de la première solution pour la précision de ses résultats.

### 5.3.2. Choix du type d'ondelette

Nous avons réalisé quatorze essais avec des types différents d'ondelettes et nous avons ensuite appliqué la segmentation par FCM. Les ondelettes de Daubechies ont donné un résultat meilleur, ce qui favorise l'utilisation de cette famille d'ondelette. En terme de rapidité, nous remarquons que l'ondelette Db1 donne un résultat optimal.

### 5.3.3. Valeur de l'exposant flou

La validité de la classification est étudiée par la fonction [8] (Bonnert et al., 1996).

$$\inf(m, C, U) = (C \cdot \sum_{i=1}^C \sum_{k=1}^N \mu_{ik}^m - N) / (N \cdot (C - 1)) \quad [8]$$

Avec :

- N : nombre de vecteurs à classer
- C : nombre de classes
- U : matrice d'appartenance issue de la classification des attributs en C classes.

Cet indice doit être maximal pour que la répartition en C classes et avec un exposant flou m, soit optimale. Pour tester la validité de cette fonction, considérons la figure-6 qui comporte trois images de test : l'image texturée (image-1) contenant trois textures (cuir, eau, laine), l'image à régions homogènes (image-2) comportant trois classes homogènes (noire, grise, blanche) et l'image mixte (image-3) qui comporte quatre textures (Raffia, bois, eau, Fabric) et une région homogène.

L'objectif de ces tests est de montrer que la fonction de validation choisie fonctionne aussi bien pour les images texturées que sur les images homogènes et même pour des images mixtes.



Figure 6. Images de test : (a) Image-1, (b) Image-2, et (c) Image-3

L'exposant flou m est un coefficient  $\geq 1$ . Le poids de cet exposant peut être interprété comme un paramètre de distorsion. Le « flou » de la partition augmente avec ce coefficient. Un tel coefficient accentue les faibles niveaux d'appartenance et contribue donc à mieux séparer les classes.

Dans cette partie, nous nous proposons d'étudier l'influence de ce paramètre sur le résultat de la classification FCM. Pour cela, nous allons faire varier ce paramètre pour les trois images de test de la figure 9, et nous calculons à chaque fois l'indice *inf* [8] correspondant à une variation de C de 1 à 8 (considéré comme nombre maximal de classes pour nos tests). La valeur maximale de l'indice *inf* correspond au nombre de classes adéquat pour le paramètre m choisi.

Tableau-2. Nombre de classes obtenues en faisant varier le coefficient flou m.

	Valeur du coefficient flou m							
Image	1.5	2	2.5	3	3.5	4	4.5	5
Image-1	3	3	2	2	2	2	2	2
Image-2	3	3	8	7	7	7	8	8
Image-3	3	5	5	7	8	8	5	7

Les résultats des tests réalisés sur les trois images image-1, image-2 et image-3 sont présentés dans le tableau-2. Nous remarquons que pour les trois images de test, la classification est correcte pour une valeur de m égale à 2. D'ailleurs ce choix est fortement conseillé pour les images à régions homogènes et il

reste valable aussi pour les régions texturées. Pour tout ce qui suit, m gardera la valeur 2.

### 5.4 Détermination automatique du nombre de classes

La classification FCM est considérée comme une technique semi-automatique de classification puisque le nombre de classes doit être fourni comme paramètre ce qui représente une limite pour l'algorithme. Afin d'aboutir à une classification totalement automatique, nous devons automatiser la détermination du nombre de classes. Cette automatisation est réalisée en utilisant l'indice *inf* défini par l'équation [8] (Xiaou, 1998). Ainsi, après avoir fixé le paramètre  $m=2$ , nous faisons varier le nombre de classe C dans un intervalle donné et nous calculons pour chaque valeur de C l'indice *inf* correspondant. Le nombre de classes optimal est obtenu lorsque l'indice *inf* atteint sa valeur maximale. La figure-7 présente la variation de l'indice *inf* pour l'image-3 de la figure-6 en fonction du nombre de classes. La courbe atteint sa valeur maximale lorsque le nombre de classes trouvées est égal au nombre de classes existantes dans l'image.




Figure 7. Courbe représentative de l'indice « inf » en fonction du nombre de classes. Le maximum de la courbe est atteint lorsque le nombre correspond au nombre de classes existant dans l'image

## 6. Résultats

Nous avons testé notre méthode sur des images de synthèse ensuite sur des images issues de l'album de Brodatz et enfin sur des images médicales contenant des textures naturelles. Ces tests ont été réalisés en utilisant l'ondelette DB1 avec une fenêtre d'analyse de taille 3x3.

