

République Algérienne Démocratique et Populaire
Ministère de l'enseignement supérieur et de la recherche scientifique

Université Abderrahmane MIRA de Bejaia
Faculté de la Technologie
Département d'électronique

Mémoire

Présenté pour obtenir le diplôme de Magister
Spécialité : Automatique et traitement du signal (Option Systèmes)

Thème

Segmentation d'images IRM

Présenté par : Mr. NASRI Nadjib

Soutenu le 30 Mai 2010 devant le Jury :

Mr ZEBOU DJ Youcef	Professeur	Président.
Mr MOKRANI Karim	Maitre de Conférences	Rapporteur.
Mr MENDIL Boubekour	Professeur	Examineur.
Mr BERRAH Smail	Maitre de Conférences	Examineur.

*Avec amour, amitié et gratitude, je dis merci à mes parents, mon frère unique
et mes sœurs.*

Remerciements

*Il m'est agréable d'exprimer mes vifs sentiments de gratitude à Mr **MOKRANI Karim**, Maitre de conférences à l'université de Bejaia, pour sa direction, sa disponibilité et ses conseils lors de l'élaboration de ce travail.*

*Je remercie également Mr **ZEBOUDJ Youcef**, Professeur à l'université de Bejaia pour avoir accepté de présider le jury. Mr **MENDIL Boubekour**, Professeur à l'université de Bejaia et Mr **BERRAH Smail**, Maitre de conférences à l'université de Bejaia pour avoir accepté de faire partie de ce jury.*

*Je tiens à remercier aussi ma grande famille, mes amis (en particulier **Idris**), la promotion d'électronique 2007 (en particulier **Halim**) ainsi que la promotion d'automatique (en particulier **Abdenour**) pour leur soutien et encouragements au cours de ma formation.*

Sommaire

Liste des algorithmes	01
Liste des tableaux	02
Liste des figures	03
Introduction générale	04

Chapitre I : La segmentation par approche classification

I.1 Introduction	06
I.2 Principe de la segmentation	07
I.3 Chaîne de traitement d'images	07
I.3.1 Acquisition d'une scène	07
I.3.2 Prétraitement	07
I.3.3 Segmentation	07
• Extraction de caractéristiques	07
• Classification	08
• Post-traitement	08
I.3.4 Interprétation des résultats et prise de décisions.	08
I.4 Méthodes de segmentation par classification	08
I.4.1 Classification nette par K-means	10
I.4.1.1 Distances métriques	11
I.4.1.2 Contraintes liés à la classification par K-means	12
I.4.2 Classification floue par FCM	12
I.5 Conclusion	12

Chapitre II : Classification floue : FCM et variantes

II.1 Introduction	14
II.2 Théorie des sous ensembles flous	15
II.2.1 Notion d'appartenance	15
II.2.2 Fonction d'appartenance	16
II.3 Classification floue (FCM)	17
II.3.1 Fonctionnement du FCM	18
II.3.2 Convergence de FCM	19
II.3.3 Influence de l'initialisation	19
II.3.4 Etude de l'influence du bruit et de l'inhomogénéité	20
II.3.5 Evaluation de la méthode FCM	21
II.3.6 Taux de miss-classification	22
II.4 Algorithme PDI (Population Diameter Independent)	23
II.4.1 Influence de l'initialisation	25
II.4.2 Influence du bruit et de l'inhomogénéité	25
II.5 Conclusion	26

Chapitre III : Classification par considération du contexte spatial

III.1 Introduction	28
III.2 Notion de voisinage	29
III.3 Algorithme RFCM	29
III.3.1 Choix du paramètre β	31
III.3.2 Influence de l'initialisation	31
III.3.3 Influence du bruit et de l'inhomogénéité	32
III.4 Algorithme FCM_S (Spatial FCM)	33
III.4.1 Fonctionnement du FCM_S1 et FCM_S2	35
III.4.2 Influence du bruit et de l'inhomogénéité sur FCM_S1	35
III.4.3 Influence du bruit et de l'inhomogénéité sur FCM_S2	36
III.5 Improved FCM Algorithm	37
• Influence du bruit et de l'inhomogénéité sur IFCM_S	38
III-6 Conclusion	39

Chapitre VI : Application à l'Imagerie par Résonance Magnétique

IV.1 Anatomie du cerveau	40
IV.2 Imagerie par résonance magnétique	41
IV.2.1 Principe de fonctionnement	41
IV.2.2 Imperfections en IRM	42
IV.3 Base de données Brainweb	43
IV.4 Pré-segmentation de la zone d'intérêt du cerveau	43
IV.5 Résultats et Discussion	44
IV.5.1 Etape d'initialisation	44
IV.5.2 Choix des paramètres	44
IV.5.3 Problème d'évaluation	45
IV.5.4 Influence du bruit	46
IV.5.5 Influence des inhomogénéités	48
IV.5.6 Influence du bruit et de l'inhomogénéité sur les classes	50
• Classification par FCM	50
• Comparaison des différents algorithmes	51
VI.6 Conclusion	54

Conclusion générale	55
Annexe 1 : Algorithme Isodata	57
Annexe 2 : Résonance Magnétique Nucléaire	58
Bibliographie	61

Liste des algorithmes

<i>Algorithme I-1 : Méthode des K-means</i>	11
<i>Algorithme II-1 : Méthode des K-moyennes floues(FCM)</i>	19
<i>Algorithme II-2 : Méthode PDI (Population Diameter Independent)</i>	24
<i>Algorithme III-1 : Méthode RFCM (Robust FCM)</i>	30
<i>Algorithme III-2 : Méthode FCM_S (Spatial FCM)</i>	34
<i>Algorithme III-3 : Méthode IFCM_S (Spatial FCM)</i>	38

Liste des tableaux

Tableau II-1	MCR obtenu pour la classification de la 2 ^{ème} image synthétique par FCM	22
Tableau II-2	MCR obtenu pour la classification de la 2 ^{ème} image synthétique par PDI	26
Tableau III-1	MCR obtenu pour la classification de la 2 ^{ème} image synthétique par RFCM.	31
Tableau III-2	MCR obtenu pour la classification de la 2 ^{ème} image synthétique par RFCM	32
Tableau III-3	MCR obtenu pour la classification de la 2 ^{ème} image synthétique par FCM_S	36
Tableau III-4	MCR obtenu pour la classification de la 2 ^{ème} image synthétique par FCM_S2	37
Tableau III-5	MCR obtenu pour la classification de la 2 ^{ème} image synthétique par IFCM_S	38
Tableau VI-1	MCR calculé pour les images bruitées	47
Tableau VI-2	MCR calculé pour les images IRM ayant 5% de bruit et 20,40 et 60% d'inhomogénéité	49
Tableau VI-3	Taux de classification pour différentes classes Obtenues par FCM	50
Tableau VI-4	Taux de classification pour différentes classes Obtenues par FCM, PDIRFCM, FCM_S1 et FCM_S2 pour une image à (5%bruit ,40% inh).	52
Tableau VI-5	MCR et coefficient de Jaccard pour différentes classes Obtenue par FCM, PDI, RFCM, FCM_S1et FCM_S2 pour une image à (5%bruit,40% inh).	53

Liste des figures

Figure I-1 : Chaîne de segmentation d'images	07
Figure I-2 : Extraction de caractéristiques (Niveau de gris)	08
Figure I-3 : Partitions emboîtées d'un ensemble X à 6 éléments	09
Figure I-4 : Exemple de classification à l'aide des centres mobiles	09
Figure I-5 : Exemple de classification par K-means	10
Figure I-6 : Classification nette et Classification floue	12
Figure II-1 : Notion d'appartenance dans les sous ensembles flous	15
Figure II-2 : Exemple de fonction d'appartenance dans la théorie des sous ensembles et la théorie des sous ensembles flous	16
Figure II-3 : Forme d'une fonction d'appartenance	16
Figure II-4 : Exemples de fonction d'appartenance	17
Figure II-5 : Schéma d'un contrôleur flou	18
Figure II-6 : Exemple de point selle d'une fonction	19
Figure II-7 : Effet du bruit sur l'histogramme d'une image	20
Figure II-8 : Résultat de la classification de la 1 ^{ère} image synthétique par FCM	21
Figure II-9 : Résultat de la classification de la 2 ^{ème} image synthétique par FCM	22
Figure II-10 : Exemple de classification de données 2D et sa représentation en 3D	23
Figure II-11 : Influence de l'initialisation sur l'algorithme PDI	25
Figure II-12 : Résultat de la classification de la 1 ^{ère} image synthétique par PDI	25
Figure II-13 : Résultat de la classification de la 2 ^{ème} image synthétique par PDI	26
Figure III-1 : Connexité 4 et connexité 8	29
Figure III-2 : 1- transition directe 2- transition graduelle	30
Figure III-3 : Influence de l'initialisation sur l'algorithme RFCM	32
Figure III-4 : Résultat de la classification de la 2 ^{ème} image synthétique par RFCM	32
Figure III-5 : Illustration du fonctionnement de FCM_S1	35
Figure III-6 : Résultat de la classification de la 1 ^{ère} image synthétique par FCM_S	35
Figure III-7 : Résultat de la classification de la 2 ^{ème} image synthétique par FCM_S1	36
Figure III-8 : Résultat de la classification de la 2 ^{ème} image synthétique par FCM_S2	36
Figure III-9 : Résultat de la classification de la 2 ^{ème} image synthétique par IFCM_S	38

Figure VI-1 : Système nerveux central humain	40
Figure VI-2 : Coupe coronale du cerveau.	41
Figure VI-3 : Acquisition des images IRM.	42
Figure VI-4 : Exemple d'une image réelle.	42
Figure VI-5 : Pré-segmentation d'une image IRM.	43
Figure VI-6 : Images IRM bruitées (a) 3%, (b) 5% et (c) 7%	46
Figure VI-7 : Résultats de la segmentation par (a) FCM, (b) PDI, (c) RFCM, (d) FCM_S1 et (e) FCM_S2 pour une image à 3% de bruit.	46
Figure VI-8 : Résultats de la segmentation par (a) FCM, (b) PDI, (c) RFCM, (d) FCM_S1 et (e) FCM_S2 pour une image à 5% de bruit.	47
Figure VI-9 : Résultats de la segmentation par (a) FCM, (b) PDI, (c) RFCM, (d) FCM_S1 et (e) FCM_S2 pour une image à 7% de bruit.	47
Figure VI-10 : Images IRM à 5% de bruit et à (a) 20%, (b) 40% et (c) 60% d'inhomogénéités.	48
Figure VI-11 : Résultats de la segmentation par : (a)FCM, (b) PDI, (c)RFCM,(d) FCM_S1 et (e)FCM_S2 pour une image à 5% de bruit et 20% d'inhomogénéité.	48
Figure VI-12 : Résultats de la segmentation par : (a)FCM, (b) PDI, (c)RFCM,(d)FCM_S1 et (e)FCM_S2 pour une image à (5% de bruit et 40% d'inhomogénéité.	49
Figure VI-13 : Résultats de la segmentation par : (a)FCM, (b) PDI, (c)RFCM, (d) FCM_S1 et (e)FCM_S2 pour une image à 5% de bruit et 60% d'inhomogénéité.	49
Figure VI-14 : Taux de classification pour différentes classes (LCR, MG et MB) Obtenues par FCM pour différents niveaux de bruit et d'inhomogénéités.	49
Figure VI-15 : Classes de l'image originale (Données de Brainweb).	50
Figure VI-16 : Séparation de classes pour les différents algorithmes : (a) FCM, (b) PDI, (c)RFCM et (d) FCM_S1 pour une image à 5%bruit et 40% inh.	52
Figure VI-17 : Taux de classification pour différentes classes obtenues par FCM, PDI, RFCM, FCM_S1 et FCM_S2 pour une image à 5%bruit et 40% inh.	53

Introduction générale

La segmentation des tissus du cerveau par IRM (Imagerie par résonance magnétique) est une problématique très importante. L'IRM étant « non invasive », est devenue un outil de diagnostic clinique très utilisé dans la neuroradiologie. Cette technique est très préconisée dans le suivi de différentes pathologies : alzheimer, parkinson, ... etc. Néanmoins les images IRM sont soumises, lors de leurs acquisitions, à différentes imperfections (bruit, artefacts de mouvement, inhomogénéités d'intensité) qui peuvent déformer l'image ou simuler un processus pathologique. Ceci va rendre l'analyse de l'image plus complexe et peut induire à des erreurs d'interprétation. Traiter ces imperfections pendant l'acquisition par filtrage du bruit et correction d'inhomogénéité, est une solution peu tolérée [2]. Car elle est couteuse en temps, notamment quand les données sont d'une grande dimension, et peut entraîner une perte d'informations (détails de l'image). L'idéal est de trouver un algorithme de segmentation robuste au bruit et aux inhomogénéités d'intensité.

Une multitude de méthodes de segmentation sont proposées dans la littérature, Nous nous intéresserons à la segmentation par approche classification, issue des méthodes statistiques multidimensionnelles. La classification cherche à regrouper les pixels qui présentent une similarité et une uniformité selon un critère prédéfini, on parle de partitionnement ou de clustering. Les FCM (Fuzzy C-means) [6] fait partie des méthodes de classification basées sur l'optimisation de l'inertie. Sa complexité réduite, sa considération de l'aspect graduel des niveaux de gris (par l'intégration des degrés d'appartenance), sont les facteurs qui ont fait sa popularité. Néanmoins cet algorithme ne prend pas en compte la disposition spatiale des pixels et ne considèrent que le vecteur de caractéristiques (attributs) utilisé. Négligeant ainsi les propriétés du voisinage du pixel considéré, ce qui induit à une sensibilité au bruit et aux inhomogénéités d'intensité. De ce fait, l'information seule du niveau de gris du pixel actuel, sans prise en compte de son voisinage, n'est pas suffisante pour aboutir à une classification robuste [6]. La solution est d'incorporer les informations spatiales de l'image initiale dans l'algorithme de segmentation [21][22]. La littérature est riche dans cet axe, plusieurs travaux ont été réalisés afin de modifier la fonction coût de FCM, d'où l'apparition de plusieurs variantes [16][18][21][22][24].

Nous allons étudier quelques algorithmes qui répondent à ce problème. Pour ce faire, nous commençant dans le premier chapitre par une brève description de la segmentation par approche classification, et la famille d'où découle la méthode des K-means [5] qui à été généralisée pour obtenir l'algorithme FCM. Nous allons ensuite, présenter dans un second chapitre, l'algorithme FCM, ainsi que quelques notions de la théorie des sous ensembles flous. Et on termine par la présentation de l'une des variantes de FCM, l'algorithme PDI [17] qui tente de normaliser la fonction objective du FCM.

Le troisième chapitre sera consacré à la présentation de quelques méthodes, qui considèrent le contexte spatial de l'image. Parmi les variantes, on retrouve : RFCM (Robust FCM) [22], qui considère que le pixel actuel ne doit pas être classé avant d'examiner l'appartenance de ses voisins. On passe ensuite à la famille FCM_S (Spatial FCM) : FCM_S1[21], FCM_S2[23] et IFCM_S[24]. Des versions modifiées de FCM qui considèrent les propriétés spatiales du voisinage (moyenne et médiane). Enfin, le quatrième chapitre sera consacré, en grande partie, pour la présentation des résultats obtenus de l'application des différents algorithmes à des images IRM réelles. Une comparaison des performances des algorithmes est faite par le calcul de quelques critères, qui renseignent sur la qualité de la classification (MCR, coefficient de Jaccard [3]). Une conclusion conclut notre travail en présentant quelques perspectives.

Chapitre I

La segmentation par approche classification

La classification est importante dans plusieurs domaines, et intéresse les praticiens confrontés, dans leurs travaux à des données multidimensionnelles importantes : la médecine, science sociale, industrie, marketing, météorologieetc.

I.1 Introduction :

La segmentation est une étape importante pour l'extraction des informations qualitatives de l'image. Elle consiste à découper l'image considérée en régions ayant une homogénéité selon un critère prédéfini (niveau de gris, moments, coefficients d'ondelettes ...). L'union des régions obtenues doit redonner l'image initiale. La segmentation d'image n'est pas considérée comme un but en soi, mais dépend du type de traitement fixé a priori.

Une multitude de méthodes de segmentation sont proposées dans la littérature, elles se répartissent en trois grandes familles : la segmentation par approche contour, région et classification [1].

L'approche contour consiste à identifier les discontinuités qui séparent les différentes régions de l'image, cette approche cherche les dissimilarités.

L'approche région a pour objectif de décomposer l'image en un ensemble de régions connexes les plus homogènes possible; et les plus différentes pour celles qui se côtoient.

L'approche classification, quant à elle, cherche à regrouper les pixels qui présentent une similarité et une uniformité selon un critère prédéfini, on parle de partitionnement ou de clustering. C'est cette approche qui nous intéresse dans ce travail.

Dans ce chapitre nous présentons brièvement la segmentation par approche classification, et la famille d'où découle la méthode des K-means qui a été généralisée pour obtenir l'algorithme FCM.

I.2 Principe de la segmentation :

La segmentation consiste à partitionner une image I en groupes de pixels $\{R_i\}_{i=1..n}$ qui sont homogènes par rapport à un prédicat donné [1] :

$$\begin{cases} \forall i, R_i \neq \emptyset \\ \forall i, j \ i \neq j, R_i \cap R_j = \emptyset \\ I = \cup R_i \end{cases}$$

Les régions R_i doivent être disjointes et celles qui sont adjacentes doivent être hétérogènes.

Il n'existe pas une technique unique de segmentation car la nature des images et le but de la segmentation sont multiples. Le choix de la technique est lié aux facteurs suivants [2]:

- Caractéristiques de l'image : éclairage, présence de reflet, bruit, ... etc.
- Objectif de la segmentation : localisation (de pathologies par exemples : le suivi du Parkinson et l'Alzheimer), reconnaissance de formes (aide au contrôle de la qualité), aide au diagnostic (temps réel ou pas : Chirurgie assisté par ordinateur).
- Primitives à extraire : contours, objets, formes, région, texture.

I.3 Chaîne de traitement d'images [2]:

Le processus de traitement d'images se décompose en plusieurs étapes :

I.3.1 Acquisition d'une scène (image) : permet de discrétiser l'image réelle afin d'être traitée par l'ordinateur.

I.3.2 Prétraitement : permet d'obtenir l'image la plus nette que possible.

I.3.3 Segmentation : permet l'extraction des indices pertinents présents dans l'image (région, contour, ...). Dans ce travail, nous avons opté pour la segmentation par approche classification qui se décompose à son tour en trois étapes :



Figure I-1 : Chaîne de segmentation d'images.

- **Extraction de caractéristiques :** l'image est représentée dans l'algorithme de segmentation par son vecteur de caractéristiques, nommé souvent vecteur d'attributs.

Ce vecteur, selon le sujet traité, peut être formé par les niveaux de gris de l'image, des mesures locales (moyenne, variance, ...), coordonnées spatiales des pixels ... etc.

