

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Mouloud MAMMERI, Tizi-Ouzou



Faculté de Génie Electrique et d'Informatique
Département d'Automatique

MEMOIRE DE FIN D'ETUDES

En vue de l'obtention du diplôme

de MASTER ACADEMIQUE EN AUTOMATIQUE
OPTION : COMMANDE DES SYSTEMES

Thème

***Segmentation d'image IRM cérébral par
FCM et ses variantes***

Proposé par : NAIT- BELAID Ouiza

Présenté par :

DERMECHE Arezki Massinissa
BENYOUSSEF Sofiane

Dirigé par : NAIT- BELAID Ouiza

Soutenu le : 03/10/2013

Promotion 2013

Remerciements

*Nous éprouvons notre gratitude à Mme **NAIT BLAID Ouiza** qui nous a présenté et dirigé ce travail, et aussi nous tenons à remercier tous les enseignants ayant participé durant notre formation, et ceux qui nous ont aidé durant la réalisation de notre travail, et ainsi que toute la famille qui nous a aidé et encourager. Et nous n'oublions pas nos chers amis qui nous ont tenu compagnie durant notre parcours.*

En vue des avancées technologiques en particulier dans le domaine du traitement d'images IRM, on a étudié de près les méthodes choisies pour ce traitement, parmi elles on trouve les méthodes de classification floues non supervisées (FCM et ses variantes).

Dans le cadre de notre travail, le but principal est d'obtenir une meilleure segmentation avec une hybridation de deux méthodes de classification floues, et cela nous a conduits à des résultats positifs.

Mots clés : FCM, PCM, sFCM, IRM, Hybridation.

sommaire

Introduction générale.....	1
----------------------------	---

Chapitre I : IRM cérébrale

I.1. Introduction.....	3
I.2. Quelques notions d'anatomie cérébrale	4
I.2.1. Le Cerveau	4
I.2.2. Observation de cerveau	5
I.2.3. Généralité sur les tissus cérébraux	6
I.2.3.1. Le liquide céphalo-rachidien	7
I.2.3.2. La matière grise	7
I.2.3.3. La matière blanche.....	9
I.3. Imagerie par résonance magnétique (IRM).....	9
I.3.1. Principe de la résonance magnétique nucléaire	10
I.3.1.1. Magnétisme et atomes	10
I.3.1.2. Résonance et signal.....	11
I.3.2. Séquences IRM	13
I.3.2.1. Image pondérée en densité de protons (ρ).....	13
I.3.2.2. Image pondérée en T1	13
I.3.2.3. Image pondérée en T2	14
I.4. Domaine d'application de l'IRM.....	14
I.4.1. L'IRM fonctionnelle	15
I.4.2. L'imagerie anatomique	15
I.4.3. L'imagerie par RMN.....	16

I.5. Défauts des images acquises par IRM	16
I.6. Conclusion	17

Chapitre II : Segmentation des images IRM

II.1. Introduction	18
II.2. Pourquoi segmenté des images.....	18
II.3. Définition de la segmentation.....	19
II.4. Les différentes approches se segmentation	20
II.4.1. Approche région	20
II.4.2. Approche contour	22
II.4.3. Segmentation par seuillage	23
II.4.4. Segmentation par classification	24
II.4.4.1. Méthodes supervisées.....	24
II.4.4.2. Méthodes non supervisées.....	26
II.5. Conclusion.....	28

Chapitre III : FCM et ses variantes

III.1. Introduction	29
III.2. L'algorithme des c-moyennes floues	29
III.3. Les variantes des c-moyennes floues	32
III.3.1. Les c-moyennes floues Spatial (s-FCM).....	32
III.3.2. Les c-moyennes possibiliste.....	32
III.3.3. Extension aux contours courbés.....	33
III.3.4. L'approche de Gath et Geva	33
III.3.5.L'approche de Davé	34
III.3.6. L'approche de Kamel et Selim.....	34
III.3.7.L'approche de Gustafson et Kessel	35
III.3.8. Une approche partiellement supervisée des FCM.....	36
III.3.9. Une approche due à Pedrycz : FCM conditionnelles	38

III.3.10.Approximations.....	39
III.3.11. Les FCM à prototypes multiples	39
III.3.12. Des FCM à haut contraste	40
III.4. Conclusion.....	41

Chapitre IV : Tests et résultats

IV.1. Introduction.....	42
IV.2. Méthodes de segmentation.....	42
IV.2.1. Le choix du vecteur forme	46
IV.2.2. Choix des paramètres des méthodes utilisées	46
IV.3. Les différents résultats	47
IV.3.1. Résultat obtenus sur la première image pondérée en T1.....	47
IV.3.2. Résultat obtenus sur la deuxième image pondérée en T2	50
IV.3.3. Résultat obtenus sur la troisième image pondérée en T2.....	53
IV.3.4. Résultat obtenus sur la quatrième image pondérée en T2.....	56
IV.4. Evaluation de la méthode de classification	58
IV.5. Analyses et interprétations	59
IV.6. Conclusion	60
Conclusion générale	61

Introduction générale

Malgré les avancées technologiques dans le domaine médical et en particulier dans l'imagerie médicale, l'étude du cerveau humain est un problème ardu et reste un sujet de recherche de forte actualité, du fait de l'évolution des techniques d'imagerie, la grande capacité de calcul des machines...etc. Une des modalités d'imagerie les plus couramment utilisées, à laquelle nous nous sommes intéressés dans le cadre de ce travail, est l'Imagerie par Résonance Magnétique (IRM), qui est devenue un outil indispensable pour tout examen clinique, elle présente l'avantage d'être non invasive et permet l'acquisition d'images bi ou tridimensionnelles sur lesquelles différents contrastes sont possibles. Cette modalité permet en outre la réalisation d'études du cerveau aussi bien anatomiques que fonctionnelles grâce aux techniques d'IRM et d'IRMf (IRM fonctionnelle).

L'IRM offre une série d'image du patient dont l'intensité des pixels représente une propriété physique différente selon les caractéristiques des tissus. Ce pendant, si les techniques d'acquisition évoluent chaque jour, la lecture et la compréhension des images restent souvent un art difficile à maîtriser. Les progrès réalisés en technologie informatique ont permis de résoudre en partie la lecture en traduisant l'information contenue dans l'image filtrée ou segmentée. L'image traitée et améliorée doit être précise et fiable pour une interprétation facile et rapide. Les techniques de traitement d'images nécessaires dans l'analyse d'imagerie médicales peuvent aller du classique tel que le dé-bruitage et l'amélioration de contraste à des techniques plus modernes telles que la segmentation. Le premier peut être considéré comme prétraitement pour les deux évaluations. La segmentation est la division d'une image en régions. Dans notre travail nous parlerons de la segmentation par classification flou (FCM), cette méthode est beaucoup employée dans le traitement d'images tel que l'imagerie médicale et satellite ...etc. Bezdek [17] a soutenu une thèse de doctorat sur les mathématiques floues pour la classification homogène dans laquelle figurent les conditions nécessaires de la minimisation du critère général qui définit la famille d'algorithmes connus sous le nom des c-moyennes floues (FCM). Bezdek a aussi étudié la convergence des FCM. D'autres variantes de ces algorithmes ont ensuite été mises au point afin d'en accroître les performances.

La segmentation des IRM cérébrales présente des particularités par rapport à d'autres domaines d'applications de la segmentation, comme celle des images satellitaires, ou la segmentation des visages. Ces particularités sont liées principalement aux bruits, à l'inhomogénéité de la radio fréquence, au patient lui-même (à cause de ses mouvements pendant l'acquisition de l'image, etc.), à l'effet du volume partiel que l'on retrouve lorsqu'un pixel ayant un certain niveau de gris correspond en réalité à un mélange de deux ou plusieurs tissus. Ces artéfact existe principalement aux frontières entre tissus (Matière Grise/Matière Blanche notamment). Les images IRM sont des mesure globales de composition des tissus au niveau moléculaire .L'IRM est de loin la technique de formation d'images la plus souple à cause de l'existence d'un grand nombre de paramètre à contrôler au cours du processus de formation d'images .Il peut mesurer des paramètres aussi complexes telle que les cartes d'activité cérébrale et la circulation sanguine .La principale difficulté avec L'IRM est le cout. Les machines coutent très cher et les dépenses de fonctionnement sont élevées .De plus, seuls les radiologistes qualifiées peuvent interpréter les résultats.

Le présent mémoire propose de traiter le problème de la segmentation des images IRM pour isoler les trois parties du cerveau : matière blanche (MB), matière grise (MG) et le liquide Céphalo-rachidien (LCR), et dans le cas de présence de pathologie on aura une quatrième partie qui est la pathologie en utilisant la méthode par hybridations de deux méthodes de classification flou. Et parmi les méthodes utilisé FCM, FCM Spatial et PCM.

Nous avons scindé ce mémoire en quatre chapitres :

- Le premier chapitre a pour objectif de présenter une brève description de l'anatomie cérébrale, et les notions d'imagerie IRM sont présentées.
- Dans le deuxième chapitre, sont montrées les différentes méthodes de segmentation d'images.
- Le troisième chapitre est consacré à la méthode FCM et ses variantes.
- Le chapitre quatre est consacré à l'application des méthodes de classification flou dans le cadre de segmentation d'images IRM cérébrales.

