



République Algérienne Démocratique et populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Abderrahmane Mira-Bejaia
Faculté de Technologie
Département de Génie électrique

Projet fin d'études

En vue de l'obtention du diplôme Master

Filière : Electronique

Option : Télécommunication

Thème :

Méthode coopérative pour la segmentation d'image :
Application a l'imagerie médicale

Présenté par :

M^{elle} AISSOU Nabila
M^{elle} BENKACI Amira

Encadré par :

Mr. MEKHMOUKH Abdenour
Mr. CHELBI Salim

Promotion 2016

Remerciements

Avant tout, nous remercions Dieu le très haut qui nous a donné le courage et la volonté de réaliser ce modeste travail.

Nous remercions notre encadreur Mr. Mekhmoukh Abdenour, docteur à l'Université Abderrahmane mira Bejaia, de nous avoir proposé un tel intéressant sujet, nous ouvrant ainsi les portes sur un domaine de recherche assez vivant.

Nous remercions tous les membres du jury qui ont accepté d'évaluer notre travail

Nous tenons aussi à remercier tous ceux qui ont, de près ou de loin, aidé à rendre ce travail possible, que ce soit par des idées ou par des Encouragements.

Dédicaces

Je dédie ce modeste travail

A ma **chère mère**

Pour son grand amour, ses sacrifices et toute l'affection qu'elle m'a
toujours offerte.

A mon **cher père**

Pour sa patience et ses considérables sacrifices pour me parvenir à ce
niveau.

A mes frères (nabil , massinissa), mes sœurs (ania , katia)

Spécialement à **fatima benhamouche** pour ses encouragements, sa
patience et son aide.

A **yassine** Pour son aide précieux et sa présence capitale et à toute sa
famille,

A mes **chers amis**

A tous ceux qui m'ont aidé de Prés au de loin a la réussite de ce travail.

Nabila Aïssou

DEDICACES

Je tiens à dédier ce modeste travail en guise de respect et de reconnaissance à mes précieux parents, ma mère en premier lieu qui a toujours été là pour moi de jour comme de nuit, à mon très cher père et mes très chers frères et mon fiancé Aimad qui m'ont beaucoup aidés, ainsi qu'à toute personne qui m'a soutenu lors de mon parcours d'études.

Benkaci Amira

SOMMAIRE

INTRODUCTION GENERALE..... 1

CHAPITRE 1

INTRODUCTION A LA SEGMENTATION D'IMAGES

1.1 INTRODUCTION: 3

1.2 DEFINITION DE LA SEGMENTATION D'IMAGE 3

1.3 DIFFERENTES APPROCHES DE SEGMENTATION 3

1.3.1 APPROCHE REGION4

1.3.2 APPROCHES FRONTIERES (CONTOUR)5

1.3.2.1 La méthode déformable (Level set)6

1.3.3 APPROCHES CLASSIFICATION7

1.3.3.1 Méthodes supervisées 7

1.3.3.2 Méthodes non supervisées8

1.4 CONCLUSION 9

CHAPITRE 2

LA SEGMENTATION PAR CLASSIFIEUR NON SUPERVISE

2.1 INTRODUCTION 10

2.2 SEGMENTATION NETTE D'IMAGES PAR CLASSIFICATION DE PIXELS 10

2.2.1 ALGORITHME DES K-MEANS10

2.2.1.1 Choix du nombre K de classes (clusters)11

SOMMAIRE

2.3 SEGMENTATION FLOU D'IMAGE PAR CLASSIFICATION DE PIXELS :	12
2.3.1 LES C-MEANS	13
2.3.2 LES FUZZY C-MEANS (FCM)	13
2.3.2.1 <i>Analyse de l'algorithme FCM</i>	16
2.3.2.2 <i>Avantages et inconvénients de l'algorithme (FCM)</i>	16
2.3.3 LES C-MEANS FLOUS AVEC CONTRAINTES SPATIALES FCM-S.....	17
2.3.3.1 <i>Algorithme FCM-S1 (Fuzzy c-means with spatial constraints)</i>	17
2.4 LA COOPERATION ENTRE LEVEL SET ET FCM_S.....	19
2.4.1 ALGORITHME DE LEVEL SET.....	19
2.5 RESULTATS ET DISCUSSIONS	21
2.5.1 PROBLEME D'INITIALISATION	22
2.5.2 IMMUNITE AU BRUIT	25
2.6 APPLICATION DE LA METHODE COOPERATIVE (FCM_S1 ET LEVEL SET).....	28
2.7 CONCLUSION.....	29

CHAPITRE 3

APPLICATION A L'IMAGERIE MEDICALE

3.1 INTRODUCTION.....	30
3.2 SEGMENTATION DES TISSUS CEREBRAUX (MB, MG, LCR) :.....	30
3.2.1 ANATOMIE CEREBRALE	30
3.2.1.1 L'encéphale	31
3.2.1.2 Les tissus du cerveau	32
3.2.1.3 La matière grise (MG)	32
3.2.1.4 La matière blanche (MB).....	32
3.2.1.5 Le liquide céphalo-rachidien (LCR)	32
3.3. L'IMAGERIE PAR RESONANCE MAGNETIQUE (IRM).....	33
3.3.1 L'OBSERVATION DU CERVEAU	33

SOMMAIRE

3.4 RESULTATS EXPERIMENTAUX ET DISCUSSION.....	34
3.4.1 PRESENTATION DE BASES DE DONNEES UTILISEE (BRAINWEB).....	34
3.4.2 RESULTATS SUR LES IMAGES IRM SIMULEES.....	35
3.4.2.1 Etude d’image sans bruit	36
3.4.3.2 Etude de l’influence du bruit	38
3.4.3.3 Critère d’évaluation	42
3.4.4 INTERPRETATIONS DES RESULTATS	42
3.5 SEGMENTATION DES IMAGES IRM AVEC LA COOPERATION DU FCM_S ET LA METHODE DEFORMABLE (LEVEL SET)	45
3.6 CONCLUSION.....	46
CONCLUSION ET PERSPECTIVES	48

Tables des Figures

Figure 1.3.1 : Les approches de segmentation d'image.....	4
Figure 1.3.2 : Segmentation par approche région.....	5
Figure 1.3.3 : Segmentation par approche frontière.....	6
Figure 1.3.4 : formulation de level set	6
Figure 1.3.5 :Les méthodes de segmentation par classification.....	7
Figure 2.3.1 : Détail de l'image originale entre R5 et R6.....	12
Figure 2.3.2 : Classification FCM (C1, C2, C3, C4 les classes et V1, V2, V3, V4 les centroïdes)	16
Figure 2.4.1 : principe de la coopération des résultats.....	19
Figure 2.4.2 : L'évolution de la fonction de level set et la propagation de contour correspondant : (a) la vue topologique de l'évolution de $\emptyset(x, y)$, (b) les changements de level set initial $C : \emptyset(x, y)$	20
Figure 2.5.1 : Image synthétiques avant la segmentation utilisée pour les tests.....	22
Figure 2.5.2 : Résultats de segmentation par algorithme K-means sur l'image synthétique 1	24
Figure (2.5.4) : résultats de la segmentation par l'algorithme FCM_S, sur l'image synthétique 1.....	24
Figure 2.5.5 : Images synthétiques 1 et 2.....	25
Figure 2.5.6 : Résultats de la segmentation pour un bruit salt & papper	26
Figure 2.5.7 : résultats de la segmentation pour un bruit gaussien.....	26
Figure 2.5.8 : Résultats de la segmentation par l'algorithme FCM.....	27
Figure 2.5.9 : Résultats de la segmentation par l'algorithme FCM-S1.....	28
Figure 2.6.1 : Segmentation de la région R_4	28
Figure 2.6.2 : Segmentation de la région R_3	29

Figure 3.2.1 : Système nerveux central humain.....	32
Figure 3.2.2 : l'image (a) illustre l'encéphale, composé du cerveau, du cervelet et du tronc cérébral. L'image (b) montre une coupe histologique d'un cerveau mettant en évidence les trois matières principales de l'encéphale.....	32
Figure 3.2.3 : Coupe de cerveau mettant une évidence les trois matières principales	34
Figure 3.3.1 : Les différentes courbes du cerveau.....	35
Figure 3.4.1 : Simulateur d'image BrainWeb.	36
Figure 3.4.2 : Résultats obtenu sur une courbe axiale pondérée en T_1 par K-means	38
Figure 3.4.3 : Résultats obtenu sur une courbe axiale pondérée en T_1 par FCM.....	38
Figure 3.4.4 : Résultats obtenu sur une courbe axiale pondérée en T_1 par FCM_S1.....	38
Figure 3.4.5 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit salt & pepper par K-Means.....	39
Figure 3.4.6 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit salt & pepper par FCM.	40
Figure 3.4.7: Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit salt & pepper par FCM_S1.....	40
Figure 3.4.8 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit gaussien par K-means.....	41
Figure 3.4.9 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit gaussien par FCM.....	41
Figure 3.4.10 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit gaussien par FCM_S1.....	42
Figure 3.4.11 : segmentation de la région d'intérêt des lésions de la SEP (coupe axial) par k-means et FCM et FCM_S1, avec nombre de classe = 5, (a) image initial ; (b) résultat du K-means ;(c) résultat du FCM ; (d) résultat du FCM_S1.....	42
Figure 3.4.12 : Evaluation des performances des différents algorithmes pour image IRM Simulées sans bruit.....	44
Figure 3.4.13 : Evaluation des performances des différents algorithmes pour image IRM simulées avec bruit salt & papper.	45

Figure 3.4.14 : Evaluation des performances des différents algorithmes pour image IRM simulées avec bruit gaussien.	45
Figure 3.5.1 : segmentation du tissu MB avec la méthode coopérative : (a) contour initial, (b) après 1000 itération, (c) apes 2000 itération (Vert).....	46
Figure 3.5.2 : Segmentation du tissu MG avec la méthode coopérative : (a) contour initial, (b) après 1000 itération, (c) apes 2000 itération (Vert).....	47
Figure 3.5.3 : Segmentation du tissu LCR avec la méthode coopérative : (a) contour initial, (b) après 1000 itération, (c) apes 2000 itération (Vert).....	47

Liste des tableaux

Tableau 3.1 : Résultats obtenus pour les trois algorithmes K-Means, FCM, et FCM_S1 sans bruit et avec bruit.....	43
---	----

Liste des algorithmes

- 2.1 Algorithme général d'exécution du K-means.
- 2.2 Algorithme générale d'exécution FCM.
- 2.3 Algorithme générale d'exécution FCM_S1.

Introduction générale

Dans le domaine du traitement d'images, la segmentation continue encore de susciter un grand engouement chez les chercheurs dans le domaine de la vision artificielle. L'objectif de la segmentation consiste à partitionner l'image en sous-ensembles ou régions homogènes de sorte que l'interprétation entre ses sous-ensembles soit vide et leur union constitue l'image initiale. Pour ce faire, diverses méthodes ont été proposées dans la littérature. Cette diversité est en rapport avec le type d'image à traiter, sa complexité en termes de forme, de texture et de l'espace de représentation ainsi que la nature de bruit qu'elle renferme.

A ces jours il existe de nombreuses méthodes de segmentation que l'on peut regrouper en deux grandes familles :

- Les méthodes de segmentation par contours basés sur la recherche des discontinuités locales présentés dans l'image.
- Les méthodes de segmentation en régions homogènes consistent à trouver des ensembles de pixels qui partagent des propriétés similaires. Les régions homogènes sont construites à partir des parties connexes de ses ensembles, les techniques les plus connues dans cette méthode, est la classification.
- Les méthodes de classification fournissent une partition de l'image en regroupant des pixels ayant des niveaux de gris similaires dans une même classe de pixels. Les régions sont définies par les ensembles maximaux de pixels connexes appartenant à la même classe. En général, on peut les répartir en : méthodes supervisées qui se basent sur un modèle exacte, fourni par un expert, des classes à obtenir et les méthodes non supervisées où aucune connaissance a priori n'est disponible.

Dans ce mémoire nous nous intéresserons essentiellement à la segmentation par classification non supervisée qui ne nécessite pas des connaissances a priori, comme l'algorithme K-Means, Fuzzy C-Means (FCM) et Fuzzy C-Means Spatial (FCM-S).

L'imagerie médicale est l'un des domaines qui exploite les techniques de traitement et d'analyse d'image. L'imagerie par résonance magnétique (IRM), constitue une des avancées les plus significatives en médecine, permet au praticien de faire un diagnostic et un suivi de plusieurs pathologies. Vu la taille des données à analyser, le recours aux techniques de traitement d'images peut offrir un outil d'aide au diagnostic, à l'intervention et au suivi thérapeutique. Pour cela, nous nous proposons d'appliquer les méthodes de segmentation par classification de pixels en vue d'une segmentation correspondant aux différents tissus cérébraux.

Introduction générale

L'objectif de notre travail, est l'utilisation d'une méthode coopérative entre l'approche contours et l'approche région. En effet, nous tirons parti d'une méthode de segmentation utilisant l'image dans sa globalité pour la segmenter basée sur le FCM, combinée à un algorithme qui permet de tenir compte des caractéristiques locales de l'image basée sur la méthode des Level set.

Ce mémoire s'articule autour de trois chapitres qui nous permettront de présenter les différents aspects de notre travail.

Dans le premier chapitre, nous présentons un aperçu des différentes approches de segmentation que nous pouvons trouver dans la littérature.

Dans le deuxième chapitre, nous détaillerons les méthodes des segmentations d'images par classification. Cette partie est consacrée à la présentation des résultats expérimentaux obtenus sur des images synthétiques par l'utilisation combinée entre les Level set et la classification floue FCM.

Dans le troisième chapitre, nous nous intéressons aux images cérébrales IRM en vue d'une classification des différentes classes correspondant aux différents tissus cérébraux ainsi qu'à l'application de la méthode coopérative sur ce type d'images.

Enfin, une conclusion générale permet d'analyser les résultats obtenus ainsi que quelques perspectives dans ce domaine.

1.1 Introduction :

Une bonne analyse de l'image vient d'une bonne segmentation qui est une étape très importante dans cette chaîne, car c'est à partir de l'image segmentée que les mesures sont effectuées pour l'extraction des paramètres discriminants en vue de la classification ou de l'interprétation. La tâche de segmentation peut se résumer de la manière suivante : étant donnée une image, l'objectif de la segmentation est à partir de toutes les données, de retrouver l'information utile et de la coder sous une forme de liste de primitives, plus facilement exploitable par un futur processus d'interprétation.

Dans ce chapitre, nous nous intéressons à définir l'opération de la segmentation d'images en général avec ces diverses approches, on présentera les principales méthodes que l'on peut trouver dans la littérature avec l'introduction des différentes méthodes algorithmiques à utiliser par la suite

1.2 Définition de la segmentation d'image :

La segmentation est considérée comme une étape de traitement, bas niveau de l'image. Elle consiste à partitionner l'ensemble des pixels de l'image en différents groupes et chaque groupe est supposé correspondre à un "objet" de l'image. C'est une étape importante pour l'extraction des informations qualitatives de l'image. Elle consiste aussi à découper une certaine image en un certain nombre de régions disjointes ayant une homogénéité selon un critère prédéfini (niveau de gris, la couleur, la texture ...) et il existe de très nombreuses approches permettant ce découpage [1].

L'intérêt de ces régions est de pouvoir être manipulées ensuite via des traitements de haut niveau pour extraire des caractéristiques de forme, de position, de taille,.... L'union des régions obtenues doit redonner l'image initiale.

1.3 Différentes approches de segmentation :

La segmentation d'images ainsi définie est un domaine vaste où l'on retrouve de très nombreuses approches. Toutes ces approches visent à l'extraction des indices visuels. Après de nombreuses années passées à rechercher la méthode optimale, les chercheurs ont compris que la segmentation idéale n'existait pas. On peut même montrer que le problème de la segmentation est le plus souvent un problème mal posé. Étant donnée une image, il existe toujours plusieurs segmentations possibles. Une bonne méthode de segmentation sera donc celle qui permettra d'arriver à une bonne interprétation. Elle devra donc avoir simplifié l'image sans pour autant en avoir trop réduit le contenu. Entre autres, elle devra éviter les choix irréversibles. Donc beaucoup des méthodes de segmentation existent dans la littérature et peuvent être séparées en deux grandes familles [2].

Chapitre 1 : Introduction à la segmentation d'image

1. Les méthodes de segmentation par contours. 2. Les méthodes de segmentation en région homogènes.

Dans la première approche, On s'intéresse aux frontières des régions et dans la deuxième approche on s'intéresse au contenu de région (la figure 1.3.1)

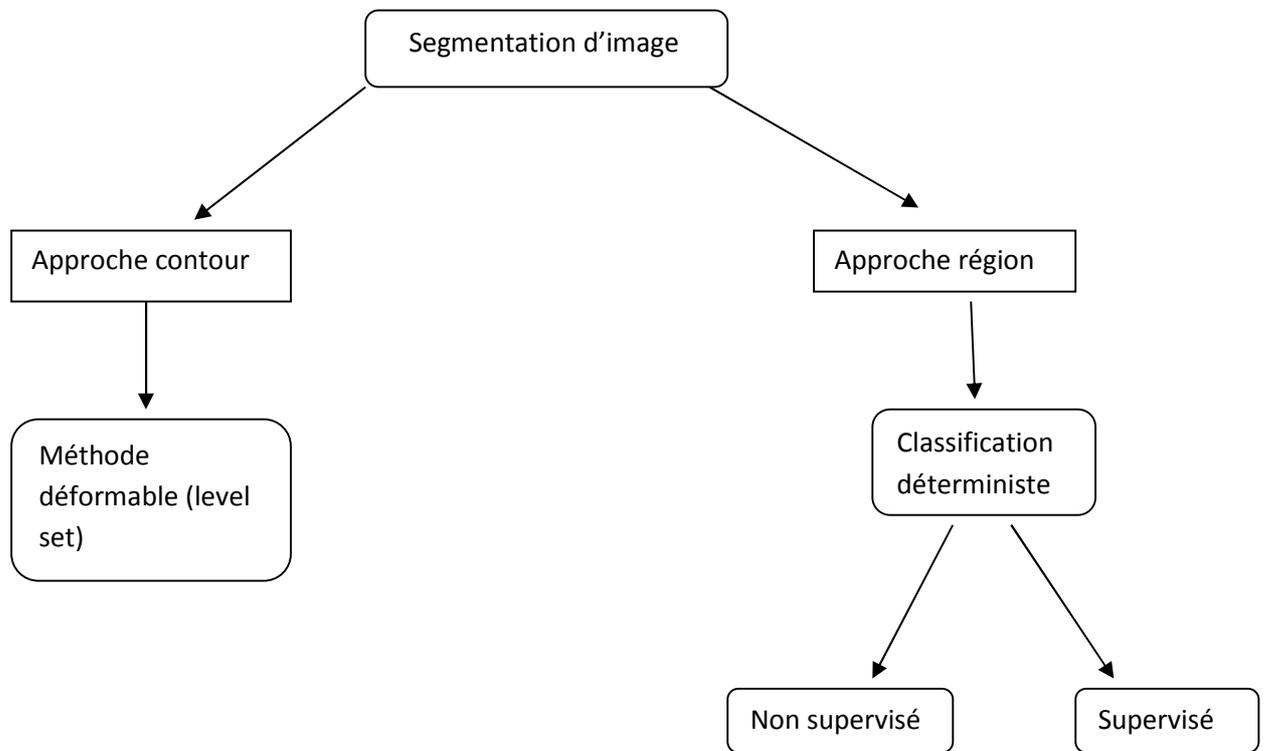


Figure 1.3.1 : Les approches de segmentation d'image.