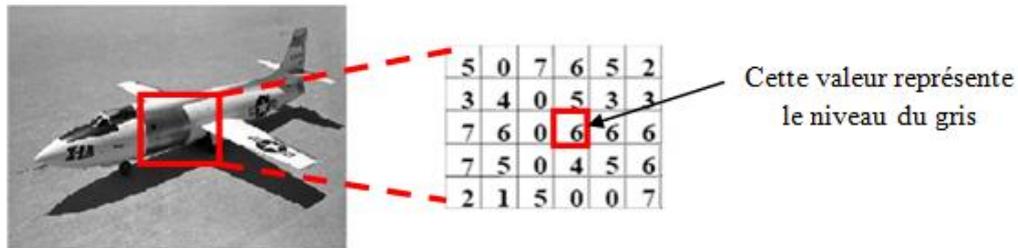


Figure I-2 : Extraction de caractéristiques (Niveau de gris).

- **Classification** : (ou clustering) est le processus de regroupement d'objets similaires en une classe (cluster) unique, et les objets dissimilaires en des classes différents. Ceci selon un critère de similarité donné.
- **Post-traitement** : visualisation, stockage, (dans le cas de FCM, la fonction d'appartenance obtenue est utilisée pour afficher l'image et ses différentes classes).

I.3.4 Interprétation des résultats et prise de décisions.

I.4 Méthodes de segmentation par classification :

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.

En général, on peut les répartir en :

Les 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. Ici le nombre de classes est déduit directement des données. (Cas des images cérébrales IRM : les classes qu'on cherche sont trois : MB, MG et LCR).

On parle aussi de **méthodes avec ou sans apprentissage**, cela dépend de la disponibilité d'une base de connaissance préalables sur les données.

Enfin, **les méthodes paramétriques et non paramétriques**, dans le cas où l'on possède un modèle qui décrit les données.

Les méthodes statistiques de classification peuvent aussi être décomposées, en deux grandes familles : méthodes hiérarchiques [3] et méthodes basées sur l'optimisation de l'inertie.

La première famille a pour principe la construction, pas à pas, d'une suite de partitions emboîtées depuis la partition la plus fine jusqu'à la partition la plus grossière. Au départ, on dispose de n objets à classer, on calcule les distances les séparant deux à deux et on agrège les deux éléments les plus proches en un nouvel élément. On se retrouve alors avec $(n - 1)$ éléments à classer, on réitère le processus jusqu'à ce que tous les objets soient regroupés.

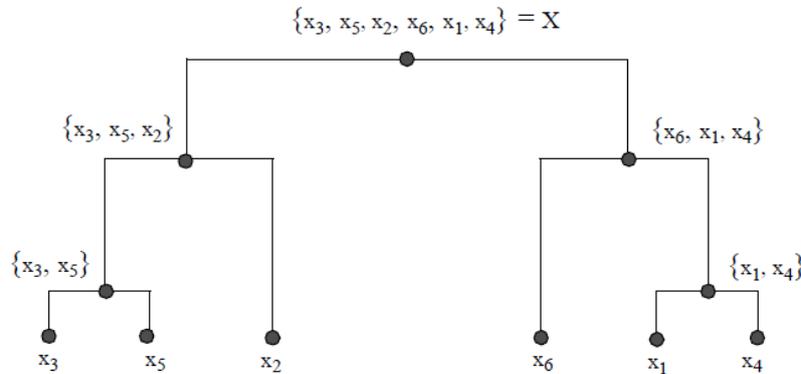


Figure I-3 : Partitions emboîtées d'un ensemble X à 6 éléments.

La seconde famille consiste à optimiser un critère de type inertie. L'inertie d'une classe est une mesure de compacité. Donc une classe est d'autant plus compacte que son inertie est faible. Ce qui revient à dire que si l'inertie d'une classe est élevée alors les points lui appartenant sont éloignés de son centre.

Le critère de regroupement consiste, alors, à minimiser l'inertie intra-classe. La méthode des centres mobiles [4] est basée sur ce principe.

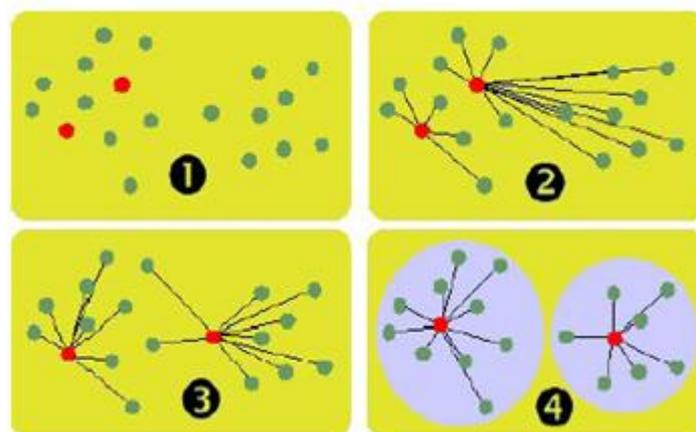


Figure I-4 : Exemple de classification à l'aide des centres mobiles.

En effet la méthode des centres mobiles, comme son nom l'indique, est basée sur le mouvement des centres de gravité des classes qui se déplacent vers une position de stabilité.

Mac Queen [5] a généralisé cette méthode, tel que chaque nouvelle affectation d'un pixel à une classe donnée, entraîne une modification (mise à jour) du centre correspondant. Il développe ainsi l'algorithme appelé par K-means (ou K-moyennes).

I.4.1 Classification nette par K-means :

Les K-means fut proposé par Mac Queen en 1967 [5]. Le principe est de minimiser la fonction objective :

$$J(y, v) = \sum_{j \in \Omega} \sum_{k=1}^c \|y_j - v_k\|^2 \quad (\text{I-1})$$

v_k : est le centre de la classe i .

$\| \cdot \|$: est la norme Euclidienne qui mesure la similarité entre un pixel et un autre.

La procédure de classification est assez simple :

- Déterminer aléatoirement les centres initiaux des classes.
- Déterminer la distance entre chaque pixel et les c centres.
- Grouper les pixels qui ont une distance minimale au $k^{\text{ième}}$ centre dans la $k^{\text{ième}}$ classe.

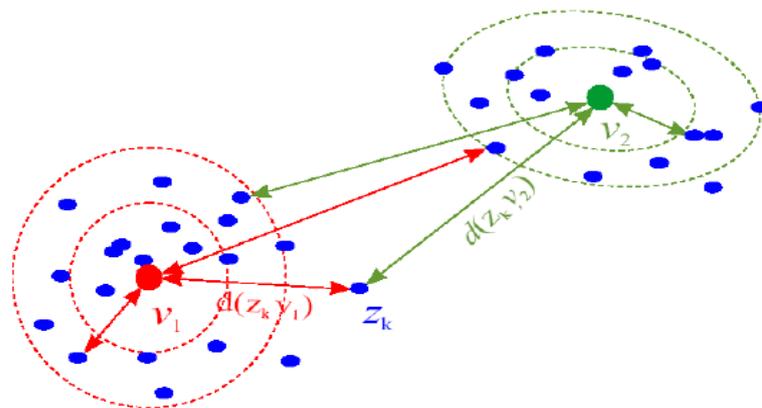


Figure I-5 : Exemple de classification par K-means.

Chaque pixel ayant le niveau de gris Z_k est distant des différents centres V_i par une distance $d(Z_k, V_i)$. le pixel sera à la classe dont il est plus proche. L'algorithme des K-means est donné par :

Algorithme 1

Etape 1 : Obtenir aléatoirement les centres de classes initiaux v_k ; $k=1,\dots,C$

Etape 2 : Assigner y_j à la classe j ; $j = 1,\dots,c$ si :

$$\|y_j - v_i\| \leq \|y_j - v_p\| \quad ; p = 1,\dots,c \quad \text{avec : } j \neq p$$

Etape 3 : Mettre à jour les centres de classes par la formule :

$$v_k = \frac{1}{n_i} \cdot \sum_{j \in \Omega} y_j \quad (\text{I-2})$$

n_i : est le nombre de pixels dans la classe k

Etape 4 : Répéter de l'étape 2 et 3 jusqu'à atteindre la convergence : $v_i^* = v_i$; $i = 1,\dots,c$

Algorithme I-1 : la méthode des K-means.

La mesure de la similarité entre différents points de l'image se fait à base de distances (dans l'espace des attributs) appelées distances métriques.

I.4.1.1 Distances métriques : [1]

Une distance métrique sur un corps K entre deux vecteurs X et Y , définis dans un espace à n dimensions est définie par :

- $d(X, Y) = d(Y, X)$
- $d(X, Y) \geq 0$
- $d(X, Y) = 0 \Leftrightarrow X = Y$
- $d(X, Z) \leq d(X, Y) + d(Y, Z)$

Il existe de nombreuses distances dans la littérature. Une famille très utilisée est celle de Minkowski. Leur forme est :

$$d(X_i, Y_j) = (\sum_{k=1}^n \|X_i - Y_j\|^p)^{1/p} \quad \text{avec } p \geq 1 \quad (\text{I-3})$$

Notons que lorsque $p = 1$, nous obtenons la distance de Manhattan et lorsque $p = 2$, nous obtenons la distance Euclidienne. Cette dernière est utilisée dans ce travail.

D'autres distances sont définies telle la distance de Mahalanobis, qui a la forme :

$$d(X_i, Y_j) = \sqrt{(X_i - Y_j)^p \cdot S^{-1} \cdot (X_i - Y_j)} \quad (\text{I-4})$$

Avec : S^{-1} est l'inverse de la matrice de covariance de X et Y .

I.4.1.2 Contraintes liées à la classification par K-means :

Cet algorithme à plusieurs points faibles [6] :

- Sensibilité à l'initialisation du fait que les centres initiaux des différentes classes sont choisis aléatoirement.
- K-means est fortement sensible au bruit.
- Convergence vers un minimum local.

La solution apportée à ces différents problèmes fut l'intégration de la notion de degrés d'appartenance inspirée de la théorie des sous ensembles flous.

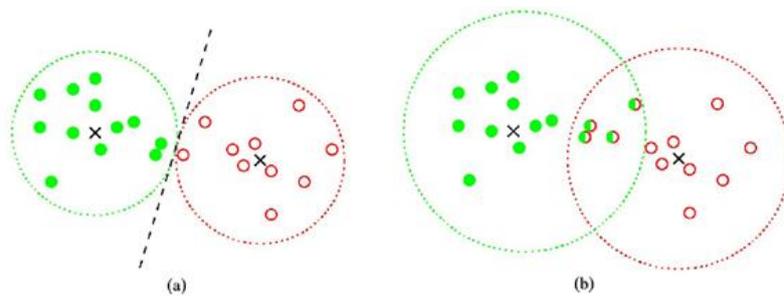


Figure I-6 : a-Classification nette b-Classification floue.

I.4.2 Classification floue par FCM :[6]

Basé sur la théorie des sous ensembles flous. L'algorithme FCM considère que chaque pixel x_i appartient aux différentes classes par un degré d'appartenance u_i . En effet FCM n'est qu'une généralisation des K-means. Cet algorithme est devenu très populaire et est devenu l'un des algorithmes les plus utilisés.

FCM est une méthode de classification floue non supervisées donc sans apprentissage.

I.5 Conclusion :

Nous avons parlé dans ce chapitre des différentes approches de segmentation qui sont traitées dans la littérature. Notre travail va porter sur la segmentation par approche classification. Ensuite nous avons présenté le principe des méthodes se basant sur l'optimisation d'un critère de type inertie, tel que la méthode des centres mobiles. Cette dernière est en effet l'origine de la méthode K-means qui est à son tour, fut généralisée pour obtenir la méthode FCM.

FCM a introduit la notion d'appartenance, ce qui permet de surpasser les problèmes liés à l'aspect binaire de la classification nette, un pixel peut donc appartenir à plusieurs classes avec différents degrés.

Dans le chapitre suivant, on présentera en détail l'algorithme FCM, et on étudiera son apport et ses limites.

Chapitre II

Classification floue : FCM et variantes

L'aspect graduel des niveaux de gris en fait qu'un pixel n'appartient pas à une classe unique, La classification floue modélise, justement, ce problème par l'introduction des degrés d'appartenance sous l'hypothèse que chacun des pixels appartient à chacune des classes avec un coefficient d'appartenance U .

II.1 Introduction :

Ruspini [7] fut le premier à proposer, en 1969, une approche combinant le concept des sous ensembles flous et les techniques basées sur la minimisation d'un critère, il introduit ainsi la notion de partition floue. Un peu plus tard, en 1973, Dudani [8] s'est intéressé à la généralisation de l'algorithme des k -means classique en utilisant l'approche de Ruspini. Ce fut en 1981 que Bezdek [9] à introduit l'algorithme FCM (Fuzzy C-Means), en généralisant la technique d'Isodata [10] et en développant les travaux de Dunn. Bezdek a établi en effet le premier théorème qui étudie la convergence de FCM. En plus, il a introduit un paramètre m , qui prend des valeurs strictement plus grandes que 1, appelé indice de flou. Lorsque m vaut 1 l'algorithme obtenu est quasiment équivalent à la technique classique *Isodata* (**annexe1**).

Nous allons étudier dans ce chapitre, l'algorithme FCM et son fonctionnement, ainsi que quelques notions de la théorie des sous ensembles flous. Ensuite, nous allons introduire quelques variantes de FCM (algorithmes qui modifient la fonction coût du FCM afin d'améliorer les résultats de classification).

II.2 Théorie des sous ensembles flous :

La théorie a été formulée par Lotfi Zadeh [11] en 1965, dans le but d'obtenir une théorie mathématique modélisant les notions larges du langage naturel afin de surpasser l'inadéquation de la théorie des ensembles classiques, ainsi que certaines difficultés liées à l'utilisation de l'interprétation binaire. L'intérêt de cette théorie dans la classification est la considération des classes d'objets dont les frontières ne sont pas clairement définies. Pour les images aux niveaux de gris par exemple, la transition d'une région à une autre n'est pas directe, elle est plutôt graduelle. Ceci est compensé par l'introduction d'une fonction caractéristique prenant des valeurs entre 0 et 1 (fonctions d'appartenance).

II.2.1 Notion d'appartenance :

Dans la théorie des ensembles, un élément peut appartenir ou pas à un ensemble A. Sur la figure suivante, l'élément x_2 est dans le sous ensemble A donc son degré d'appartenance à A est $\mu_A(x_2) = 1$. Par contre l'élément x_1 est en dehors de A, son degré d'appartenance est alors égale à $\mu_A(x_1) = 0$.

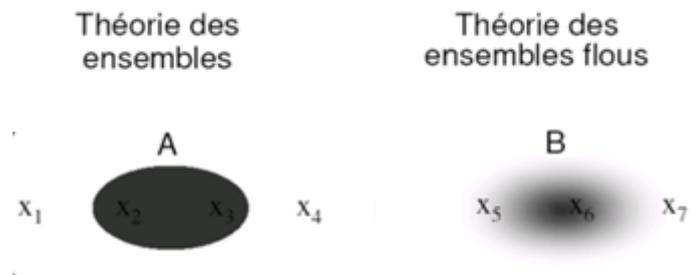


Figure II-1 : Notion d'appartenance dans les sous ensembles flous.

La théorie des sous ensembles flous, quant à elle, considère l'aspect graduel des niveaux de gris, alors un élément peut appartenir aux différentes classes avec un degré d'appartenance donné. Dans la figure précédente, x_5 est dans la zone extérieure de B (ce qui est considéré comme une deuxième classe), son degré d'appartenance va être $\mu_A(x_5) = 0.3$. Par contre x_6 est plus proche à la zone intérieure que celle de l'extérieure, son degré d'appartenance va être plus élevé $\mu_A(x_5) = 0.9$.

Le schéma suivant montre un exemple de fonctions d'appartenance dans les deux cas de classification : nette et floue.

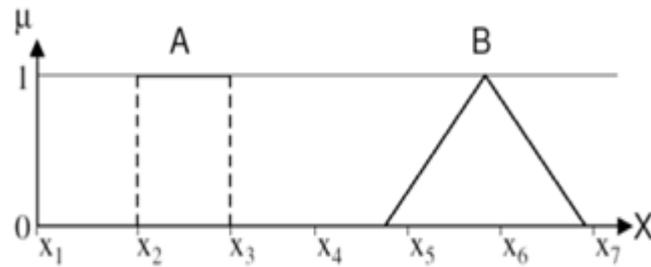


Figure II-2 : Exemple de Fonction d'appartenance dans la théorie des sous ensembles et la théorie des sous ensembles flous.

II.2.2 Fonction d'appartenance :[12]

Comme son nom l'indique, la fonction d'appartenance traduit le degré avec lequel un élément x appartient à un sous ensemble A .

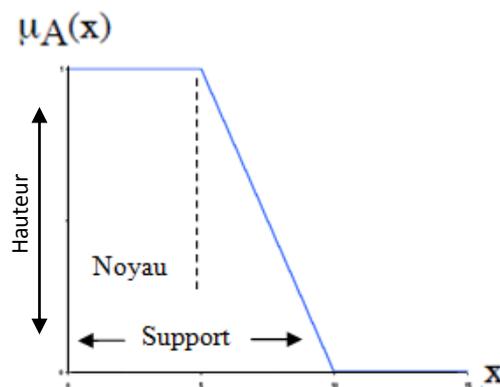


Figure II-3 : Forme d'une fonction d'appartenance.

- **Le noyau :** ensemble d'éléments x_i qui appartiennent « vraiment » à A , leurs degrés d'appartenance est égale à 1.

$$\text{Noyau}(A) = \{x \in A / \mu_A(x) = 1\} \quad (\text{II-1})$$

- **Le support :** ensemble d'éléments x_i appartenant à A dont les degrés d'appartenance n'est pas nul.

$$\text{Support}(A) = \{x \in A / \mu_A(x) \neq 0\} \quad (\text{II-2})$$

- **La hauteur :** valeur maximale de la fonction d'appartenance sur l'ensemble A .

$$\text{Hauteur}(A) = \max \mu_A(x) \quad (\text{II-3})$$

Les fonctions d'appartenance peuvent avoir différentes formes :

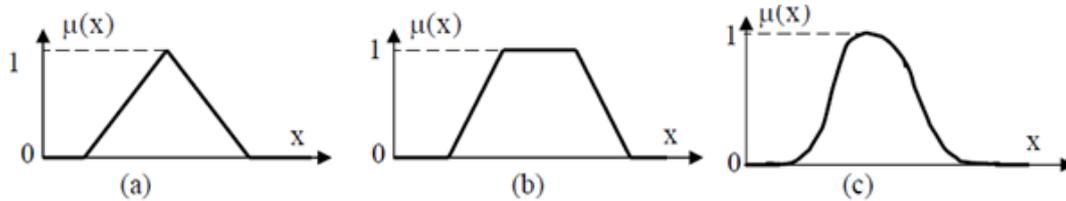


Figure II-4 : Exemples de Fonctions d'appartenance.