Nous terminerons par une conclusion générale.

I.1. Introduction

L'étude du cerveau humain, que ce soit sur le plan anatomique ou fonctionnel, est actuellement un domaine de recherche en plein essor. Les principaux facteurs qui contribuent à rendre possibles ces études sont principalement l'évolution des matériels et des techniques d'imagerie. Une des techniques d'imagerie les plus couramment utilisées, à laquelle nous nous sommes intéressées dans le cadre de ce travail, est l'Imagerie par Résonance Magnétique (IRM), qui est devenue un outil indispensable pour tout examen clinique. Elle repose sur le phénomène de résonance magnétique nucléaire (RMN), c'est-à-dire sur le couplage qui existe entre le moment magnétique du noyau et le champ magnétique externe, qui a été découvert par F.Bloch et E.M. Purcell en 1946.

En 1973, P. Lauterbur réalise la première image (Zeumatographie) basée sur la RMN en utilisant le principe du marquage spatial par des gradients de champ magnétique et en s'inspirant des méthodes de reconstruction d'images utilisées en tomodensitométrie. En 1975, Ernst propose le codage de phase par variation de l'amplitude d'un gradient de champ magnétique, qui facilite l'utilisation de la transformée de Fourier (TF) pour analyser le codage en fréquence et en phase du signal IRM. La première image (image d'un doigt) sur un patient est obtenue en 1976 par Mansfield, et un an plus tard Lauterbur réalise la première acquisition corps entier.

Cette technique d'imagerie est aujourd'hui largement utilisée en routine clinique et en recherche biomédicale. Elle permet d'obtenir des images hautement résolues spatialement, sans irradiation et avec une large gamme de contraste. L'IRM utilise des phénomènes physiques complexes pour créer une image d'aimantation protonique dans un milieu.

Dans ce chapitre, Dans un premier temps nous présentons quelques éléments d'anatomie du cerveau, afin de préciser le vocabulaire et les notions qui seront utilisés. Ensuite, dans un second temps, nous présentons brièvement les principes physiques de l'imagerie de résonance magnétique et les spécificités des images obtenues via l'imagerie par résonance magnétique et nous décrirons les diverses parties du cerveau.

I.2. Quelques notions d'anatomie cérébrale

I.2.1. Le Cerveau

Bien que représentant seulement 2% du poids total du corps humain (soit environ 1,4 Kilogrammes) le cerveau gère directement ou indirectement 98 % de ses fonctions. Il est responsable des fonctions humaines les plus complexes comme la pensée, la résolution de problèmes, les émotions, la conscience et les comportements sociaux, et régit les fonctions essentielles du corps comme la respiration, le processus d'alimentation, le sommeil, les mouvements et cinq sens.

En dépit de son extrême complexité, le cerveau n'est composé que de deux types de cellules : les neurones et les cellules gliales. Les neurones sont des cellules nerveuses capables de recevoir et transmettre l'information. Ils sont constitués d'un corps cellulaire, de plusieurs prolongements afférents appelés dendrites et d'un prolongement efférent appelé axone. Chaque neurone peut posséder jusqu'à 10 000 connexions avec d'autres neurones, ce qui conduit à un nombre très élevé de réseaux interconnectés. Les cellules gliales sont quant à elles des cellules de soutien qui contribuent à assurer le bon fonctionnement des neurones, sans participé directement au transfert de l'information. Le cerveau contient plus de 100 000 millions de neurones et encore d'avantage de cellules gliales

Le cerveau est la partie la plus volumineuse du système nerveux central. Il est placé dans la boîte crânienne. Il se situe dans une enceinte liquidienne (Liquide Céphalo-Rachiden) qui a la particularité de pénétrer également à l'intérieur du cerveau dans les cavités du système ventriculaire. Il est constitué de deux hémisphères principaux. Les hémisphères sont reliés par différentes structures cérébrales comme le corps calleux ou thalamus.

Le système nerveux central est constitué de la moelle épinière logée dans le canal vertébral et de l'encéphale, comme illustré par la Figure 1. Le poids moyen de ce dernier est entre 1400 à 1800 grammes, il occupe la majeure partie de la boîte crânienne. L'encéphale est composé du tronc cérébral, du cervelet et du cerveau. L'ensemble flotte dans un coussin protecteur de liquide céphalo-rachidien (LCR).




Fig.1. Structure générale d'un cerveau humain.

I.2.2. Observation de cerveau

Le cerveau peut être observé par des coupes bidimensionnelles selon plusieurs angles de vue. Il existe principalement trois axes anatomiques qui permettent de réaliser les coupes : axiale, sagittale et frontale




Fig.2. Plans de coupe en imagerie médicale.

- **Coupes axiale (ou transverse)**

Ces coupes correspondent quasiment à un plan horizontal. En imagerie par résonance magnétique, elles correspondent à un plan perpendiculaire à l'axe du champ magnétique principal.

- **Coupes sagittale**

Ces coupes sont prises dans des plans parallèles au plan inter hémisphérique. Il s'agit des vues latérales du cerveau.

- **Coupes frontale (ou coronale)**

Ce sont des coupes perpendiculaires aux coupes axiales et sagittales, elles correspondant à des vues de face du cerveau.




Fig.3.Les trois axes de coupe pour la visualisation du cerveau

I.2.3. Généralités sur les tissus cérébraux

Lorsque l'on observe le cerveau, on remarque que ce dernier est principalement constitué d'une matière blanchâtre à laquelle on donne le nom de substance blanche. `A la surface du cerveau se trouve une fine pellicule de matière grisâtre : le cortex cérébral, ou substance grise. Cette différence de couleur provient du fait que le cortex contient principalement les corps cellulaires des neurones, alors que la substance blanche est constituée d'un agglomérat d'axones qui relient les différentes aires corticales les unes aux autres. Les axones sont responsables de la transmission du flux nerveux.

I.2.3.1. Le liquide céphalo-rachidien

Le liquide céphalo-rachidien ou cérébro-spinal est un liquide clair, incolore, constituée de 99% d'eau formé dans les ventricules cérébraux [1]. Il soutient le tissu nerveux ainsi protégé des coups, des frottements et des compressions. Le liquide céphalo-rachidien remplit par ailleurs des fonctions importantes au niveau des échanges de substances entre le sang et le tissu nerveux.

Les espaces remplis de liquide céphalo-rachidien sont l'espace sous-arachnoïdien, entourant le cerveau et la moelle épinière, et le système ventriculaire. Le système ventriculaire comporte quatre cavités qui communiquent entre elles : deux ventricules latéraux de part et d'autre du plan inter hémisphérique et les troisième et quatrième ventricules. Le liquide céphalo-rachidien passe de l'un à l'autre par le trou de Monro et l'aqueduc de Sylvius. Le quatrième ventricule se prolonge jusqu'au canal épendymaire et possède trois connexions avec l'espace sous-arachnoïdien.

I.2.3.2. La matière grise

Les principales structures de substance grise (MG) sont le cortex, à la périphérie du cerveau, et les noyaux gris centraux (Fig.4). La substance grise est essentiellement composée de neurones et elle constitue le siège de l'activité cérébrale [2]. On la trouve par exemple dans le centre de la moelle épinière et dans le cortex (écorce des hémisphères cérébraux). Elle est responsable du traitement des informations.




Fig.4.Structures anatomiques de la substance grise

- **Le cortex** : Le cortex recouvre la totalité du télencéphale en une couche de 3 à 5 mm d'épaisseur et contient 70% de l'ensemble des neurones du cerveau. Du fait de cette grande densité de neurones, le cortex apparaît gris terne à l'œil dans les images pondérées en T1 obtenues par IRM. Il est le centre de la conscience. Tout mouvement volontaire part des zones motrices du cortex, et toute sensation consciente parvient à ses zones sensibles. Il est essentiellement formé de corps cellulaires de neurones et de prolongements dendritiques, dépourvus de myéline. Sa surface est particulièrement étendue, plissée en de nombreux sillons qui délimitent des circonvolutions. Les sillons les plus importants sont appelés scissures (de Sylvius, de Rolando) et divisent les hémisphères en quatre lobes [3].
- **Les noyaux de base** : Les noyaux centraux, qui sont avec le cortex les seules structures de substance grise du cerveau, sont également formés de corps cellulaires neuroniques mais avec une densité moins importante que dans le cortex. Ils sont composés des noyaux du télencéphale, ces noyaux sont appelés les noyaux de base (ou corps strié),

➤ **Les noyaux du diencéphale** : parmi ces noyaux :

- ✓ **Le thalamus** : est à l'intérieur du diencéphale, constitué de deux gros noyaux gris symétriques. Le thalamus joue un rôle d'intégration, de réception et d'analyse des informations avant de les transmettre à la périphérie du cerveau. Autrement dit, le thalamus permet de traiter les informations sensibles avant de les transmettre au cortex.
- ✓ **L'hypothalamus** : qui comprend lui-même de petits noyaux gris se prolongeant par deux glandes : l'hypophyse en bas et l'épiphysse en arrière. L'hypothalamus, région centrale du cerveau, joue un double rôle de sécrétion des hormones et de régulation du SNV, et contrôle l'activité des viscères;

I.2.3.3. La matière blanche

La matière blanche est comprise entre le cortex, les noyaux gris centraux et les ventricules. Elle est composée d'axones qui établissent les connexions entre les corps cellulaires du cortex et d'autres parties du cerveau. Généralement, la substance blanche peut être considérée comme la partie du cerveau responsable de la transmission des informations.