1.3.1 Approche région :

Les approches de segmentation régions comme le montre la figure (1.3.1) visent à créer une partition de l'image en un ensemble de régions homogènes au sens d'un ou plusieurs critères pour avoir des ensembles de pixels partageant des propriétés communes. Les régions sont différenciées entre elles par des propriétés élémentaires fondées sur des critères locaux tels que le niveau de gris de chaque pixel, ou bien sur un attribut estimé dans le voisinage du pixel tel que la valeur moyenne, la variance, ou des paramètres de texture. L'ensemble des regroupements de pixels constitue une segmentation d'image [3]



Figure 1.3.2 : Segmentation par approche région.

1.3.2 Approches frontières (contour) :

Contrairement aux approches régions, qui cherchent à former des zones homogènes, les approches contours se basent sur les discontinuités des images pour déterminer les contours des régions et trouver les di similarités avec la recherche à exploiter le fait qu'il existe une transition détectable entre deux régions connexes. La détection de contours consiste à repérer les points d'une image numérique qui correspondent à un changement brutale du niveau de gris, comme le montre la figure (1.3.3) [4].

Les méthodes de détection de contours donnent de bons résultats quand les contours de l'image sont bien définis. Cependant, dans le cas des images bruitées ou faiblement contrastées les contours obtenus ne sont pas connexes et fermés, alors c'est une méthode qui nécessite une étape supplémentaire afin de fermer les bords des régions.

Dans la littérature, il existe plusieurs méthodes utilisant l'approche contours, dans ce qui suit, nous allons présenter l'une des plus importantes qui est le Level Set appartenant aux modèles déformables [5].

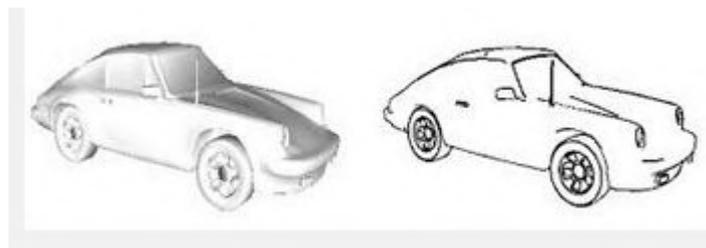


Figure 1.3.3 : Segmentation par approche frontière.

1.3.2.1 La méthode déformable (Level set) :

Dans le modèle d'origine des contours actifs, la courbe est représentée par une liste de points et d'évolution de la courbe par la variation des coordonnées de ces points. Elle introduit un modèle géométrique, puis notion de contour géodésique. Malladi implémente une évolution de la courbe basée sur un schéma de «Level set » qui permet de gérer automatiquement les changements de topologie.

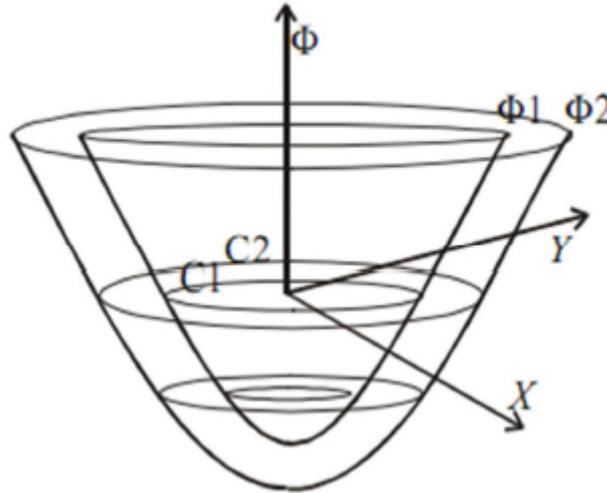


Figure 1.3.4 : formulation de level set

En rapport avec la figure (1.3.4), pour une courbe fermée C dans le plan d'équation $\phi=0$, on peut construire une fonction $\phi(x, y)$ telle que $\phi(x, y) < 0$ à l'intérieur de C , $\phi(x, y) > 0$ à l'extérieur de C et $\phi(x, y) = 0$ sur C . La courbe C est appelée « level set » de ϕ . Deux fonctions $\phi : \phi_1$ et ϕ_2 chacune avec leur « Level sets » C_1 et C_2 apparaissent sur la figure (1.3.3).

Si, on suppose, dans le plan $\phi=0$, qu'une courbe évolue de C_1 à C_2 , avec une certaine fonction de vitesse, au lieu de faire évoluer la courbe, il est possible d'obtenir le même résultat en faisant évoluer une fonction ϕ correspondante :

1. Faire $\phi = \phi_1$ pour qui le « level set » est C_1 .
2. Faire décroître graduellement ϕ vers ϕ_2 ainsi le « level set » se s'étend graduellement de C_1 vers C_2 .

Il est possible de réaffecter les propriétés souhaitées de C_1 et C_2 comme propriétés d'évolution de ϕ_1 et ϕ_2 [6].

1.3.3 Approches classification :

La Classification est un processus qui permet de rassembler les pixels d'une image dans des sous-ensembles qui présentent une similitude et une uniformité selon un critère prédéfini, on parle de partitionnement ou de clustering (classe). Cette approche s'appuie sur les concepts de la logique floue [7].

Les méthodes de classification sont issues des méthodes statistiques multidimensionnelles. Il n'existe pas une méthode de classification qui peut s'appliquer à tout type d'image et qui peut fournir un partitionnement optimal. Ce qui explique la grande diversité de méthodes de classification qui existe dans la littérature.

Le choix d'une méthode est déterminé par différents facteurs tels que le nombre de classes attendues, la forme des classes extraites ou encore le chevauchement ou non des classes [8].

En général, on peut les répartir en : méthodes supervisées qui se basent sur un modèle exacte, fourni par un expert, des classes à obtenir et les méthodes non supervisées ou aucune connaissance à priori n'est disponible figure (1.3.5).

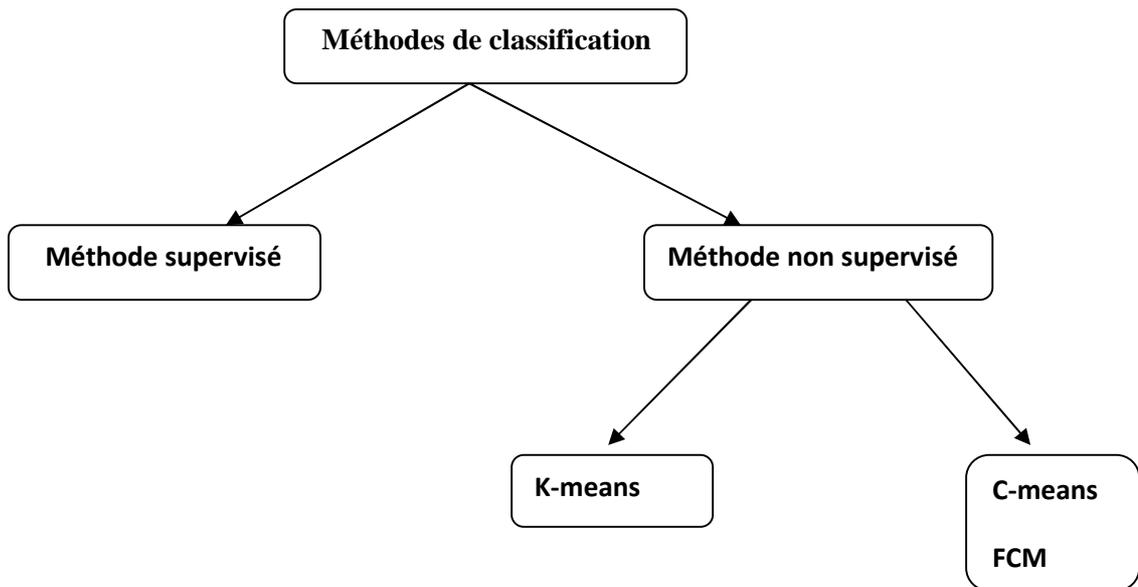


Figure 1.3.5 : Les méthodes de segmentation par classification.

1.3.3.1 Méthodes supervisées :

Les méthodes de classification supervisée nécessitent une base d'images déjà segmentées manuellement. Cette base permet de faire un apprentissage du classifieur. Une fois les paramètres du classifieur déterminés, de nouvelles images peuvent être segmentées. L'exemple le plus simple de ces méthodes est le classifieur du plus proche voisin où chaque

pixel est affecté à la même classe que celle du pixel présent dans la base d'apprentissage ayant le plus proche niveau de gris [7].

1.3.3.2 Méthodes non supervisées :

À l'inverse des méthodes de classification supervisée, les méthodes de classification non supervisée, appelées aussi méthodes de regroupement (*clustering*), ne nécessitent pas une base d'images segmentées. Afin de compenser le manque d'une base d'apprentissage, ces méthodes alternent entre classifications des pixels et caractérisation des classes ; en ce sens, les méthodes de regroupement apprennent d'elles-mêmes en utilisant les données disponibles. Les méthodes de regroupement de données qui ont connu un large succès sont : l'algorithme des K-moyennes (*K-means* en anglais) ou ISODATA et l'algorithme des C-moyennes floues (*fuzzy C-means* "FCM" en anglais), d'où découle la méthode FCM_S sur lequel nous sommes basés dans ce mémoire.

En se fondant sur la théorie de la logique floue introduite par L. Zadeh 1965 [8], J. Bezdek 1981 [9] a proposé pour la première fois l'algorithme des c-moyennes floues. Très vite, cet algorithme a trouvé un large succès dans diverses applications, Gath et al, 1983 [10] ; Granath, 1984 [11] ; Huntsherger et al, 1985 [12].

La méthode des C-moyennes floues a pour objectif de déterminer les centres des différentes classes, ainsi que les degrés d'appartenance de chaque pixel aux différentes classes. Les centres des différentes classes sont déterminés de telle sorte que la distance entre un centre de classe et les pixels appartenant à cette classe soit minimale (Eq.1.3.4) [7] :

$$J_m(U, V) = \sum_{i=1}^C \sum_{k=1}^n \mu_{ik}^m d^2(x_k, V_i) \quad (1.3.4)$$

Ou :

$d = \|x_k - V_i\|$ est la norme Euclidienne.

V_i représente le centre de la classe i .

m : est l'indice de flou.

Grace à son efficacité et de sa simplicité de mise en œuvre, la méthode des C-moyennes floues (FCM) est largement utilisée dans les problèmes de segmentation d'image. Néanmoins, cette méthode présente les inconvénients suivants [5] :

- Le non prise de l'information spatiale dans le critère de segmentation.
- L'utilisation de la distance Euclidienne.

Chapitre 1 : Introduction à la segmentation d'image

- La sensibilité aux solutions initiales. En effet, l'algorithme FCM ne fournit aucune garantie de convergence vers un optimum globale.

Pour surmonter ces inconvénients plusieurs modifications ont été apportées à cet algorithme afin d'améliorer la qualité de la classification. Une des solutions proposée est de modifier la fonction objective en incorporant les informations locales de l'image initiale dans l'algorithme de segmentation. C'est l'objet de l'algorithme FCM_S (FCM with Spatial constraints).

1.4 Conclusion :

Nous avons présenté dans ce chapitre les différentes méthodes pour la segmentation d'images : contour, région, et par classification. Bien elles aient toutes des avantages, elles présentent également plusieurs inconvénients. Pour cela, plusieurs chercheurs se sont intéressés aux approches coopératives, car elles donnent des résultats plus intéressants par rapport aux deux autres approches (par région et par contour).

Dans le deuxième chapitre, nous introduirons la notion de coopération en segmentation d'images, l'utilisation combinée de l'approche par classification (algorithme des c-meansfloue) et de l'approche contour (algorithme des levels sets).

2.1 Introduction :

La classification non supervisée désigne un corpus de méthodes ayant pour objectif de dresser ou de retrouver une typologie existante caractérisant un ensemble de N observations, à partir de P caractéristiques mesurées sur chacune des observations.

L'intérêt des méthodes non supervisées ne nécessite pas des connaissances a priori, dans notre application, nous avons appliqué l'algorithme k-means, et l'algorithme FCM dans laquelle est intégrée l'information spatiale voisine aux pixels d'intérêt. Ainsi, dans le but de préciser les approches contours. Nous introduisons l'algorithme des levels sets et pour rendre cet algorithme robuste au bruit et rapide, nous avons implanté l'algorithme FCM-S, l'initialisation et les paramètres de contrôle de l'algorithme des levels sets sont estimés à partir du résultat de cette méthode.

2.2 Segmentation nette d'images par classification de pixels :

Les méthodes de classification permettent de regrouper des objets en groupes ou classes d'objets plus homogènes. Les objets regroupés ont des caractéristiques communes, ils sont similaires, mais se distinguent clairement des objets des autres classes. Les éléments classés sont les pixels de l'image qui nous permettent d'avoir des groupes. Généralement, les méthodes de classification conduisent à des résultats plus ou moins différents [13].

L'algorithme des K-Means est l'algorithme de classification utilisé, du fait de sa simplicité de mise en œuvre.

2.2.1 Algorithme des K-means :

C'est un algorithme itératif qui minimise la somme des distances entre chaque pixel et le centroïde de son cluster. Ces centroïdes sont initialement placés le plus loin possible les uns des autres afin d'optimiser la qualité des résultats obtenus.

Le principe de cet algorithme consiste à échanger des pixels entre deux classes jusqu'à ce que la somme des distances intra classes ne puisse plus diminuer.

Le résultat idéal serait un ensemble de clusters compacts et clairement séparés. Néanmoins cette méthode nécessite comme unique paramètre un nombre de classes K prédéfini a priori par l'utilisateur [14].

Le principe des K-means est de minimiser la fonction objective :

$$v_k = \frac{1}{n_i} \sum_{i=1}^n x_i \quad (2)$$

$$J(x, v) = \sum_{i=1}^n \sum_{k=1}^c \|x_i - v_k\|^2 \quad (2.2.1)$$

- c est le nombre de classe
- n est le nombre de données.
- v_k est le centre de classe k
- $\|\cdot\|$ est la norme Euclidienne qui mesure la similarité entre un pixel et un autre.

Algorithme 2.1 Algorithme général d'exécution du K-means

- **Etape 1 :** choisir une partition quelconque $P \in P(k)$, tel que $P(k)$ l'ensemble de toutes les k partitions définies sur X .
- **Etape 2 :** obtenir aléatoirement les centres de classe initiaux $v_k; k = 1, \dots, c$
- **Etape 3 :** Assigner $x_i; i = 1 \dots n$ à la classe $k; k = 1 \dots c$ si :

$$\|x_i - v_k\| \leq \|x_i - v_p\|; p = 1, \dots, c \text{ Avec : } i \neq p$$

- **Etape 4 :** Mettre à jour les centres des classes par la formule (2)
- **Etape 5 :** Répéter de l'étape 3 et 4 jusqu'à atteindre la convergence :

$$v_k^* = v_k; k = 1, \dots, c.$$

2.2.1.1 Choix du nombre K de classes (clusters) :

L'algorithme classique des K-Means laisse un paramètre libre; le nombre de classes, ce qui est dans le cas de la segmentation d'images correspond au nombre d'intensités utilisées pour représenter l'image. Généralement le choix de K est fait empiriquement en sélectionnant la valeur de K qui minimise l'équation (2.2.1).

Cette méthode de segmentation nette considère que les régions constituent des sous-ensembles nets de l'ensemble des pixels constituant l'image. La reconstruction des régions s'effectue en affectant chaque pixel à une et seule région. Cette démarche présente des limites lorsque nous ne disposons pas de connaissance a priori sur l'affectation des pixels.

Les méthodes de segmentation floue supposent que les pixels appartiennent plus ou moins à ces sous-ensembles et considèrent que les pixels peuvent ainsi être regroupés en sous-ensembles flous de pixels. Pour cela, ces méthodes sont basées sur les concepts de la logique floue [13].

2.3 Segmentation flou d'image par classification de pixels :

L'image de la figure (2.3.1) représente un détail agrandi de l'image originale (image synthétique). nous pouvons constater qu'il est délicat de décider si le pixel P_1 appartient à la région R_5 ou à la région R_6 . Pour répondre à ce type de situation, les méthodes de segmentation floue supposent que les pixels appartiennent plus ou moins à ces sous-ensembles et considèrent que les pixels peuvent ainsi être regroupés en sous-ensembles flous de pixels. Pour cela, ces méthodes sont basées sur les concepts de la logique floue [5].

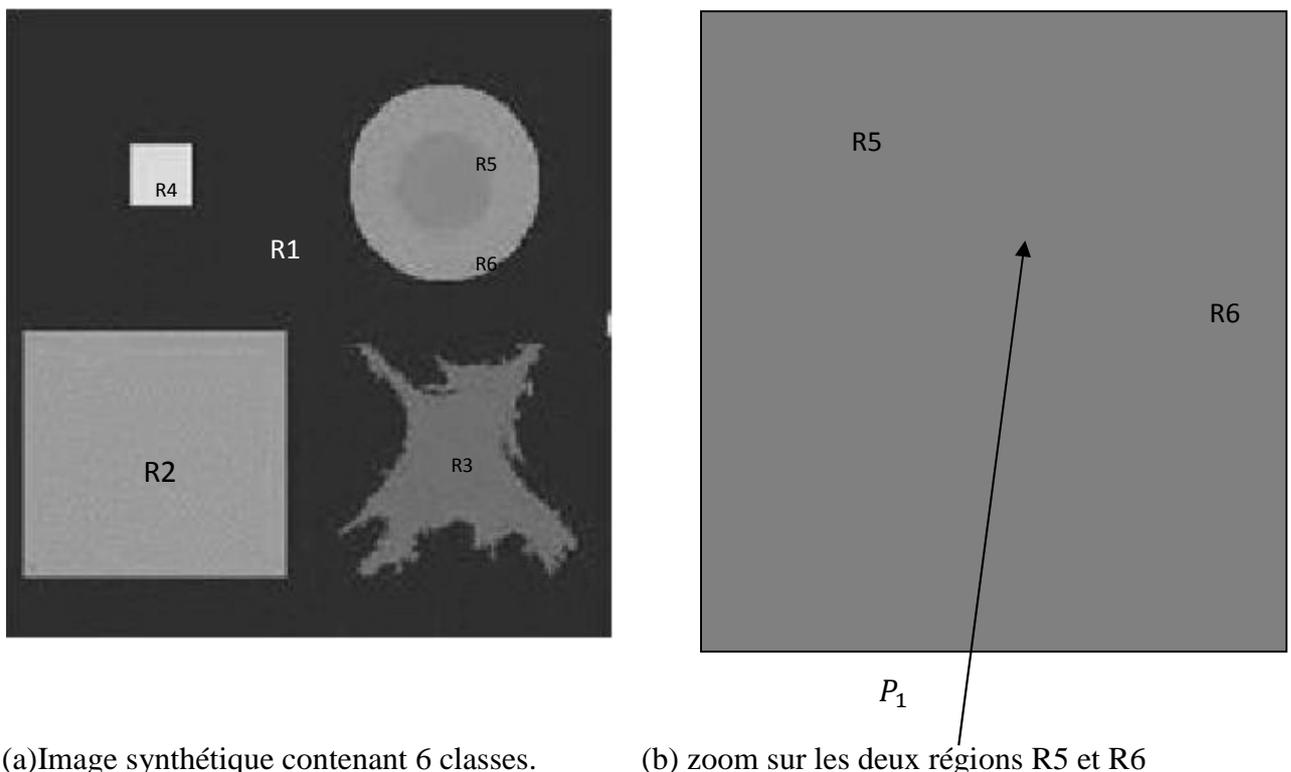


Figure 2.3.1 : Détail de l'image originale entre R_5 et R_6 .