II.3 Classification floue (FCM) :[13]

La méthode FCM est une méthode de classification itérative et non supervisée, qui permet de classer les individus selon C classes. Elle calcule à chaque fois les centres des classes et génère la matrice d'appartenance U des individus à ces classes.

U est une matrice de dimension C x N, dont tous les éléments appartiennent à l'intervalle [0,1] et la somme des éléments d'une colonne est égale à 1.

$$U = \begin{pmatrix} u_{11} & u_{12} & \dots & u_{1j} & \dots & u_{1N} \\ u_{21} & u_{22} & \dots & u_{2j} & \dots & u_{2N} \\ u_{31} & u_{32} & \dots & u_{3j} & \dots & u_{3N} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ u_{i1} & \dots & \dots & u_{ij} & \dots & u_{iN} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ u_{C1} & u_{C2} & \dots & u_{C3} & \dots & u_{CN} \end{pmatrix} \quad (\text{II-4})$$

Donc, les éléments de la $i^{\text{ème}}$ ligne représentent les degrés d'appartenance des différents éléments de l'image, au $i^{\text{ème}}$ sous ensemble flou (classe). Par contre, les éléments de la $i^{\text{ème}}$ colonne représentent les degrés d'appartenance du $j^{\text{ème}}$ élément aux différentes classes.

L'algorithme tend à minimiser la fonction coût (appelée aussi objective) suivante :

$$J_{FCM} = \sum_{j \in \Omega} \sum_{k=1}^c u_{jk}^m \|y_j - v_k\|^2 \quad (\text{II-5})$$

Avec m l'indice de flou généralement égal à 2, C est le nombre de classes, y_j est le pixel d'indice j appartenant à l'ensemble Ω qui représente l'image considérée. N est le cardinal de Ω . U_{jk} : matrice de degrés d'appartenance dont les éléments sont considérés positifs, avec la

contrainte :

$$\sum_{k=1}^c u_{jk} = 1 \quad (\text{II-6})$$

Ici, la fonction objective J_{FCM} est minimisée lorsque les degrés d'appartenance élevés sont obtenus dans les zones proches des centres de classes.

II.3.1 Fonctionnement du FCM :

L'algorithme FCM est inspiré de la théorie des sous ensemble flous. Il suit la structure d'un contrôleur flou selon le schéma suivant :

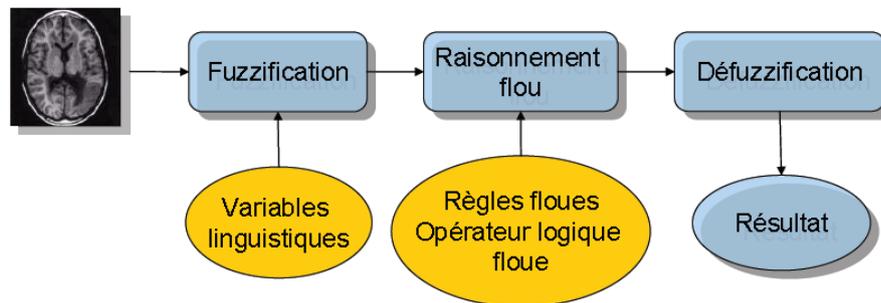


Figure II-5 : Schéma d'un contrôleur flou.

Au départ, on initialise les centres de classe aléatoirement. Puis on calcule un degré d'appartenance U_{ij} à chaque pixel j par la relation suivante [13] :

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\|y_j - v_i\|}{\|y_j - v_k\|} \right)^{\frac{2}{m-1}}} \quad (\text{II-7})$$

Ensuite, on définit les règles de décision floue :

Si « max de la colonne i de U_{ij} \in à la ligne **1** » **alors** « Pixel j \in à classe **1** »

Si « max de la colonne i de U_{ij} \in à la ligne **2** » **alors** « Pixel j \in à classe **2** »

.....

Si « max de la colonne i de U_{ij} \in à la ligne **n** » **alors** « Pixel j \in à classe **n** »

Enfin, la méthode du maximum est appliquée pour la défuzzification. On assigne chaque pixel j à la classe pour laquelle il a le plus grand degré d'appartenance.

L'algorithme FCM est donné par :

Algorithme 2

Etape 1 : Obtenir les centres de classes initiaux v_k ; $k=1, \dots, C$

Etape 2 : Calculer les degrés d'appartenance en utilisant la formule (II-7)

Etape 3 : Mettre à jour les centres de classes par la formule :

$$v_k = \frac{\sum_{j \in \Omega} u_{jk}^q \cdot y_j}{\sum_{j \in \Omega} u_{jk}^q} \quad (\text{II-8})$$

Etape 4 : Répéter l'étape 2 et 3 jusqu'à atteindre la convergence : $\|J^{new} - J^{old}\| < \varepsilon$

Algorithme II-1 : la méthode des K-moyennes floues(FCM).

II.3.2 Convergence de FCM :

Le problème est que ce genre d'algorithmes ne trouve pas nécessairement une partition optimale, correspondant à une solution globale de la fonction objective. La littérature affirme [9] que FCM converge vers une solution locale. Mais cette généralisation est remise en cause car des contre exemples sont proposés, cas des points selle [14]. Ces points sont généralement considérés comme intermédiaires pour la recherche des extrema d'une fonction.

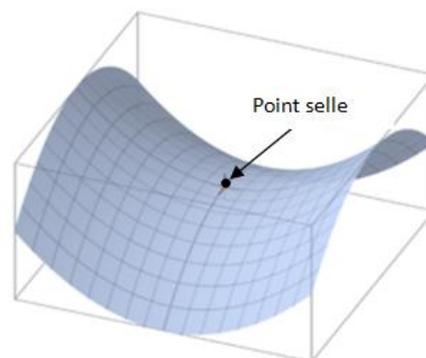


Figure II-6 : Exemple de point selle d'une fonction.

II.3.3 Influence de l'initialisation :

Le choix des centres de classe initiaux joue un rôle important dans la qualité de la solution trouvée. Une meilleure initialisation conduirait, sans doute, à une meilleure classification [15].

II.3.4 Etude de l'influence du bruit et de l'inhomogénéité :[1]

En imagerie numérique, plusieurs imperfections peuvent apparaître : le bruit qui provient principalement lors de l'étape d'acquisition, les inhomogénéités d'intensité (variation d'intensité au sein d'une même région) liées à la lumière ou aux reflets et les artefacts de mouvements (apparition d'images fantômes).

L'exemple suivant illustre l'effet du bruit sur l'histogramme d'une image, constituée de trois régions à différents niveaux de gris, corrompues par un bruit blanc gaussien.

- **Bruit blanc gaussien : [1]**

Un bruit blanc est un processus aléatoire qui suit une loi normale de moyenne et variance données, dans lequel la densité spectrale de puissance est la même pour toutes les fréquences (On l'appelle **blanc** par analogie à la lumière blanche qui a un spectre similaire). Un bruit gaussien de **1%** est donc un bruit de moyenne nulle et de variance égale à 0.01.

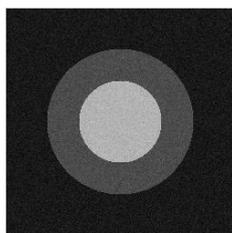
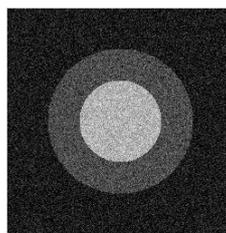
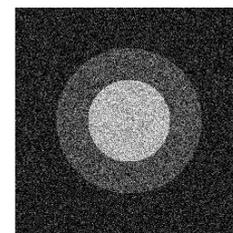


Image originale.



Bruit gaussien 1%.



Bruit gaussien 3%.

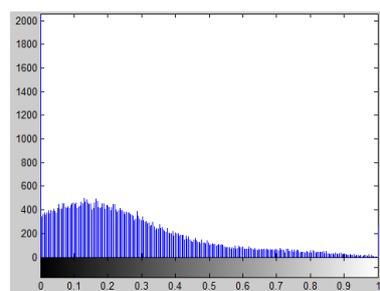
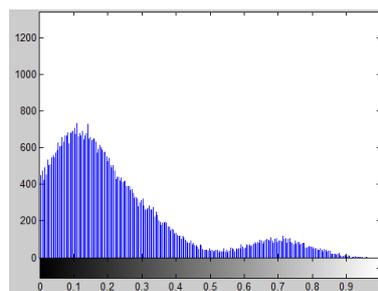
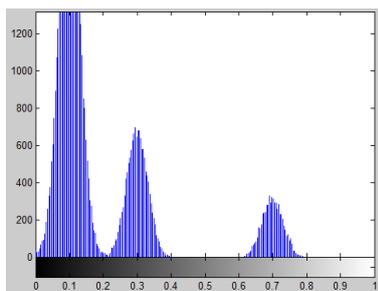


Figure II-7 : Effet du bruit sur l'histogramme d'une image.

Le premier histogramme nous renseigne, parfaitement, sur le nombre de régions, on distingue facilement les trois pics, qui représentent les trois régions de l'image. Par contre dans le second, cette information est faussée, on ne voit que deux régions et pourtant l'image n'est corrompue qu'avec 1% de bruit. Avec 3% du bruit, l'information est totalement perdue.

II.3.5 Evaluation de la méthode FCM :

Afin de comparer les différents algorithmes notamment leur robustesse au bruit. On les applique sur une image synthétique de dimension 128x128, divisée en 3 zones de différents niveaux de gris 0.1, 0.3 et 0.7. Pour tout ce qui suit le degré de flou m est égal à 2.

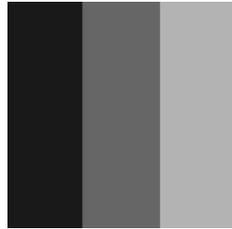


Image synthétique 1

Voici les résultats obtenus après segmentation de l'image originale corrompue par 1%, 4% et 7% de bruit gaussien additif.

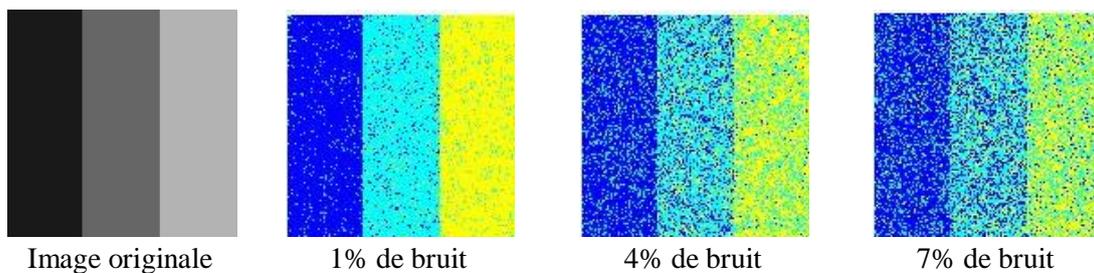


Figure II-8 : Résultat de la classification de la 1^{ère} image synthétique par FCM.

On remarque que la qualité du résultat obtenu est fortement dégradée pour un niveau élevé du bruit (7%). Comme l'algorithme des K-means, FCM est très sensible au bruit.

Mais vu que le problème que l'on retrouve souvent en imagerie IRM est les inhomogénéités d'intensité (qui sont considérées comme des bruits locaux). Nous avons utilisé une deuxième image synthétique de dimension 128x128, qui a deux niveaux de gris 0,7 et 0,3 respectivement ; avec un bruit gaussien additif localisé au centre. Ceci afin de simuler ces inhomogénéités.

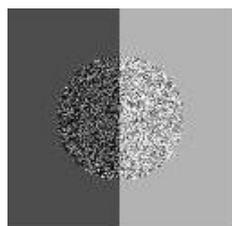


Image synthétique 2 : bruit local

On fait varier le niveau du bruit de 1%, 4%, 9% et 25% et on observe le résultat de la classification.

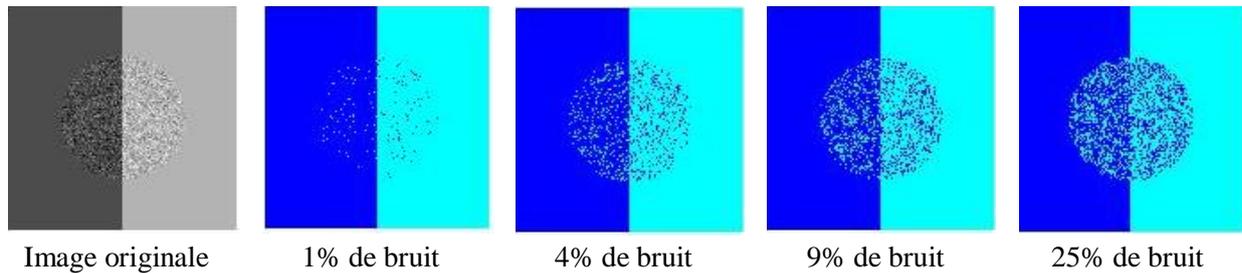


Figure II-9 : Résultat de la classification de la 2^{ème} image synthétique par FCM.

Dans le cas de cette image, une évaluation quantitative est nécessaire. Plusieurs critères sont utilisés dans la littérature pour l'évaluation des méthodes de classification. Il est évident que chaque critère est adapté à la méthode utilisée et le type de données qu'on manipule. Nous avons choisis d'utiliser le taux de classification (MCR).

II.3.6 Taux de classification [16]:

Le MCR (miss-classification rate) est parmi les critères les plus utilisés. Il représente le taux de pixels mal classés.

$$MCR = \frac{\text{Nombre de pixels mal classés}}{\text{Nombre total des pixels}} \times 100 \quad (\text{II-9})$$

Pour l'image synthétique précédente, ce tableau montre le MCR calculé à différents niveaux de bruit :

FCM	1% Bruit	4% Bruit	9% Bruit	25% Bruit
Nombre de pixels non classés	132	636	1030	1370
MCR	0,80 %	3,88 %	6,28 %	8,36 %

Tableau II-1 : MCR obtenu pour la classification de la 2^{ème} image synthétique par FCM.

Une nouvelle fois, la sensibilité de FCM au bruit apparaît. D'après le tableau le nombre de pixels mal classés est de 132 pour une image corrompue avec 1% du bruit, tandis qu'il est de 1370 pixels pour une image corrompue avec 9% du bruit. Ceci représente un MCR relativement important de 8,36%.

Malgré l'intégration de la fonction d'appartenance, FCM reste incapable de mener une classification adéquate en présence de l'inhomogénéité. Cela a plusieurs causes :

- Une bonne initialisation est difficile à atteindre, ce qui affecte la qualité de la solution trouvée.
- FCM ne prend pas en compte la disposition spatiale des pixels et ne considère que le vecteur de caractéristiques utilisé (niveau de gris), se qui rend cet algorithme sensible au bruit et aux inhomogénéités d'intensité.

La solution apportée est de modifier la fonction objective de l'algorithme FCM, afin d'avoir une meilleure classification. Plusieurs variantes sont alors apparues. Parmi ces variantes l'algorithme appelé PDI (Population Diameter Independent).

II.4 Algorithme PDI (Population Diameter Independent) :[17]

L'algorithme PDI a pour idée de normaliser FCM, en divisant par un facteur ρ . D'après l'auteur, ceci permet de ne pas favoriser une classe à une autre, car il a remarqué qu'avec la présence d'un fort bruit, les classes les moins « peuplées » (qui ont un nombre de pixels inférieur) sont généralement mal retrouvées, notamment en présence d'inhomogénéités d'intensité. Ce qui induit à un mauvais résultat.

L'auteur s'est inspiré du fait que tous les points d'une classe sont uniformément répartis autour de leur centre en formant ainsi un cercle en 2D.

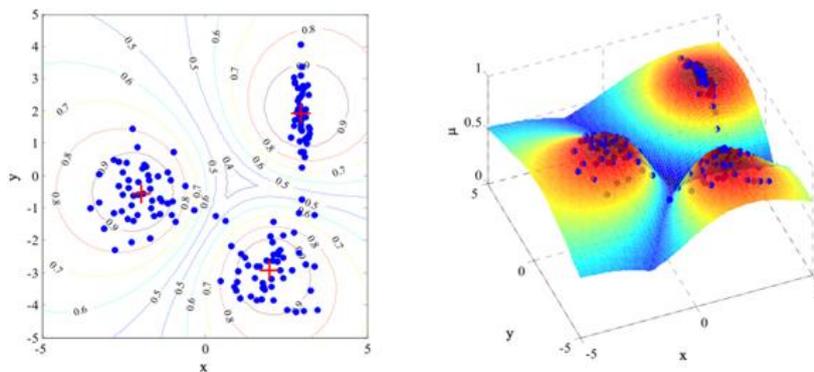


Figure II-10 : Exemple de classification de données 2D et sa représentation en 3D.

L'algorithme PDI a pour fonction objective :

$$J_{PDI} = \sum_{k=1}^C \frac{1}{\rho_k} \sum_{j=1}^N u_{jk}^m \|y_j - v_k\|^2 \quad (\text{II-10})$$

Avec m l'indice de flou généralement égale à 2 [6], C est le nombre de classes, y_j est le pixel d'indice j appartenant à l'ensemble Ω qui représente l'image considérée. N est le cardinal de Ω . U_{jk} est la matrice de degrés d'appartenance dont les éléments sont considérés positifs, avec la

$$\text{contrainte : } \sum_{k=1}^c u_{jk} = 1 \quad (\text{II-11})$$

ρ_k est le terme qui normalise la fonction objective sous la contrainte :

$$\sum_{k=1}^c \rho_k = 1 \quad (\text{II-12})$$

L'influence du ρ_k varie en fonction de r ($r > 0$). Mais, généralement, r est pris égal à 1.5. Notons que Quand $r = 0$ l'algorithme PDI devient équivalent à l'algorithme FCM.

La fonction d'appartenance est modifiée, elle est définie par [17]:

$$u_{jk} = \frac{\left(\frac{\rho_k^r}{d_{ik}^2} \right)^{1/m-1}}{\sum_{k=1}^c \left(\frac{\rho_k^r}{d_{ik}^2} \right)^{1/m-1}} \quad (\text{II-13})$$

avec :

$$\rho_k = \frac{\left[\sum_{j=1}^N u_{jk}^m \cdot d_{ik}^2 \right]^{1/r+1}}{\sum_{k=1}^c \left[\sum_{j=1}^N u_{jk}^m \cdot d_{ik}^2 \right]^{1/r+1}} \quad (\text{II-14})$$

Le nouveau algorithme est donné par :

Algorithme 3

Etape 1 : Obtenir les centres de classes initiaux V_k ; $k=1, \dots, C$ par K-means.

Etape 2 : Mettre à jour les degrés d'appartenance par l'équation (II-13).