I.3. Imagerie par résonance magnétique (IRM)

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale non-invasive qui permet d'obtenir des vues en 2D et 3D de l'ensemble des parties et des tissus du corps humain, aussi bien des tissus durs (les os), que des tissus mous (moelle osseuse, système nerveux central, muscles, cœur).

L'IRM est basée sur le phénomène de résonance magnétique nucléaire qui permet d'obtenir des informations sur l'intérieur d'un objet fermé, en le soumettant à un champ magnétique qu'on fait varier. Elle est basée sur la propriété de certains noyaux d'atomes (en particulier l'Hydrogène) (RMN, terme créé en 1930 par Isidor Isaac Rabi; prix Nobel de Physique en 1944). Ce phénomène fut observé pour la première fois en 1945 de façon simultanée par deux équipes américaines, l'équipe de Felix Bloch à Stanford et celle de Edward Mills Purcell à Harvard, qui publièrent leurs résultats en 1946 (Bloch et al, 1946; Purcell et al., 1946) (prix Nobel de physique conjoint en 1952). Le nom d'IRM (Image par

Résonance Magnétique) n'a été donné que plus tard à la RMN car le terme « nucléaire » inquiétait le public.




Fig.5.Salle d'imagerie par résonance magnétique.

I.3.1. Principes de la résonance magnétique nucléaire

I.3.1.1. Magnétisme et atomes

- ✓ un atome est la plus petite partie indivisible d'un corps simple. Il est généralement constitué d'un noyau composé de protons et de neutrons autour desquels se trouvent des électrons.
- ✓ Proton : particule possédant une charge électrique de signe positif
- ✓ Neutron : particule neutre qui n'a pas de charge électrique
- ✓ Electron : particule possédant une charge électrique de signe négatif.

Une manifestation immédiate du magnétisme naturel est la déviation de la boussole aimantée dans le champ magnétique terrestre. Ce n'est qu'en 1820 qu'Oersted mit en évidence l'association d'un courant électrique avec le magnétisme. Un conducteur électrique, une spire, un bobinage parcourus par un courant électrique créent dans leur environnement un champ magnétique détectable par l'orientation de l'aiguille d'une boussole. Le champ magnétique peut être à volonté modulé ou pulsé par le courant électrique, ouvrant ainsi toutes les applications que nous connaissons : moteurs électriques, électroaimants, relais électriques etc.

Les noyaux atomiques tournent sur eux-mêmes ; cela entraîne une aimantation ($\vec{\mu}$) qui est appelée spin. Le spin est une propriété des particules atomiques. On peut la représenter classiquement comme la rotation des particules sur elles mêmes (tout comme la terre tourne sur elle même en 24 heures). Ce mouvement produit une aimantation parallèle à l'axe de

rotation. Mais ce n'est qu'une analogie, car la mécanique au niveau microscopique est très différente de la mécanique classique. Le proton réagit donc comme un dipôle magnétique. En absence de tout champ magnétique, les protons s'orientent aléatoirement. La résultante magnétique de l'ensemble est donc nulle ($\vec{\mu}=0$).

Lorsqu'un champ magnétique ($\vec{B_0}$) apparaît, les spins, polarisés, s'orientent dans la direction du champ, mais pas forcément dans le même sens. La proportion de spins dans le même que ($\vec{B_0}$) est supérieure à celle des spins orientés dans le sens contraire (antiparallèle) : c'est la statistique de Boltzmann. Cet écart de population est proportionnel à l'amplitude du champ magnétique principal. Cette différence crée une aimantation macroscopique ($\sum \vec{\mu} = \vec{M_0}$). Sur 2 millions et 3 protons, alignés dans un champ magnétique de 0,3 teslas, il y en aura 1million + 3 dans le sens du champ magnétique, et 1 million dans le sens antiparallèle.

Bien que faible, c'est sur cette différence que se base le principe de l'IRM. Lorsque l'on augmente la puissance du champ, on augmente la différence du signal. Dans la réalité, l'alignement des spins sur ($\vec{B_0}$) n'est pas parfait. Leurs mouvement autour de l'axe ($\vec{B_0}$) forme un cône, c'est le mouvement de précession. Il peut être apparenté à une toupie qui bascule mais qui reste en équilibre de rotation. La vitesse de précession de ces protons est la fréquence de Larmor. Elle augmente avec l'intensité du champ.

I.3.1.2. Résonance et signal

Comme l'indique son nom, la résonance magnétique nucléaire utilise la résonance. C'est un phénomène couramment utilisé ou subit. En effet, elle permet d'expliquer le fonctionnement d'une balançoire mais peut aussi causer la destruction d'un pont (comme celui de Tacoma), ou moins important, d'un verre. La résonance est une absorption d'énergie par un système à une fréquence déterminée. Par exemple, elle permet d'expliquer le bris d'un verre en cristal sous l'effet de certaines notes émises par une personne.

Pour l'IRM, L'état de l'ensemble de spins peut être modifié au moyen d'une onde, appelée onde radiofréquence (**RF**) de fréquence identique à la fréquence de précession. L'énergie délivrée par l'onde RF a pour effet de basculer certains spins de l'état aligné vers l'état anti-aligné. Avant l'application de l'onde RF, les spins étant alignés, l'aimantation est maximale. Avec le basculement, l'aimantation nette diminue jusqu'à s'annuler, puis à changer de direction si l'énergie RF est suffisante. Pour que le système entre en résonance, il faudra que cette onde ait exactement la même fréquence que la fréquence de Larmor. La mise en

résonance se traduit par un débattement plus ample du mouvement de précession (angle de bascule). Il va y avoir deux phases : une phase d'excitation durant laquelle l'onde sera émise, puis une phase de relaxation après l'arrêt de l'onde.

a. Phase d'excitation : avec l'onde **RF** dont la fréquence est celle de Larmor, la résultante de l'aimantation tissulaire $\vec{M}_0$ (somme de tous les moments magnétique $\vec{\mu}$) bascule. L'angle de cette bascule dépend de l'intensité et de la durée du champ magnétique. On peut décomposer l'aimantation tissulaire en une composante longitudinale (selon l'axe **Z**, aligné sur $\vec{B}_0$) et une composante transversale. La phase d'excitation génère la bascule qui se traduit par une diminution de l'aimantation longitudinale (qui peut aller jusqu'à s'inverser), et l'apparition d'une aimantation transversale (tant qu'il n'y a pas retournement). Cette aimantation apparaît car tous les protons précessionnent en phase avec l'excitation **RF**. La variation de l'aimantation longitudinale est donc la somme de deux effets : l'amplification du mouvement de précession, mais aussi l'inversion des spins parallèle en spins antiparallèles. L'aimantation transversale est due à une mis en phase des spins.

b. Phase de relaxation : le système retourne à son état d'équilibre en restituant l'énergie sous la forme d'un signale **RF** (sinusoïde amortie) recueilli par une antenne dans le plan **xy**. Pour la relaxation, on va différencier les composantes longitudinales et transversales.

- **La repousse longitudinale :** correspond au retour à l'état d'équilibre des spins excités. Cette repousse se fait selon une loi exponentielle caractérisée par le temps **T1** qui est la Constante de temps caractérisant la relaxation longitudinale (retour progressif de l'aimantation le long de B_0 . Constante de temps nécessaire pour que 63 % des spins se réalignent le long du champ magnétique.
- **Relaxation transversale** est due au déphasage des spins. Cette chute de l'aimantation transversale suit une courbe décroissante caractérisée par le temps **T2** qui est le temps au bout duquel un tissu a perdu **63%** de son aimantation transversale maximale.

T1 est dû à un transfert d'énergie entre le proton et le milieu dans lequel il se trouve. Il est donc caractéristique du tissu où sont engagées les molécules d'hydrogène dont les protons ont été excités.

T2 est dépendant aussi du tissu dans lequel le proton se trouve. Le déphasage des spins est dû à des interactions spins-spins.

T1 sera toujours supérieur à **T2** (généralement **10** fois), quel que soit le milieu.

Le contraste en IRM est dû à la différence entre ces deux temps.

I.3.2. Séquences IRM

Nous pouvons identifier les paramètres qui influencent le contraste de l'image IRM en deux grandes classes :

- La première est constituée de paramètres intrinsèques liés directement aux tissus observés. Il s'agit de la densité en protons ρ , des temps de relaxation T1 et T2
- La seconde est constituée de paramètres liés à l'appareil lui-même (en particulier l'intensité et la constance du champ magnétique B_0) et à la séquence d'acquisition.

Dans notre cas nous nous limitons à la description des pondérations ρ , T1 et T2.

I.3.2.1. Image pondérée en densité de protons (ρ)

Pour un TR long (de l'ordre de 2s) et un TE court (de l'ordre de 20ms), la différence de densité protonique entre la substance grise et la substance blanche s'exprime. On obtient une séquence pondérée en densité de protons ou (ρ) qui reflète la localisation et la concentration des noyaux d'hydrogène des différentes structures. Les tissus sont ordonnés par niveaux de gris croissants en matière blanche (MB), matière grise (MG) et liquide cérébro-spinal (LCS) figure 6.