Le point clé de la segmentation d'images par classification de pixels est la construction des classes de pixels en présence. Celle-ci s'appuie sur les concepts de la logique floue d'écrits précédemment en considérant les pixels comme des sous-ensembles flous. Les méthodes de construction des classes telles que les C-means et les Fuzzy C-means seront présentées dans ce qui suit.

Les algorithmes C-means ont été introduits par Duda et Hart [15] en 1973 et ils ont été améliorés par Bazdek [9] en 1981. Ce sont des algorithmes basés sur la minimisation des

Chapitre 2 : Segmentation par classifieurs non supervisés

probabilités qui permettent l'approximation efficace des centres des classes. L'algorithme initial des CM est une extension des Hard C-means [16] ainsi que le FCM appelé Fuzzy ISODATA [17].

2.3.1 Les C-means :

Soit $E = \{x_1, x_2, \dots, x_n\}$ l'ensemble des échantillons de la base d'apprentissage. x_n Est le nième vecteur d'attribut x . les prototypes ou ensembles des centres de classes sont $\{V_1, V_2, \dots, V_c\}$ ou c dénote le nombre de classe.

La méthode des C-moyennes floues a pour objectif de déterminer les centres des différentes classes, ainsi que les degrés d'appartenance de chaque pixel aux différentes classes. Les centres des différentes classes sont déterminés de telle sorte que la distance d entre un centre de classe et les pixels appartenant à cette classe soit minimale. La fonction objective J est de la forme [18] :

$$J = \sum_{i=1}^c \sum_{k=1}^n \mu_{ik} d^2(x_k, V_i) \quad (2.2.2)$$

Ou :

- V_i : représente le centre de la classe i .

- μ_{ik} : Degré d'appartenance de x_k à la classe c_i

2.3.2 Les Fuzzy C-means (FCM) :

L'algorithme des c-moyennes floues (FCM) est une méthode de classification non-supervisée de données (regroupement de données) basée sur le principe de la logique floue où chaque exemple de données n'appartient pas uniquement à une seule classe, mais à toutes les classes avec un certains degrés d'appartenance.

Cette méthode fait partie des méthodes dites « méthodes des centres mobiles » où chaque classe est représentée par son centre (prototype), plus une donnée est proche d'un centre de classe, plus son degré d'appartenance à cette classe est important. L'objectif de cette méthode est donc de trouver à la fois les positions des centres des classes et les degrés d'appartenance des données aux différentes classes, en minimisant un critère quadratique de distance (2.2.3) [7].

Soit E un ensemble de vecteurs d'attributs, $\{V_1, V_2, \dots, V_c\}$ Les centres des différentes classes où c dénote le Nombre de classes. Le degré d'appartenance d'un élément x_k à un

Chapitre 2 : Segmentation par classifieurs non supervisés

groupe V_i est noté $\mu_i(x_k)$. Dans cette approche, un vecteur d'attribut donné peut appartenir à plusieurs groupes

U est la matrice des degrés d'appartenance (appelée également matrice de C-partition floue) de dimension $c \times n$ où c est le nombre de classes et n le nombre d'éléments à classer.

$$J_m(U, V) = \sum_{i=1}^c \sum_{k=1}^n \mu_{ik}^m d^2(x_k, V_i) \quad (2.2.3)$$

Où : $d = \|x_k - V_i\|$ est la norme Euclidienne et V_i représente le centre de la classe i .

Le paramètre $m > 1$ contrôle le degré de flou. Plus m est grand, plus la partition n'est floue. En effet, Dunn a tout d'abord étendu J_1 (pour $m=1$) à J_2 (pour $m=2$) [19]. Bazdek lui a généralisé J_2 à J_m ($1 < m < \infty$).

$\forall i, j, \mu(x_k) \in \{0,1\} U = [\mu_{ik}(x_k)]$ c'est-à-dire :

$$U = \begin{pmatrix} \mu_{11} & \mu_{12} & \dots & \mu_{1n} \\ \vdots & \cdot & & \vdots \\ \mu_{c1} & \dots & & \mu_{cn} \end{pmatrix}$$

Trois contraintes sont définies pour la matrice des degrés d'appartenance U. la première (2.2.4) impose que les valeurs des μ_{ik} soient comprises entre 0 et 1 ce que signifie que tout pixel appartient à la réunion des classes. La deuxième (2.2.5) impose que l'appartenance d'un pixel soit répartie sur l'ensemble des classes, sans exclure l'existence de degrés d'appartenance nuls. Enfin, la troisième (2.2.6) exprime que la classification ne produise pas de classe vide afin que tous les pixels soient caractérisés. Formellement, ces contraintes s'écrivent comme [5] :

$$0 \leq \mu_{ik} \leq 1 \quad 1 \leq i \leq c, \quad 1 \leq k \leq n \quad (2.2.4)$$

$$\sum_{i=1}^c \mu_{ik} = 1, \quad \forall k \in [1, n] \quad (2.2.5)$$

$$0 \leq \sum_{i=1}^c \mu_{ik} \leq 1, \quad \forall k \in [1, n] \quad (2.2.6)$$

Le FCM est basé sur la mise à jour de la fonction d'appartenance pendant l'itération de l'algorithme donc le FCM fait ainsi évoluer la partition (matrice U) en minimisant la fonction objective J_m (voir **Algorithme 2.2**)

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m-1}}} \quad (2.2.7)$$

Où μ_{ik} est la fonction de mise à jour des degrés d'appartenance (avec $d_{ik} = \|x_i - V_k\|$).
La fonction de mise à jour des centres est :

$$V_i = \frac{\sum_{k=1}^c \mu_{ik}^m x_k}{\sum_{k=1}^c \mu_{ik}^m} \quad (2.2.8)$$

Le test d'arrêt au temps $t+1$ est donné par $|J_m^{t+1} - J_m^t| < \text{seuil}$.

Algorithme 2.2 Algorithme général d'exécution du FCM

- **Etape 1 :**
 - choisir le nombre de classes : c
 - fixer m , $1 < m < \infty$
 - choisir ϵ pour le test d'arrêt.
 - initialiser ($t=0$) la matrice de partition $U^t=0$ des fonctions d'appartenance à des valeurs aléatoires ou bien en leur affectant comme valeur $1/c$.
 - choisir la mesure d_{ik} on prend par exemple $d_{ik} = \|x_i - V_k\|$.
- **Etape 2 :** calculer le vecteur C-means V_i des centres en utilisant l'équation (2.2.8).
- **Etape3 :** mettre à jour U^t en utilisant :

$$\mu_{ik}^{t+1} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m-1}}} \quad (2.2.9)$$

- **Etape4 :** comparer à J_m^{t+1} si $|J_m^{t+1} - J_m^t| < \epsilon$ alors arrêt sinon $t=t+1$ et retourner à l'étape 2

La figure 2.3.2 : illustre la classification par FCM. Il existe quatre classes à segmenter (C1, C2, C3, C4). Le carré dans chaque sous-région est le centre de la ClasseCorrespondante (V1, V2, V3, V4).

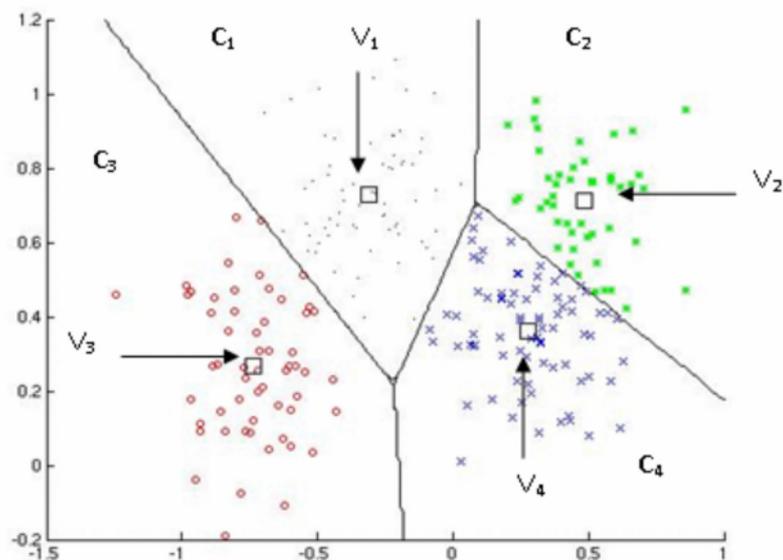


Figure 2.3.2 : Classification FCM (C1, C2, C3, C4 les classes et V1, V2, V3, V4 les centroïdes)

2.3.2.1 Analyse de l'algorithme FCM :

L'algorithme est limité par le choix a priori des paramètres suivant [7] :

1. Le nombre de classe qui est fourni à l'avance.
2. L'initialisation aléatoire des paramètres.
3. Le choix du prototype.
4. Le paramètre de contrôle du flou (m).

2.3.2.2 Avantages et inconvénients de l'algorithme (FCM) :

Le principal avantage de l'algorithme provient de l'introduction des degrés d'appartenance μ_{ik} . Grâce à eux le processus d'optimisation itératif est rendu beaucoup plus robuste notamment en permettant de prendre en compte les recouvrements entre les classes. Il permet ainsi d'obtenir des partitions plus pertinentes et plus proches de la réalité.

En outre ces degrés permettent de prendre des décisions nuancées pour l'assignation d'une forme à une classe ce qui s'avère très intéressant pour toute forme de classification.

Parmi les autres avantages de l'algorithme, nous pouvons noter que sa complexité algorithmique est relativement réduite par rapport à d'autres algorithmes de classification non supervisés, cela le rend plus facilement exploitable pour traiter des problèmes de taille importante (avec beaucoup de données).

Malgré tout l'algorithme possède aussi quelques inconvénients [5] :

Chapitre 2 : Segmentation par classifieurs non supervisés

- L'absence de l'information spatiale dans le critère de segmentation.
- L'utilisation de la distance Euclidienne, qui suppose que toutes les classes ont des formes hyper-sphériques à diamètre égal, Or, cette hypothèse n'est pas vraie, surtout en problème de segmentation d'image, et induit une erreur de la classification des pixels situés au niveau des frontières entre les régions.

- La sensibilité aux solutions initiales. En effet, l'algorithme FCM ne fournit aucune garantie de convergence vers un optimum global. Différentes initialisations peuvent aboutir à différentes partitions).

Dans les FCM la contrainte imposée aux degrés d'appartenance des individus fait que les classes sont établies les unes par rapport aux autres. La conséquence directe est la forme particulière des fonctions d'appartenance ; qu'elles soient définies les unes par rapport aux autres et traduisent la notion de "partage" des individus entre les classes. Une autre conséquence de cette notion de partage est que l'algorithme reste assez sensible aux bruits. .

Afin de remédier au problème du voisinage et la prise en compte de l'information spatiale, l'algorithme FCM-S1 correspond à une telle évolution

2.3.3 Les C-means flous avec contraintes spatiales FCM-S :

L'information spatiale consiste en la somme des degrés d'appartenance des voisins directs du pixel considéré, l'algorithme FCM standard reste le même avec l'insertion d'une nouvelle formule de calcul du Fuzzy c-means (FCM) avec des contraintes spatiales (FCM_S) qu'est un algorithme efficace adapté à la segmentation d'images. Son efficacité contribue non seulement à l'introduction de flou pour les appartenances de chaque pixel, mais aussi l'exploitation des informations contextuelles spatiales [19].

- **FCM-S1 :**

L'information spatiale consiste en la moyenne des niveaux de gris des voisins directs du pixel considéré avec une modification au niveau de la fonction objectif et la formule de calcul de la matrice U et les centres V , l'algorithme se déroule avec un seul passage par itération .

Cette technique donne des régions plus homogènes que ceux des méthodes classiques, réduits et/ou élimines les tâches parasites et bruyantes, elles sont moins sensibles au bruit.

2.3.3.1 Algorithme FCM-S1 (Fuzzy c-means with spatial constraints):

Chen and Zhang, 2004 [20] ont proposé de remplacer la moyenne des distances des pixels voisins au centre de classe par la distance entre la moyenne des pixels voisins au centre

Chapitre 2 : Segmentation par classifieurs non supervisés

de classe. Cela revient à utiliser l'image moyenne déterminée au préalable. Le nouveau critère est le suivant (EQ (2.2.10))[5] :

$$J_m(U, V) = \sum_{i=1}^c \sum_{k=1}^n \mu_{ik}^m d^2(x_k, V_i) + \alpha \sum_{i=1}^c \sum_{k=1}^n \mu_{ik}^m d^2(\bar{x}_k, V_i) \quad (2.2.10)$$

Avec α qui est un coefficient de pondération, \bar{x}_k est considéré comme la moyenne des voisins dans une fenêtre spécifiée autour de x_k dont il représente le niveau de gris de $K^{ème}$ pixel de l'image moyenne \bar{X} de l'image originale X , en obtient l'algorithme FCM-S1

La fonction des degrés d'appartenance est :

$$\mu_{ik} = \frac{(\|x_k - V_i\|^2 + \alpha \|\bar{x}_k - V_i\|^2)^{-\frac{1}{m-1}}}{\sum_{i=1}^c (\|x_k - V_j\|^2 + \alpha \|\bar{x}_k - V_j\|^2)^{-\frac{1}{m-1}}} \quad (2.2.11)$$

La fonction de mise à jour des centres est :

$$V_i = \frac{\sum_{k=1}^n \mu_{ik}^m (x_k + \alpha \bar{x}_k)}{(1 + \alpha) \sum_{k=1}^n \mu_{ik}^m} \quad (2.2.12)$$

Algorithme 2.3 Algorithme général d'exécution du FCM-S1

- **Etape 1 :**
 - Choisir le nombre de classe : c
 - Fixer m , $1 < m < \infty$
 - Choisir ϵ pour le test d'arrêt.
 - Initialiser ($t=0$) la matrice de partition $U^{t=0}$ des fonctions d'appartenance a des valeurs aléatoires ou bien en leur affectant comme valeur $1/c$.
 - Choisir la mesure d_{ik} on prend par exemple $d_{ik} = \|x_i - V_k\|$.

- **Etape 2 :** Calculer le vecteur C-means V_i en utilisant l'équation (2.2.12).

$$\mu_{ik}^{t+1} = \frac{(\|x_k - V_i\|^2 + \alpha \|\bar{x}_k - V_i\|^2)^{-\frac{1}{m-1}}}{\sum_{i=1}^c (\|x_k - V_j\|^2 + \alpha \|\bar{x}_k - V_j\|^2)^{-\frac{1}{m-1}}} \quad (2.2.13)$$

- **Etape 3:** Comparer J^{t+1} à J^t si $|J_m^{t+1} - J_m^t| < \epsilon$ alors arrêt sinon $t=t+1$ et retourner à l'étape 2

2.4 La coopération entre level set et FCM_S :

Dans la première partie de notre travail, nous avons appliqué la méthode de classification floue FCM dans laquelle est intégrée l'information spatiale voisine aux pixels d'intérêt. Dans cette deuxième partie, nous allons utiliser la méthode des Level set comme étape supplémentaire afin de rechercher les contours d'une région donnée.

Cette partie combine deux méthodes de segmentation (Level set et FCM-S) dans le but de résoudre le problème au choix du contour initial des Level set.

La figure suivante résume l'ensemble des étapes du processus de segmentation

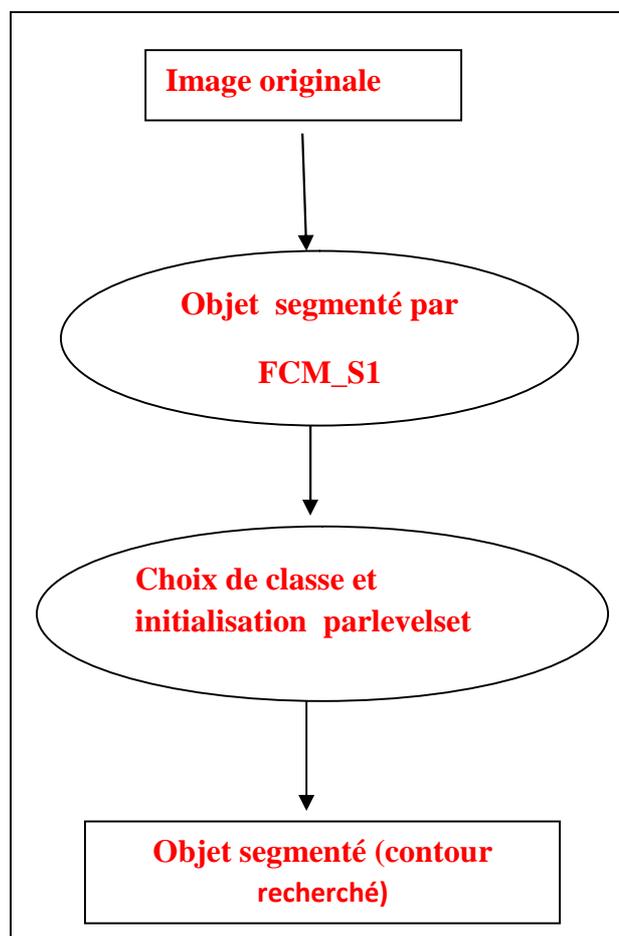


Figure 2.4.1 : principe de la coopération des résultats.

2.4.1 Algorithme de level set :

Dans cette section, nous développons l'algorithme des levels sets et les techniques adaptés dans notre approche. Comme vu précédemment, l'approche "levels sets" consiste à représenter le contour C implicitement via une fonction continue $\phi(x, y)$.

$$\phi(x, y) = \Omega \rightarrow R$$

$$\begin{aligned} \phi(x, y) < 0 & \text{ si } (x, y) \text{ int\'erieur de } C(t) \\ \phi(x, y) = 0 & \text{ si } (x, y) \text{ dans de } C(t) \\ \phi(x, y) > 0 & \text{ si ext\'erieur de } C(t) \end{aligned} \quad (2.2.14)$$

Où Ω le plan entier de l'image.

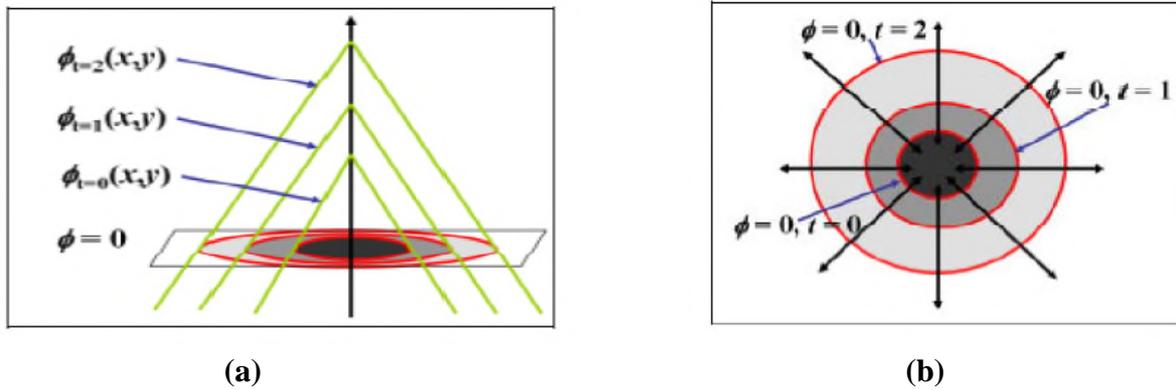


Figure 2.4.2 : L'évolution de la fonction de level set et la propagation de contour correspondant : (a) la vue topologique de l'évolution de $\phi(x, y)$, (b) les changements de level set initial $C : \phi(x, y)$.