Etape 3 : Mettre à jour les centres de classes par la formule :

$$v_k = \frac{\sum_{j=1}^N u_{jk}^m \cdot y_j}{\sum_{j=1}^N u_{jk}^m} \quad (\text{II-15})$$

Etape 4 : Répéter de l'étape 2 jusqu'à atteindre la convergence. $\|v^{new} - v^{old}\| < \varepsilon$

Algorithme II-2 : Méthode PDI (Population Diameter Independent).

II.4.1 Influence de l'initialisation :

L'étape d'initialisation des centres de classes est très importante comme montré précédemment. On va maintenant voir son effet sur l'algorithme PDI. On l'initialise une fois aléatoirement, puis par K-means.

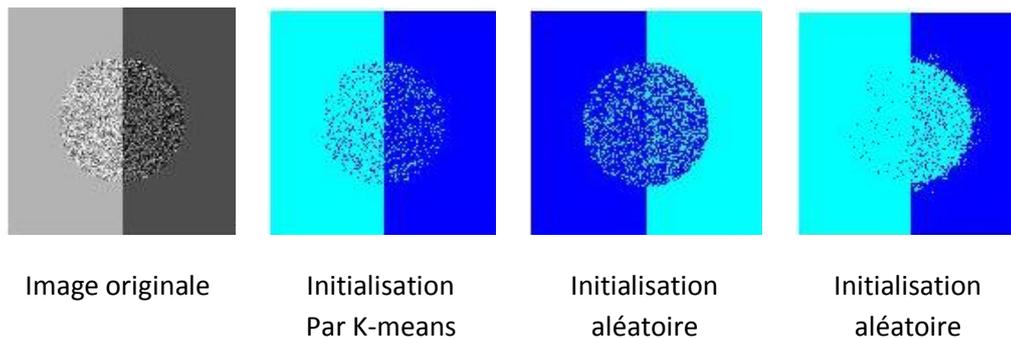


Figure II-11 : Influence de l'initialisation sur l'algorithme PDI.

On a remarqué à la fin des tests que le résultat dépendait fortement de l'initialisation. Dans le cas des centres de classes aléatoires, le résultat obtenu ne peut être interprété.

II.4.2 Influence du bruit et de l'inhomogénéité :

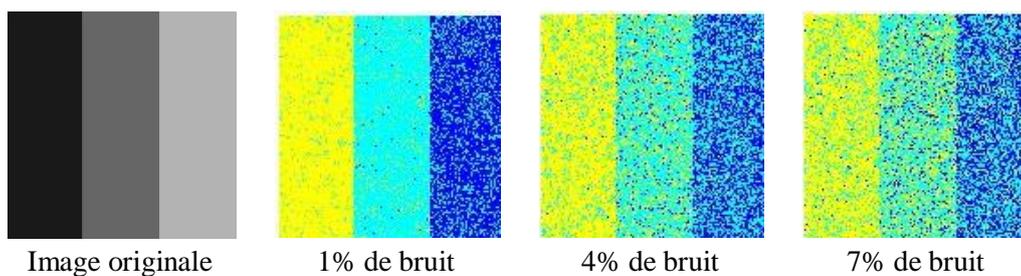


Figure II-12 : Résultat de la classification de la 1^{ère} image synthétique par PDI.

PDI n'a pas apporté grand choses pour la 1^{ère} image synthétique, qui est totalement corrompue avec du bruit. Néanmoins, il donne un meilleur résultat pour la 2^{ème} image.

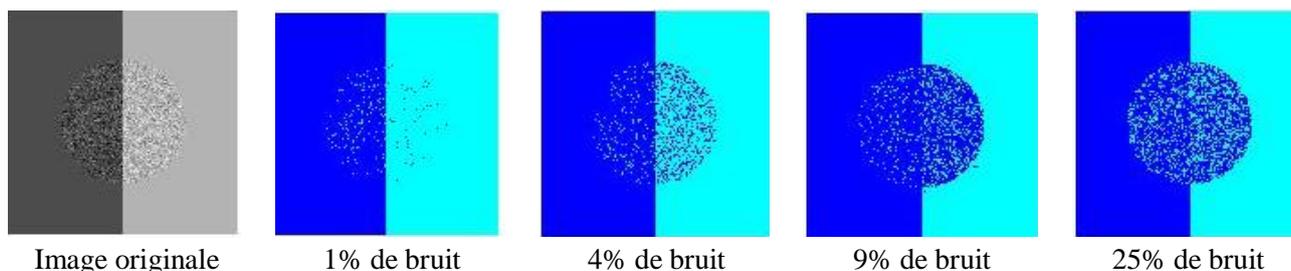


Figure II-13 : Résultat de la classification de la 2^{ème} image synthétique par PDI.

Le calcul du MCR a donné le tableau suivant :

bruit	1%	4%	9%	25%
Nombre de pixels non classés	80	330	370	980
MCR	0,48 %	2,01 %	2,25 %	5,98 %

Tableau II-2 : MCR obtenu pour la classification de la 2^{ème} image synthétique par PDI.

Il est clair que ces résultats sont meilleurs en comparant avec FCM. Le MCR est de 5,98 pour l'image corrompue avec 25% du bruit alors qu'il est de 8,36% pour le FCM. Mais le problème est la forte dépendance de l'algorithme PDI de l'initialisation.

La littérature est très riche de variantes similaires. Plusieurs autres modifications sont adoptées afin d'améliorer la méthode FCM. Certains auteurs proposent de travailler sur l'histogramme de l'image, cas du GCFPCM (Gain Field Correction Fast FCM) [18], d'autres préfèrent travailler sur l'étape d'initialisation du fait qu'une bonne initialisation amènera probablement à une bonne classification. Une autre alternative est l'approche possibiliste [19], qui propose d'ajouter une contrainte aux degrés d'appartenance. Le principe est de rendre l'appartenance d'un pixel à une classe la plus grande que possible, inversement à FCM qui assume une appartenance relative à différentes classes.

Malheureusement, ces méthodes assument que l'intensité d'une classe est constante sur toute l'image, ce qui peut poser des problèmes pour des images ayant des inhomogénéités d'intensité [20].

II.5 Conclusion :

L'algorithme FCM est largement utilisé en traitement d'images, en particulier, médicales. Sa complexité réduite, son implémentation facile, notamment pour les données de taille importante, mais aussi son aspect flou (l'intégration du degré d'appartenance), sont les points forts qui lui ont attiré plus d'attention.

Néanmoins cet algorithme ne prend pas en compte la disposition spatiale des pixels et ne considère que le vecteur de caractéristiques utilisé. Négligeant ainsi les propriétés du voisinage du pixel considéré, ce qui induit à une sensibilité au bruit et aux inhomogénéités d'intensité.

Plusieurs modifications sont apportées à FCM afin d'améliorer la qualité de la classification, mais cela reste insuffisant. De ce fait, l'information seule du niveau de gris du pixel actuel, sans prise en compte de son voisinage, n'est pas suffisante pour aboutir à une classification robuste. La solution est d'incorporer les informations spatiales (locales) de l'image initiale dans l'algorithme de segmentation.

La littérature est riche dans cet axe, plusieurs travaux ont été réalisés afin de modifier la fonction coût de FCM. D'où l'apparition de plusieurs variantes, citons celles que nous allons étudier : RFCM (Robust FCM) [22] et la famille FCM_S (FCM with Spatial constraints) [21] (FCM_S1, FCM_S2, IFCM_S (Improved FCM algorithm)).

Chapitre III

Classification par considération du contexte spatial

L'algorithme FCM comme la méthode des centres mobiles, donne une partition globale de l'image sans tenir compte de l'interaction de l'information entre les pixels. L'intégration de l'information du voisinage permettra de réduire la sensibilité au bruit ainsi qu'aux inhomogénéités d'intensité. Pour ce faire, un terme tenant compte du contexte spatial est ajouté à la fonction objective de FCM.

III.1 Introduction :

Il existe deux approches de classification qui ont pour but la compensation des inhomogénéités d'intensité. La première propose de procéder d'abord à un filtrage et une correction d'inhomogénéité, puis passer à l'étape de classification. Ceci nécessite une connaissance à priori des paramètres d'acquisition [20]. La seconde approche propose l'utilisation des algorithmes qui intègrent les propriétés spatiales afin de réduire l'effet des inhomogénéités. Nous allons étudier quelques algorithmes qui répondent à ce problème. Parmi les variantes qu'on retrouve dans la littérature : Robust FCM (RFCM) [22], qui propose de travailler sur les degrés d'appartenance. En effet l'algorithme considère que le pixel actuel ne doit pas être classé avant d'examiner l'appartenance de ses voisins. (On peut « grossièrement » dire, que si les voisins appartiennent à la classe 2, même si le degré d'appartenance du pixel actuel à la classe 2 est faible, il l'a rejoindra comme même).

On passe ensuite à la famille dite Spacial FCM (FCM_S) [21], une version modifiée de FCM qui considère le contexte (propriétés) spatiale du voisinage. Ici on décide de l'appartenance d'un pixel à une classe donnée, en examinant la moyenne de son voisinage (moyenne de l'intensité du voisinage) pour FCM_S1, la médiane du voisinage pour FCM_S2 et les deux propriétés pour IFCM_S.

III.2 Notion de voisinage [1]:

Dans le cas d'une image à 2 dimensions, on définit deux types de voisinage :

- **4-voisins** (ou connexité 4) : prendre les voisins immédiats du pixel considéré.
- **8-voisins** (ou connexité 8) : prendre les voisins formant une fenêtre 3x3 autour du pixel considéré.

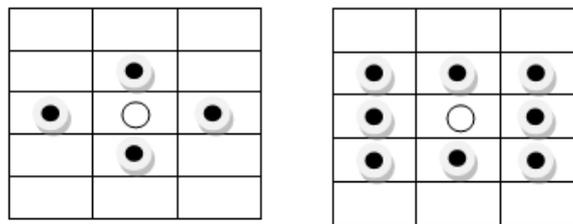


Figure III-1 : Connexité 4 et connexité 8

III.3 Algorithme RFCM [22] :

Il est clair que la fonction objective de la FCM standard ne prend pas en considération le contexte spatial. La sensibilité au bruit nécessitera donc un prétraitement de l'image avant la segmentation ; or on peut surpasser ce problème par une meilleure approche : la modification de la fonction coût de FCM.

Cet algorithme est appelé RFCM (Robust FCM). Sa fonction objective est donnée comme :

$$J_{FCM} = \sum_{j \in \Omega} \sum_{k=1}^c u_{jk}^m \|y_j - v_k\|^2 + \frac{\beta}{2} \sum_{j \in \Omega} \sum_{k=1}^c u_{jk}^m \cdot \sum_{l \in N_j} \sum_{q \in M_k \dots q \neq k} u_{lq}^m \quad (\text{III-1})$$

Avec m est l'indice de flou généralement égale à 2, C est nombre de classes, y_j est le pixel d'indice j appartenant à l'ensemble Ω qui représente l'image considérée. N est le cardinal de Ω . U_{jk} est matrice de degrés d'appartenance dont les éléments sont considérés positifs, avec la

contrainte :

$$\sum_{k=1}^c u_{jk} = 1 \quad (\text{III-2})$$

M_k est l'ensemble des centres de classes. β est un paramètre qui contrôle l'effet du voisinage sur un pixel donné. Le choix de ce paramètre est d'une grande importance.

La différence avec FCM standard est que les degrés d'appartenance d'un pixel incluent aussi ceux de ses voisins (on exploite le fait que la transition d'une région à une autre est graduelle).

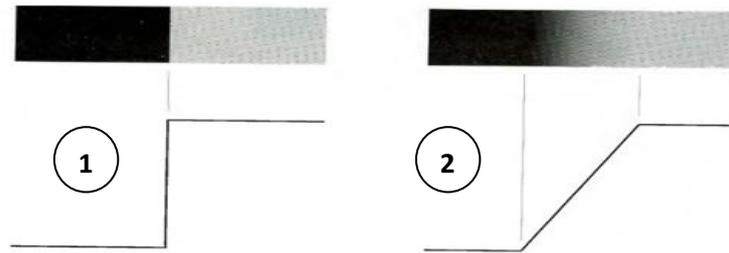


Figure III-2 : 1- transition directe 2- transition graduelle.

Le pixel actuel n'est affecté à une classe donnée que si les degrés d'appartenance de ses voisins, aux autres classes, sont relativement faibles.

La fonction d'appartenance est définie comme suit [22] :

$$u_{jk} = \frac{(\|y_j - v_k\|^2 + \beta \sum_{l \in N_j} \sum_{q \in M_k} u_{lq}^m)^{-1/(m-1)}}{\sum_{i=1}^c (\|y_j - v_k\|^2 + \beta \sum_{l \in N_j} \sum_{q \in M_k} u_{lq}^m)^{-1/(m-1)}} \quad (III-3)$$

Le nouveau algorithme est donné par :

Algorithme 5

Etape 1 : Obtenir les centres de classes initiaux v_k ; $k=1, \dots, C$

Etape 2 : Calculer les degrés d'appartenance en utilisant la formule (III-3)

Etape 3 : Mettre à jour les centres de classes par la formule :

$$v_k = \frac{\sum_{j \in \Omega} u_{jk}^m \cdot y_j}{\sum_{j \in \Omega} u_{jk}^m} \quad (III-4)$$

Etape 4 : Répéter l'étape 2 et 3 jusqu'à atteindre la convergence $\|V^{new} - V^{old}\| < \epsilon$

Algorithme III-1 : méthode RFCM (Robust FCM).

III.3.1 Choix du paramètre β :

Zung et Pham [22] ont étudié l'influence du paramètre β , ils ont remarqué qu'un bon choix de ce dernier est d'une grande importance, pour retrouver une solution optimale.

Quand on pose $\beta=0$, on obtient exactement l'algorithme FCM. Quand $\beta>0$, la fonction d'appartenance est dépendante des pixels voisins.

Il faut noter qu'il est difficile de retrouver le β adéquat d'une image qu'après avoir fait plusieurs tests. Ceci est dû au fait que la valeur optimale de ce paramètre varie d'une image à une autre.

III.3.2 Influence de l'initialisation :

Pour RFCM, on a choisi l'utilisation de la connexité 4 pour le voisinage. On a tenté d'utiliser différentes initialisations : par K-means et par histogramme. Puisque on a deux niveaux de gris, donc il suffit de chercher les deux pics significatifs pour initialiser les centres.

On a testé la 2^{ème} image synthétique avec 4% de bruit. Les résultats sont illustrés par la figure (III-4) :

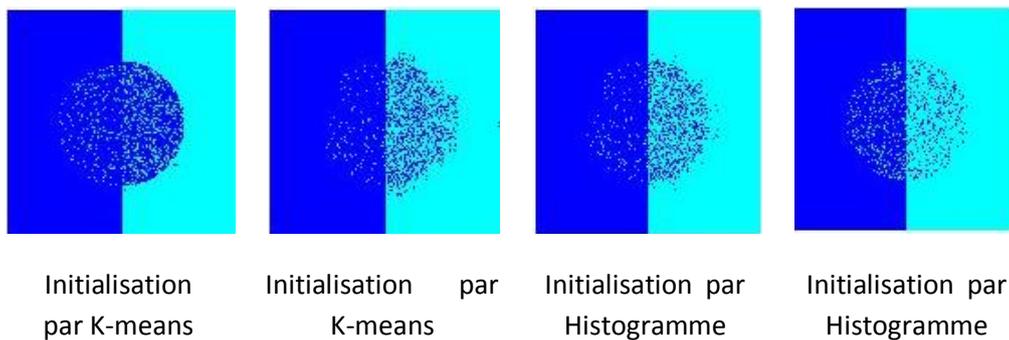


Figure III-4 : Influence de l'initialisation sur l'algorithme RFCM.

Pour mieux illustrer le problème d'initialisation, on a calculé le MCR correspondant pour chaque image.

Initialisation	K-means	K-means	Histogramme	Histogramme
Nombre pixels mal classés	830	690	246	190
MCR	5,06 %	4,21 %	1,50 %	1,16 %

Tableau III-1 : MCR obtenu pour la classification de la 2^{ème} image synthétique par RFCM.

Les résultats retrouvés sont différents pour une même initialisation. En effet le choix de β joue un rôle important dans la qualité de classification obtenue.

Et c'est évident que l'initialisation par histogramme est meilleure que l'utilisation de l'algorithme K-means. Malheureusement, ceci ne peut pas se faire pour toutes les images. Notamment pour celles qui présentent une inhomogénéité d'intensité, un gradient faible ou celles qui sont fortement texturés. Avoir les pics de l'histogramme dans ces cas ne sera pas évident.

III.3.3 Influence du bruit et de l'inhomogénéité :

On a opté pour une initialisation par histogramme. En variant le niveau du bruit, on observe les différents résultats.

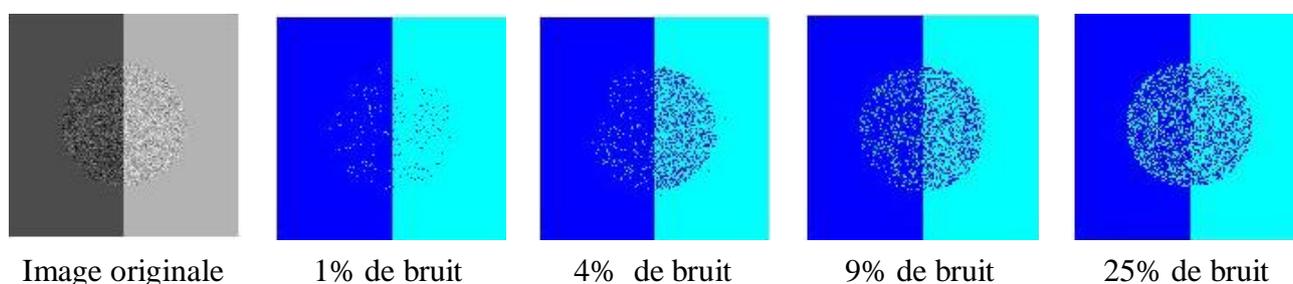


Figure III-5 : Résultat de la classification de la 2^{ème} image synthétique par RFCM.

Le tableau suivant donne le MCR correspondant à chaque image.

Bruit	1%	4%	9%	25%
Nombre de pixels non classés	114	190	700	1016
MCR	0,69 %	1,16 %	4.25 %	6,20 %

Tableau III-2 : MCR obtenu pour la classification de la 2^{ème} image synthétique par RFCM.

Cet algorithme donne des résultats nettement meilleurs que FCM. Pour 9% du bruit, par exemple, on a un MCR de 4,25% au lieu de 6,28% pour FCM. C'est vrai que l'algorithme PDI donne aussi de bons résultats, mais sa dépendance à l'initialisation est importante lorsque l'image présente des inhomogénéités d'intensité.

Bien que RFCM est plus robuste au bruit, mais il présente un inconvénient majeur : le choix du paramètre β . La sensibilité à l'initialisation, est moins importante, car on peut toujours compenser par le réglage de β .