### 6.1 Image de synthèse

Nous avons testé d'abord notre algorithme sur l'image de la figure 8.a qui est codée sur 256 niveaux de gris. Elle contient trois régions homogènes de tailles et de formes différentes qui peuvent être associées à des classes de pixels non équiprobables. Le résultat présenté dans la figure 8.b montre que la méthode a bien reconnu les trois classes existantes dans l'image.

### 6.2 Image de l'album de Brodatz

Nous avons appliqué la méthode sur un échantillon de textures issues de l'album de Brodatz. La figure 9.a montre une image contenant une mosaïque de régions

texturées de l'album de Brodatz parmi lesquelles a été insérée une région homogène noire. Les textures représentent la texture du cuir, du bois, de la laine, de l'eau et de la texture Raffia. Le résultat de la segmentation présenté dans la figure-9b montre que les régions ont été reconnues et bien délimitées.




Figure 8. (a) Image de synthèse et (b) image segmentée




Figure 9. a. Image nature comportant des textures naturelles et b. image segmentée

### 6.3 Images médicales

Enfin, nous avons appliqué notre méthode sur des images médicales présentant des textures. La première image représente une image de mélanome malin qui est un cancer de la peau considéré en France, comme la première cause de mortalité des femmes de 25 à 29 ans avec chaque année 6000 nouveaux cas. Il est responsable de 1500 décès par an. La reconnaissance de ce cancer n'est pas une tâche facile et fait l'objet de nombreux projets de recherche. Un des critères de classification est lié à la texture de la lésion. Dans cette partie, nous allons utiliser cette approche pour la segmentation de lésions cutanées en vue de la reconnaissance de mélanomes malins (Connors et al., 1980). La figure-10 présente l'image originale et l'image segmentée.




Figure 10. (a) Image lésion représentant une tumeur noire, (b) Résultat de la segmentation de l'image lésion

La figure-11 montre une autre image de mélanome pour laquelle nous disposons du résultat de la segmentation obtenu par (Serruys, 2002) (figure-11 .b) en utilisant des attributs statistiques tels que la moyenne locale et la variance. La figure-11.c montre

le résultat obtenu par notre méthode. Les deux résultats présentent une différence au niveau du « lobe » qui est détecté par notre méthode et non par la méthode de (Serruys, 2002).

Nous avons aussi appliquée notre méthode sur des images scintigraphiques du cœur. Ces images sont souvent entachées d'un bruit, mal contrastées et de mauvaise résolution ce qui rend difficile la perception des régions d'intérêt (Figure-12). Un des problèmes posé à l'analyse de ce genre d'images est de délimiter le ventricule gauche dont l'activité renseigne sur l'état du cœur. Les contours étant flous, l'approche par région est donc plus appropriée pour la détection des cavités cardiaques. Nous avons testé notre méthode pour la segmentation d'un échantillon de ces images. Le résultat, présenté dans la figure-13, montre que les cavités cardiaques sont bien délimitées.




Figure 11. (a) Image d'une tumeur noire, (b) Résultat de la segmentation de l'image par Cucchira, (c) notre résultat de segmentation qui a détecté les lobes que présente l'image originale.




Figure 12. Régions d'intérêts du cœur : Ventricule droit et gauche




Figure 13. Résultats de la segmentation pour quelques images scintigraphiques

## 7. Conclusion

Nous avons présenté dans ce papier une méthode de segmentation d'images texturées basée sur l'extraction des attributs par une analyse multi-échelle par la transformée par ondelettes et la classification dans l'espace des attributs par la méthode C-moyenne floue. L'analyse par ondelette est faite au voisinage de chaque pixel et le vecteur des attributs obtenu est composé de l'énergie de sept sous-bandes obtenues lors d'une décomposition sur deux niveaux par l'ondelette de Daubechies. Pour la classification par C-moyenne floue, une discussion a été présentée portant sur le choix du coefficient floue et de la manière de déterminer d'une manière automatique le nombre de classes constituant l'image.

La méthode a été appliquée sur des images de synthèse, des images composées de texture de l'album de Brodatz et sur des images médicales de mélanome ainsi que sur des images scintigraphiques. Le résultat est très encourageant.

Ce travail montre que l'analyse de texture trouve dans l'analyse par ondelette un outil assez robuste pour la caractérisation de textures et que sa conjonction avec la méthode de classification C-moyenne floue suivie d'une étape d'étiquetage fournit une méthode de segmentation assez fiable.

En perspective, nous pensons qu'il faudrait étudier le comportement de la méthode avec d'autres attributs différents de l'énergie considérée dans ce travail. On peut minimiser les attributs utilisés par une méthode statistique d'optimisation. De plus, nous pouvons introduire un classifieur neuro-flou pour améliorer le résultat obtenu.