I.3.2.2. Image pondérée en T1

Pour des TR courts (de l'ordre de 600ms), le contraste entre les tissus dépend essentiellement de leur vitesse d'aimantation, donc de T1. Pour des TE courts (environ 20ms), les différences de décroissance du signal entre les tissus n'ont pas le temps de s'exprimer, rendant le contraste indépendant de T2. Ainsi, on obtient une image pondérée en T1, où les tissus sont ordonnés par niveaux de gris croissants en LCS, MG, MB (figure 6).

I.3.2.3. Image pondérée en T2

Pour des TR longs (de l'ordre de 2s) et des TE longs (environ 90ms), la décroissance du signal domine la différence de densité protonique entre tissus, et le signal est suffisant pour réaliser une image dite pondérée T2, où les tissus sont ordonnés par niveaux de gris croissants en MB, MG, LCS




Fig.6.Les différentes pondérations

- **Temps de répétition (TR) :** C'est l'intervalle de temps séparant les excitations successives des spins. En écho de spin, il s'agit du temps séparant deux impulsions excitatrices de 90° successives [4].
- **Temps d'écho (TE) :** C'est la durée qui sépare le milieu de l'onde RF et le milieu du temps de lecture. En écho de spin, TE est court pour des images pondérés en T1 (avec un TR court), TE est long pour des images pondérées en T2 (avec un TR long).

I.4. différents techniques de l'IRM

De multiples techniques d'exploration, telles que la spectroscopie ou l'angiographie, sont possibles par IRM, dans de nombreux domaines d'application comme par exemple la chirurgie stéréotaxique ou la neuronavigation fonctionnelle. Nous présentons maintenant trois de ces domaines d'application.

I.4.1. L'IRM fonctionnelle

L'IRM fonctionnelle est fondée sur l'observation en temps réel des variations de l'oxygénation du sang et des débits sanguins cérébraux locaux, sans injection de traceur radioactif, puisque le traceur est endogène. Des examens répétés peuvent, de ce fait, être réalisés sans aucun inconvénient c'est à dire de manière non invasive L'oxygène, libéré au niveau des capillaires cérébraux, entraîne la réduction du fer qui se retrouve à l'état d'ion ferreux (Fe^{2+}), laissant deux électrons non appariés au sein de la molécule de déoxy-hémoglobine (dHb). Ces électrons sont à l'origine du paramagnétisme de cette molécule et génèrent une modification du champ magnétique local. La désoxyhémoglobine se comporte comme une hétérogénéité magnétique. L'augmentation de la concentration locale en dHb

entraîne ainsi une atténuation du signal IRM dans les zones (voxels) contenant du sang désoxygéné. Alors que l'oxyhémoglobine n'a aucune influence sur le champ magnétique local. L'activité cérébrale s'accompagne d'un enrichissement en oxygène des régions mises en jeu : cet apport d'oxygène réduit les hétérogénéités dues à la dHb dans le compartiment veineux de la circulation et le signal enregistré, lui, augmente. Dans les zones en activité les augmentations locales de débit sanguin cérébral font donc plus que compenser la consommation d' O_2 (et de glucose) et se traduisent par une augmentation locale de l'oxygénation du sang et donc réduisent le taux de dHb. Il en résulte une augmentation locale du signal IRM, appelé dans ce cas signal BOLD (Blood Oxygen Level Dependent).

L'IRM permet ainsi de localiser dans un cerveau les zones mises en jeu (activées) par la réalisation d'une tâche simple.

I.4.2. L'IRM anatomique

En médecine, on applique souvent le RMN aux noyaux d'hydrogène, élément présent en abondance dans l'eau et les graisses des tissus biologiques. C'est la structure anatomique que l'on visualise ainsi, et on parle alors d'IRM anatomique.

I.4.3. L'imagerie par RMN

Elle remonte au début des années 1970. Pour obtenir une image, l'idée est, très schématiquement, d'appliquer un champ magnétique variable dans l'espace, de sorte que la valeur de la fréquence de résonance change d'un point à l'autre de l'objet étudié. Avec une onde de fréquence fixe, seule une région sera donc à résonance et fournira un signal. En décalant le champ magnétique, une région différente se retrouve en situation de résonance et on sonde par conséquent une autre zone de l'objet. Le signal magnétique émis par les noyaux, juste après la résonance, est détecté par des bobines conductrices, " via " la force électromotrice qui est créée. Un traitement par ordinateur permet alors de faire la synthèse de tous les signaux recueillis et de construire une image tridimensionnelle.

I.5. Défauts des images acquises par IRM

Trois paramètres entrent en jeu dans la formation d'une image : la densité protonique ρ , le temps de relaxation spin-réseau $1T$ et le temps de relaxation spin-spin $2T$. Mais d'autres facteurs que l'on ne maîtrise pas toujours affectent la qualité des images et provoquent des

artefacts, compliquant la segmentation des tissus cérébraux ou la reconnaissance de structures cérébrales [3].

- **Les facteurs liés au mouvement :** Tout mouvement de protons lors de la formation de l'image a des conséquences sur la qualité de l'image acquise. De même, comme en photographie, les mouvements du sujet nuisent à la qualité de l'image. Dans les vaisseaux, les protons possèdent un mouvement plus ou moins rapide qui va perturber les moments magnétiques longitudinaux et transversaux des régions analysées et donc modifier des signaux de résonance magnétique.
- **Le déplacement chimique :** Dans les milieux biologiques, les électrons ne sont pas libres mais liés à une molécule. Dans ces conditions, le champ magnétique effectif qui agit sur un proton n'est pas véritablement celui escompté car il est modifié par son environnement chimique. Il en résulte une modification de la fréquence de résonance des protons, ou déplacement chimique.
- **Le champ statique :** En principe, on considère que le champ statique est homogène. En pratique, il ne l'est pas tout à fait. On parle alors de l'hétérogénéité du champ qui modifie localement la fréquence de résonance des protons. De plus, les variations locales de susceptibilité magnétique vont provoquer des distorsions du champ magnétique.
- **Le recouvrement de spectre :** Il y a recouvrement de spectre lorsque le champ d'exploration (FOV) est plus petit que l'échantillon étudié. Ce phénomène se traduit par une superposition d'informations situées en dehors du champ d'exploration sur l'image.
- **Le bruit :** le bruit peut être généré par l'agitation thermique des protons chez le patient qui est à l'origine d'émissions parasites. De même, ce bruit peut être généré par la chaîne de mesure et plus particulièrement de convertisseurs analogiques-numériques et des antennes.

I.6. Conclusion

Le principe de l'imagerie par résonance magnétique et son apport dans le cadre de l'acquisition de l'image IRM ont été présentés ci-dessus. Nous pouvons ainsi mieux prendre conscience des difficultés d'une segmentation automatique des images IRM en terme de traitement d'image d'une part et en terme de choix des données à utiliser d'autre part. Notre objectif est d'améliorer la visibilité des parties segmentées afin de mieux interpréter les résultats par le médecin ou l'expert.

Dans le chapitre suivant nous exposons les différentes méthodes de segmentation d'images IRM.

II.1. Introduction

La segmentation d'images est une étape fondamentale et importante dans beaucoup d'applications de vision par ordinateur. C'est une étape primordiale pour l'interprétation d'images. Beaucoup de méthodes de segmentation ont été développées, mais il n'y a pas encore de mesures de performance satisfaisante. Concevoir une bonne mesure pour la qualité de segmentation est un problème dur. De nombreuses publications font état de segmentation. Comment préférer l'une ou l'autre est un débat ouvert qui fait rage dans bien des laboratoires.

Dans ce qui suit, nous allons survoler, d'une manière succincte, chacune des différentes méthodes couramment utilisées après avoir évoqué quelques notions élémentaires sur la segmentation d'images.

II.2. Pourquoi segmenter des images ?

L'objectif de la segmentation est de permettre l'exploitation du contenu de l'image pour l'interprétation : aide au diagnostic en imagerie médicale, satellitaire pour une éventuelle localisation et reconnaissance (vidéo surveillance, contrôle robotique) ou une mesure des évolutions (contrôle qualité, suivi thérapeutique, etc.). La segmentation fait partie d'une chaîne de traitement que l'on peut résumer en quatre étapes principales :

- Acquisition des images : processus de production d'images exploitable par ordinateur.
- Prétraitement des images : améliorer ces images lorsqu'elles possèdent du bruit ou des défauts.
- Segmentation des images : construire une image symbolique en générant des régions Homogènes selon un critère défini à priori.
- Analyse des images : extraire des paramètres ou des fonctions représentatives de l'image ou des régions.