Un autre problème paraît lorsque l'image est fortement inhomogène. Un MCR de 6,20% est loin d'être bon pour une image à deux niveaux de gris. Donc l'information du niveau de gris seule ne suffit pas, il est intéressant de faire appel aux propriétés spatiales du voisinage. C'est la modification apportée par la famille FCM_S.

III.4 L'algorithme FCM_S (Spatial FCM) :

Ici l'algorithme considère les propriétés spatiales des pixels formant une fenêtre **3x3**, telle que la moyenne et la variance, pour former le vecteur d'attributs, en plus des niveaux de gris de chaque pixel.

FCM est modifié de telle sorte que chaque pixel soit influencé par son voisinage, la fonction objective devient alors : [21]

$$J_{FCM_S} = \sum_{j=1}^N \sum_{k=1}^c u_{jk}^m \cdot \|y_j - v_k\|^2 + \frac{\alpha}{N_j} \sum_{j=1}^N \sum_{k=1}^c u_{jk}^m \cdot \sum_{r \in N_R} \|y_r - v_k\|^2 \quad (\text{III-5})$$

Avec y_j est un élément de l'image initiale. v_k est le centre de la classe i . u_{ik} est le degré d'appartenance de l'élément i à la classe k . y_r est le pixel voisin. N_R est le nombre de voisins dans la fenêtre 3x3 (soit égal à 8). N_k est le cardinal du sous ensemble des voisins. α est un paramètre qui contrôle l'effet du voisinage. Quand $\alpha=0$, on obtient l'algorithme FCM standard.

La matrice d'appartenance est donnée par la relation suivante [21]:

$$u_{jk} = \frac{(\|y_j - v_k\|^2 + \frac{\alpha}{N_j} \sum_{r \in N_R} \|y_r - v_k\|^2)^{\frac{-1}{m-1}}}{\sum_{k=1}^c (\|y_j - v_k\|^2 + \frac{\alpha}{N_j} \sum_{r \in N_R} \|y_r - v_k\|^2)^{\frac{-1}{m-1}}} \quad (\text{III-6})$$

Les centres de classe dépendent eux aussi des propriétés de leur voisinage, ils sont donnés par la relation suivante :

$$v_k = \frac{\sum_{j=1}^N u_{jk}^m (y_j + \frac{\alpha}{N_j} \sum_{r \in N_R} y_r)}{(1 + \alpha) \cdot \sum_{j=1}^N u_{jk}^m} \quad (\text{III-7})$$

Le terme $\frac{1}{N_j} \sum_{r \in N_R} y_r$ représente la moyenne des niveaux de gris des voisins formant une fenêtre 3x3 du pixel considéré. Il a l'effet d'un filtre moyennneur parcourant toute l'image.

Ce terme est calculé pour chaque itération, ce qui rend l'algorithme couteux en temps d'exécution, notamment pour les données d'importante taille. Pour y remédier, Chen et Zhang [21] ont simplifié la fonction objective en le remplaçant par la moyenne des voisins \bar{y} qui peut être, directement, calculée hors de la boucle principale.

La fonction objective sera alors [21]:

$$J_{FCM_S} = \sum_{j=1}^N \sum_{k=1}^c u_{jk}^m \cdot \|y_j - v_k\|^2 + \alpha \sum_{j=1}^N \sum_{k=1}^c u_{jk}^m \cdot \|\bar{y}_j - v_k\|^2 \quad (\text{III-8})$$

La fonction d'appartenance est donnée par :

$$u_{jk} = \frac{(\|y_j - v_k\|^2 + \alpha \|\bar{y}_j - v_k\|^2)^{\frac{-1}{m-1}}}{\sum_{k=1}^c (\|y_j - v_k\|^2 + \alpha \|\bar{y}_j - v_k\|^2)^{\frac{-1}{m-1}}} \quad (\text{III-9})$$

Et les centres de classes sont donnés par :

$$v_k = \frac{\sum_{j=1}^N u_{jk}^m (y_j + \alpha \bar{y}_j)}{(1 + \alpha) \cdot \sum_{j=1}^N u_{jk}^m} \quad (\text{III-10})$$

En remplaçant la moyenne des voisins \bar{y} par leurs médiane \tilde{y} , nous obtenons l'algorithme FCM_S2 [23].

L'algorithme FCM_S1 et FCM_S2 est donné par:

Algorithme 6

- Etape 1** : Fixer le nombre de classes C.
- Etape 2** : Initialiser les centres de classes par K-means.
- Etape 3** : Calculer le filtre médian (pour FCM_S2) ou moyennneur (pour FCM_S1).
- Etape 4** : Mise à jour de la matrice d'appartenance avec la relation (III-9).
- Etape 5** : Mise à jour des centres de classes avec la relation (III-10).
- Etape 6** : Répéter les étapes 4 et 5 jusqu'à : $\|v^{new} - v^{old}\| < \varepsilon$.

Algorithme III-2 : la méthode FCM_S (Spatial FCM).

III.4.1 Fonctionnement du FCM_S1 et FCM_S2:

On considère la portion d'image suivante :

123	124	120	120	119
130	120	120	10	117
127	120	255	119	120
128	120	120	122	122
120	121	110	119	120

Figure III-6 : Illustration du fonctionnement de FCM_S1.

Pour le pixel représenté par la case en rouge, l'algorithme FCM_S1 (respectivement FCM_S2) calcule la **moyenne** (respectivement la **médiane**) de ces voisins représentés par la fenêtre 3x3 représentée en bleu. Ceci est fait pour toute l'image. Analogie à l'application du FCM avec un vecteur d'attributs {niveau de gris, moyenne} (ou {niveau de gris, médiane}). Le pixel actuel n'est affecté à une classe donnée que si la moyenne (respectivement la médiane) des intensités des voisins est très proche de l'intensité du centre de cette classe.

III.4.2 Influence du bruit et de l'inhomogénéité sur FCM_S1:

On a testé cet algorithme avec les deux images synthétiques. La première totalement noyée dans 1%, 4%, 7% de bruit.

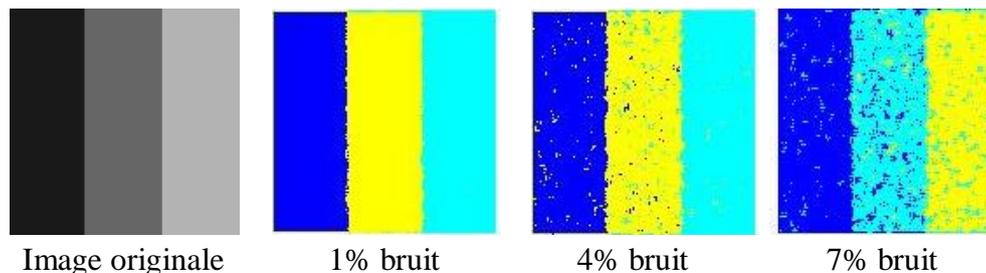


Figure III-7 : Résultat de la classification de la 1^{ère} image synthétique par FCM_S1.

L'inconvénient majeure pour l'algorithme FCM_S et ses variantes est de trouver une valeur optimale du paramètre α (pour ces images $16 < \alpha < 18$). La variation de ce paramètre affecte énormément la qualité de la segmentation.

Cet algorithme est très robuste au bruit, nous remarquons que pour 1% et 4% de bruit, la classification est assez bonne.

Voici les résultats obtenus pour la deuxième image synthétiques :

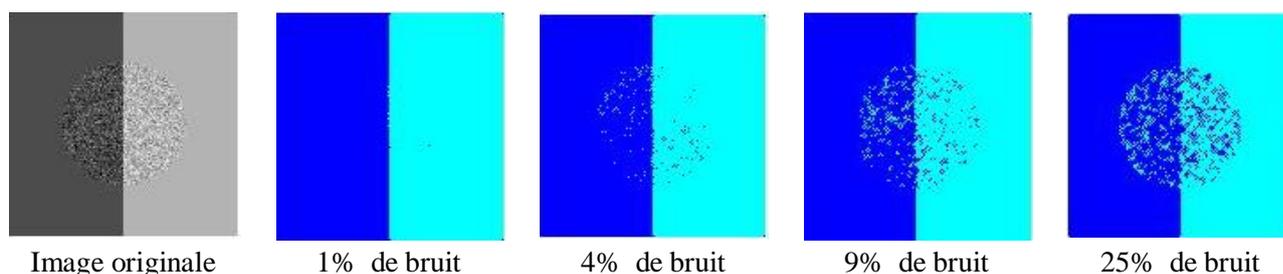


Figure III-8 : Résultat de la classification de la 2^{ème} image synthétique par FCM_S1.

D'après les résultats, cet algorithme n'est pas seulement plus robuste au bruit, mais aussi traite mieux les inhomogénéités d'intensité. Pour l'image à 1% de bruit, la classification est presque parfaite, elle est très bonne aussi pour 4% du bruit. Le calcul du MCR illustre mieux ces résultats:

Bruit	1%	4%	9%	25%
Nombre de pixels non classés	8	74	259	640
MCR	0.05%	0.45%	1.58%	3.90%

Tableau III-3 : MCR obtenu pour la classification de la 2^{ème} image synthétique par FCM_S1.

III.4.3 Influence du bruit et de l'inhomogénéité sur FCM_S2:

On a testé cet algorithme avec la deuxième image synthétique. On a obtenu les résultats suivants :

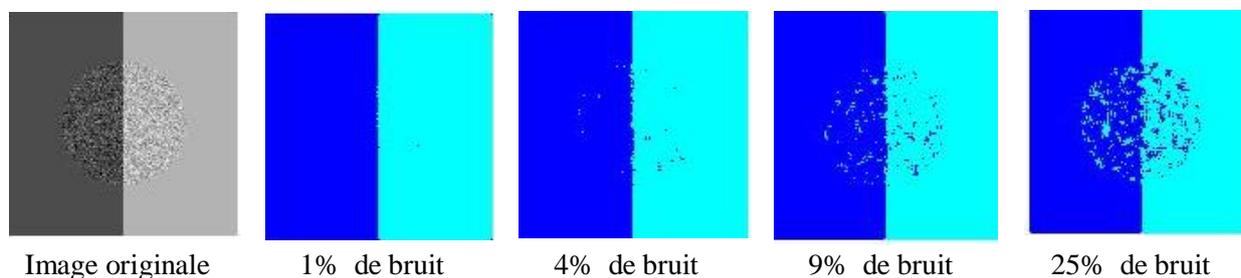


Figure III-9 : Résultat de la classification de la 2^{ème} image synthétique par FCM_S2.

Pour pouvoir comparer cet algorithme avec FCM_S1, et voir l'effet d'utiliser la médiane au lieu de la moyenne, on calcule le MCR correspondant à chaque image.

Bruit	1%	4%	9%	25%
Nombre de pixels non classés	7	54	176	485
MCR	0.042%	0.32%	1.07%	2.96%

Tableau III-4 : MCR obtenu pour la classification de la 2^{ème} image synthétique par FCM_S2.

En comparant les deux tableaux III-3 et III-4, on remarque que FCM_S2 donne un meilleur taux de classification.

III.5 Improved FCM Algorithm :

Puisque l'introduction des deux propriétés spatiales (moyenne et médiane) a beaucoup amélioré la qualité de la classification, il serait intéressant de combiner les deux.

La fonction objective devient alors [24]:

$$J_{IFCM_S} = J_{FCM_S1} + \alpha_2 \sum_{j=1}^N \sum_{k=1}^c u_{jk}^m \cdot \|\tilde{y}_j - v_k\|^2 \quad (\text{III-11})$$

Avec y_j est un élément de l'image initiale. v_k est le centre de la classe k . u_{ik} est le degré d'appartenance de l'élément i à la classe k . y_r est le pixel voisin. N_R est nombre de voisins dans la fenêtre 3x3 (soit égal à 8). N_k est le cardinal du sous ensemble des voisins. α_1 et α_2 sont des paramètres qui contrôlent l'effet du voisinage. Quand $\alpha_1 = \alpha_2 = 0$, on obtient l'algorithme FCM standard. \tilde{y}_j est la médiane des voisins représentée par la fenêtre 3x3 du pixel actuel y_j .

La fonction d'appartenance est donnée par [24] :

$$u_{jk} = \frac{(\|y_j - v_k\|^2 + \alpha_1 \|\bar{y}_j - v_k\|^2 + \alpha_2 \|\tilde{y}_j - v_k\|^2)^{\frac{-1}{m-1}}}{\sum_{k=1}^c (\|y_j - v_k\|^2 + \alpha_1 \|\bar{y}_j - v_k\|^2 + \alpha_2 \|\tilde{y}_j - v_k\|^2)^{\frac{-1}{m-1}}} \quad (\text{III-12})$$

Les centres de classes sont données par :

$$v_k = \frac{\sum_{j=1}^N u_{jk}^m (y_j + \alpha_1 \bar{y}_j + \alpha_2 \tilde{y}_j)}{(1 + \alpha_1 + \alpha_2) \cdot \sum_{j=1}^N u_{jk}^m} \quad (\text{III-13})$$

L'algorithme est donnée par :

Algorithme 7

Etape 1 : Fixer le nombre de classes C .

Etape 2 : Initialiser les centres de classes par K-means.

Etape 3 : Calculer le filtre médian et le filtre moyenneur.

Etape 4 : Mise à jour de la matrice d'appartenance avec la relation (III-12).

Etape 5 : Mise à jour des centres de classes avec la relation (III-13).

Etape 6 : Répéter les étapes 3 et 4 jusqu'à : $\|v^{new} - v^{old}\| < \varepsilon$.

Algorithme III-3 : la méthode FCM_S (Spatial FCM).

• **Influence du bruit et de l'inhomogénéité sur IFCM_S:**

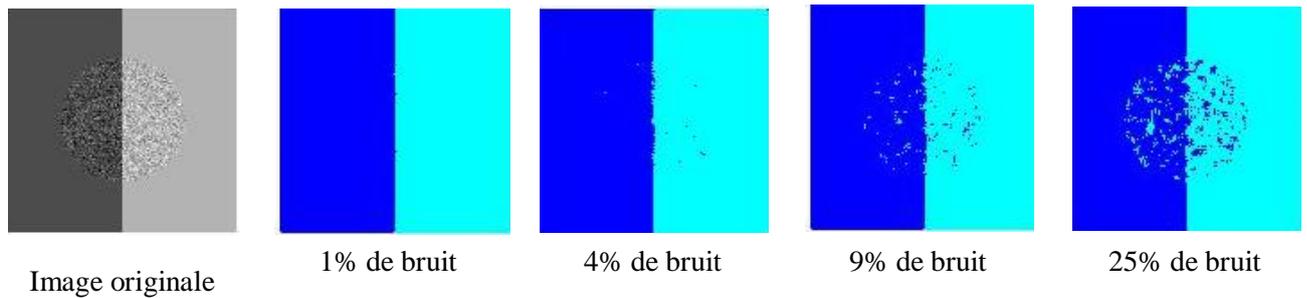


Figure III-10 : Résultat de la classification de la 2^{ème} image synthétique par IFCM_S.

Le tableau suivant montre le MCR calculé pour chaque image :

bruit	1%	4%	9%	25%
Nombre de pixels non classifiés	7	42	116	419
MCR	0.042%	0.25	0.70	2.56%
α_1 et α_2	17 et 36	26 et 16	36 et 16	36 et 16

Tableau III-5 : MCR obtenu pour la classification de la 2^{ème} image synthétique par IFCM_S.

On remarque que l'intégration des deux propriétés (moyenne et médiane) a amélioré d'avantage le résultat de la classification.

III-6 Conclusion :

Nous avons étudié dans ce chapitre quelques variantes de FCM. Nous avons montré que l'incorporation du contexte spatial était très bénéfique, et a rendu l'algorithme de classification plus performant.

Le premier algorithme (RFCM) a démontré une robustesse au bruit en le comparant avec FCM standard, mais lorsque l'image est inhomogène cet algorithme ne donne pas de résultats satisfaisants. En plus que la qualité de classification est trop dépendante du paramètre β . L'inconvénient n'est pas seulement la recherche de β mais aussi sa variation d'une image à une autre.

Les résultats obtenus de la classification par la famille d'algorithmes FCM_S sont encourageants. Même si le problème du choix des paramètres se pose aussi. En effet l'information extraite du voisinage a permis d'obtenir des structures lisses, et de diminuer, remarquablement, les inhomogénéités d'intensité.

Dans le prochain chapitre, le test des différents algorithmes sur des images réelles, et de leurs performances dans le cas de la classification d'images médicales est effectué. Notre étude va porter sur des images IRM (Imagerie par Résonance Magnétique) du cerveau. L'objectif est de retrouver les trois régions qui représentent les tissus principaux du cerveau (la substance blanche (MB), le cortex cérébral ou substance grise (MG) et le liquide Céphalo-rachidien (LCR)).

Chapitre VI

Application à l'Imagerie par Résonance Magnétique(IRM)

L'imagerie par résonance magnétique permet d'analyser à distance des organes tels que le cerveau, la colonne vertébrale, les articulations ...etc de manière très précise. L'IRM est devenu un outil de diagnostic clinique très utilisé. Néanmoins les images IRM sont sujettes, lors de leurs acquisitions, à différentes imperfections (bruit, artefacts de mouvement, inhomogénéités d'intensité) qui peuvent déformer l'image ou de simuler un processus pathologique (une anomalie qui n'existe pas en réalité). Ceci affectera sûrement l'interprétation du résultat. Donc posséder un algorithme performant de classification sera d'un apport très important pour les cliniciens.

IV.1 Anatomie du cerveau [25] :

Le système nerveux est constitué de la moelle épinière logée dans le canal vertébral et de l'encéphale. Cette dernière se compose du tronc cérébral, du cervelet et du cerveau. L'ensemble flotte dans le liquide céphalo-rachidien.

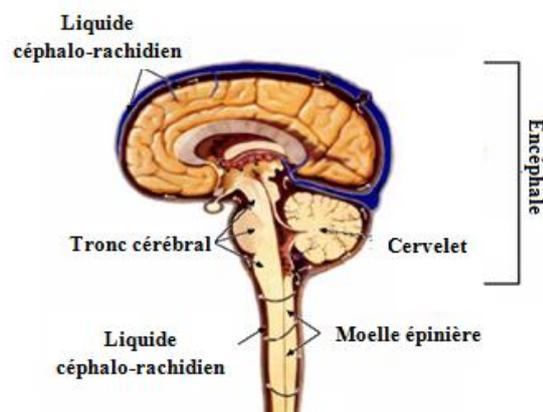


Figure VI-1 : Système nerveux central humain.

Les tissus principaux du cerveau sont : la substance blanche (MB), le cortex cérébral ou substance grise (MG) et le liquide Céphalo-rachidien (LCR).