Comme la fonction des levels sets $\phi(x, y)$ sur le plan de l'image Ω s'accroît depuis son étape initiale, l'ensemble correspondant du contour C c'est-à-dire le contour rouge sur la figure (2.4.2) se propage vers l'extérieur. Avec cette définition, l'évolution du contour est équivalente à l'évolution de la fonction level set, c'est-à-dire : $\frac{\partial C(t)}{\partial t} = \frac{\partial \phi(x, y)}{\partial t}$.

L'avantage de l'utilisation du niveau zéro est qu'un contour peut être défini comme les frontières entre une surface positive et une surface négative (l'équation (2.2.14)). Ainsi le contour peut être identifié par la vérification du signe de la fonction de level set $\phi(x, y)$. L'évolution de la fonction ϕ est totalement déterminée par l'équation de level set qui est donnée par [21] :

$$\begin{cases} \frac{\partial \phi}{\partial t} + F|\nabla \phi| = 0 \\ \phi(x, y, 0) = \phi_0(x, y) \end{cases} \quad (2.2.15)$$

Où, $\phi_0(x, y)$ est la fonction de level set initiale, $|\nabla \phi|$ désigne la norme directionnelle et F représente la force global, y compris la force interne d'interface, c'est-à-dire la courbure

Chapitre 2 : Segmentation par classifieurs non supervisés

moyenne la longueur de contour et la surface, et la force extérieure, c'est-à-dire le gradient d'image.

La force F doit être régularisée par la fonction d'indication de contour g dans l'ordre d'arrêter l'évolution des levels sets quand elle atteint la solution optimale (frontière de l'objet)

$$g = \frac{1}{1 + |\nabla(G_\sigma * I)|^2} \quad (2.2.16)$$

Où I est l'intensité de l'image, ∇ est l'opérateur gradient de l'image, et $G_\sigma * I$ est le produit de convolution de l'intensité I et du filtre gaussien G_σ d'écart type σ

Le modèle de contour actifs sous une formulation de level set est donné par :

$$\frac{\partial \phi}{\partial t} = g |\nabla \phi| \left(\operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + v \right) \quad (2.2.17)$$

Où $\operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right)$ se rapproche de la courbe moyenne et v est une force dite ballon

La fonction des Level set initial ϕ_0 obtenue par la classification floue spatiale (FCM-S1), l'évolution de ϕ se rapprochera aux véritables limite.

La méthode des ensembles de niveaux présente de nombreux avantages [5] :

- La courbe peut se diviser ou fusionner au cours de l'évolution.
- Les propriétés géométriques de la courbe, telles que la courbure ou le vecteur normal qui sont importants pour les contours actifs, peuvent être simplement déterminés.
- La formation n'est pas limitée aux courbes en deux dimensions et peut être facilement étendue aux dimensions plus élevées.

2.5 Résultats et discussions :

Cette partie est consacrée à l'application des méthodes présentées et à leurs évaluations quantitativement et qualitativement en faisant appel à plusieurs critères différents.

Nous parlerons de la classification dans le but d'une segmentation, réalisée par les algorithmes : K-Means, C-Moyennes Floues standard (FCM) et C-Moyennes Floues Spatial avec la technique FCM-S1. Nous appliquons ces algorithmes sur des images synthétiques, qui contiennent différents nombres de classes auxquelles nous avons ajouté un bruit de type salt

Chapitre 2 : Segmentation par classifieurs non supervisés

et papper et gaussien, et en fixant les paramètres qui contrôlent l'effet de la classification, tel que ces paramètres varient d'une image à l'autre, ce qui rend fastidieuse, la recherche de la valeur optimale de chaque paramètre.

Pour ce travail, nous avons fixé les différents paramètres comme suit :

- Le degré flou $m=2$.
- Le critère d'arrêt $\varepsilon = 0.001$
- Pour le FCM_S1 le coefficient de pondération $\alpha = 3$ et une fenêtre de 3×3 .

Les tests ont été implémentés sous matlab2009 et exécuté sur un PCcondor, Intel(R) celeron(R) CPU N2830 @ 2.16 GHz, sous le système d'exploitation Microsoft Windows 8.

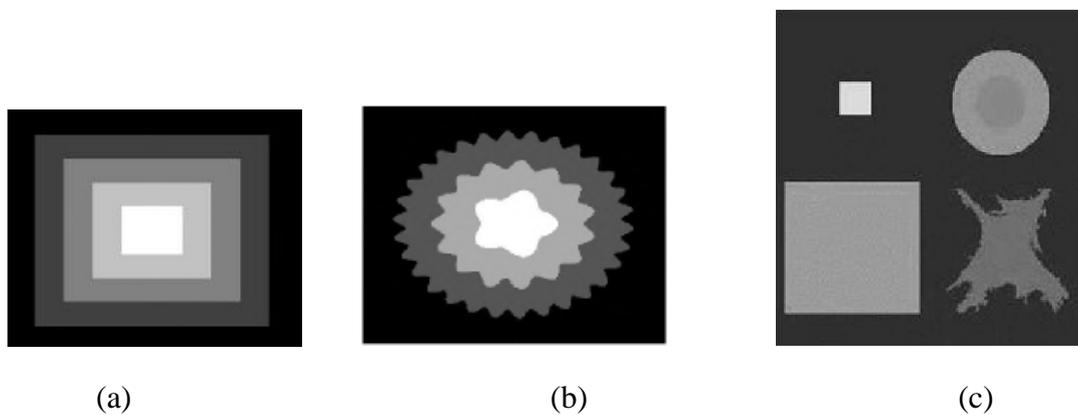


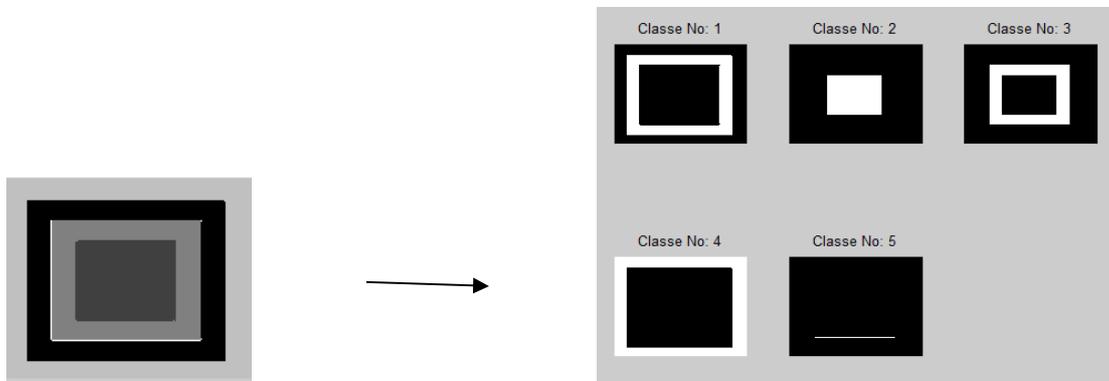
Figure 2.5.1 :Image synthétiques avant la segmentation utilisée pour les tests

- **Image synthétique 1** : composée de 5 régions ($K=5$) de forme carrée bien distinctes.
- **Image synthétique 2** : composé de 4 régions ($K=4$) de forme d'une fleur.
- **Image synthétique 3** : composée de 6 régions ($K=6$) de forme diverses (rectangle, carré, disque, anneau et une forme irrégulière) bien distinctes.

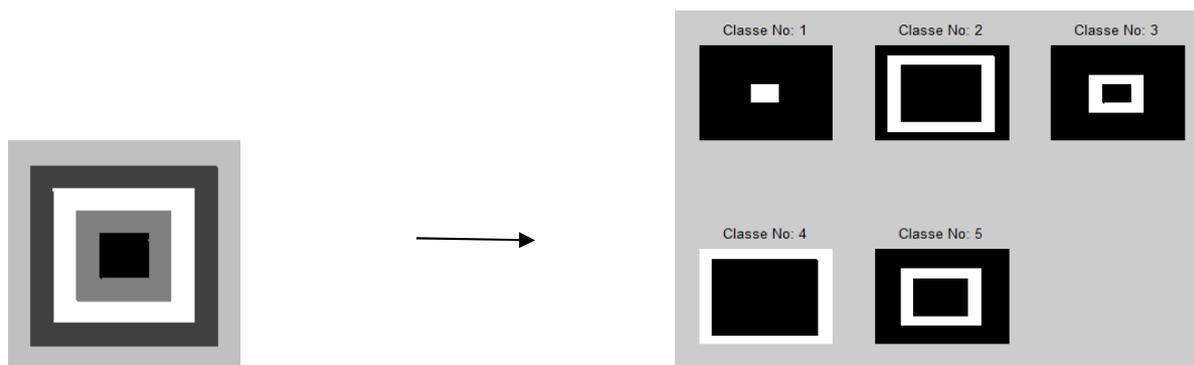
2.5.1 Problème d'initialisation:

Nous avons procédé à une expérience sur l'image de la figure (2.5.1.a) mettant en évidence l'influence de l'initialisation.

- Application de l'algorithme K-means :



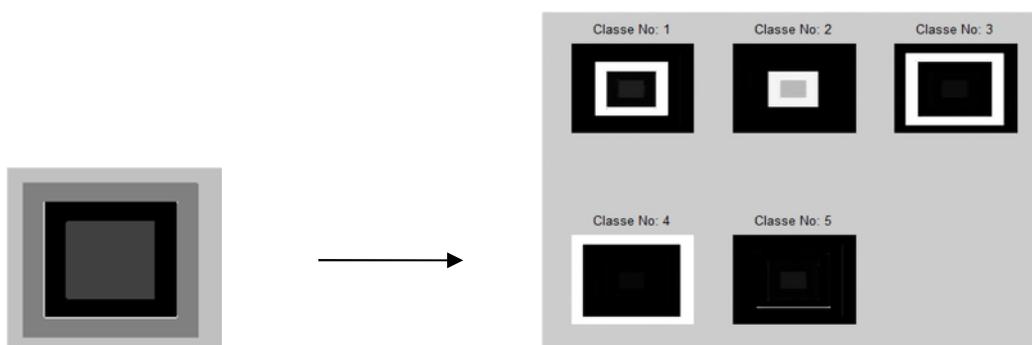
(a) Première initialisation



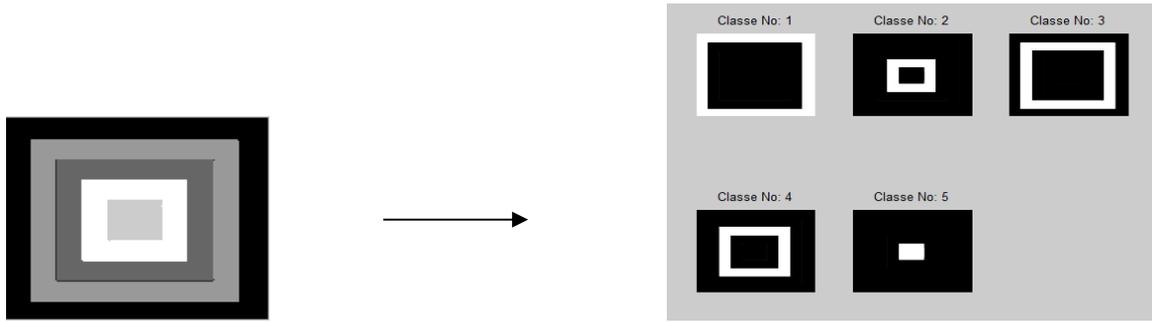
(b) Deuxième initialisation

Figure 2.5.2 : Résultats de segmentation par algorithme K-means sur l'image synthétique 1

- Application de l'algorithme FCM :



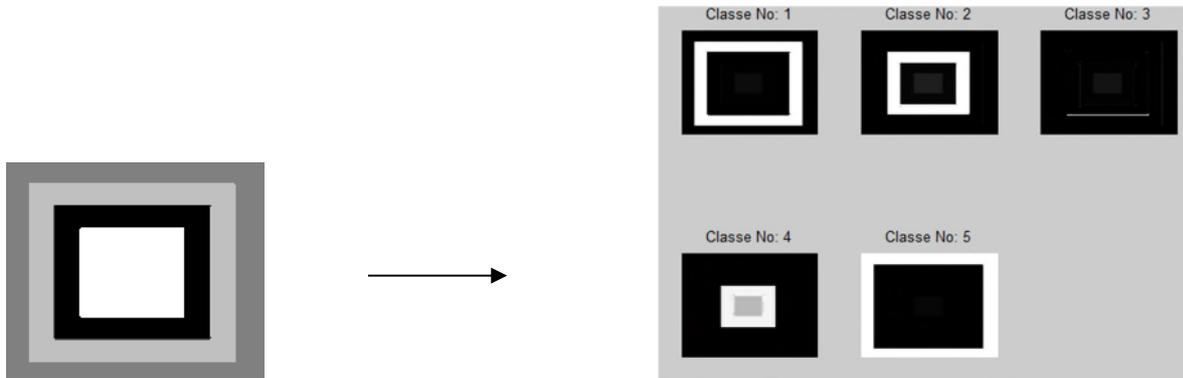
(a) Première initialisation



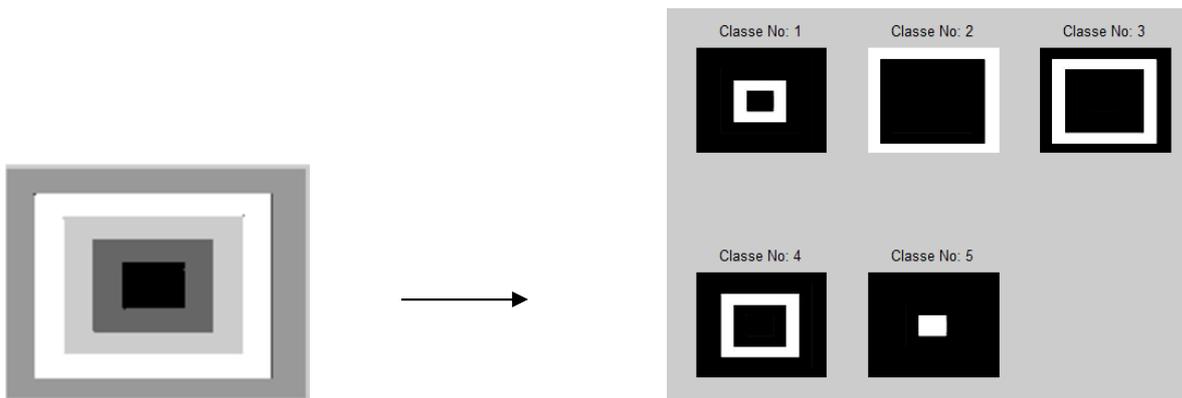
(b) Deuxième initialisation

Figure 2.5.3 : résultats de segmentation par algorithme FCM sur l'image synthétique (1)

- Application de l'algorithme FCM-S :



(a) Première initialisation



(b) Deuxième initialisation

Figure (2.5.4) : résultats de la segmentation par l'algorithme FCM_S, sur l'image synthétique 1.

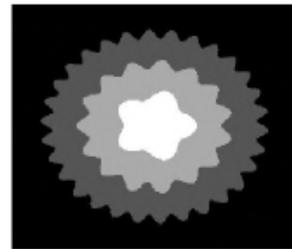
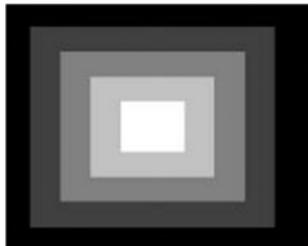
Chapitre 2 : Segmentation par classifieurs non supervisés

Nous avons appliqué les trois algorithmes sur l'image synthétique 1, nous obtenons les résultats présentés en figure (2.5.2) à (2.5.4). Puisque l'initialisation des centres de classes est aléatoire, les résultats peuvent varier considérablement d'une initialisation à une autre comme le montre les résultats de la figure (2.5.2.a et b) et (2.5.3.a et b) et (2.5.4.a et b).

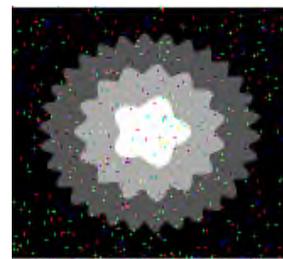
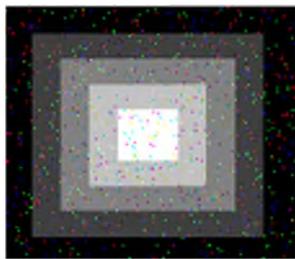
Puisque l'un des inconvénients de ces algorithmes est le choix de la partition initial ainsi que les centres initiaux. Donc pour obtenir une classification des pixels satisfaisante, il faudrait initialiser les centres aux plus proches des centres réels des différentes classes.

2.5.2 Immunité au bruit :

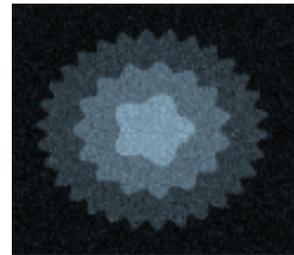
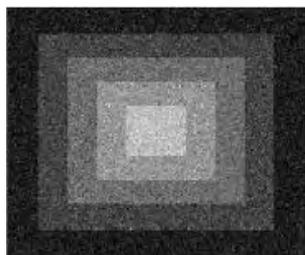
Pour tester l'immunité des algorithmes décrits précédemment vis-à-vis du bruit, nous avons ajouté à l'image synthétique 1, 2 et 3 de la figure (2.5.1) un bruit de type salt&pepper et gaussien.



(a) image originale.



(b) image bruitée avec salt et pepper.