Fig.1. Chaîne de Traitement d'images

II.3. Définition de la segmentation

La segmentation d'image est une opération de traitement d'image qui a pour but de séparer des objets du fond d'une image numérique et entre eux, ou d'une manière plus générale, de rassembler les différents pixels ayant des propriétés communes. Si la segmentation sépare deux classes de pixels ; elle est appelée binarisation. L'homme sait naturellement séparer des objets dans une image. Il se base pour cela sur des connaissances de haut niveau, qui lui permettent de détecter ce qui l'intéresse dans l'image. En traitement d'image, la segmentation est le partitionnement d'une image I en N régions R_i disjointes et homogènes selon un prédicat, ou critère P déterminé (couleur, texture...). Formellement l'ensemble des régions $\{R_1, R_2, \dots, R_N\}$ est une segmentation de l'image I si :

$$\checkmark \quad U_{i=1}^N (R_i) = I, \quad i = 1, \dots, N \quad (\text{II.1})$$

$$\checkmark \quad R_i \cap R_j = \emptyset \quad \forall i \neq j \quad (\text{II.2})$$

$$\checkmark \quad R_i \text{ est connexe } \forall i \in \{1, \dots, N\} \quad (\text{II.3})$$

$$\checkmark \quad P(R_i) = \text{vrai} \quad \forall i \in \{1, \dots, N\} \quad (\text{II.4})$$

$$\checkmark \quad P(R_i \cap R_j) = \text{faux} \quad \forall i \neq j \text{ et } R_i \text{ adjacente à } R_j \quad (\text{II.5})$$

Où $P(R_i)$ est un prédicat d'uniformité pour tous les éléments dans la série R_i et $\emptyset$ l'ensemble vide [5] ;

Dans ce qui précède, la condition (II.1) souligne que la somme des régions segmentées doit inclure tous les pixels d'une image. La condition (II.2) souligne que les différentes

régions segmentées ne doivent pas se chevaucher. La condition (II. 3) souligne que les pixels dans la même région segmentée sont connexes. La condition (II. 4) souligne que les pixels dans les mêmes régions segmentées doivent avoir des propriétés similaires, et enfin, La condition (II. 5) souligne que les pixels appartenant à différentes régions segmentées doivent avoir des propriétés différentes [6].

II.4. Les différentes approches de segmentation

La segmentation fait référence aux notions de différence et de similarités perçues par le système visuel humain. Ces notions ont donné naissance à une multitude techniques de segmentation présentée dans la littérature, on peut les regrouper en trois grandes familles : les méthodes de segmentation par contours, les méthodes de segmentation en régions et les méthodes de classification. Un algorithme de segmentation s'appuie sur trois points essentiels suivants [7] :

- La recherche de discontinuités afin de mettre en évidence les contours.
- La recherche d'homogénéité locale pour définir les régions.
- Ou encore sur la coopération des deux principes.

II.4.1. Approche région

Les approches de segmentation régions visent à créer une partition de l'image en un ensemble de régions homogènes au sens d'un ou plusieurs critères [8]. Elles regroupent les pixels vérifiant des propriétés communes (niveau de gris, écart-type,...). Il existe plusieurs méthodes telles que la segmentation par division de région, par fusion de région, et par fusion/division que nous présentons ci-dessous.

II.4.1.1. Segmentation par croissance de régions

L'idée derrière cette méthode est de fixer un point de départ dans l'image, que l'on nommera germe de la région. On fixe ensuite un critère d'homogénéité pour la région qui est en général une intensité comprise entre deux valeurs, tout comme la méthode de seuillage. Par une procédure récursive, on inclut dans cette région, les points connexes qui vérifient le critère. Dans cette manière, on fait croître la région tant que le critère est respecté et on obtient en bout de ligne, une nouvelle région connexe.




Fig.2. Evolution de la segmentation à partir de deux germes (a)

II.4.1.2. Segmentation par fusion de régions

Les techniques de réunion (*region merging*) sont des méthodes ascendantes où tous les pixels sont visités. Pour chaque voisinage de pixel, un prédicat P est testé. S'il est vérifié les pixels correspondants sont regroupés dans une région. Après le parcours de toute l'image, les groupes de voisinages se voient appliquer le même test, et sont réunis si P est vérifié. Le processus est itéré jusqu'à satisfaction d'un critère d'arrêt.

II.4.1.3. Segmentation par division de régions

La division consiste à partitionner l'image en régions homogènes selon un critère donné. Le principe de cette technique est de considérer l'image elle-même comme région initiale, qui par la suite est divisée en régions. Le processus de division est réitéré sur chaque nouvelle région (issue de la division) jusqu'à l'obtention de classes homogènes

Cette méthode présente un inconvénient majeur qui est la sur-segmentation. Toutefois, ce problème peut être résolu en utilisant la méthode de division-fusion que nous présentons dans ce qui suit.

II.4.1.4. Segmentation par fusion / division

Son principe est de combiner les deux dernières méthodes présentées a fin de pallier à leurs inconvénients (division de régions et fusion de régions) de la manière suivante : une première étape de division donne comme résultat, une image divisée en plusieurs régions. Par la suite, une étape de fusion intervient afin de corriger le résultat obtenu par la première étape, en regroupant les régions similaires. Ce procédé est répété jusqu'à l'obtention d'une segmentation [6].

II.4.2. Approches contour

Il existe une deuxième grande famille de segmentation qui elle tente non pas de former des régions, mais plutôt de détecter les contours contenus dans les images afin d'éventuellement pouvoir séparer celle-ci et ainsi la segmenter

La segmentation par approche contours s'intéresse aux contours de l'objet dans l'image. En général, un élément de contours est un point de l'image appartenant à la frontière de deux ou plusieurs objets ayant des niveaux de gris différents. Les variations d'intensité de lumière et de couleurs sont très bien perçues par le système visuel humain. En effet, une frontière est définie comme un endroit de l'image où le changement en niveaux de gris est le plus important. Ces frontières constituent le contour des objets. Le contour s'appuie alors sur les transitions plus ou moins importants (de type marche, toit, pointe) (voir la Fig.3), ou encore sur les frontières entre zones homogènes distinctes ou non (présence d'une ligne)




Fig.3.Quelques modèles de contours

Ainsi, la détection de contours est souvent le premier problème qu'on rencontre en traitant une image et constitue un problème classique du traitement d'image. Cependant, les difficultés de la détection des contours proviennent du bruit important présent dans les images (bruit du capteur, bruit d'échantillonnage, irrégularité des surfaces des objets...). Une discontinuité dans l'image n'est pas forcément liée à une variation géométrique ou physique de la surface observée ; elle peut également être due à une différence d'éclairage (ex. effet d'ombre) (voir la Fig.4.).




Fig.4.Contour d'image

L'approche contour n'aboutit pas forcément à une segmentation, car les contours détectés ne sont pas toujours connexes. Il existe cependant des techniques qui permettent à ces méthodes d'avoir des contours fermés.

II.4.3. Segmentation par seuillage

Le seuillage est une technique de segmentation des images utilisé pour extraire des objets de leur fond. Les techniques de seuillage permettent de séparer les pixels d'une image, en n'utilisant que son histogramme, en deux classes (seuillage simple) ou plusieurs classes (multiseuillage).

- Le seuillage simple consiste à attribuer un niveau de gris identique (le blanc) à tous les pixels dont la valeur est supérieure à un seuil donné et un autre niveau (le noir) aux pixels restants.
- Le multiseuillage est nécessaire quand il s'agit d'images qui contiennent plusieurs objets qui diffèrent par leurs niveaux de gris, et pour extraire ces objets, plusieurs seuils sont nécessaires.

II.4.4. Segmentation par classification

De manière générale, les problèmes de classification s'attachent à déterminer des procédures permettant d'associer une classe à un objet (individu). Ces problèmes se déclinent essentiellement en deux variantes selon Bezdek : la classification dite « *supervisée* » et la classification dite « *non supervisée* » (Automatique).

II.4.4.1. Méthode supervisées

Ce sont des méthodes dans lesquelles les classes sont connues a priori avant d'effectuer l'opération d'identification des éléments de l'image. Elle demande une phase d'apprentissage sur l'échantillon représentatif dans le but d'apprendre les caractéristiques de chaque classe et une autre phase pour décider l'appartenance d'un individu à telle ou telle classe.

➤ Champs de Markov

La segmentation par champ de Markov étant un processus supervisé, les ensembles d'apprentissage E_i sont supposés connus pour chaque classe à segmenter. cette méthode est utilisé pour obtenir les cartes d'apprentissage aux tissus cérébraux. Le problème se ramène alors à l'estimation d'un processus label L (voxel² étiqueté) à partir d'un processus voxel connu X . La probabilité a posteriori d'un tel processus est définie par [9] :

$$P(L = I \mid X = x) = \frac{P(X = x \mid L = I)}{P(X = x)} \quad (\text{II. 6})$$

➤ Algorithme des k plus proches voisins

C'est une approche très simple et directe. Elle ne nécessite pas d'apprentissage mais simplement le stockage des données d'apprentissage. Son principe est le suivant. Une donnée de classe inconnue est comparée à toutes les données stockées. On choisit pour la nouvelle donnée la classe majoritaire parmi ses k plus voisins (Elle peut donc être lourde pour des grandes bases de données) au sens d'une distance choisie.

Afin de trouver les K plus proches d'une donnée à classer, on peut choisir la distance euclidienne. Soient deux données représentées par deux vecteurs x_i et x_j , la distance entre ces deux données est donnée par [21] :

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^d (x_{ik} - x_{jk})^2} \quad (\text{II. 7})$$

➤ Réseaux de Neurones

Un réseau de neurones artificiels [10, 11] est en général composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. Chaque couche i est composée de N_i neurones. Fig.5. prenant leurs entrées sur les N_{i-1} neurones de la couche précédente. A chaque synapse est associée un poids synaptique, de sorte que les N_{i-1} sont multipliés par ce poids, puis additionnés par les neurones de niveau i , ce qui est équivalent à multiplier le vecteur d'entrée par une matrice de transformation. Mettre l'une derrière l'autre les différentes couches d'un réseau de neurones reviendrait à mettre en cascade plusieurs matrices de transformation et pourrait se ramener à une seule matrice, produit des autres, s'il n'y avait à chaque couche, la fonction de sortie qui introduit une non-linéarité à chaque étape. Ceci montre l'importance du choix judicieux d'une bonne fonction de sortie : un réseau de neurones dont les sorties seraient linéaires, n'aurait aucun intérêt.