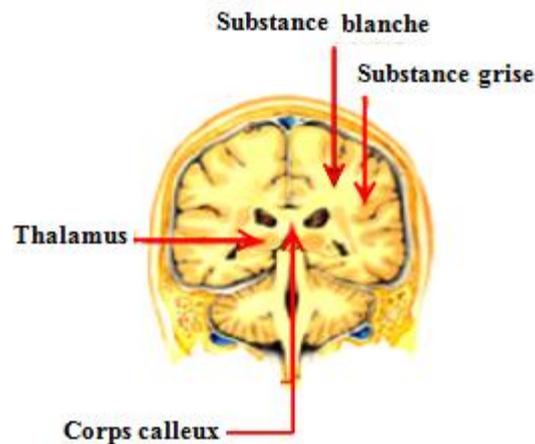


Figure VI-2 : Coupe coronale du cerveau.

IV.2 Imagerie par résonance magnétique :

L'IRM étant « non invasive », est devenue l'un des plus populaires outils de diagnostic dans la neuroradiologie. Cette technique est très utilisée dans le suivi de différentes pathologies : Alzheimer, Parkinson, ... etc.

L'IRM est une technique d'imagerie médicale basée sur le principe de la résonance magnétique nucléaire RMN [annexe2]. Elle donne une description 2D ou 3D d'une partie du corps, notamment du cerveau (En pratique, les images IRM sont fournies sous forme d'un ensemble de coupes 2D qui, mises dans la bonne géométrie, vont former une image tridimensionnelle).

IV.2.1 Principe de fonctionnement [26]:

Le principe consiste à mesurer l'aimantation des tissus biologiques et à reconstruire une image à partir de ces aimantations [annexe2]. Cette dernière est induite par l'hydrogène, qui s'y trouve en abondance dans le corps humain.

Placés dans un puissant champ magnétique, tous les atomes d'hydrogène s'orientent dans la même direction : ils sont alors excités par des ondes radio durant une très courte période. A l'arrêt de cette stimulation, les atomes restituent l'énergie accumulée en produisant un signal qui est enregistré et traité sous forme d'image par un système informatique. La zone étudiée peut être restituée en deux ou trois dimensions.

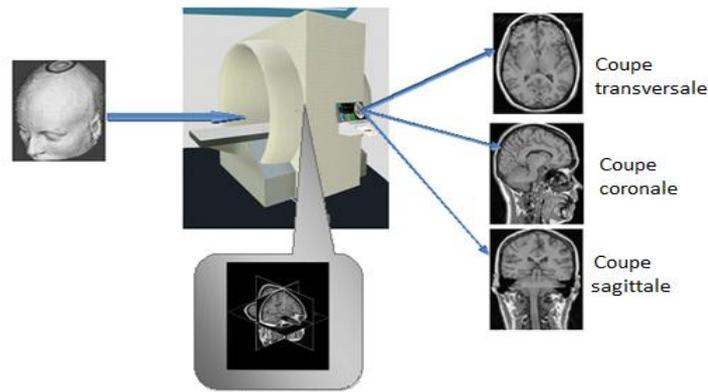


Figure VI-3 : Acquisition des images IRM.

IV.2.2 Imperfections en IRM :

En IRM, il existe plusieurs formes de perturbations qui affectent la qualité de la segmentation [27] :

- **Le bruit** : dû soit au processus d'acquisition, soit aux conditions d'environnement (lumière, reflet ...).
- **Les inhomogénéités RF** : les inhomogénéités dans le champ magnétique généré par les ondes radio (ou impulsions radiofréquence) appliquées lors de l'acquisition, provoquent des variations d'intensité au sein d'un même tissu.
- **Les artefacts de mouvement** : dû aux mouvements du patient pendant l'acquisition de l'image (apparition d'images fantômes).

Ces perturbations peuvent déformer l'image ou simuler un processus pathologique. Ceci va rendre l'analyse de l'image plus complexe et induira à une erreur d'interprétation.

Traiter ces imperfections pendant l'acquisition (filtrage du bruit et correction d'inhomogénéités) est une solution peu tolérée car elle est couteuse en temps. L'idéal est de trouver un algorithme de segmentation robuste au bruit et aux inhomogénéités d'intensité.

Voici un exemple d'une image réelle qui présente une inhomogénéité d'intensité. Malheureusement, nous n'avons aucune connaissance a priori sur cette image, pour pouvoir l'utiliser pour les tests. Ceci est d'ailleurs la difficulté majeure dans la segmentation : la non disponibilité d'une base de vérité terrain.



Figure VI-4 : Exemple d'une image réelle.

IV.3 Base de données Brainweb:

Bien que certains cliniciens développent leurs propres bases, elles sont, malheureusement, inaccessibles. C'est pour cela que la littérature recommande d'utiliser **Brainweb** [<http://mouldy.bic.mni.mcgill.ca/brainweb/>], une base de données fournie par un puissant simulateur, mis en ligne par le centre d'imagerie cérébrale McConnell de l'institut neurologique de Montréal à l'université McGill. Cet institut s'intéresse à mieux comprendre les maladies neurologiques par différentes méthodes d'imagerie.

Ce simulateur permet d'obtenir des images très proches de la réalité. En plus il nous permet de choisir différents paramètres : niveaux de bruit, taux d'inhomogénéité, modalité T1 ou T2 [Annexe2], résolution, ... etc. Il offre aussi des images de référence ainsi leurs segmentations (réalisées manuellement).

C'est ces données, qui nous permettent d'évaluer les performances des différents algorithmes.

IV.4 Pré-segmentation de la zone d'intérêt du cerveau :

La segmentation de la zone d'intérêt du cerveau constitue un prétraitement usuel des images IRM. L'objectif d'une telle étape est d'isoler le cerveau. Une image IRM est essentiellement composée de matière blanche, matière grise, liquide céphalo-rachidien, ainsi que d'autres tissus environnant (peau, graisse, crâne,...).

L'étape de la pré-segmentation vise à éliminer ces tissus environnants. L'intérêt d'un tel prétraitement est double. D'une part, il permet de réduire la zone de travail (réduire le volume des données à traiter). D'autre part, travailler seulement sur les régions d'intérêt (MG, MB et LCR), rend les traitements plus performants.

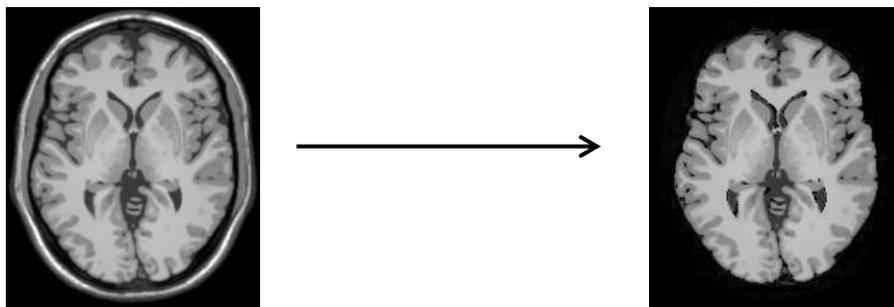


Figure VI-5 : Pré-segmentation d'une image IRM.

IV.5 Résultats et Discussion :

Nous présentons dans ce qui suit les résultats obtenus pour les différents algorithmes étudiés dans les chapitres précédents.

Les algorithmes sont implémentés sous Matlab, sur un PC qui possède un microprocesseur Intel Pentium 4 (2 x 2,17 GHz) et une RAM de 2GO.

Nous avons utilisé des images IRM, de pondération **T1**, de dimension (181x217x181), et comme nous travaillons en 2D, on a utilisé la coupe transversale n°79 (slice79).

Nous avons choisi un jeu d'images corrompues par différents niveaux de bruit (3%, 5% et 7%) et d'inhomogénéités (20%, 40% et 60%).

IV.5.1 Etape d'initialisation :

Pour l'algorithme FCM, l'initialisation des centres de classes est aléatoire, pour les autres algorithmes, l'initialisation est faite par l'algorithme K-means.

Le vecteur d'attributs est constitué des différents niveaux de gris constituant l'image et pour la mesure de similarité, la distance Euclidienne est utilisée.

Le degré de flou m est choisi égal à 2, le nombre de classes est de 3 (LCR, MG et MB), l'erreur (critère d'arrêt) ε égale à 0.01, le paramètre r de l'algorithme PDI est égal à 1.5 et pour les propriétés spatiales des voisins, nous avons utilisé une fenêtre 3x3.

IV.5.2 Choix des paramètres :

On a vu dans le chapitre précédent que les algorithmes dépendent tous des paramètres (β pour RFCM, α_1 et α_2 pour FCM_S), qui contrôlent l'effet du voisinage sur le processus de classification.

Le choix de ces paramètres est d'une importance majeure, et influe considérablement sur la qualité de la classification. Malheureusement, ces paramètres varient d'une image à une autre, ce qui rend, fastidieuse, la recherche de la valeur optimale de chaque paramètre (sans oublier que la classification elle-même dépend de l'étape d'initialisation).

Pour ce travail, nous avons trouvé que le paramètre β de RFCM varie entre 210 et 320 pour les images étudiées. Et α_1 et α_2 de FCM_S varient entre 0.08 et 0.2.

IV.5.3 Problème d'évaluation [2] :

Un critère d'évaluation a pour objectif d'attribuer à une partition donnée un coefficient qui reflète la qualité de la classification obtenue par l'algorithme considéré. Le problème est qu'il n'existe pas un critère universel qui puisse décider de cela.

C'est la raison pour laquelle, l'évaluation et la comparaison des différents algorithmes restent subjectives, et dépendent de type de données que l'on possède ainsi que les connaissances a priori les concernant (nombre de classes, modèle de classes fourni par un expert, modèle décrivant les données ...).

En effet, il existe deux approches d'évaluation. Dans la première, la partition trouvée est évaluée en mesurant l'écart qu'elle présente par rapport à une segmentation (classification) de référence (Pour notre cas, Brainweb fourni des images réelles IRM avec une segmentation de référence effectuée manuellement). La seconde approche consiste à se référer à l'image originale. Dans ce cas, un modèle d'erreur est défini afin d'estimer la qualité du résultat (pour une segmentation par approche région par exemple, un critère d'homogénéité est défini, afin de mesurer l'homogénéité entre les régions).

Les critères d'évaluation utilisés dans ce qui suit sont le taux de classification (MCR) défini dans le deuxième chapitre, et pour les différentes classes un taux de classification (CR) appelé, généralement, dans la littérature par SA (Segmentation Accuracy) et le coefficient de Jaccard (J).

- Le taux de classification (CR) traduit le pourcentage des pixels appartenant à une classe (LCR par exemple) classés correctement à cette classe (LCR). Il est défini de la même manière que le MCR :

$$CR = \frac{\text{Nombre de pixels correctement classés à la classe } i}{\text{Nombre total de pixels de la classe } i} \times 100 \quad (\text{VI-1})$$

- Quand toutes les méthodes donnent un MCR presque égal. Un autre coefficient peut être calculé, Il s'agit du coefficient de Jaccard [3] qui examine la classification de plus près. A chaque classe, il vérifie l'ensemble des pixels classés au tissu d'origine et aussi l'ensemble des pixels qui sont classés à tort à un autre tissu. Il est défini par :

$$J = \frac{VP}{VP \cup FP \cup FN} \quad (\text{VI-2})$$

Avec : VP (Vrai Positif) est l'ensemble des pixels correctement identifiés (C.à.d. : un pixel appartenant à LCR est classé à LCR).

FP (Faux Positif) est l'ensemble des pixels classés à tort comme appartenant à la classe considérée. (C.à.d. : un pixel appartenant à MG est classé à LCR).

FN (Faux Négatif) est l'ensemble des pixels classés à tort comme appartenant à une autre classe. (C.à.d. : un pixel appartenant à LCR est classé à MB).

L'opérateur \cup désigne l'union d'ensembles.

Une valeur nulle du coefficient J indique une segmentation complètement fautive, tandis qu'une valeur égale à l'unité indique une segmentation parfaite.

IV.5.4 Influence du bruit :

Nous comparons FCM aux différentes variantes en utilisant des images bruitées à différents niveaux de bruit : 3%, 5% et 7% avec 0% d'inhomogénéités. Les résultats obtenus sont présentés dans la figure suivante :

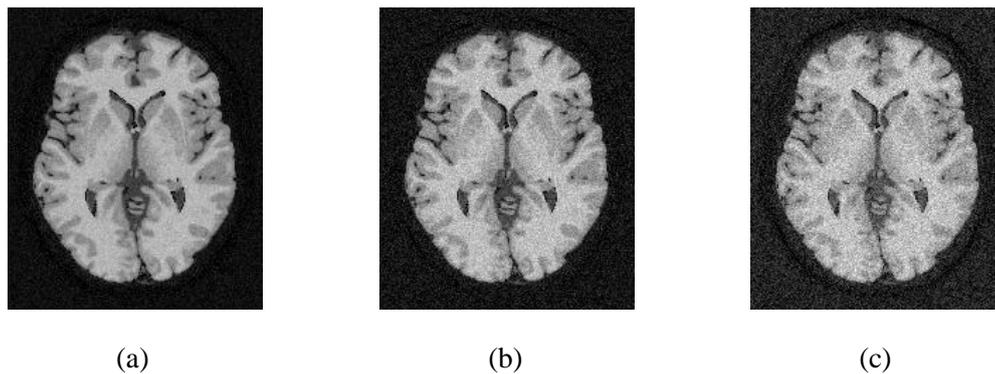


Figure VI-6 : Images IRM bruitées (a) 3%, (b) 5% et (c) 7%.

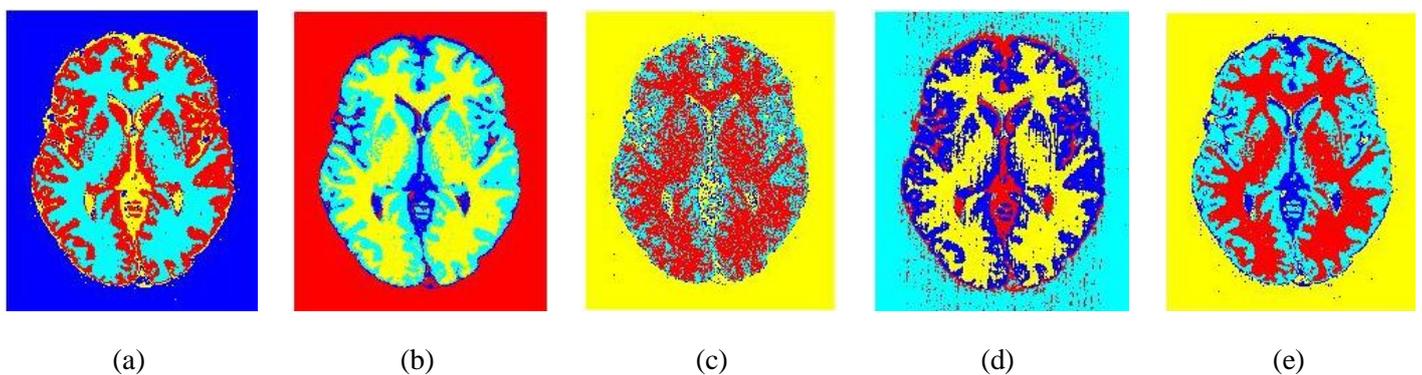


Figure VI-7 : Résultats de la segmentation par (a) FCM, (b) PDI, (c) RFCM, (d) FCM_S1 et (e) FCM_S2 pour une image à 3% de bruit.

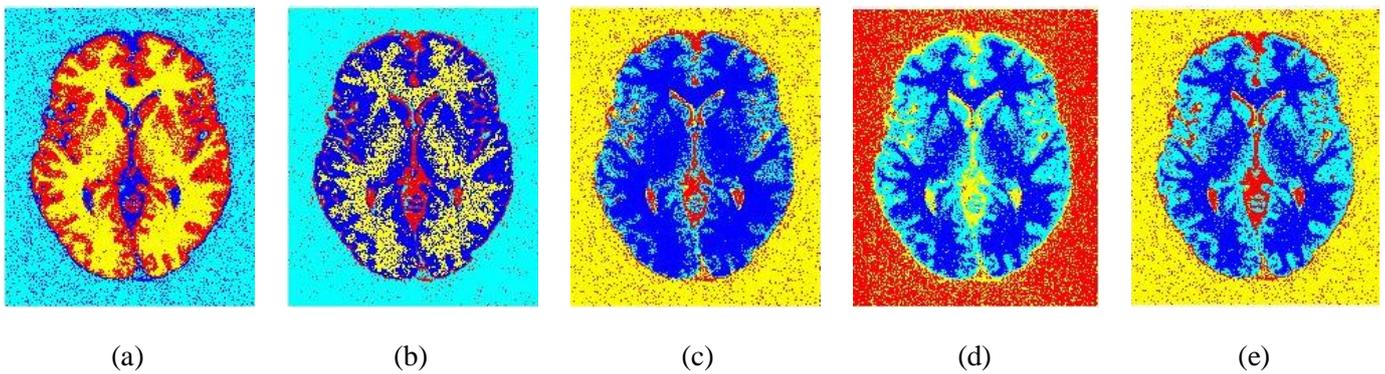


Figure VI-8 : Résultats de la segmentation par (a) FCM, (b) PDI, (c) RFCM, (d) FCM_S1 et (e) FCM_S2 pour une image à 5% de bruit.

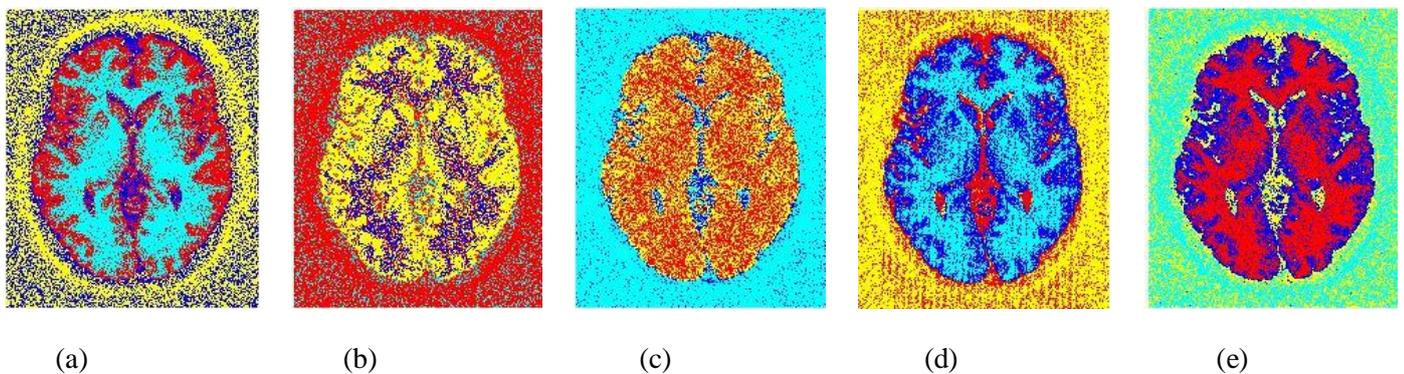


Figure VI-9 : Résultats de la segmentation par (a) FCM, (b) PDI, (c) RFCM, (d) FCM_S1 et (e) FCM_S2 pour une image à 7% de bruit.