(c) image bruitée avec un bruit gaussien

Figure 2.5.5 : Images synthétique

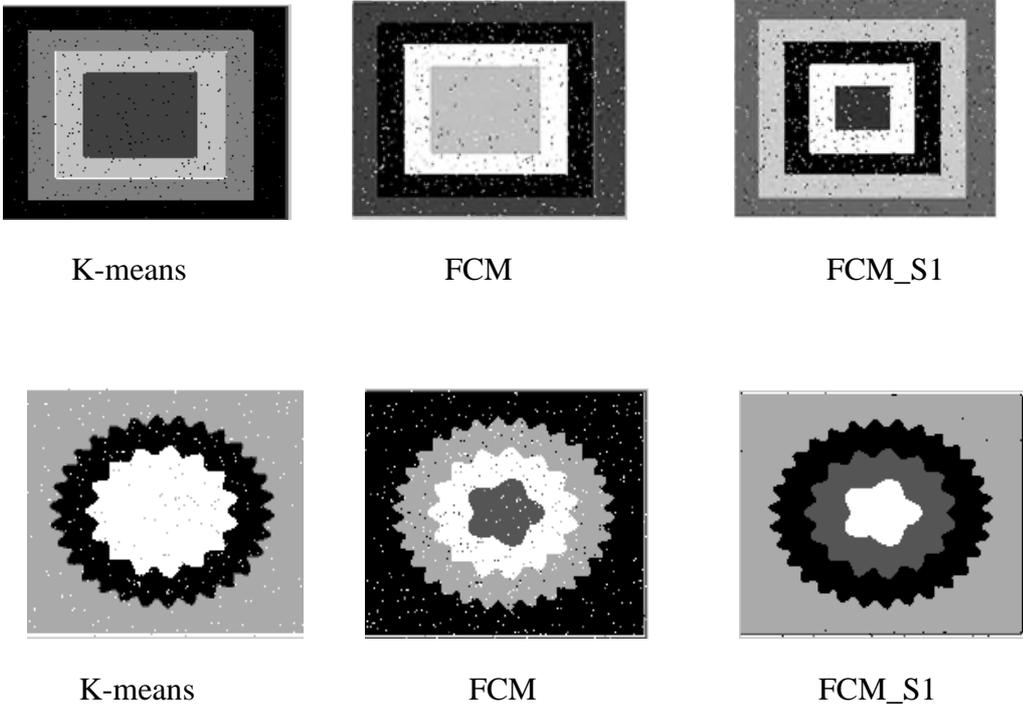


Figure 2.5.6 : Résultats de la segmentation pour un bruit salt&papper

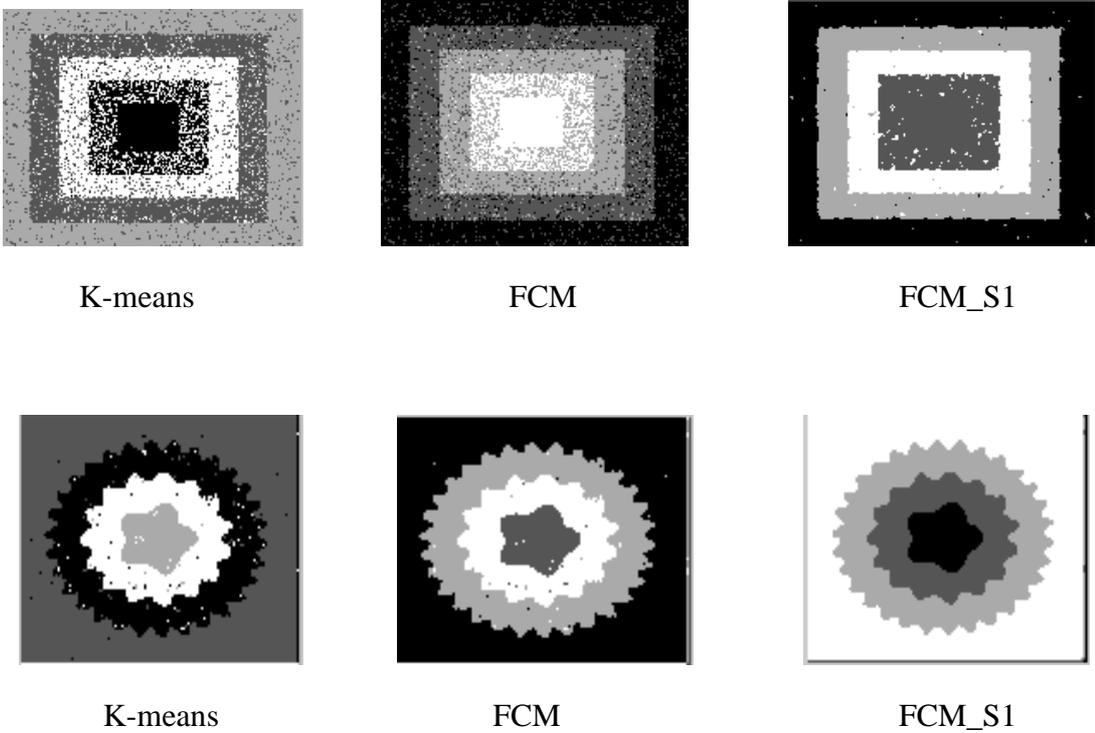
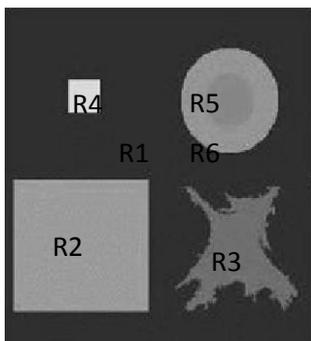


Figure 2.5.7 : résultats de la segmentation pour un bruit gaussien.

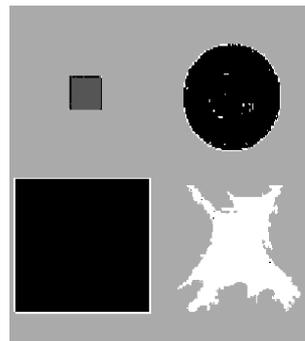
Chapitre 2 : Segmentation par classifieurs non supervisés

Les résultats de la segmentation sont illustrés dans les figures (2.5.6) et (2.5.7). visuellement, nous pouvons voir que FCM_S1 donne des résultats cohérentes et meilleurs contours dans le cas où l'image est affectée par un bruit de type salt&pepper ou gaussien.

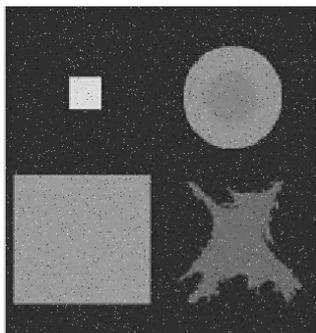
Nous avons procédé aussi à la segmentation de l'image synthétique 3 qui contient des régions de formes complexes.



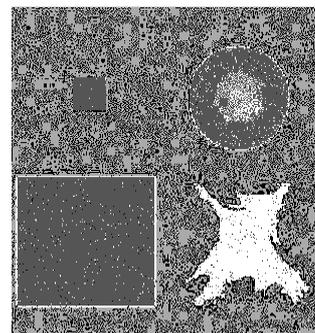
(a) image originale



(b) Image segmentée

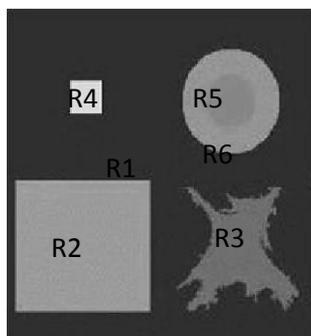


(c) Image bruitée

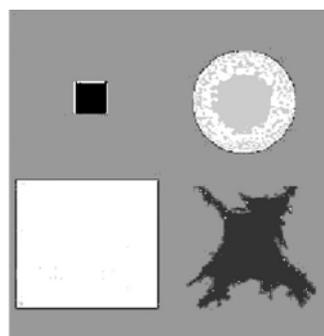


(d) image segmentée

Figure 2.5.8:Résultats de la segmentation par l'algorithme FCM.



(a) image originale



(b) Image segmentée

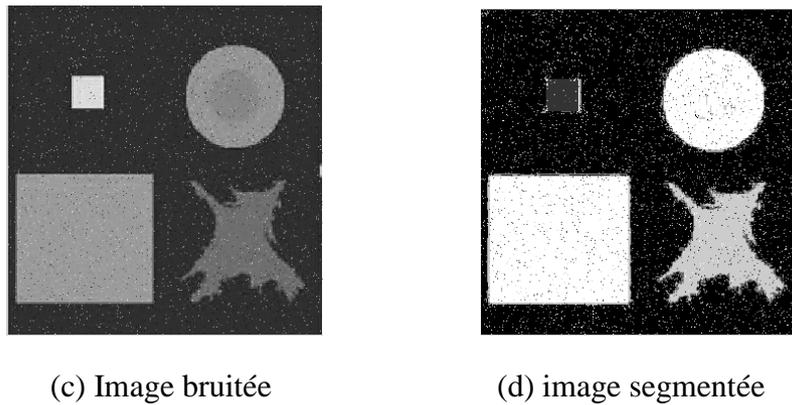


Figure 2.5.9:Résultats de la segmentation par l'algorithme FCM-S1.

Les résultats de la figure (2.5.8) décrivent les régions obtenues : pour l'image de la figure (2.5.8.b), nous remarquons que toutes les classes ne sont pas détectées car la région R5 qui est très proche de la région R6 elle n'est pas construite. Par contre l'image de la figure (2.5.8.d) représentant le résultat de la classification des pixels de l'image originale bruitée, nous constatons que le résultat est médiocre.

Concernant l'image de la figure (2.5.9) toutes les classes ont été bien détecté même la région R5. Par contre l'image de la figure (2.5.9.d) représentant le résultat de la classification des pixels de l'image originale bruitée, nous constatons que le résultat est meilleur comparé à celui obtenu en appliquant l'algorithme FCM, mais ce résultat reste médiocre.

2.6 Application de la méthode coopérative (FCM_S1 et Level set) :

Afin de tester la dernière étape et d'initialiser automatiquement un modèle déformable (Level set) et de raffiner le résultat de segmentation, nous avons utilisé l'image de la figure (2.5.1.c), pour les régions R_3 et R_4 .

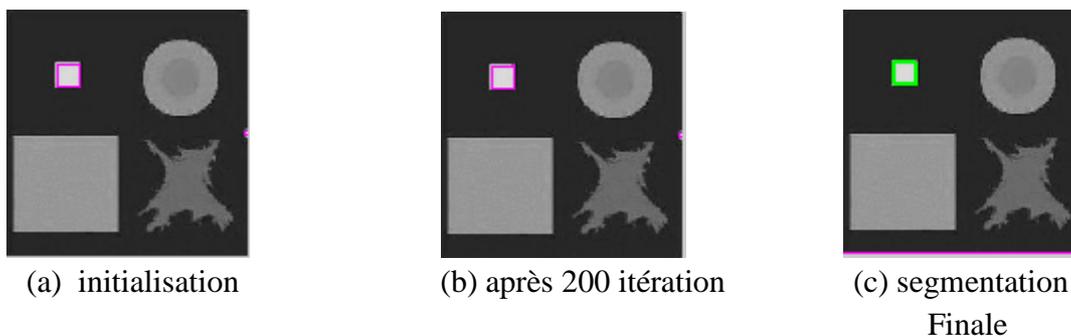


Figure 2.6.1: Segmentation de la région R_4

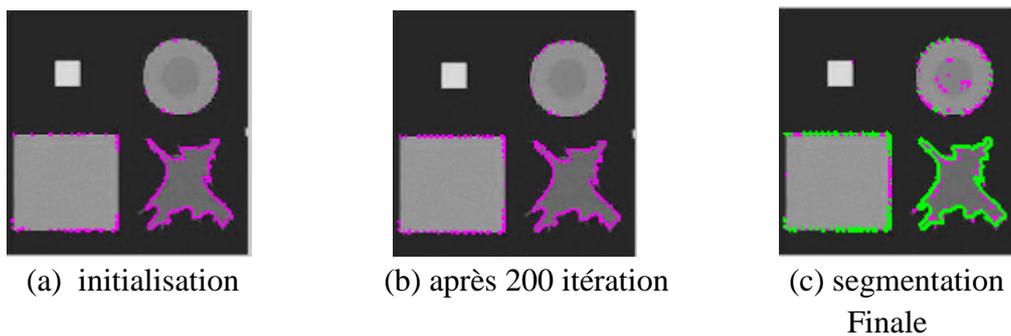


Figure 2.6.2: Segmentation de la région R_3

Comme nous pouvons constater les résultats des figures (2.6.1) et (2.6.2), nous avons obtenus une bonne détection du contour de la région R_4 contrairement à la détection du contour de la région R_3 , qui est mal détecté et cela est dû à la migration de pixels d'une région à l'autre dans le voisinage de leur frontière, ce qui conduit à une déformation des contours des objets détectés.

2.7 Conclusion :

Dans ce chapitre nous avons présenté les méthodes les plus utilisées pour la segmentation des images où nous nous intéressons aux techniques de classification non supervisées (K-means, Fuzzy C-means et FCM-S). Nous avons vu que la segmentation par classification permet de regrouper des objets en classes.

Nous avons testé ces méthodes sur trois images synthétiques contenant différentes formes et nombre de classe. D'après les résultats obtenus, nous avons constaté que ces méthodes souffrent de quelques inconvénients comme le problème d'initialisation des centres et la sensibilité au bruit.

Afin d'initialiser le contour initial des Level set, le résultat de la segmentation issu de la classification des pixels de l'image est exploité.

3.1 Introduction :

L'imagerie par résonance magnétique (IRM), constitue une des avancées les plus significatives en médecine, elle permet au praticien de faire un diagnostic et un suivi de plusieurs pathologies et offrir un outil d'aide au diagnostic. Les techniques de classification dites non supervisées issues de l'intelligence artificielle et de la logique floue, des probabilités et des statistiques, connaissent un très grand succès proportionnel aux flux de données de plus en plus importants. Dans cette optique, nous proposons d'appliquer les méthodes de segmentation d'images par classification afin de segmenter des images cérébrales IRM en vue d'une classification des différentes régions correspondant aux différents tissus et structures.

Dans ce chapitre nous nous intéressons principalement à la segmentation des tissus cérébraux et particulièrement la matière grise, la matière blanche, le liquide céphalo-rachidien et les lésions.

3.2 Segmentation des tissus cérébraux (MB, MG, LCR) :

La segmentation des tissus du cerveau à partir de données médicales est une problématique importante pour de nombreuses applications, notamment liées au diagnostic et au suivi de maladies neurodégénératives. Elle peut aussi être utilisée comme étape préliminaire pour d'autres processus d'analyse d'images complexes.

Dans ce qui suit, nous allons introduire les notions de base concernant l'anatomie cérébrale afin de comprendre les structures cérébrales que nous souhaitons segmenter en différentes classes (Matière Blanche, Matière Grise et Liquide Céphalo-rachidien) en appliquant les approches de classification décrites dans le chapitre précédent [5]

3.2.1 Anatomie cérébrale :

Le système nerveux centrale humain est composé de l'encéphale et la moelle épinière. L'ensemble du système nerveux flotte dans un coussin protecteur de liquide céphalo-rachidien (LCR). L'encéphale est constitué du cerveau, du cervelet et du tronc cérébral. Le cerveau est composé de trois matières principales à savoir, la matière blanche (MB), La matière grise (MG) et le liquide céphalorachidien (LCR) [22].

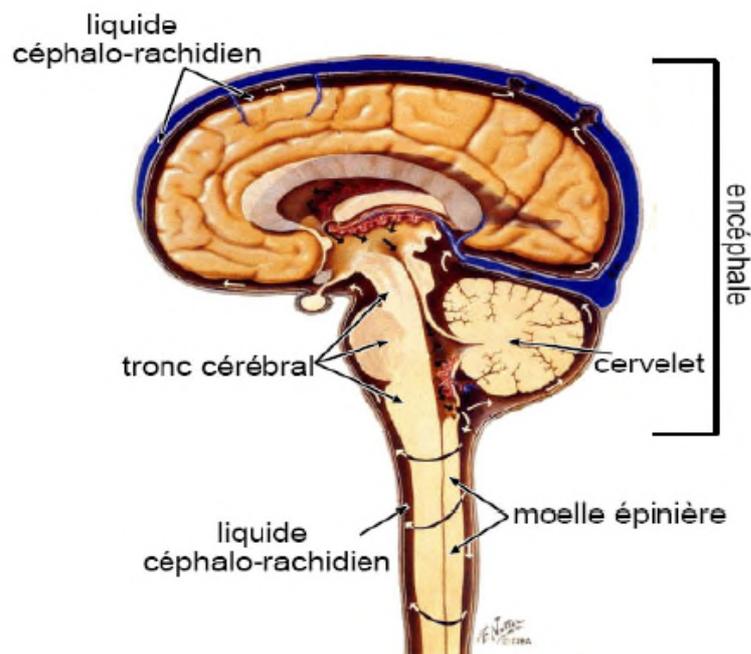


Figure 3.2.1 : Système nerveux central humain.

3.2.1.1 L'encéphale :

L'encéphale est la partie du système nerveux contenue dans la boîte crânienne et reposant sur la base du crâne. Il comprend le cerveau, le cervelet et le tronc cérébral (voir Figure 3.2.2) [23] :

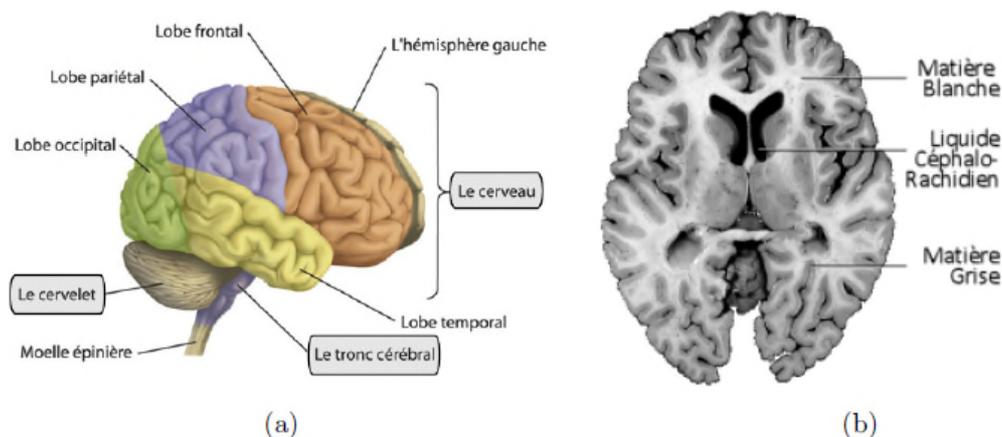


Figure 3.2.2 : l' image (a) illustre l'encéphale, composé du cerveau, du cervelet et du tronc cérébral. L'image (b) montre une coupe histologique d'un cerveau mettant en évidence les trois matières principales de l'encéphale.

3.2.1.2 Les tissus du cerveau :

Lorsque nous observons le cerveau, il est principalement constitué d'une substance blanchâtre, d'où le nom de matière blanche, et a la surface du cerveau se trouve une fine pellicule de substance grisâtre : le cortex cérébral, ou la matière grise. Cette différence de couleur provient du fait que le cortex contient principalement les corps cellulaires des neurones, alors que la substance blanche est constituée d'un agglomérat d'axones qui relient les différentes aires corticales les unes aux autres.

Les axones sont responsables de la transmission du flux nerveux [5].

3.2.1.3 La matière grise (MG) :

La matière grise (ou substance grise) correspond aux corps cellulaires des neurones avec leur dense réseau de dendrites. Elle se répartit en [23] :

- une couche superficielle d'une épaisseur de quelques millimètres recouvrant le cerveau et

Le cervelet : le cortex.

- en noyaux profonds : les noyaux gris centraux

3.2.1.4 La matière blanche (MB) :

La matière blanche (ou substance blanche) correspond à la gaine de myéline qui recouvre les axones des neurones pour en accélérer la conduction. Les axones myélinisés s'assemblent

En faisceaux pour établir des connexions entre groupes de neurones [23].

3.2.1.5 Le liquide céphalo-rachidien (LCR) :

Le liquide céphalo-rachidien (Ou liquide cérébro-spinal, LCS) est le liquide dans lequel baignent le cerveau et le cervelet. D'un volume moyen de 150ml, il est absorbé par le système veineux cérébral et continuellement renouvelé. Ses principaux rôles sont[23] :

- La protection mécanique du système nerveux central contre les chocs par amortissement

Des mouvements,

- La protection contre les infections, car il contient les médiateurs de l'immunité humorale et

Cellulaire.