## Références

- Barlaud M. Editeur, *Wavelets in Image communications*, Elsevier, 1995.
- Bonnert Noel, Herbin Michel, *Classification automatique*, Séminaire LERI – Université de Reims – Février 1996.
- Bovic A.C, Clark M and Geisler W.S, *Multichannel texture analysis using localized spatial filter*, IEEE Transactions on Pattern Analysis and Machine Intelligence – Volume 12, Issue 1– January 1990
- Borges, G.A, Aldon, M.-J., *A split-and-merge segmentation algorithm for line extraction in 2D range images*, Pattern Recognition, 2000. Proceedings. 15th International Conference, Spain 2000
- Brodatz P., *Texture : A photographic album for artists and designers*. New York : Dover 1966.
- T. Chang and C.C. Kuo, *Texture analysis and classification with tree-structured wavelet transform*, IEEE Trans. Image Processing Vol-2 No-4 pp. 429-441 Oct. 1993
- Chuai-Aree, S., Lursinsap, C., Sophatsathit, P. and Siripant, S., *Fuzzy C-Mean: A statistical feature classification of text and image segmentation method*, Proc. of Intern. Conf. on Intelligent Technology 2000, December 13-15, Assumption University Bangkok, Thailand, pp. 279-284, 2000.
- Cocquerez J.P. et S. Philip, *Analyse d'images : filtrage et segmentation*, Edition Dunod (1995).
- Coifman R.R. and Y. Meyer. *Othornormal wave packet bases*. preprint, Deptt. of Maths., Yale Uni., USA, 1990.
- Connors R.W. and C.A. Harlow, *A theoretical comparison of texture algorithms*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2(3):204-222, 1980.
- Demaeyer Jonathan, *Les Ondelettes : L'Analyse de Fourier*, 2003
- Fletcher Neil D., Adrian N.Evans, *Minimum distance texture classification of SAR images using wavelet packets*, Geoscience and Remote Sensing Symposium, 2002. IGARSS '02. 2002 IEEE International, UK
- Grossman A., J. Morlet, *Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape*, SIAM J. of Math. Anal. vol. 15, no. 4, pp. 723-736, July 1984.
- Guillaume Serge, *Induction de règles floues interprétables*, Thèse de Doctorat Laboratoire d'analyse et d'architecture des systèmes du CNRS Toulouse – Novembre 2001
- Haralick, R. M., Shanmugam, K., Dinstein, I., *Textural Features for Image Classification*, IEEE Transactions on Systems, Man, and Cybernetics, vol. 3 No. 6, November 1973
- Haralick, R., *Statistical and structural approaches to texture*, Proc. of IEEE, vol. 67, no. 5, pp. 786-804, May 1979
- Mallat S. *Wavelet Tour of Signal Processing* – Academic Press, London, 1998.
- Hofmann T. *An optimization approach to unsupervised hierarchical texture segmentation*, IEEE int Conf on Image Processing, Santa Barbara, CA – October 1997
- Laine A. and Jian Fan, *Texture Classification by Wavelet Packet Signatures*, IEEE Transaction on Pattern Analysis and machine intelligence, VOL 15, No 11, November 1993
- Levesque Vincent, *Texture segmentation using Gabor filters*, Center For Intelligent Machines, McGill university December 2000.
- Mallat S. *A theory of multiresolution signal decomposition: the wavelet representation*, IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 11, no. 7, pp. 674-693, July 1989.
- Meyer Y. *Ondelettes et Opérateurs*, Hermann, Paris, 1990.
- Unser Michael *Texture classification and segmentation using wavelet frames*, IEEE Transactions on Image Processing – Volume 4, Issue 11 – November 1995
- Weszka J.S., C. R. Dyer and A. Rosenfeld, *A comparative study of texture measures for terrain classification*, IEEE Transactions on Systems, Man and Cybernetics, 6:269-285, 1976.
- Xianfeng Li, *Texture analysis for optical coherence tomography images*, PhD Thesis in computer engineering – University of Arizona 2001
- Xiaou Tang, *Texture information in Run-Length matrices*, IEEE Transactions on Image Processing – Volume

7, Issue 11– November 1998

Ying Liu, *Texture segmentation based on features in wavelet domain for image retrieval*, Visual Communications and Image Processing 2003, Lugano, Switzerland

Serruys Camille, *Classification automatique des tumeurs noires de la peau par des techniques numériques d'analyse d'images fondées sur des méthodes d'apprentissage par l'exemple : Aide au dépistage des mélanomes*, thèse de doctorat – université PARIS V – Rene Descartes – France, Décembre 2002

Sharma Mona, *Evaluation of texture methods for image analysis*, Pattern recognition letters – UK

Cucchiara R., Grana C., Piccardi M., *Iterative Fuzzy Clustering Regions of interest in Skin Lesions*, Image Processing Lab – University of Modena Italie 2002.