Il est clair qu'à fur et à mesure que le niveau du bruit augmente, la qualité de classification se dégrade. Mais il n'est pas facile de décider quel est le meilleur résultat. Alors pour mieux comparer les résultats, on a calculé le taux de miss-classification pour les différentes partitions obtenues.

Algorithme	Bruit		
	3 %	5 %	7 %
FCM_S2	07.58	08.44	12.37
FCM_S1	05.23	09.37	10.07
RFCM 4	07.58	08.48	09.38
PDI	07.77	08.24	08.50
FCM	07.88	10.39	13.37

Tableau VI-1 : MCR calculé pour les images bruitées.

La sensibilité au bruit apparait clairement sur le MCR obtenu pour FCM. PDI a donné un bon résultat mais sa dépendance de l'initialisation est très importante.

Les résultats de RFCM et FCM_S1 sont plutôt stables, bien sûr un meilleur choix de leurs paramètres donnerait une meilleure partition.

Pour le niveau de bruit 7%, il est nécessaire de signaler que l'étape de pré-segmentation (élimination des tissus non cérébraux) peut influencer le résultat de classification. Car la suppression de ces parties (l'image étant fortement bruitée) n'est pas parfaite.

IV.5.5 Influence des inhomogénéités :

Nous comparons FCM aux différentes variantes en utilisant des images bruitées à 5% et avec différents niveaux d'inhomogénéités : 20%, 40% et 60%. Les résultats obtenus sont présentés dans la figure suivante :

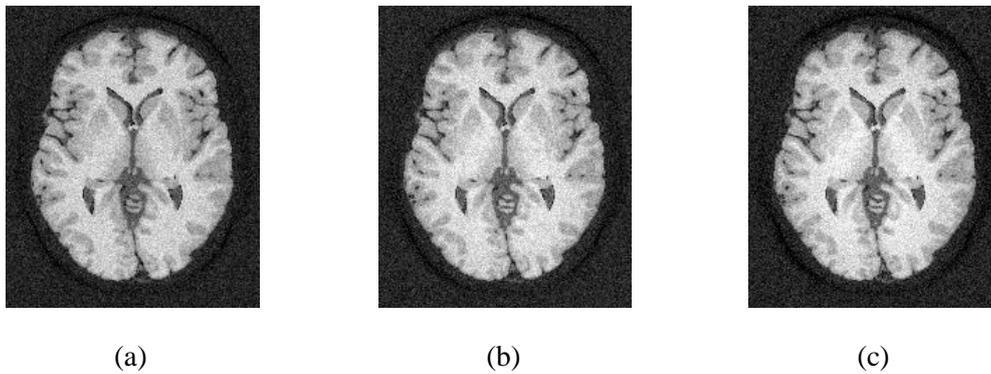


Figure VI-10 : Images IRM à 5% de bruit et à (a) 20%, (b) 40% et (c) 60% d'inhomogénéités.

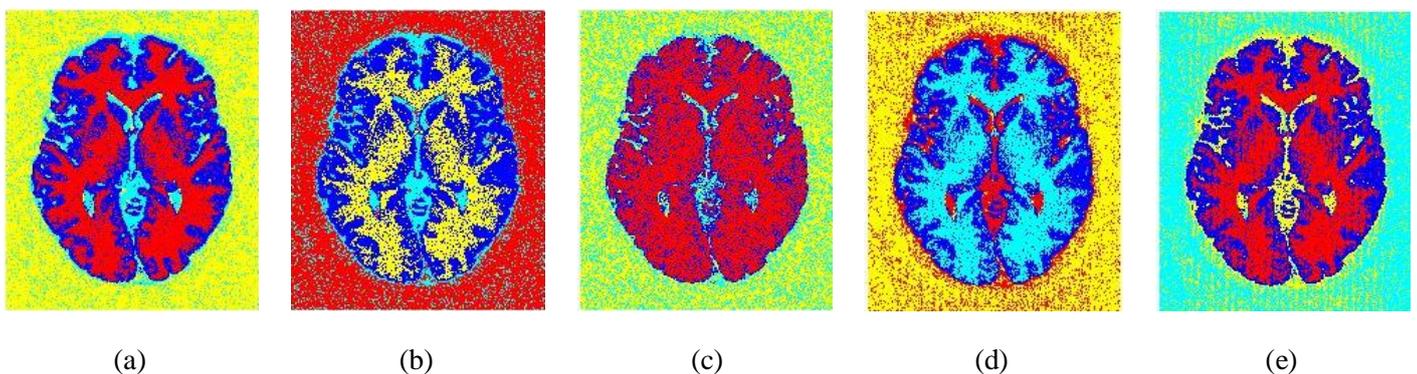


Figure VI-11 : Résultats de la segmentation par : (a)FCM, (b) PDI, (c)RFCM, (d) FCM_S1 et (e)FCM_S2 pour une image à 5% de bruit et 20% d'inhomogénéité.

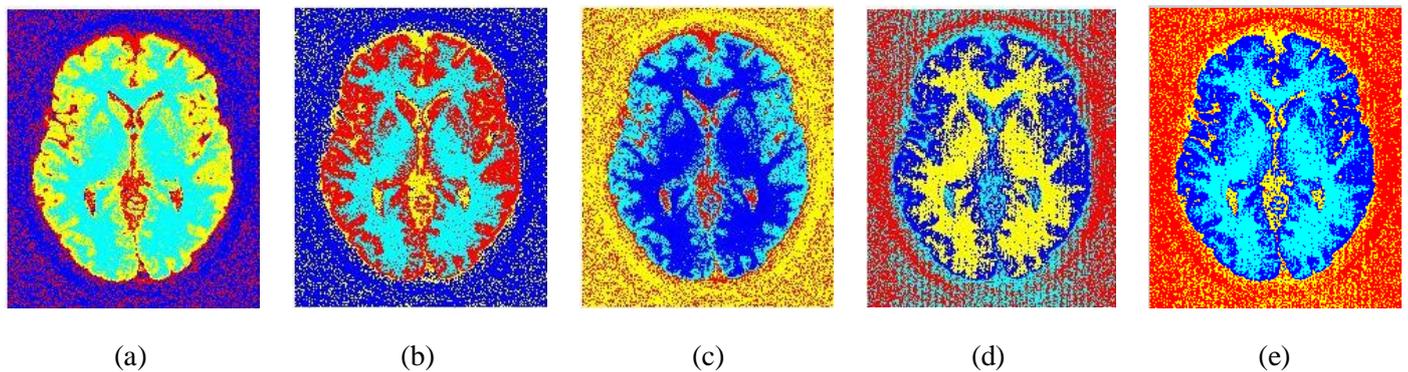


Figure VI-12 : Résultats de la segmentation par : (a)FCM, (b) PDI, (c)RFCM, (d) FCM_S1 et (e)FCM_S2 pour une image à 5% de bruit et 40% d'inhomogénéité.

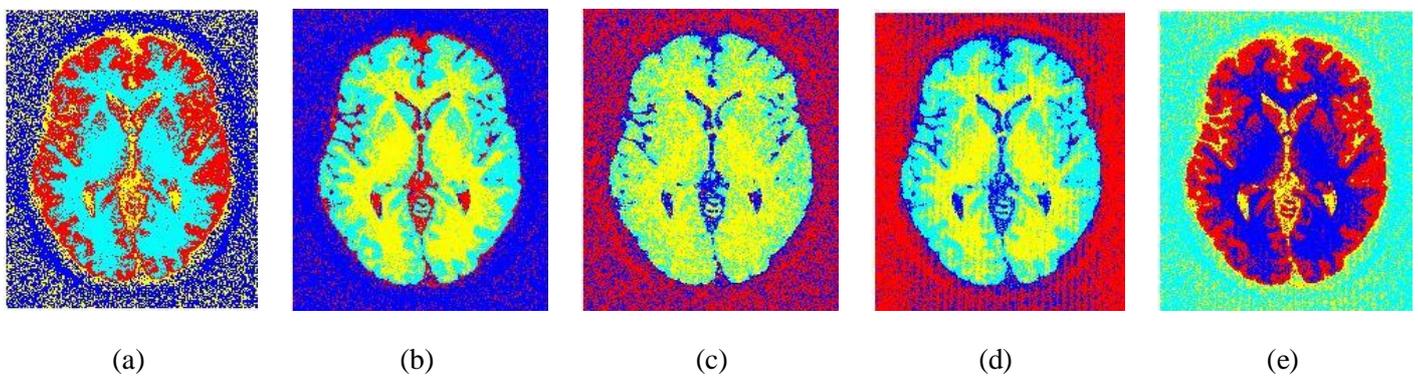


Figure VI-13 : Résultats de la segmentation par : (a)FCM, (b) PDI, (c)RFCM, (d) FCM_S1 et (e)FCM_S2 pour une image à 5% de bruit et 60% d'inhomogénéité.

Les taux de miss-classification (MCR) obtenus pour les différents algorithmes sont réunis dans le tableau suivant :

Algorithme	Bruit et taux d'inhomogénéité		
	5%B 20%Inh	5%B 40%Inh	5%B 60%Inh
IFCM_S	09.57	09.84	10.07
FCM_S2	10.16	10.59	10.91
FCM_S1	09.12	10.68	11.17
RFCM	09.42	10.89	11.80
PDI	10.03	10.57	10.65
FCM	12.27	12.63	13.20

Tableau VI-2 : MCR calculé pour les images IRM ayant 5% de bruit et 20,40 et 60% d'inhomogénéité.

Les inhomogénéités d'intensité font augmenter d'avantage le taux de miss-classification, c'est normal car les niveaux de gris sont faussés dans quelques zones.

Le FCM_S1 résiste mieux aux inhomogénéités, le calcul de la moyenne du voisinage à induit une meilleure classification, car cet algorithme, en prenant compte de l'influence du voisinage, agit comme un filtre moyennneur sur l'image.

IFCM_S à l'inconvénient du choix des paramètres. Même chose pour RFCM, le choix de β est très délicat. PDI souffre toujours de sa dépendance importante de l'initialisation.

IV.5.6 Influence du bruit et de l'inhomogénéité sur les classes :

- **Classification par FCM :**

Pour montrer l'effet du bruit et des inhomogénéités d'intensité sur les classes obtenues, pour une classification par FCM, On présente ici le taux de classification des différentes classes pour différents niveaux de bruit et d'inhomogénéité.

	3 % B 0 % Inh			5 % B 0 % Inh			5 % B 40 % Inh			7 % B 60 % Inh		
	LCR	MG	MB	LCR	MG	MB	LCR	MG	MB	LCR	MG	MB
LCR	67.40	29.66	02.94	60.06	35.38	04.54	53.54	41.16	04.84	47.43	46.63	05.94
MG	00.52	97.35	02.13	00.38	86.73	12.89	00.18	85.06	14.75	01.44	76.14	22.42
MB	0	00.36	99.64	0	03.95	96.05	0	06.07	93.92	0	12.77	87.23

Tableau VI-3 : Taux de classification pour différentes classes (LCR, MG et MB) Obtenues par FCM.

L'histogramme suivant illustre le taux de classification des différents tissus obtenus de la classification par l'algorithme FCM.

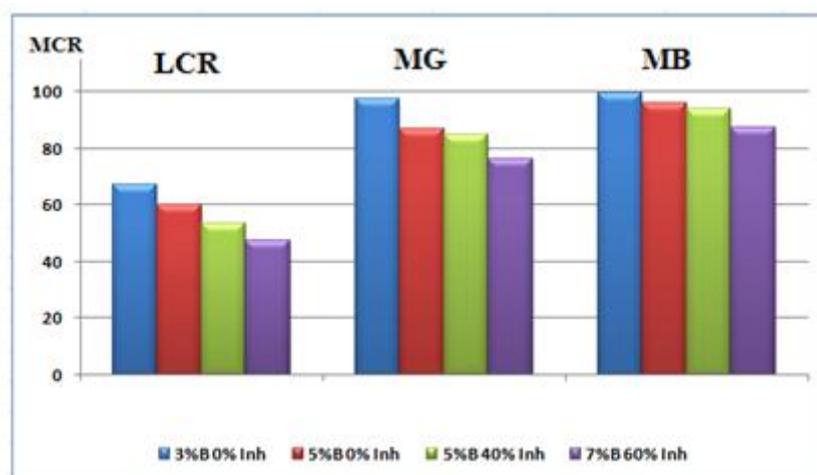
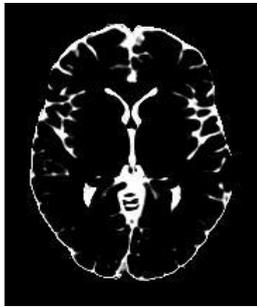


Figure VI-14 : Taux de classification pour différentes classes (LCR, MG et MB) Obtenues par FCM pour différents niveaux de bruit et d'inhomogénéités.

Les inhomogénéités ont une influence sur les classes obtenues, notamment pour le LCR, qui se dégrade fortement lorsque les niveaux du bruit sont élevés. La classe LCR est la plus touchée, car son niveau de gris est très proche de celui de la matière grise, et avec les inhomogénéités d'intensité, les pixels du LCR sont confondus avec ceux de MG (pour une image à 7% du bruit et 60% d'inhomogénéités, seulement 47.43% des pixels appartenant à LCR sont correctement classés).

- **Comparaison des différents algorithmes :**

Nous allons présenter les différentes classes obtenues pour une image corrompue de 5 % du bruit et 40 % d'inhomogénéités.



Liquide Céphalo-rachidien

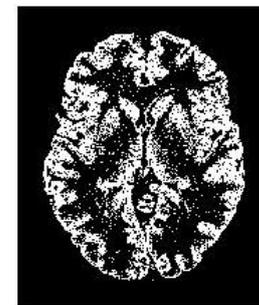
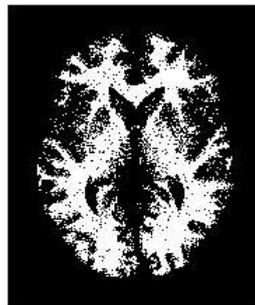
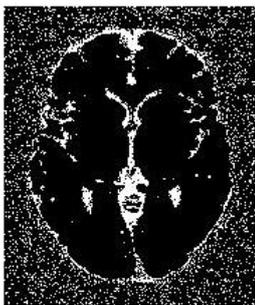


Matière blanche



Matière grise

Figure VI-15 : Classes de l'image originale (Données de Brainweb).



(a)



(b)

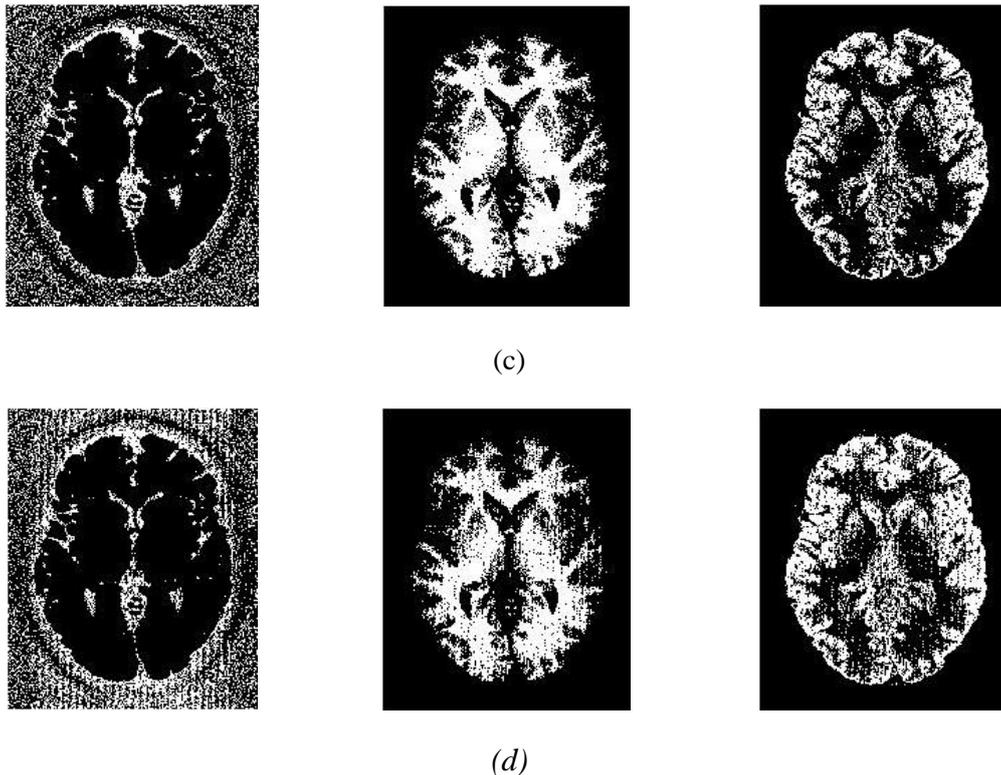


Figure VI-16 : Séparation de classes pour les différents algorithmes : (a) FCM, (b) PDI, (c) RFCM et (d) FCM_S1 pour une image à 5% bruit et 40% inh.

On a calculé le MCR pour chaque algorithme. Les résultats sont résumés dans le tableau suivant :

	FCM			PDI			RFCM			FCM_S1			FCM_S2		
	LCR	MG	MB	LCR	MG	MB	LCR	MG	MB	LCR	MG	MB	LCR	MG	MB
LCR	53.54	41.16	04.84	57.29	39.58	03.13	84.79	15.21	0	85.15	14.84	0	85.89	14.11	0
MG	00.18	85.06	14.75	00.50	90.96	08.54	00.19	76.38	23.42	00.73	87.84	11.43	00.31	88.02	11.65
MB	0	06.07	93.92	0	10.77	89.23	0	02.94	97.06	0	12.42	87.58	0	09.70	91.29

Tableau VI-4 : Taux de classification pour différentes classes (LCR, MG et MB) Obtenues par FCM, PDI, RFCM, FCM_S1 et FCM_S2 pour une image à 5% bruit et 40% inh.

On remarque qu'un nombre important de pixels appartenant au LCR sont mal classés pour FCM et PDI (près de 46% pour FCM et environ 43% pour PDI). RFCM, par contre, a réussi à identifier plus de 85% des pixels appartenant au LCR, mais échoue de classer près de 25% des pixels appartenant à MG. FCM_S1 et FCM_S2 prouvent une fois de plus leur efficacité en donnant de meilleurs taux de classification pour les trois tissus.

Nous remarquons aussi pour les méthodes considérant le contexte spatial (RFCM et FCM_S), qu'aucun pixel appartenant à LCR n'est classé à MB.