- Le transport des hormones entre les différentes régions éloignées du cerveau

La figure suivante illustre les trois matières principales du cerveau humain

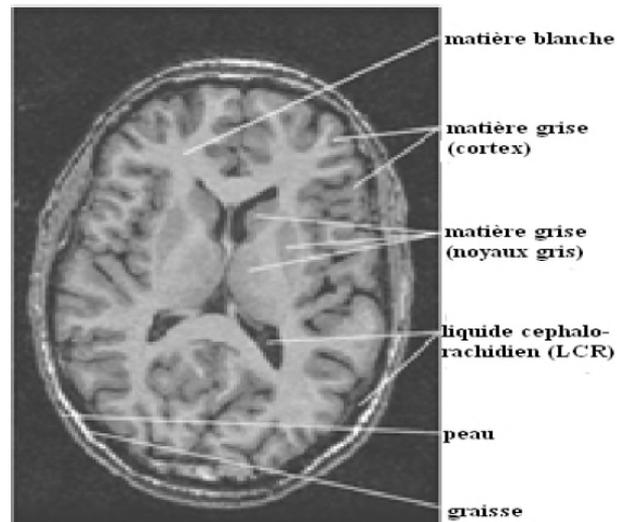


Figure 3.2.3 : Coupe de cerveau mettant en évidence les trois matières principales

3.3. L'imagerie par résonance magnétique (IRM) :

L'imagerie par résonance magnétique (IRM) est une technique de diagnostic médical fournissant des images tridimensionnelles d'une partie du corps, notamment du cerveau et en coupe (bidimensionnelle) de grande précision anatomique. Cette technique récente, non invasive, est basée sur le phénomène physique de la résonance magnétique nucléaire. Elle repose sur la propriété de certains atomes à entrer en résonance dans certaines conditions [5].

3.3.1 L'observation du cerveau :

Le cerveau peut être représenté par des coupes bidimensionnelles selon plusieurs angles vus. Il existe principalement trois axes anatomiques qui permettent de réaliser les coupes dites axiales, sagittales, et frontales [5].

1. La coupe axiales (ou transverse) représente une vue de dessus du cerveau. Elle correspond à un plan perpendiculaire au champ magnétique statique.
2. La coupe sagittale est relative à un plan parallèle au plan inter hémisphérique, il s'agit des vues latérales du cerveau.
3. La coupe frontale (ou coronale) est une vue de face du cerveau, elle est acquise sur le plan perpendiculaire aux coupes axiales et sagittales.

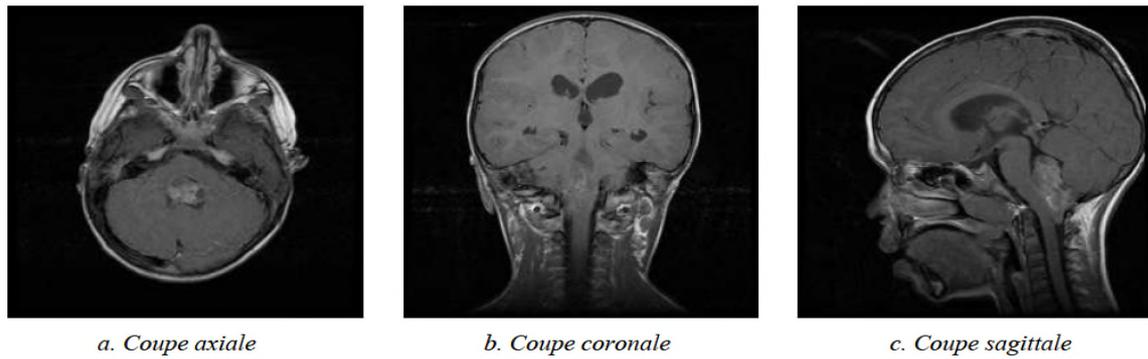


Figure 3.3.1 :Les différentes courbes du cerveau

3.4 Résultats expérimentaux et discussion :

Dans cette section, nous présentons les résultats expérimentaux des méthodes présentées : K-means et FCM, FCM-S, ainsi qu'une comparaison avec ces méthodes en utilisant des images IRM du cerveau simulées issues de la base BrainWeb

3.4.1 Présentation de bases de données utilisée (Brainweb) :

Pour appliquer et comparer les méthodes précédentes, nous nous basons sur la base de données Brainweb de l'institut Neurologique de l'Université McGill de Montréal. Cette base a été choisie dans la mesure où elle est très fréquemment utilisée et permet donc de pouvoir fournir un point de comparaison plus ais [24].

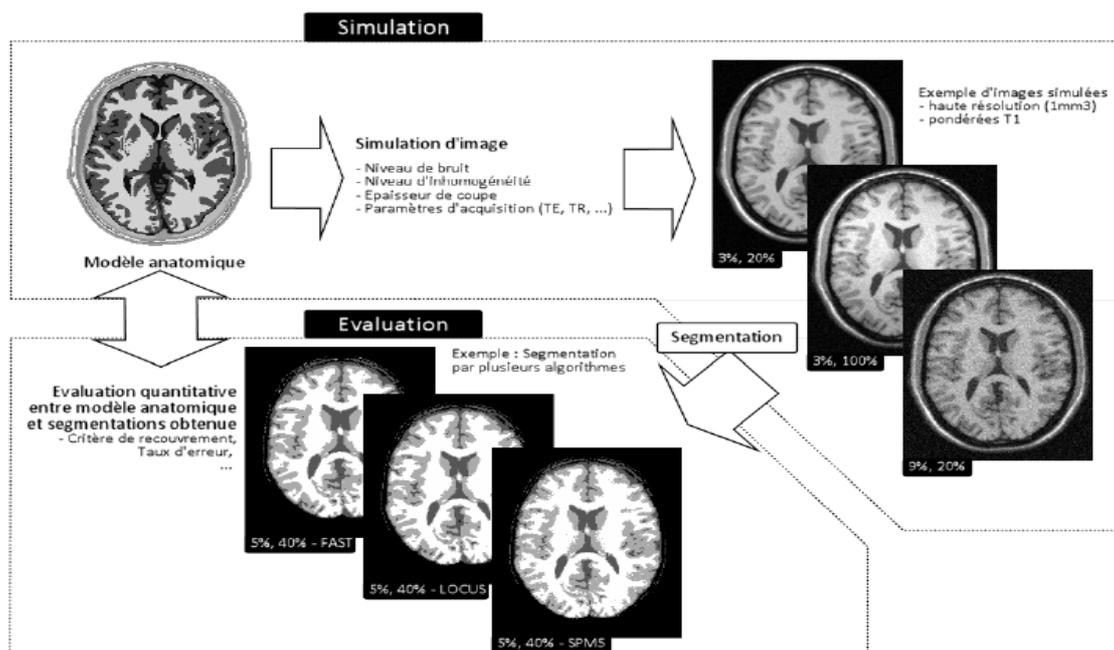


Figure 3.4.1 : Simulateur d'image BrainWeb.

3.4.2 Résultats sur les images IRM simulées :

Les tests ont été réalisés avec matlab R2009 (7.9.0.529), et exécutés sur un PC condor, Intel(R) celeron(R) CPU N2830 @ 2.16 GHz, sous le système d'exploitation Microsoft Windows 8.

- **Algorithme K-Means :**

Les principales étapes de l'algorithme k-means sont :

- ✓ Choix aléatoire de la position initiale des K clusters.
- ✓ Affecter les objets à un cluster suivant un critère de minimisation des distances(Généralement selon une mesure de distance euclidienne).
- ✓ Une fois tous les objets placés, recalculer les K centroïdes.
- ✓ Répéter les étapes 2 et 3 de l'algorithme (2.1) présenté dans le chapitre 2 jusqu'à ce que plus aucune réaffectation ne soit faite [25].

- **Algorithme FCM standard :**

Nous utilisons l'algorithme FCM, décrit dans le chapitre (2) pour segmenter les images cérébrales. Pour cela, nous présentons les différents paramètres liés à l'algorithme à savoir [19] :

- ✓ **Initialisation de l'algorithme** : initialisation aléatoire de la matrice d'appartenance U
- ✓ **Choix du paramètre m (fuzziness)** : il contrôle le degré de flou de la partition floue U. si m est proche de 1, la partition résultante est quasiment non floue, chaque pixel x_j est assigné à une classe i et une seule avec un degré d'appartenance $U_{ij}= 1$. Inversement, alors que la croissance de m dans le FCM tend à augmenter le degré de partage des pixels aux classes (les degrés d'appartenance de x_j à chacune des C classes sont égaux à $1/C$ lorsque m tend vers l'infini).Il n'existe pas de méthodes pour optimiser de manière générale ce paramètre, chaque problème fait le choix qui dépend de la nature des données. Une valeur comprise dans l'intervalle [1.5 ; 3] est généralement une valeur acceptable. Dans notre travail le paramètre m est choisi égal à deux ($m = 2$).
- ✓ **Détermination du nombre de classes C** : Nous nous plaçons ici dans une problématique de segmentation d'images cérébrales IRM, Nous cherchons donc à segmenter les tissus du cerveau (la MB, MG, LCR et l'arrière-plan) C est logiquement égale à quatre ($C = 4$).
- ✓ **Détermination du seuil** :C'est un nombre réel prédéfini par l'utilisateur et sert comme critère d'arrêt de l'algorithme, basé sur la distance séparant la matrice U calculée à l'itération au rang (t + 1) de celle calculée au rang (t). Le critère d'arrêt des

Chapitre 3 : Application a l'imagerie par résonance Magnétique(IRM)

itérations, peut servir à la stabilité des centres des classes sur deux itérations successives. Dans notre travail le seuil ε est choisi égale à 0 :001 ($\varepsilon = 0 ; 001$).

A la fin de l'exécution de l'algorithme, nous obtenons la matrice finale d'appartenance U de dimension : $(4 \times N)$, où 4 représente le nombre de classes (C) et N lenombre de pixel total sur l'image en entrée. Les images utilisées sont de dimension :

- **Algorithme FCM_S1 :**

L'algorithme FCM_S1 présenté dans le chapitre (2) pour la segmentation d'images avec la prise en compte des contraintes spatiales et le voisinage des pixels, nécessite les mêmes paramètres que ceux de l'algorithme standard FCM à savoir : l'indice flou (m), un seuil (ε) et le nombre de classes (C). En plus de ca, il existe deux autres paramètres qui sont liés directement avec la prise en compte des contraintes spatiales, il s'agit du voisinage (une fenêtre carrée centrée sur le pixel considéré) noté par NR et le paramètre de contrôle de la pénalisation α .

Avec $\alpha = 3$ et une fenêtre de 3×3 (NR = 9 nombre de voisins) et il a montré que l'algorithme donne des résultats remarquables pour $3 \leq \alpha \leq 8$. Dans notre travail et après plusieurs essais de paramètres, nous avons utilisé l'algorithme FCM_S1 avec les paramètres d'entrés suivants [19] :

- ✓ **L'indice flou (fuzziness) m** : comme pour l'algorithme FCM, la valeur de m est égale à deux ($m = 2$)
- ✓ **Le seuil ε** : c'est un nombre réel prédéfini, comme pour l'algorithme FCM la valeur de $\varepsilon = 0 : 001$.
- ✓ **Le nombre de classes C** : il s'agit des même images utilisées, donc $C = 4$.
- ✓ **Paramètre α** : $\alpha = 3$.

3.4.2.1 Etude d'image sans bruit :

- **Extraction des classes obtenues :**

Après avoir obtenu une classification de l'image IRM sans bruit avec les différents algorithmes, nous procédons à une extraction des classes correspondant aux tissus (MB, MG, LCR) afin de les comparer avec une vérité terrain (segmentation de référence des différents tissus) :

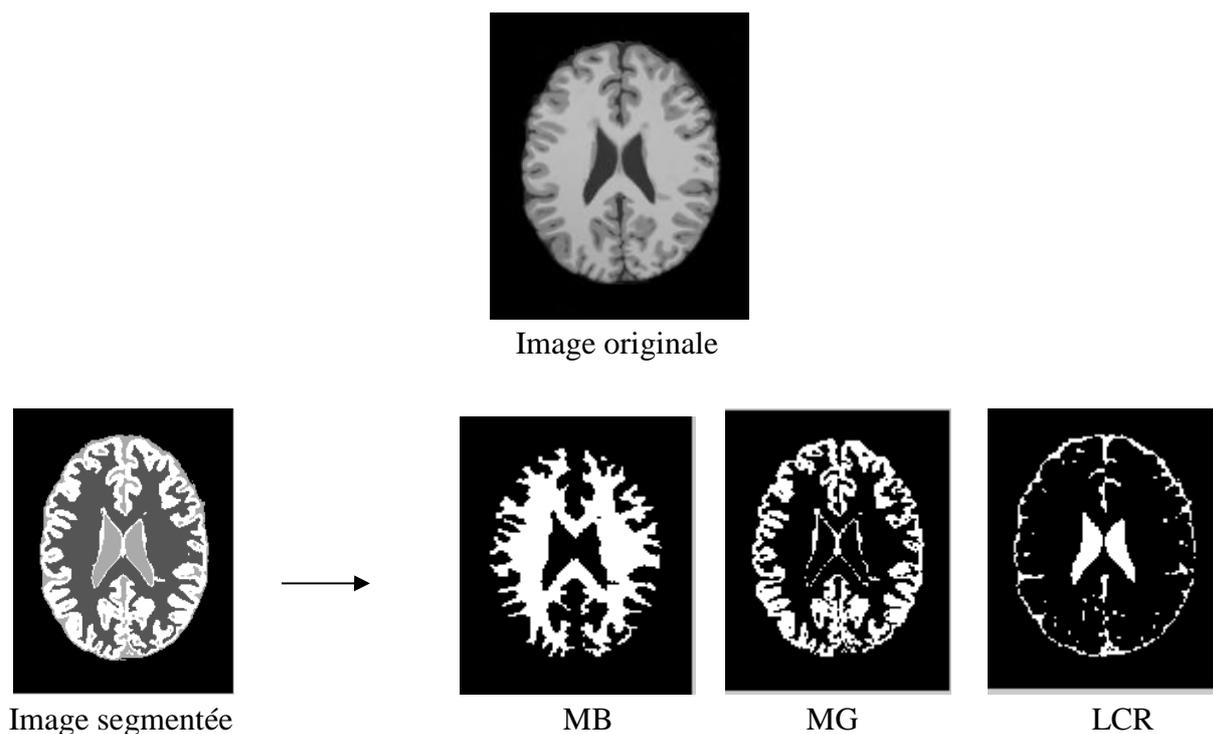


Figure 3.4.2 : Résultats obtenu sur une coupe axiale pondérée en T_1 par K-means

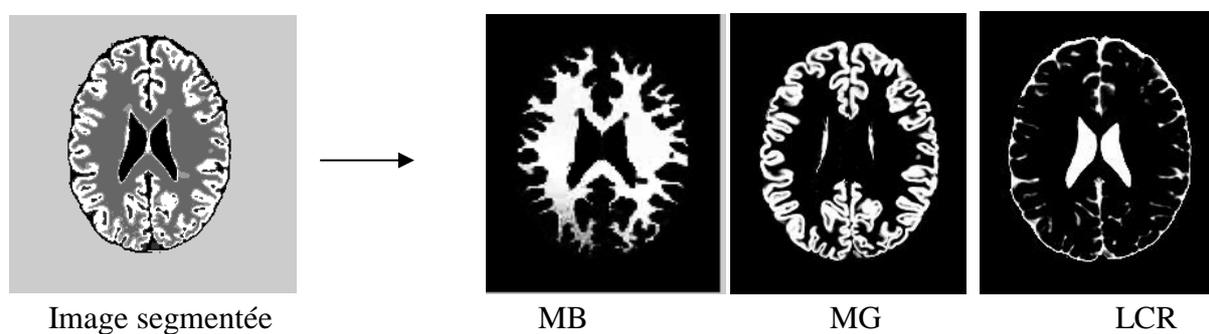


Figure 3.4.3 : Résultats obtenu sur une coupe axiale pondérée en T_1 par FCM

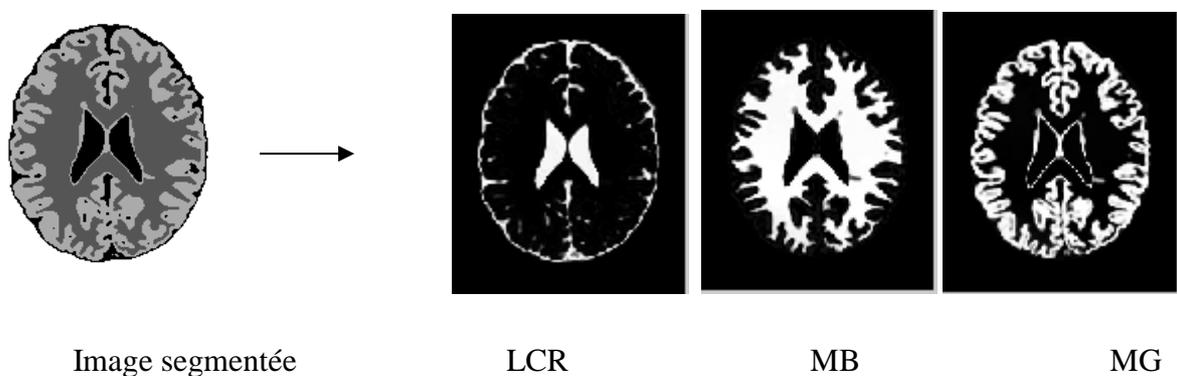
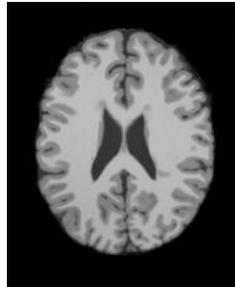


Figure 3.4.4 : Résultats obtenu sur une coupe axiale pondérée en T_1 par FCM_S1

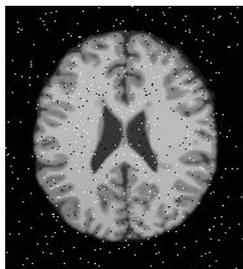
3.4.3.2 Etude de l'influence du bruit :

Nous avons ajouté un bruit salt & pepper puis un bruit gaussien sur l'image originale.



(a) image originale

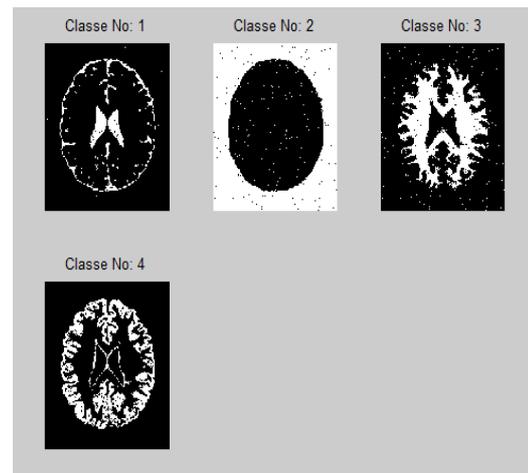
- Avec un bruit salt & pepper



(b) image bruitée



(c) image segmentée



(c) les classes obtenues : MB, MG, LCR

Figure 3.4.5 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit salt & pepper par K-Means.