Le neurone calcule la somme de ses entrées puis cette valeur passe à travers la fonction d'activation pour produire sa sortie (Fig.5.).




Fig.5. Structure d'un neurone artificiel.

Classiquement, en segmentation d'images médicales, les réseaux de neurones sont utilisés comme classifieur. Les poids synaptiques sont déterminés par apprentissage sur une base d'image dont le résultat de segmentation est connu, on parle alors de réseau de neurones supervisé. Souvent, les neurones d'entrées sont les différentes IRM disponibles et les neurones de sorties nous donnent alors les différentes classes recherchées [12,13]. Il est en outre possible d'introduire des informations a priori en plus des volumes et donc de donner plus de robustesse à cette classification.

L'inconvénient majeur de ses méthodes est l'étape d'apprentissage qui demande une intervention manuelle pour donner cette vérité terrain dont le réseau a besoin pour calculer les poids synaptiques.

II.4.4.2. Méthodes non supervisées

La classification *non supervisée* n'a pas besoin d'éléments d'apprentissage étiquetés par un expert pour définir ces classes. En contrepartie, les classes identifiées par un algorithme de classification non supervisée n'ont aucune étiquette ou notion sémantique.

➤ Algorithmes C-moyennes (Hard C-Means ou HCM)

Dans la méthode des C-moyennes (Hard C-Means), un élément de X (X est l'ensemble des pixels à classifier) est attribué à une classe et une seule parmi les C proposées. Dans ce cas, la fonctionnelle à minimiser est :

$$J(B, U, X) = \sum_{i=1}^C \sum_{j=1}^N u_{ij} d^2(x_j, b_i) \quad (\text{II. 8})$$

u_{ij} : Le degré d'appartenance d'un élément x_i à une classe i .

$d^2(x_j, b_i)$: C'est la distance euclidien entre (point) l'élément de la classe et le centre de la classe.

Les solutions au problème s'écrivent de la façon suivante :

$$u_{ij} = \begin{cases} 1 & \text{ssi } d^2(x_j, b_i) < d^2(x_j, b_k) \forall k \neq i \\ 0 & \text{sinon} \end{cases} \quad (\text{II. 9})$$

Où

$$b_i = \frac{\sum_{j=1}^N u_{ij} x_j}{\sum_{j=1}^N u_{ij}} \quad (\text{II. 10})$$

La classification des éléments de X s'effectue de manière itérative en alternant l'étape de classification (II. 9) et l'étape de mise à jour des centres (II. 10), jusqu'à stabilisation de la segmentation ou de la fonction objectif. Dans une variante nommée ILSC (Iterative Least Squares Clustering), les vecteurs b_i sont recalculés à chaque ajout d'un élément dans une classe. Ces auteurs rapportent qu'un bon taux de reconnaissance des tissus cérébraux en IRM est obtenu, affirment également que cette modification entraîne à la fois un temps de calcul plus long et une dépendance de la partition finale à l'ordre de parcours de l'image.

Dans une méthode comme HCM, les éléments sont classés de façon certaine comme appartenant à une classe et une seule. Quelle que soit la modalité d'imagerie, cette assertion ne reflète pas la réalité physique de l'échantillon étudié (bruit, volume partiel, hétérogénéité de champ). Les méthodes présentées dans les paragraphes suivants permettent d'obtenir une segmentation floue qui prend en compte ces aspects *imprécis et incertains* [14].

➤ **Algorithme EM(Estimation Maximisation)** [15] :

On suppose que la répartition de l'ensemble des pixels X peut être décrite par une fonction de densité de probabilité qui peut être assimilée à un mélange de K composantes (généralement gaussienne). Le problème de la classification revient alors à estimer les paramètres de chaque composante (moyenne, variance).

Le problème de l'estimation des paramètres des composantes dans les mélanges se base sur le principe maximisation de la vraisemblance (maximum likelihood) : c'est-à-dire que les paramètres des composantes sont choisis de manière à maximiser la probabilité des pixels d'appartenir au mélange. C'est le but de l'algorithme EM (Expectation Maximization) proposé par Dempster.

➤ **Algorithme Mean Shift**

L'algorithme du Mean Shift, introduit par Fukunaga [15] puis remis au goût du jour par Comaniciu [16], recherche le «mode» ou point de plus haute densité d'une distribution des pixels qui corresponde au centre de la classe. Cette méthode consiste à estimer la fonction de

densité de probabilité sous jacente à l'ensemble de pixels puis localisé ses maxima locaux en recherchant les zéros de son gradient.

Cette procédure est résumée comme suit :

1. considérer les images en termes de caractéristiques (via couleur, gradient, mesures de texture, etc.)
2. choisir une répartition uniforme des fenêtres de recherche initiales.
3. calculer le centroïde des données pour chaque fenêtre.
4. centrer la fenêtre de recherche sur le centroïde de l'étape 3.
5. répéter les étapes 3 et 4 jusqu'à convergence.
6. fusionner les fenêtres se trouvant au même point final.
7. grouper les pixels traversés par les fenêtres fusionnées.

Il existent d'autres Méthodes non supervisées comme :

- **Algorithmes C-moyennes floues (Fuzzy C-Means ou FCM)**
- **Algorithmes les C-moyennes possibilistes (possibilistic C-means ou PCM)**
- **Algorithmes C-moyennes floues Spatial (Spatial Fuzzy C-Means ou sFCM)**

Qui seront présenté dans le chapitre suivant.

II.5. Conclusion

Dans ce chapitre, nous avons présenté un panorama succinct des notions fondamentales du domaine de la segmentation des images ; notamment celles en usage médicale ; on a exposé un état de l'art des différentes techniques existantes, classées selon leurs approches.

Il n'y a pas de règles générales permettant de choisir une méthode particulière de segmentation pour un problème donné ; choisir l'une ou l'autre dépend des images.

Dans notre cas nous allons utiliser la méthode de classification FCM et ses variantes pour la segmentation d'images IRM cérébrales, et le chapitre suivant est consacré à cette dernière.

III.1. Introduction

Après avoir vu les différentes méthodes de segmentation d'image dans le chapitre précédant, dans ce présent chapitre nous allons étudier de près la méthode de classification floue et nous allons vous avancé l'algorithme de base des c-moyen floue (FCM) et ses variantes, on sait que le programme FCM a ces propres inconvénient c'est pour cela que plusieurs chercheurs ont proposez de différentes technique, pour amélioré ce programme conçue a la classification floue d'images.

III.2. L'algorithme des c-moyennes floues

L'algorithme des c-moyennes floues est une extension directe de l'algorithme K-moyennes, elle appartient à la classe des algorithmes de classification floue, qui permet de segmenter une image sans prendre en compte les relations spatiales entre pixels.

Cet algorithme effectue une optimisation itérative en évaluant de façon approximative les minimums d'une fonction d'erreur. Il existe toute une famille de fonctions d'erreur associées à cet algorithme qui se distinguent par des valeurs différentes prises par un paramètre réglable, m , appelé indice de flou (fuzzy index) et qui détermine le degré de flou de la partition obtenue. Les FCM sont un cas particulier d'algorithmes basés sur la minimisation d'un critère ou d'une fonction objectif.

Dans ce cas, les vecteurs x_j représentant les pixels de l'image ne sont plus assignés à une unique classe, mais à plusieurs par l'intermédiaire de degrés d'appartenance u_{ij} du vecteur x_j à la classe i . Le but des algorithmes est alors non seulement de calculer les centres de classe B mais aussi l'ensemble des degrés d'appartenance des vecteurs aux classes.

➤ Présentation de l'algorithme FCM

Formulation du problème :

Si u_{ij} est le degré d'appartenance de x_j à la classe i , la matrice $C \times N$, $U = [u_{ij}]$ est appelée matrice de C -partition floue si et seulement si elle satisfait :

$$(\forall i \in \{1 \dots C\})(\forall j \in \{1 \dots N\}) u_{ij} \in [0,1]$$

$$0 < \sum_{j=1}^N u_{ij} < N \quad (\text{III. 1})$$

$$\forall j \in \{1 \dots N\} \sum_{i=1}^C u_{ij} = 1 \quad (\text{III. 2})$$

Bezdek a montré que le problème de partition de X en C classes floues pouvait être formulé comme la minimisation d'une fonctionnelle $J(B, U, X)$ définie par :

$$J(B, U, X) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i) \quad (\text{III. 3})$$

Sous les contraintes et où :

- $m > 1$ est un paramètre contrôlant le degré de flou de la partition résultante,
- $(x_j, b_i) \rightarrow d^2(x_j, b_i)$ est une distance du vecteur x_j au prototype b_i (centre de classe i).