Les résultats précédents sont représentés dans l'histogramme suivant :

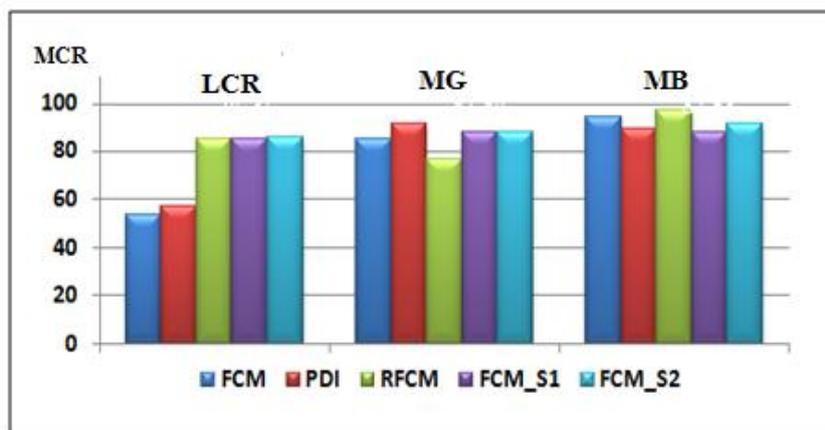


Figure VI-17 : Taux de classification pour différentes classes (LCR, MG et MB) Obtenues par FCM, PDI, RFCM, FCM_S1 et FCM_S2 pour une image à 5%bruit et 40% inh.

L'importante sensibilité à l'initialisation et au bruit de PDI et FCM influe, sur la qualité de classification. RFCM est moins sensible à l'initialisation, plus robuste au bruit mais sensible aux inhomogénéités d'intensité et le choix du paramètre β devient plus difficile.

La famille FCM_S qui tient compte du contexte spatial, fait preuve de robustesse au bruit ainsi qu'aux inhomogénéités d'intensité, son seul inconvénient est le choix des paramètres α_1 et α_2 .

On a vu que pour cette image les MCR obtenus par PDI, RFCM, FCM_S1 et FCM_S2 sont très proches l'un de l'autre, c'est pour cela qu'on calcule le coefficient de Jaccard de chaque algorithme, afin de mieux les évaluer :

	MCR (%)	J
FCM_S2	10.59	0.88
FCM_S1	10.68	0.87
RFCM	10.89	0.91
PDI	10.57	0.79
FCM	12.63	0.78

Tableau VI-5 : MCR et coefficient de Jaccard pour différentes classes (LCR, MG et MB) Obtenue par FCM, PDI, RFCM, FCM_S1 et FCM_S2 pour une image à 5%bruit et 40% inh.

D'après le tableau, RFCM, FCM_S1 et FCM_S2 possèdent un J élevé autour de 0.9 et proche l'un de l'autre. Ce résultat est attendu car ce sont ces algorithmes qui ont un taux de classification élevé des différents tissus. Bien sur ces résultats nécessitent d'être améliorés.

VI.6 Conclusion :

Pour l'instant la famille FCM_S a montré une robustesse au bruit, même en présence d'inhomogénéité. Mais le choix des paramètres α_1 et α_2 constitue un inconvénient. Même chose pour RFCM qui est sensible aux fortes inhomogénéités, du fait que β varie d'une image à une autre.

L'importante dépendance de l'algorithme PDI à l'initialisation constitue une limite majeure. En plus, les inhomogénéités d'intensité crée une confusion entre les pixels du LCR et ceux du MG, en effet ces deux tissus ont des niveaux de gris proche l'un de l'autre.

L'intégration des propriétés spatiales dans l'algorithme FCM était d'un apport considérable à la classification, même en présence du bruit et des inhomogénéités d'intensité, l'algorithme FCM_S a réussi à identifier les trois tissus, et a donné des résultats encourageants.

Conclusion générale

La classification floue, particulièrement en imagerie médicale, est un domaine de recherche très actif depuis plusieurs années. Les techniques de classification ont pour principe, de regrouper les pixels suivant un critère de similarité prédéfini. Le fait qu'aucune connaissance a priori, des données réelles est disponible, impose l'utilisation de ces techniques. Néanmoins, la plupart d'elles nécessitent le choix des valeurs de certains paramètres dont le résultat de classification peut dépendre fortement. Nous nous sommes intéressés à la méthode des FCM et quelques unes de ses variantes. Cette méthode est basée sur la recherche de la partition qui minimise au mieux une fonction objective définie. Par l'introduction de la notion d'appartenance, FCM arrive à surpasser les problèmes liés à l'aspect binaire de la classification nette (un pixel peut appartenir à plusieurs classes avec différents degrés). Néanmoins cet algorithme et ses variantes ne prennent pas en compte la disposition spatiale des pixels et ne considèrent que le vecteur de caractéristiques utilisé, négligeant ainsi les propriétés du voisinage du pixel considéré. Ce qui les rend très sensibles au bruit et aux inhomogénéités d'intensité.

Les images obtenues par résonance magnétique (IRM) souffrent d'inhomogénéités d'intensité, ce qui limite les performances du FCM. L'utilisation de filtrage ou de correction d'inhomogénéités pendant l'acquisition peut conduire à une importante perte des détails de l'image. Comme nous l'avons vu dans ce mémoire, la correction apportée par l'algorithme PDI était insuffisante, et sa forte dépendance de l'initialisation le rend non convainquant. De ce fait, on a constaté que l'information seule du niveau de gris, sans prise en compte de son voisinage, n'était pas suffisante pour aboutir à une classification adéquate. Chose prouvée par les résultats obtenus de la classification par RFCM et la famille d'algorithmes FCM_S. En effet, l'incorporation du contexte spatial était très bénéfique, et a rendu l'algorithme de classification plus performant.

Le premier algorithme (RFCM) a démontré une robustesse au bruit en le comparant avec FCM standard, mais lorsque l'image est fortement inhomogène cet algorithme ne donne pas de résultats satisfaisant. En plus que la qualité de classification est trop dépendante du paramètre β qui varie d'une image à une autre.

Les résultats obtenus de la classification par la famille d'algorithmes FCM_S sont encourageants. L'information extraite du voisinage a permis d'obtenir des structures lisses, et de diminuer, remarquablement, les inhomogénéités d'intensité. Le problème du choix des paramètres α_1 et α_2 se pose une nouvelle fois. Un choix judicieux de ces paramètres est recommandé, afin d'avoir de meilleurs résultats. Une étude approfondie resterait nécessaire afin de trouver une version modifiée de FCM, qui serait plus robuste au bruit, et qui ne dépend pas trop de l'étape d'initialisation.

Plusieurs améliorations sont à envisager : agir sur l'étape de l'initialisation afin d'avoir une meilleure estimation des centres de classes. Ceci peut se faire en utilisant l'histogramme de l'image et en cherchant les pics (qui représentent les modes de la série de données formant l'image). Plusieurs méthodes pour la sélection de modes sont proposées dans la littérature. Les plus populaires sont celles qui se basent sur la technique de noyaux [28] (l'algorithme Espérance Maximisation EM (Expectation Maximization) par exemple). Pour les méthodes FCM_S, on propose de tester l'algorithme avec différentes tailles de fenêtres (5x5 par exemple), et de voir la possibilité d'intégrer d'autres propriétés statistiques du voisinage du pixel considéré (statistiques d'ordre supérieures).

Annexe 1

Algorithme ISODATA [6]

Notons par $v = \{v_1, v_2, \dots, v_k\}$ un ensemble de vecteurs. Soit $P(k)$ l'ensemble de toutes les k partitions définies sur X (X étant un ensemble de points).

Pour toute partition $P = \{X_1, X_2, \dots, X_k\} \in P(k)$ et pour tout v , soit $J(P, v)$ la quantité suivante :

$$J(P, v) = \sum_{i=1}^k \sum_{x \in X_i} d^2(x, v_i).$$

L'algorithme connu sous le nom d'ISODATA [10] (Iterative Self-Organizing Data Analysis Technique) a été introduit pour trouver le minimum de $J(P, v)$, c'est-à-dire, trouver P^* et v^* tels que :

$$J(P^*, v^*) = \min_P \min_v J(P, v).$$

Cet algorithme peut être décomposé en quatre étapes :

ISODATA

Etape 1 : Choisir une partition quelconque $P \in P(k)$,

Etape 2 : Calculer les centroïdes \bar{x}_i des X_i ,

Etape 3 : Construire une nouvelle partition \hat{P} suivant la règle suivante :

$$x \in \hat{X}_i \Leftrightarrow d(x, \bar{x}_i) = \min_{1 \leq j \leq k} d(x, \bar{x}_j),$$

Etape 4 : Si $\hat{P} = P$, fin, sinon aller à l'étape 2.

Avec : d est la distance minimale entre le pixel considéré et le centroïde.

$$d(x, \bar{x}_i) = \min_{1 \leq j \leq k} d(x, \bar{x}_j).$$

Annexe 2

Résonance Magnétique Nucléaire

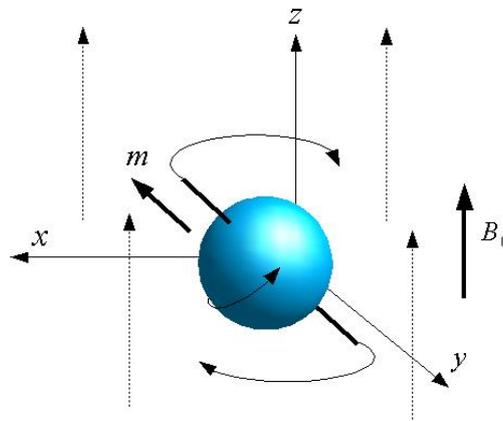
Les physiciens Bloch et Purcell reçurent le premier prix Nobel de physique en 1952 [29] pour leurs applications spectrométriques et d'imagerie. Ultérieurement ces mêmes techniques (1970) de spectrométrie RMN (spectroscopie RMN) ont été appliquées à l'imagerie médicale grâce au développement de l'informatique.

Principe de la résonance magnétique nucléaire RMN [29] :

La résonance magnétique nucléaire est basée sur l'existence d'un paramagnétisme nucléaire (formé par des atomes qui possèdent des moments magnétiques permanents en raison de la présence d'électrons isolés). La présence d'un moment magnétique associé au noyau est liée à la valeur du nombre quantique de spin I qui doit être différent de 0. Cas de l'hydrogène qui est abondamment présent dans le corps humain.

Dans un champ magnétique statique, les moments magnétiques des noyaux de spin $\frac{1}{2}$ s'orientent selon deux directions parallèles et antiparallèles au champ.

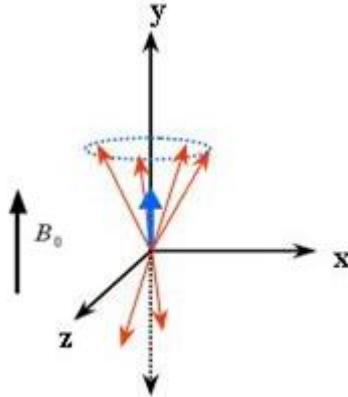
Les moments magnétiques des noyaux précessent autour du champ magnétique statique B_0 de manière à former un cône (comme illustrer sur la figure).



Mouvement de précession du noyau.

L'équation fondamentale de la résonance magnétique relie la vitesse angulaire de précession ω_0 au champ magnétique β_0 par le rapport gyromagnétique γ (rapport entre le moment magnétique et le moment cinétique d'une particule) selon la formule :

$$\omega_0 = \gamma \cdot \beta_0$$



Le phénomène de résonance magnétique nucléaire est observé quand on soumet le système de spins placés dans un champ magnétique à une onde radiofréquence (RF) dont la fréquence est égale à celle de précession des spins ($f_0 = \omega_0/2\pi$).

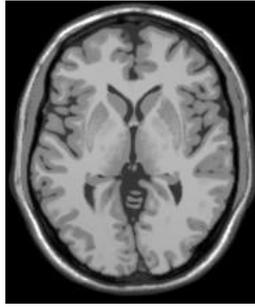
L'application de RF induit à la mise en **phase** des spins les uns par rapport aux autres (selon le modèle quantique), alors qu'ils étaient **déphasés**, c'est-à-dire qu'ils se mouvaient de manière anarchique. Ce phénomène entraîne l'apparition macroscopique d'une **composante transversale** de champ magnétique. Le retour à l'état initial s'effectue dès l'arrêt de la **RF**. C'est la relaxation longitudinale **T1**, qu'est due aux champs magnétiques fluctuants (notamment mouvements moléculaires) présents dans l'environnement, et une relaxation transversale **T2** qu'est due aux interactions des spins entre eux (déphasages).

L'imagerie par résonance magnétique IRM :

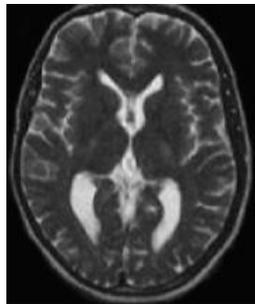
- **Les modalités en IRM :**

L'énergie du signal de la relaxation des spins peut être décomposée suivant un axe parallèle au champ magnétique (relaxation longitudinale ou **T1**), ou un axe perpendiculaire (relaxation transversale ou **T2**).

- La modalité **T1** permet d'observer les tissus de cerveau : matière blanche (MB), matière grise (MG) et le liquide céphalo-rachidien (LCR).



- La modalité **T2** ne permet pas de distinguer la matière grise de la matière blanche, mais met en évidence les lésions et le liquide céphalo-rachidien.



Bibliographie

- [1] R.C. Gonzalez, R.E. Woods, **Digital Image Processing**, Second Edition, Prentice-Hall, Upper Saddle River, New Jersey 07458, 2002.
- [2] J.P.Cocquerez, P. Foliguet, S.Maitre, **Analyse d'images : Filtrage et segmentation**, Collection Enseignement de la physique : mathématiques pour la physique, Masson, Paris, 1995.
- [3] J.P.Nakache, J.Confais, **Approche pragmatique de la classification : arbre hiérarchique, partitionnement**, Editions Technip, Paris, 2005.
- [4] E. Diday, **La méthode des nuées dynamiques**, Revue de Statistique Appliquée, vol. 19, n. 2, pp. 19-34, 1971.
- [5] J.B Queen, **Some methods for classification and analysis of multivariate observations**, Proceeding of 5th Berkeley Symposium on mathematical statistics and probability. Berkeley, university of California press, 1967.
- [6] L. Khodja, **Contribution à la Classification Floue non Supervisée**, thèse de Doctorat, université de Savoie, décembre 1998.
- [7] E. R. Ruspini, **A New Approach to Clustering**, *Inform. Control*, vol. 15, no. 1, pp. 22-32, July 1969.
- [8] S.A. Dudani, **The distance-weighted k -nearest neighbor rule**, *IEEE Trans. Syst. Man Cyber.*, vol. 6, pp.325-327, 1976.
- [9] J.C. Bezdek, **Fuzzy mathematics in pattern classification**, PH.D dissertation, Cornell Univ., Ithaca, NY, 1973.
- [10] D.J. Hall, G.H. Ball, **ISODATA, a Novel Method of Data Analysis and Pattern Classification**, *Techn report 5 RI. Project 5533*, Stanford Research Inst, Menlo Park, California, USA, 1965.
- [11] L.A Zadeh, **Fuzzy sets**, *Information Control* 8: p 338-353, 1965.
- [12] B. Marsala, B. Meunier, **Logique floue : principes, aide à la décision**, Hermès Science Publications, Paris, 2002.

- [13] K. Honda, H. Ichihashi, S. Miyamoto, **Algorithms for Fuzzy Clustering Methods in c-Means Clustering with Applications**, Springer-Verlag, Berlin Heidelberg, 2008.
- [14] J.C. Bezdek, R.J. Hathaway, M.J. Sabin, W.T. Tucker, **Convergence Theory for Fuzzy c-Means : Counterexamples and Repairs**, *IEEE Trans. Syst. Man Cyber.*, vol. SMC-17, n. 5, pp.873-877, September/October 1987.
- [15] A.Mekhmoukh, **Segmentation d'images par classifieurs non supervisés : Application à l'imagerie par resonance magnétique (IRM)**, Magister électronique, Université A.Mira de Bejaia, 2008.
- [16] Y. Yang, **Image segmentation based on fuzzy clustering with neighborhood information**, *Optica Applicata*, 2009.
- [17] A.I Shihab, **fuzzy clustering algorithms and their application to medical image analysis**, PH.D dissertation, department of computing, imperial College of Science, Technology and Medicine, University of London, LondonSW7 2AZ. December 2000.
- [18] J. Tian, J. Song, Q. Zhao, Y. Wang, **Gain Field Correction Fast Fuzzy c-Means Algorithm for segmenting magnetic resonance images**, 2006.
- [19] J.Keller, R.Krishnapuram, **An possibilistic approach to clustering**, *IEEE Trans on fuzzy system* vol 1 n2, May 1993.
- [20] S. Bricq, **Segmentation d'images IRM anatomiques par inférence bayésienne multimodale et détection de lésions**, Doctorat de l'université de Louis Pasteur, Strasbourg, 2008.
- [21] D. Zung, L.Pharm, **Spatial models for fuzzy clustering**, *Computer vision and Image Understanding* 84, 285-297, Elsevier Science (USA), 2001.
- [22] D. Zhang, S. Chen, **Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure**, *IEEE Trans. Syst, Man, Cybern*, 2004.
- [23] A. Farag, M.N. Ahmed, N. Mohamed, S.M. Yamany, T. Moriarty, **A modified fuzzy C-means algorithm for bias field estimation and segmentation of MRI data**, *IEEE Trans. Med. Imaging* 21, 193–199, 2002.
- [24] W.R. Lu , Z. Bing, **A New Algorithm for Image Segmentation Based on Fast Fuzzy C-Means Clustering**, *International Conference on Computer Science and Software Engineering*, IEEE DOI 10.1109/CSSE.2008.1466, 2008.
- [25] http://lecerveau.mcgill.ca/flash/i/i_01/i_01_cr/i_01_cr_ana/i_01_cr_ana.html#2

- [26] A.Gangi, B. Kastler, D.Vetter, **Principe de l'IRM : Manuel d'auto-apprentissage**, **Collection d'imagerie radiologique**, Edition Masson, Paris, 1994.
- [27] C. De Bazelaire, J. Frija, E. Kerviler, O. Mathieu, **Artefacts en IRM**, EMC (Elsevier SAS, Paris), Radiodiagnostic – Principes et techniques d'imagerie, 35-260-A10, 2005.
- [28] B. Stéphane, J. Jean-Michel, L. Frank , **Traitement et analyse des images numériques**, Hermès Science Publications, Paris, 2003.
- [29] J. Vion-Dury , **Cours de Résonance magnétique, Spectroscopie et Imagerie**, les cours de PCEM, Ellipses Edition Marketing SA , 2002.