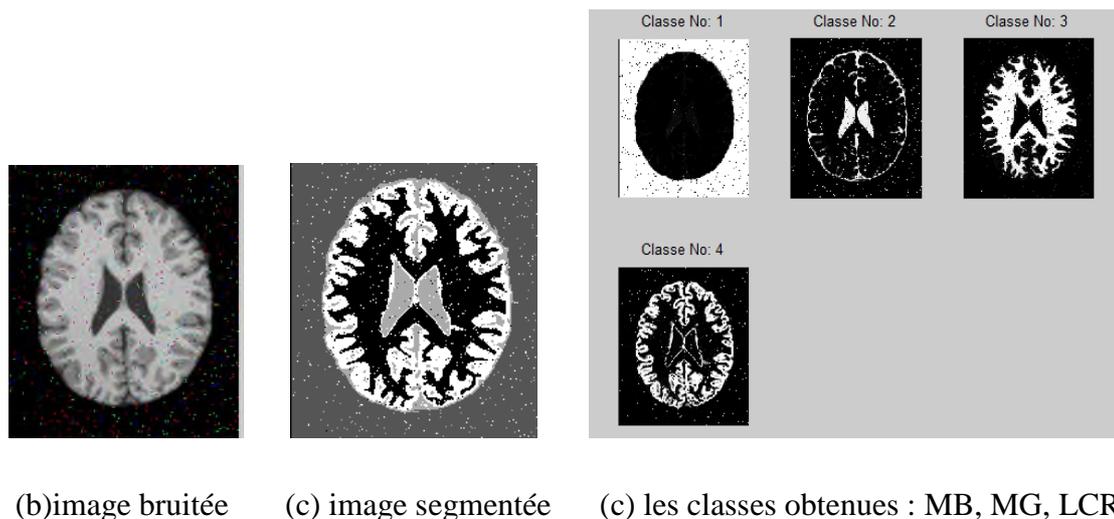


Figure 3.4.6 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit salt&pepper par FCM.

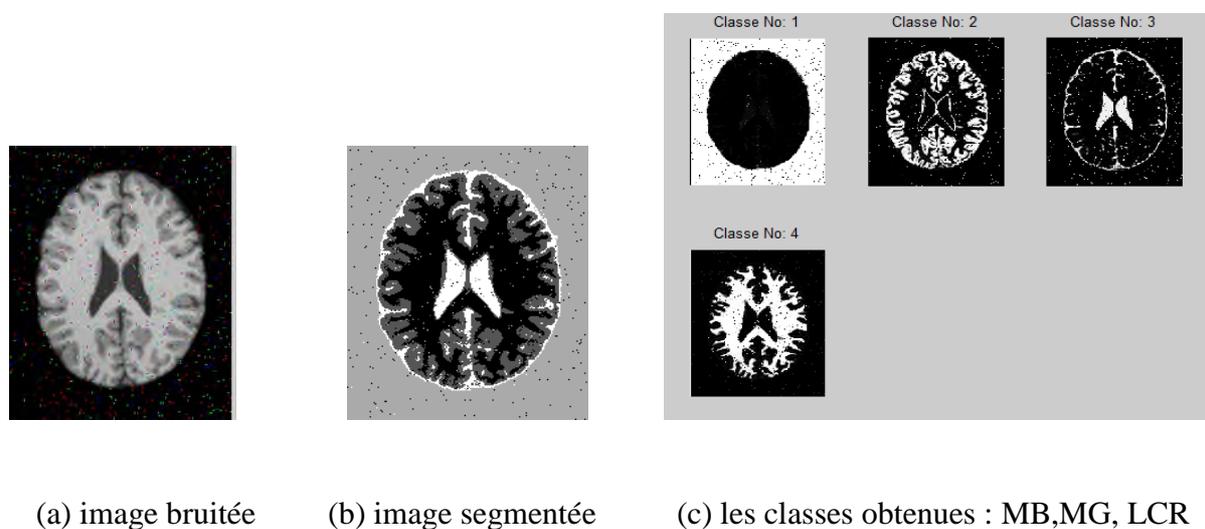


Figure 3.4.7 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit salt&pepper par FCM_S1.

- Avec un bruit gaussien

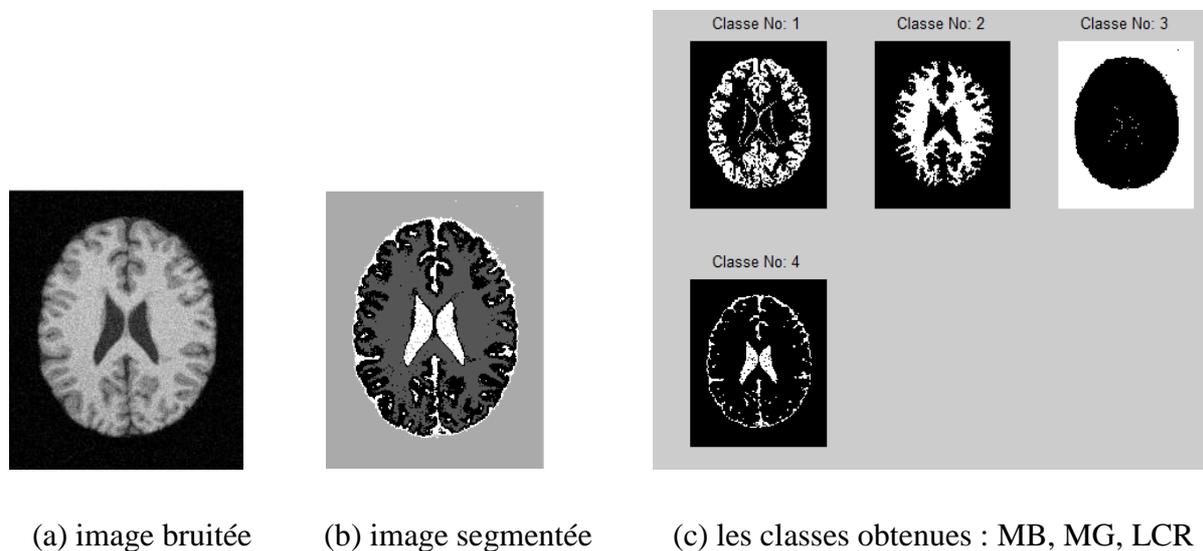


Figure 3.4.8 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit gaussien par K-means.

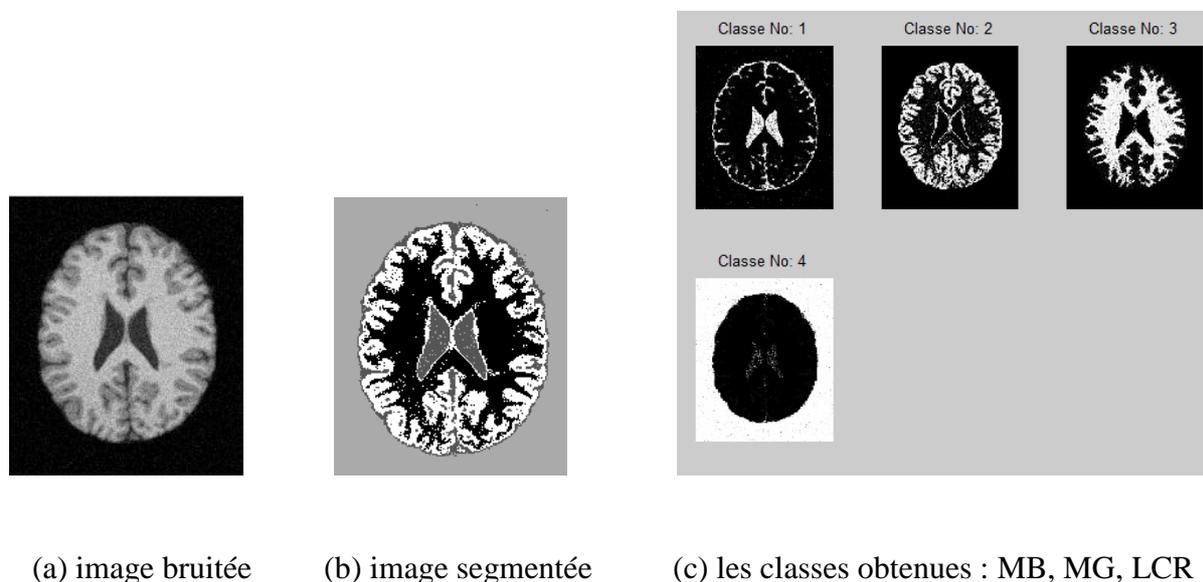
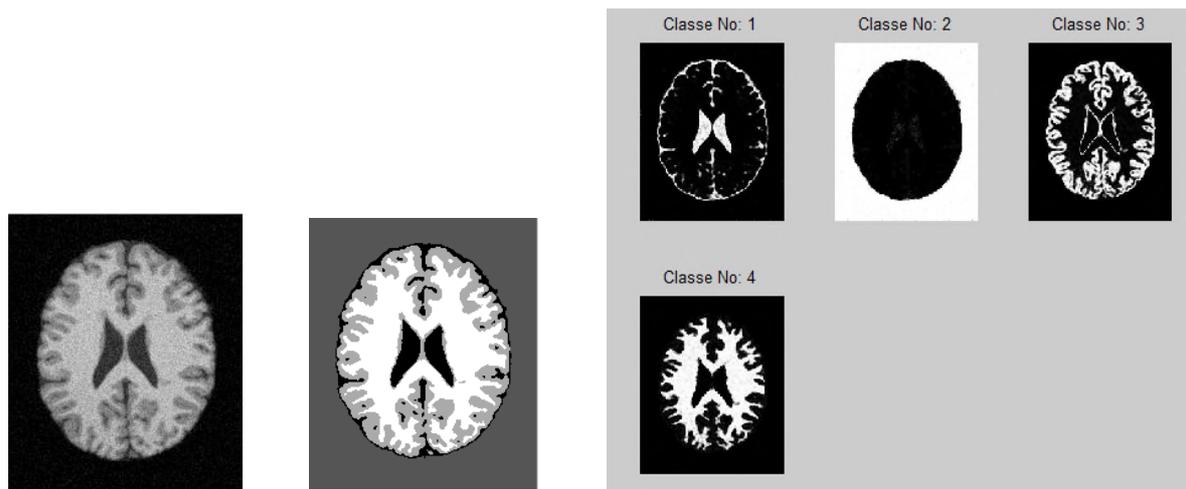


Figure 3.4.9 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit gaussien par FCM.



(a) image bruitée (b) image segmentée (c) les classes obtenues : MB, MG, LCR

Figure 3.4.10 : Résultats obtenus sur une coupe axiale pondérée en T_1 d'une image avec un bruit gaussien par FCM_S1.

Les résultats de la segmentation sont illustrés dans les figures (3.4.5)a (3.4.10).visuellement , nous pouvons voir que FCM_S1 donne des résultats cohérents et meilleurs contours dans le cas où l'image est affectée par un bruit de type gaussien .

- Pour ce second test, nous utilisons une image avec présence d'une lésion au cerveau.

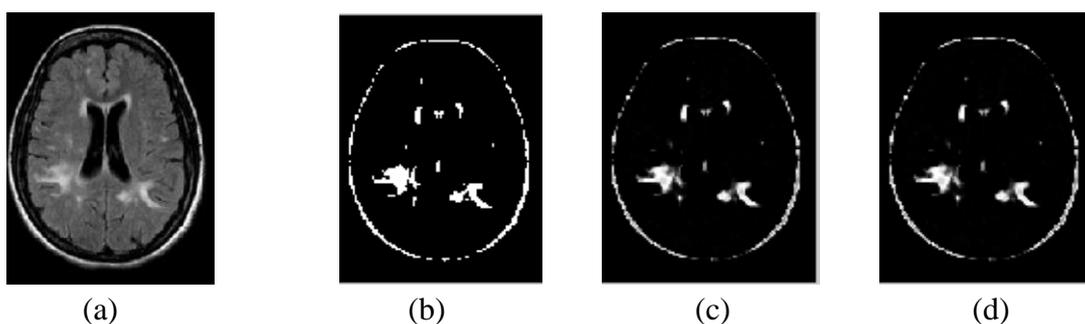


Figure 3.4.11 : segmentation de la région d'intérêt des lésions de la SEP (coupe axial) par k-means et FCM et FCM_S1, avec nombre de classe = 5, (a) image initial ; (b) résultat du K-means ;(c) résultat du FCM ; (d) résultat du FCM_S1.

3.4.3.3 Critère d'évaluation :

Dans le but d'évaluer les résultats de notre méthode de segmentation, nous avons calculé le taux de reconnaissance (équation 3.4) tel que [19] :

$$\text{Taux} = \frac{\text{nombre de pixels correctement classés}}{\text{nombre total de pixels}} \times 100 \quad (3.4)$$

Ce taux correspond à la proportion de vrais positifs par rapport à l'ensemble des pixels qui devraient être segmentés. Cet indicateur permet d'évaluer dans quelle mesure l'intégralité d'une structure recherchée est segmentée.

Ces résultats sont présentés dans le tableau (3.1), nous avons calculé les taux de reconnaissance sur la totalité des images afin d'avoir une moyenne de ces valeurs. Les résultats obtenus sont comparés avec ceux des deux approches (K-means et FCM et FCM_S1) dans la partie interprétation des résultats du même chapitre.

	Taux								
	Sans bruit			Avec bruit Salt & Pepper			Avec bruit gaussien		
Les tissus cérébraux	MB	MG	LCR	MB	MG	LCR	MB	MG	LCR
K-means	98.7906	97.7595	99.0249	97.1255	96.3948	98.5080	97.1357	95.5801	98.1007
FCM	98.8237	97.7595	99.0045	97.1077	96.2879	98.5870	97.0364	95.3841	98.1312
FCM_S1	98.6582	97.4336	98.7754	98.1490	96.6953	98.6150	98.1592	96.5782	98.5946

Tableau 3.1 : Résultats obtenus pour les trois algorithmes K-Means, FCM, et FCM_S1 sans bruit et avec bruit.

3.4.4 Interprétations des résultats :

Nous avons mesuré et quantifié les performances de segmentation de l'ensemble des images en comparant les résultats avec les images vérité terrain. Pour cela nous avons utilisé un critère : taux de reconnaissance. Des résultats visuels de la segmentation sont présentés.

Le tableau (3.1) montre les taux de reconnaissance obtenus pour les trois algorithmes K-means, FCM et FCM_S1 sans bruit et avec bruit. Et d'après le tableau, on remarque que le taux de reconnaissance de l'algorithme FCM_S1 est plus élevé par rapport aux deux autres

Chapitre 3 : Application a l'imagerie par résonance Magnétique(IRM)

algorithmes (K-means et FCM) pour les images sans bruits. K-means donne le meilleur taux de classification de 98.7754% (LCR) pour les images sans bruit, et FCM-S donne le meilleur de classification pour les images bruitées, 98.6150 % (LCR) avec bruit salt et pepper et 98.5946% (LCR) avec bruit gaussien, cet algorithme est plus robuste pour l'image affectée par un bruit de type gaussien.

A la lumière des résultats présentés et des résultats visuels, nous constatons une amélioration remarquable de la segmentation entre l'algorithme K-means, FCM et FCM_S1, cela est due à l'intégration de l'information spatiale et la prise en compte des contraintes spatiales dans FCM_S1. Mais l'algorithme de K-means et FCM peuvent être performants à certain images et médiocres pour d'autres images.

Le tableau 3.1 montre que FCM_S1 donne des meilleurs résultats et surpasse les autres algorithmes, en particulier, en présence du bruit. Les comparaisons qualitatives des algorithmes confirment l'évolution visuelle. Ces résultats sont également illustrés sur la figure (3.4.12) et (3.4.13) et (3.4.14).

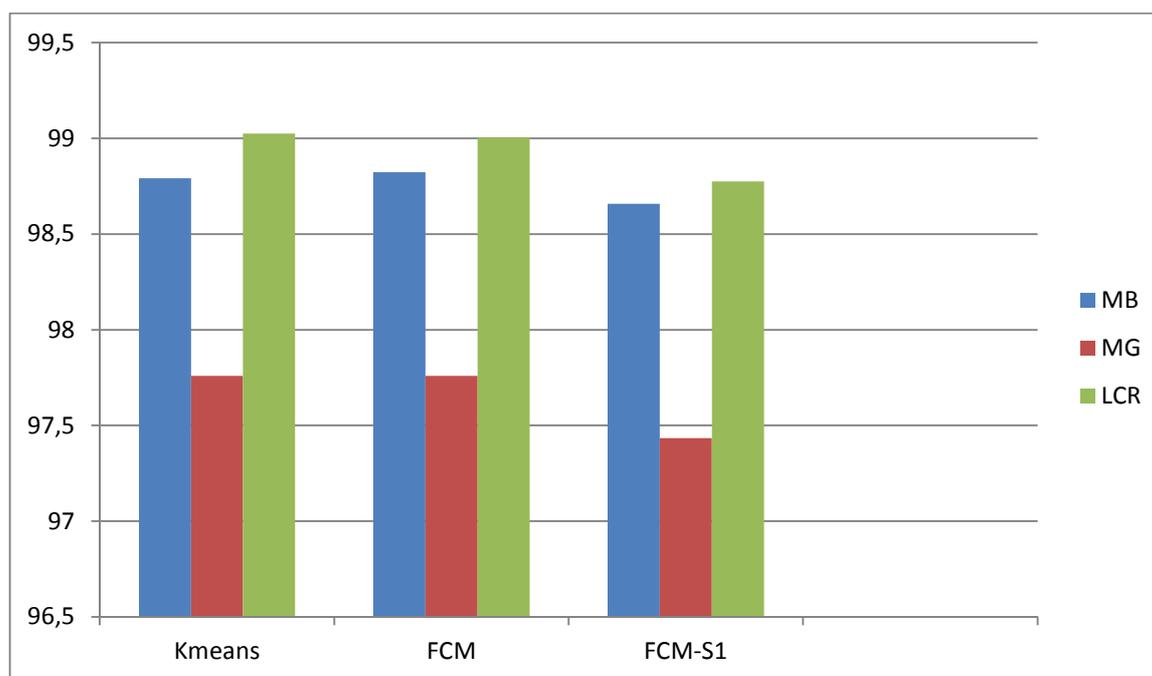


Figure 3.4.12 : Evaluation des performances des différents algorithmes pour image IRM Simulées sans bruit.

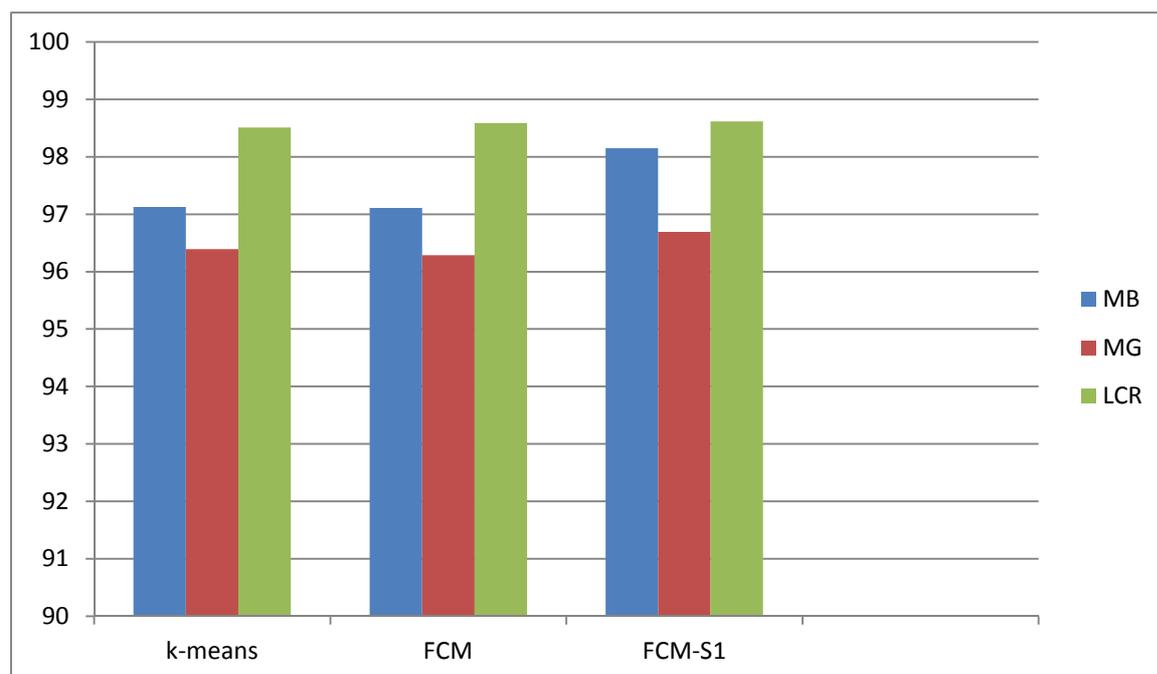


Figure 3.4.13 : Evaluation des performances des différents algorithmes pour image IRM Simulées avec bruit salt&papper.