Obtention de U et B :

Les solutions au problème de minimisation précédent sont obtenues par une méthode lagrangienne. Plus précisément, si $H(x_j)$ est défini pour chaque vecteur x_j par :

$$H(x_j) = \sum_{i=1}^C u_{ij}^m d^2(x_j, b_i) - \alpha \left(\sum_{i=1}^C u_{ij} - 1 \right), \alpha > 0, \quad (\text{III. 4})$$

L'annulation des dérivées partielles par rapport à u_{ij} et α donne :

$$\frac{\partial H(x_j)}{\partial \alpha} = 0 \text{ et } \frac{\partial H(x_j)}{\partial u_{ij}} = m \cdot u_{ij}^{m-1} \cdot d^2(x_j, b_i) - \alpha = 0, \quad (\text{III. 5})$$

De telle sorte que, si $d^2(x_j, b_i) \neq 0$:

$$u_{ij} = \left(\frac{\alpha}{m \cdot d^2(x_j, b_i)} \right)^{\frac{1}{m-1}}, \quad (\text{III. 6})$$

Avec

$$\sum_{i=1}^C u_{ij} = \left(\frac{\alpha}{m} \right)^{\frac{1}{m-1}} \sum_{i=1}^C \left(\frac{1}{d^2(x_j, b_i)} \right)^{\frac{1}{m-1}} = 1, \quad (\text{III. 7})$$

Et finalement

$$u_{ij} = \left[\sum_{k=1}^c \left(\frac{d^2(x_j, b_i)}{d^2(x_j, b_k)} \right)^{\frac{1}{(m-1)}} \right]^{-1} \quad (\text{III. 8})$$

Si $d^2(x_j, b_i) = 0$, x_j est un prototype b_i et $u_{ij} = 1$ avec $u_{kj} = 0$, $k \neq i$.

Pour C et X fixés, l'annulation des dérivées partielles $H'(B, g)$ par rapport à une direction quelconque g de B donne enfin :

$$b_i = \frac{\sum_{k=1}^n u_{ik}^m \cdot x_k}{\sum_{k=1}^n u_{ik}^m} \quad (\text{III. 9})$$

L'algorithme des C -moyennes floues (FCM) consiste alors en l'application itérée de (III. 4) et (III. 5) jusqu'à stabilité des solutions. Le critère d'arrêt des itérations, définissant cette stabilité, peut par exemple consister en l'étude de la norme de la matrice U ou en la stabilité des centres de classe sur deux itérations successives.

III.3. Les variantes des c-moyennes floues

De nombreuses variations de l'algorithme FCM sont possibles. Nous décrivons dans ce qui suit quelques-unes des nombreuses variantes qui dérivent des c-moyennes floues. Les trois premières généralisations suivantes proposées respectivement par Davé [17], Pedrycz [18] et Krishnapuram et Keller [19] lèvent la contrainte liant les degrés d'appartenance d'un point donné. Kamel et Selim [20], et Kehtarnavaz et al. [21] ont proposé des méthodes qui tiennent compte du voisinage des points étudiés. Gath et Geva [22] ont, par ailleurs, mis au point une variante s'inspirant du critère du maximum de vraisemblance. Pedrycz [23] a introduit une généralisation des FCM dans un environnement partiellement supervisé. Davé [24] a étudié une technique dédiée à la détection de contours courbés. Cannon et al [25] ont proposé une implémentation de l'algorithme qui permet d'en accroître la vitesse. Rousseeuw et al [26] ont introduit une variante à plus grand contraste entre les degrés d'appartenance.

III.3.1. Les c-moyennes floues Spatial (s-FCM)

FCM spatial (s-FCM) est une extension de l'algorithme FCM, en d'autres termes, les pixels voisins d'une image ont une grande probabilité qu'ils appartiennent à la même classe. Cette relation spatiale est importante dans le regroupement, mais elle n'est pas utilisée dans l'algorithme de base (FCM). Chuang et al. ont proposé un algorithme FCM spatiale, dans laquelle l'information spatiale peut être intégrée dans la fonction d'appartenance floue (faire changer la fonction objective) [27]. Et la fonction spatiale est définie comme suit :

$$h_{ij} \leftarrow \sum_{k \in \text{NB}(x_j)} u_{ik} \quad (\text{III. 10})$$

Où $\text{NB}(x_j)$ représente une fenêtre carrée centrée sur le pixel x_j dans le domaine spatial. La fonction spatiale h_{ij} représente la probabilité que le pixel x_j appartient à la $i^{\text{ème}}$ classe.

III.3.2. Les c-moyennes possibilistes

Krishnapuram et Keller ont proposé une approche possibiliste des c-moyennes appelée Possibilistic C-Means, ou PCM [28][29]. Leur approche est censée conduire à une meilleure performance en présence de bruit. Mais leur travail est motivé essentiellement par le désir de remédier au caractère relatif des degrés d'appartenance générés par les FCM. En effet, ces derniers sont interprétés en tant que degrés de vérité relatifs décrivant l'appartenance d'un vecteur quelconque à chacune des classes possibles. Un élément à classer est donc, en quelque sorte, partagé entre ces différentes classes. A cette idée de partage Krishnapuram et Keller préfèrent substituer la notion de typicalité. En effet, le résultat d'un regroupement devrait décrire la parenté absolue entre un objet et chacune des c classes possibles, indépendamment du lien entre cet objet et les $(c - 1)$ classes restantes.

La méthode est basée sur la minimisation du critère suivant:

$$J_m(U, v) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 + \sum_{i=1}^c \eta_i \sum_{j=1}^n (1 - u_{ij})^m \quad (\text{III. 11})$$

Où η représente le degré de pondération.

III.3.3. Extension aux contours courbés

C'est une approche basé sur la détection de contours courbés (circulaires, elliptiques) et particulièrement utile en traitement d'image. Proposé par Davé[30,31] connue sous le nom de « Fuzzy C-Shells » ou FCS. D'autres travaux ont été menés sur le thème des «Fuzzy C-Shells » par des auteurs tels que Davé et Bhaswan [32] , Bezdek et Hathaway [33] qui en ont étudié la convergence, Krishnapuram, Nasraoui et Frigui [34] qui ont proposé une autre approche des FCS.

III.3.4. L'approche de Gath et Geva

L'idée de l'approche se base sur l'estimation par le maximum de vraisemblance [35]. Pour adapter les FCM à des cas correspondant à des classes hyper-ellipsoïdales, à des densités différentes pour les différentes classes, ou à des distributions inégales de l'ensemble des points au sein des différentes classes, cette approche introduit une distance exponentielle $d_e(x_j, v_i)$ (basé sur le maximum de vraisemblance) dans le calcul des degrés d'appartenance Gath et Geva ont assimilées les degrés d'appartenance à des probabilités conditionnelles :

$$u_{ij} = P(i|x_j) \quad (\text{III. 12})$$

III.3.5. L'approche de Davé

Si l'algorithme est appliqué en recherchant 3 classes au lieu de 2. Les deux autres groupes correspondront alors à de bonnes données, donc les points associés au bruit seront affecté au troisième groupe intrus. Cependant ces points n'ont pas forcément une distribution aussi triviale .Si l'on suppose que (c-1) groupe existent, alors un $c^{ième}$ groupe associé au bruit est ajouter. Davé propose une caractérisation de ce groupe basée sur l'idée de prototype. Contrairement aux prototypes des groupes habituels, le groupe associé au bruit est égale distance δ , de tous les points du nuage comme suit :

$$\forall j \in \{1,2, \dots n\}, d(x_j, v_c) = \delta \quad (\text{III. 13})$$

La probabilité que tous les points est égale de tomber dans le groupe intrus. Les formules itératives donnant les différents u_{ij} et v_i sont également inchangées. Le degré d'appartenance le plus élevé correspond, pour un vecteur x_j , à la classe dont le centre est le plus proche de ce vecteur.

Le choix de la valeur de δ est donc crucial. Dans le cas le plus général, on ne dispose pas d'informations permettant d'estimer la valeur optimale de δ . Et cette dernière dépend, bien sûr, de la structure des données étudiées. Davé propose d'estimer δ^2 à partir de la distance carrée inter-points moyenne calculée sur les $(c - 1)$ bons groupes. La formule que cet auteur utilise est la suivante :

$$\delta^2 = \lambda \cdot \frac{\sum_{i=1}^{c-1} \sum_{j=1}^n (d_{ij})^2}{n(c-1)} \quad (\text{III. 14})$$

Où λ est un facteur multiplicatif permettant d'obtenir δ^2 à partir de la moyenne du carré des distances entre les n points et les $(c - 1)$ centres de groupe. La valeur de δ est donc entièrement déterminée par celle de λ . Néanmoins, Davé ne donne pas de méthode pour l'estimation de λ .