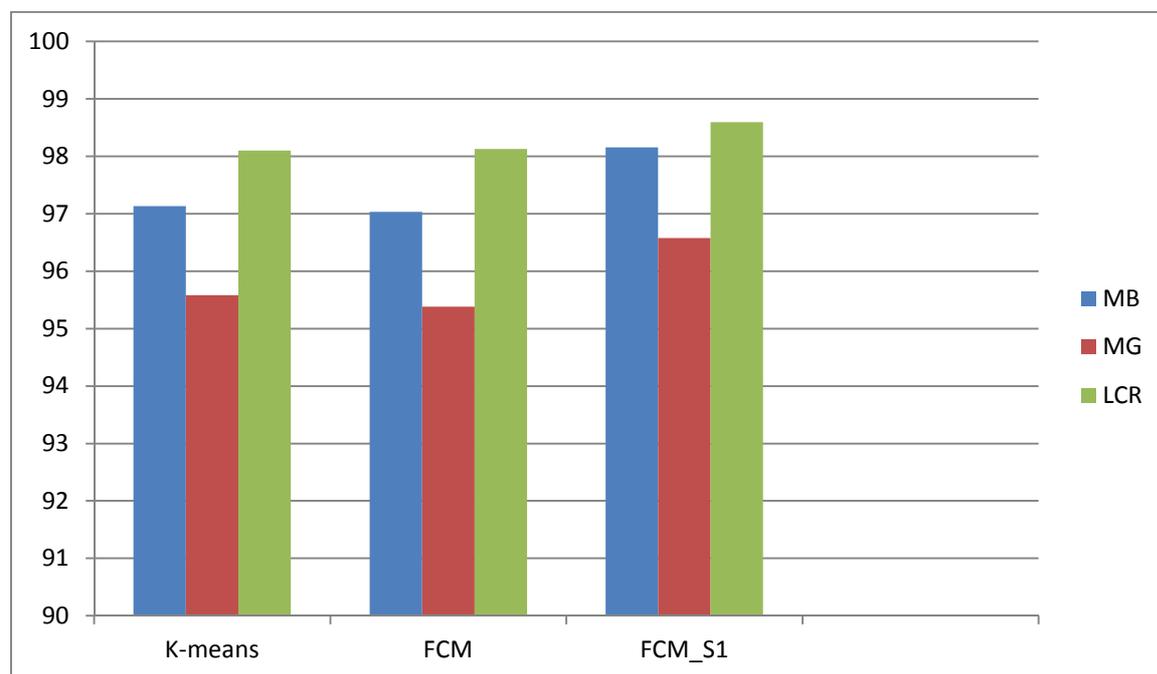


Figure 3.4.14 : Evaluation des performances des différents algorithmes pour image IRM Simulées avec bruit gaussien.

Les observations qui ressortent de l'analyse des graphes des indices non supervisés nous informes que l'algorithme FCM est le meilleur d'un point de vue séparation et compacité par rapport à K-means et FCM_S1 dans la figure (3.4.12).

Par contre pour les autres graphes (3.4.13) et (3.4.14) on remarque que l'algorithme FCM_S1 est le meilleur par rapport au deux autres algorithmes.

3.5 Segmentation des images IRM avec la coopération du FCM_S et la méthode déformable (Level set) :

L'approche que nous avons citée dans le chapitre précédent est une approche coopérative, qui permet d'exploiter les avantages de différentes méthodes.

Cette approche combine laméthode d'ensemble de niveau (Level set) avec la classification floue (FCM_S),dans le but de détecter les différents tissus cérébraux.

Afin d'illustre la nécessité d'une initialisation automatique du contour, nous prenons un cas difficile qui nécessite la séparation de la matière blanche (MB) et de la matière grise (MG) et le liquide céphalo-rachidienne (LCR), à partir d'une coupe IRM cérébrale .Il est évident que MB et MG entrelacent les unes avec les autres et sont dispersées sur toute la coupe, ce qui rend presque impossible l'initialisation manuelle.

Les figures (3.5.1) et (3.5.2) et (3.5.3) présentent les résultats après plusieurs itérations. Une bonne segmentation est obtenue grâce à cette étape de clustering réalisée par FCM_S1 en initialisant automatiquement le modèle déformable.

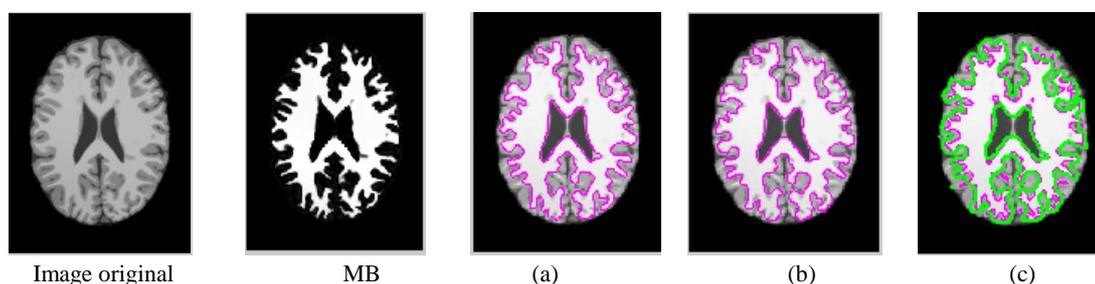


Figure 3.5.1 : segmentation du tissu MB avec la méthode coopérative : (a) contour initial, (b) après 1000 itération, (c) apès 2000 itération (Vert).

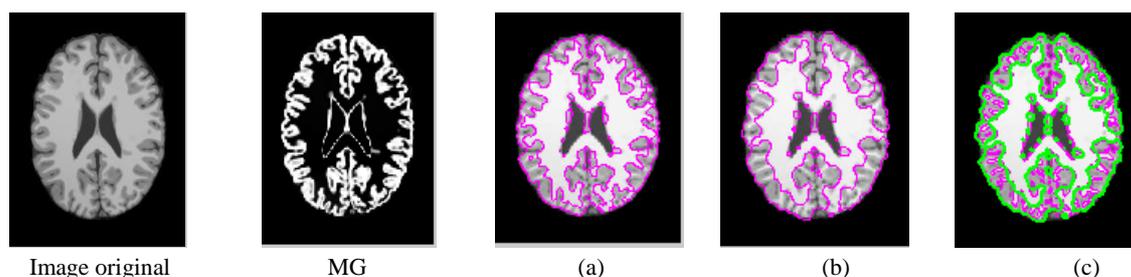


Figure 3.5.2 : Segmentation du tissu MG avec la méthode coopérative : (a) contour initial, (b) après 1000 itération, (c) apes 2000itération (Vert).

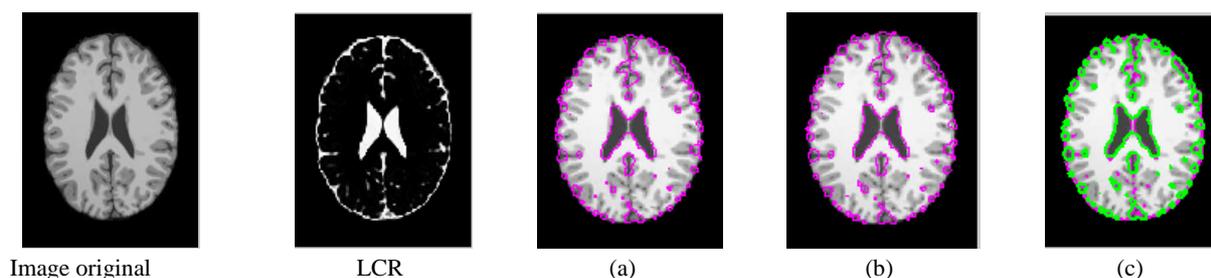


Figure 3.5.3 : Segmentation du tissu LCR avec la méthode coopérative : (a) contour initial, (b) après 1000 itération, (c) apes 2000 itération (Vert).

D'après les résultats de cette coopération, on peut dire que cette coopération donne une bonne segmentation des images IRM cérébrales. Mais d'après la figure (3.5.3) on remarque que le contour initial de LCR ni pas bien initialisés.

Cette démarche permet de résoudre le problème de l'initialisation, qui dépend de plusieurs paramètres comme la largeur, la longueur du contour et le nombre important d'itération.

3.6 Conclusion :

Actuellement, la tendance en matière de segmentation d'image est de combiner deux ou plusieurs méthodes afin de tirer les avantages de chacune d'elles pour traiter au mieux la variabilité des images et la richesse d'information qu'elles contiennent.

Pour cela, nous avons proposé dans ce dernier chapitre de combiné entre deux méthodes de segmentation (Level set et FCM_S), nous avons utilisé la classification floue issue de FCM-S1 pour initialiser la fonction initiale du modèle déformable (level set) ce qui peut approcher mieux les contours de l'image à segmenter.

Chapitre 3 : Application a l'imagerie par résonance Magnétique(IRM)

La méthode présentée dans ce chapitre a été testés sur des images médicales:Les images IRM du cerveau, les résultats expérimentaux ont montré que la méthode décrite donne les meilleurs résultats de segmentation en utilisant le résultat de la classification floue comme étape d'initialisation automatique du modèle déformable que pour l'initialisation manuelle de ce dernier.

Conclusion et perspectives

Le travail présenté dans ce mémoire concerne le domaine de traitement d'image et plus précisément celui de la segmentation d'image médicale qui reste un domaine de recherche très vaste et une étape cruciale dans tout processus d'analyse d'images. Elle consiste à préparer l'image afin de la rendre plus exploitable par un processus automatique tel que l'interprétation ou un diagnostic.

Une étude bibliographique a été faite sur les méthodes de segmentation d'images, ça nous a permis d'appréhender la diversité des méthodes de segmentation des tissus cérébraux. Plusieurs approches de segmentation sont proposées dans la littérature, la segmentation par contour et la segmentation par région d'où on peut en ressortir la segmentation par classification. Comme nous avons pu le constater à travers cette étude, l'application des différentes méthodes de segmentation par classification de pixels ont abouti à des résultats de segmentation différents. À ce stade trois algorithmes ont été testés pour répondre à des besoins spécifiques qui aboutissent à des classifications plus distinctes. Néanmoins comme nous avons pu le voir, la plupart de ces techniques nécessitent le choix des valeurs de certains paramètres dont les résultats peuvent dépendre très fortement et le fait qu'aucune connaissance a priori des données n'est disponible, impose l'utilisation de ces techniques. À cet effet, nous nous sommes intéressés aux méthodes dites non supervisées

Dans un premier lieu, nous avons testé l'algorithme K-Means ainsi que les deux algorithmes FCM et FCM-S1 sur des images synthétiques, et les résultats ont été considérablement différents. L'algorithme K-Means fournit des résultats moins performants par rapport aux autres méthodes. Ces dernières, utilisent la logique floue et introduisent la notion d'appartenance, arrivent à surpasser le problème lié à l'appartenance des pixels à une classe (un pixel peut appartenir à plusieurs classes avec différents degrés). L'algorithme des FCM reste sensible au bruit et les propriétés spatiales des pixels ne sont pas prises en compte, pour cela la famille d'algorithme FCM_S dont nous avons choisi l'algorithme des FCM_S1 qui intègre l'information spatiale de l'image était très bénéfique, ce qui conduit à une classification plus adéquate et plus adaptée à l'identification des classes de l'image.

Par la suite, nous avons tenté de tester la méthode coopérative (Level Set et FCM-S1) sur les mêmes images synthétiques dont le but est de détecter les contours des différentes classes. Pour certaines images, les résultats étaient satisfaisants, mais pour d'autres nous avons remarqué que le contour des classes n'était pas bien défini.

En dernier stade, arrivé à notre objectif, nous avons appliqué la méthode coopérative sur des images IRM afin de bien cerner les contours des différents tissus cérébraux (MB, MG et LCR)

Enfin, comme perspectives, la prise en compte d'autres problèmes et contraintes comme la métrique utilisée (distance euclidienne), l'initialisation des centres de classes (utilisation des métaheuristiques pour palier à l'initialisation aléatoire) ou encore la topologie de l'image est des paramètres importants qui peuvent améliorer la qualité de la segmentation. En plus de la stratégie de plusieurs algorithmes de segmentation travaillant en coopération permet de pallier aux problèmes rencontrés par l'utilisation d'un seul algorithme et de rendre la segmentation des images.

Bibliographie

- [1] B. Mohammed, "Construction d'une technique d'aide au diagnostic en imagerie médicale application à la compression d'images", Thèse de magister, 2012
- [2] S. Ameer et Z. Ameer, "Revue des approches de segmentation d'images textures: exemple des images météorologiques", 3rd International Conférence : Science of Electronic, Technologies of Information and Telecommunication, Tunisia, 2005.
- [3] J.-P.COCQUEREZ et S.PHILIPP, "Analyse d'images : filtrage et segmentation", Paris, 2003.
- [4] J. J. ROUSSELLE, "Les contours actifs une méthode de segmentation: Application à l'imagerie médicale", Thèse doctorat, juillet 2003
- [6] J.Jacques Rosselle, "Les contour actifs une, méthode de segmentation, application a L'imagerie médicale", These de doctorat Université tours, Le 9 /06/2003
- [5] A. Mekhmoukh, "Segmentation d'images IRM par améliorations de l'algorithme FCM", thèse doctorat, Université de A.mira-Béjaia le 30/01/2016.
- [7] A.N.Benaichouche, "Conception de métaheuristiques d'optimisation pour la segmentation d'images. Application aux images IRM du cerveau et aux images de Tomographie par Émission de positons ", thèse de doctorat université paris 12, 2012.
- [8] Lotfi A Zadeh. "Fuzzy sets". Information and control, 8(3): 338–353, 1965.
- [9] J. C. Bazdec, "Models for pattern recognition", in pattern recognition with fuzzy objective function algorithms ,ed : Springer, 1981
- [10] I Gath, D Lehmann, & E Bar-On, "Fuzzy clustering of EEG signal and vigilance performance", International journal of neuroscience, 20(3-4): 303–312,
- [11] Göran Granath, "Application of fuzzy clustering and fuzzy classification to evaluate the provenance of glacial till", Journal of the International Association for Mathematical Geology, 16(3): 283–301, 1984.
- [12] TL Huntsherger, CL Jacobs, & Robert L Cannon, "Iterative fuzzy image segmentation", Pattern recognition, 18(2): 131–138, 1985.
- [13] A.Mekhmoukh, "Segmentation d'images par classifieurs non supervisés : Application à L'Imagerie par Résonance Magnétique IRM", Mémoire de Magister, Université A.Mira De Béjaia, Mai 2008.

- [14] H. Charif, " Segmentation d'images par une approche biomimétique Hybride", mémoire de magister Boumerdès 2012.
- [15] R. O. Duda and P. E. Hart, "pattern classification and scene analysis Vol. 3", Wiley New York, 1973.
- [16] W. T. Tucker, " Counterexamples to the convergence theorem for fuzzy iso-data clustering algorithms", the analysis of fuzzy information, vol. 3 ,1987.
- [17] C. G. Looney, " A Fuzzy clustering and fuzzy merging algorithm", Reno, NV, 1999.
- [18] M. Mokhtar Bendib, " Détection de pathologies à partir d'IRM cérébrales ".Thèse de doctorat ,2014/2015.
- [19] M. L. BENOMAR, " Segmentation d'images microscopiques de cytologie", Mémoire de magistère ,2012
- [20] S. Lila ," Segmentation d'image par classification floue". Mémoire de magistère, Université mouloud mammeri Tizi-ouzou le 03/05/2015.
- [21] K. Mesloub, " Analyse d'image IRM sur l'étude de la sclérose en plaque ", mémoire de magistère. Université mouloud mammeri Tizi-ouzou.
- [22] B. Scherrer, " la Segmentation des tissus et structures sur les IRM cérébrales : agents markoviens locaux coopératifs et formulation bayésienne réalisé", thèse de doctorat, le 29 Octobre 2008.
- [23] BrainWeb, Similated Brain Database, McConnel BrainImaging Centre, Montreal Neurological Institute, McGill, 2015.
- [24] J. Lecoœur, C.Barillot , "Segmentation d'images cérébrales : État de l'art",Rapport de recherche, RR-6306, INRIA. 2007, pp.46.

Résumé

La segmentation d'image est le processus de partitionnement d'une image en régions non chevauchées, homogène vis-à-vis de certaines caractéristiques, telle que le niveau de gris, la couleur, texture ...etc. . Elle a des applications dans plusieurs domaines comme l'imagerie médicale, l'imagerie par satellite ...etc. Le processus de segmentation représente une étape cruciale dans le système de vision par ordinateur car les caractéristiques et décisions sont extraites et prise à partir de son résultat. Les premiers algorithmes de segmentation d'image ont vu le jour dans les années 1970, depuis de nombreuses techniques et méthodes de segmentation ont été expérimentées pour essayer d'améliorer les résultats, ces dernières années l'introduction des méta-heuristiques dans le domaine du traitement d'images a permis d'étudier la segmentation sous un angle différent avec des résultats plus ou moins réussis.

Dans le but d'apporter notre contribution et d'améliorer davantage les performances des méthodes de segmentation, nous avons proposé des algorithmes basés sur la classification floue en utilisant l'algorithme standard de classification non-supervisée C-Moyennes Floues (FCM) est très populaire en segmentation d'images, mais il ne tient pas à la topologie de l'image il ne se base que sur la valeur des pixels de ce fait il reste très sensible aux bruits et aux inhomogénéités dans l'image, de plus il reste tributaire de l'initialisation des centres de classes. Afin de rendre l'algorithme plus robuste face aux imprécisions et aux bruits, deux Techniques d'intégration et de prise en compte de l'information spatiale ont été introduites par (FCM_S1). Nous avons combiné l'algorithme FCM_S1 avec la méthode de level set en initialisant automatiquement le contour initial d'une région recherchés.

Les méthodes proposées ont été évaluées sur des bases de données expérimentales composées d'images synthétiques, d'images IRM simulés, Les résultats montrent que les techniques proposées qui intègrent l'information spatiale donnent de meilleure performance de segmentation.

Mots clés : segmentation d'image, K-means, c-moyenne floue (FCM), information spatiale(FCM_S1), level set