III.3.6. L'approche de Kamel et Selim

Cette approche est connue dans la littérature sous le nom de semi-c-moyennes floues, ou c-moyennes floues à seuil (TFCM, pour Thresholded FCM). Ces étapes supplémentaires peuvent être vues comme une tâche de pré-défuzzification. Proposé par Kamel et Selim [36] elle consiste à forcé à zéro les degrés d'appartenance u_{ik} de la partition final, lorsque le vecteur x_k à la classe i est inférieur à une valeur de seuil, τ , et les autres degrés d'appartenance sont ensuite normalisés de telle sorte que leur somme soit égale à 1. Pratiquement, cette approche est mis en œuvre en ajoutant les étapes suivantes à la fin de l'algorithme de Bezdek :

- calcul du seuil (global) :

$$\tau = \min (\min \max u_{ik}, \min \max u_{ik}) \quad (\text{III. 15})$$

- seuillage :

$$(si (u_{ik} < \tau) \text{ alors } u_{ik} = 0) \quad (III. 16)$$

➤ normalisation, calcul de nouveaux degrés d'appartenance u_{ik}^* :

$$u_{ik}^* = \frac{u_{ik}}{\sum_{j=1}^c u_{ik}} \quad (III. 17)$$

III.3.7. L'approche de Gustafson et Kessel

Proposé par Gustafson et Kessel [37]. Où chaque classe d'indice i est associée une matrice carrée A_i à p lignes et p colonnes, p étant la dimension de l'espace des données. Les matrices $A_1, A_2, \dots, A_c$, qui dépendent des x_j et dont les déterminants sont fixés ($\det A_i = \rho_i$), sont définies positives et sont utilisées pour le calcul des distances :

$$d_{ij}^2 = \|x_j - v_i\|_{A_i}^2 = (x_j - v_i)^T \cdot A_i \cdot (x_j - v_i) \quad (III. 18)$$

La fonction objective utilisée par Gustafon et Kessel est donc la suivante :

$$J_m^{GK} = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \|x_j - v_i\|_{A_i}^2 \quad (III. 19)$$

La formule permettant le calcul des différents centres est inchangée. Celle relative aux degrés d'appartenance est légèrement modifiée en faisant intervenir le nouveau calcul des distances et non plus la matrice unité correspondant à la distance euclidienne. Les matrices A_i sont remises à jour à chaque itération :

$$A_i = (\rho_i(\det S_i))^{1/p} S_i^{-1} \quad (III. 20)$$

Où S_i est une matrice calculer comme suite :

$$S_i = \frac{\sum_{j=1}^n u_{ij}^m (x_j, v_i)(x_j - v_i)^T}{\sum_{j=1}^n u_{ij}^m} \quad (III. 21)$$

Gath et Geva, ont aussi introduit une méthode qui descend des FCM et qui fait intervenir une distance non euclidienne.

III.3.8. Une approche partiellement supervisée des FCM

Cette approche peut être exploitée pour reconnaître les différents groupes présents dans les données. Soit X_1 un sous-ensemble de X constitué de points d'apprentissage. On associe à un vecteur x_k appartenant à X_1 le vecteur g à composantes binaires dont la transposée est :

$$g^T = (g_1 \ g_2 \ \dots \ g_n) \quad (\text{III. 22})$$

Où :

$$g_k = 1 \text{ si } x_k \in X_1 \text{ et } g_k = 0 \text{ si } x_k \notin X_1, k = 1, 2, \dots, n \quad (\text{III. 23})$$

L'information relative aux points d'apprentissage peut être représentée par une matrice F à c lignes et n colonnes :

$$F = (f_{ij})_{\substack{i=1,2,\dots,c \\ j=1,2,\dots,n}} \quad (\text{III. 24})$$

Pour un vecteur x_1 , quelconque de X_1 , les éléments de matrice f_{ij} , $i = 1, 2, \dots, c$ de la $j^{\text{ième}}$ colonne de F sont fixés tels que :

$$\sum_{i=1}^c f_{ij} = 1 \quad (\text{III. 25})$$

et représentent les degrés d'appartenance de x_j aux différents groupes. Pour un vecteur x_k n'appartenant pas à X_1 , les éléments de matrice f_{ik} , $i = 1, 2, \dots, c$, de la $k^{\text{ième}}$ colonne de F sont fixés arbitrairement et ne jouent aucun rôle dans l'algorithme. L'information liée aux

éléments de X_1 , est ensuite utilisée pour modifier la fonction objectif des FCM. Un critère possible tenant compte de cette information est [23] :

$$\varrho_1 = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^2 d_{ij}^2 + \sum_{i=1}^c \sum_{j=1}^n (u_{ij} - f_{ij} g_j)^2 d_{ij}^2 \quad (\text{III. 26})$$

La deuxième double somme figurant dans la définition de ϱ_1 fait intervenir l'écart entre les degrés d'appartenance calculés (u_{ij}) pour les points de X_1 et les degrés fixés par l'utilisateur pour ces mêmes points (f_{ij}). Elle peut se mettre sous la forme suivante :

$$\sum_{i=1}^c \sum_{j=1}^n (u_{ij} - f_{ij} g_j)^2 d_{ij}^2 = \sum_{i=1}^c \sum_{x_j \in X_1} (u_{ij} - f_{ij})^2 d_{ij}^2 \quad (\text{III. 27})$$

En effet, g_j est différent de 0 si x_j appartient à X_1 . La minimisation de ϱ_1 est obtenue à l'aide des formules suivantes [38] mettant à jour les degrés d'appartenance à partir des dernières valeurs calculées pour les centres v_i , $i = 1, 2, \dots, c$ et inversement :

$$v_i = \frac{\sum_{j=1}^n u_{ij}^2 x_j}{\sum_{j=1}^n u_{ij}^2} \quad (\text{III. 28})$$

$$u_{ij} = \frac{2 - \sum_{s=1}^c f_{sj} g_j}{2 \sum_{t=1}^c \frac{d_{ij}^2}{d_{it}^2}} + \frac{1}{2} f_{ij} g_j, i = 1, 2, \dots, c, j = 1, 2, \dots, n \quad (\text{III. 29})$$

On pourra aussi consulter l'algorithme adaptatif de classification dans un environnement partiellement supervisé proposé par Béreau et Dubuisson.

III.3.9. Une approche due à Pedrycz : FCM conditionnelles

L'approche possibiliste, en tant que technique de regroupement, s'intéresse essentiellement à la structure inhérente aux données, alors que l'approche de Pedrycz cherche à trouver les éléments vérifiant une certaine condition.

Pedrycz [39] a proposé cette version des FCM qui fait intervenir des variables auxiliaires. Les vecteurs sont groupés en tenant compte de leurs coordonnées dans l'espace des données mais aussi de la valeur prise par la variable auxiliaire, et qui traduit une certaine condition fixée par l'utilisateur. Si f est la variable auxiliaire utilisée et $f_1, f_2, \dots, f_n$ sont les valeurs qu'elle prend pour les différents vecteurs, alors f_k décrit le degré d'engagement du vecteur x_k dans la construction de la partition. Il ne s'agit pas simplement de trouver la structure ou les groupes d'un ensemble de données X , mais d'en identifier les groupes sous une certaine condition, ou dans un certain contexte défini par les variables auxiliaires. Une telle condition peut éventuellement être énoncée linguistiquement. Pedrycz a proposé les deux options suivantes :

$$\sum_{i=1}^c u_{ik} = f_k \quad (\text{III. 30})$$

$$\max_i u_{ik} = f_k \quad (\text{III. 31})$$

Afin de minimiser la fonction objectif de Bezdek, où les degrés d'appartenance sont mis à jour par la formule suivante :

$$u_{ik} = f_k \frac{\frac{1}{(d(x_k, v_i))^{\frac{2}{m-1}}}}{\sum_{i=1}^c \frac{1}{(d(x_k, v_i))^{\frac{2}{m-1}}}} \quad (\text{III. 32})$$

Le calcul des centre reste inchangé.

III.3.10. Approximations

Cette approche, baptisée AFCM (*Approximate FCM*), proposé pas Cannon et al [40], qui fait intervenir des calculs sur des quantités approchées, entières ou réelles. Est 6 fois plus rapide que l'implémentation faisant appel au calcul exact des degrés d'appartenance et des coordonnées des centres. Elle ne possède cependant pas les mêmes propriétés de convergence que les FCM. L'utilisation de tables pour le calcul approché de puissances et de distances implique la rapidité de la méthode.

Cheng, Goldgof et Hall ont proposé un algorithme baptisé MRFCM (*Multistage Random Sampling FCM*) plus rapide que l'algorithme de base et ayant les mêmes propriétés de convergence.

III.3.11. Les FCM à prototypes multiples

Yen, Chang et Ying [41] ont proposé leur approche appelée MFCM (Multi-prototype FCM), qui s'agit d'associer à chacun des groupes plusieurs prototypes pour mieux rendre compte de la forme de ces groupes. L'algorithme est initialisé en choisissant les prototypes de départ lorsque les positions de ces derniers peuvent être devinées d'avance. A chaque classe d'indice i est associé un ensemble Z_i contenant r_i prototypes $v_{i1}, v_{i1}, \dots, v_{ir_i}$, décrivant cette classe. Nous noterons encore par c le nombre de classes, mais le nombre de prototypes est désormais égal à $r_1 + r_2 + \dots + r_c$. Leur le critère J_2 est généralisé et remplacé par :

$$J'_2(U, v) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^2 \min_{v_{il} \in Z_i} \|x_k - v_{il}\|^2 \quad (\text{III. 33})$$

Ils ont montré que les deux conditions (III.29) et (III.30) sont nécessaires pour la minimisation de J'_2 :

$$v_{il} = \frac{\sum_{x_k \in X_{il}} u_{ik}^2 x_k}{\sum_{x_k \in X_{il}} u_{ik}^2} \quad (\text{III. 34})$$

Où X_{il} est l'ensemble de tous les vecteurs x_k plus proches du prototype v_{il} que de n'importe quel autre prototype représentant la $i^{\text{ème}}$ classe. Lorsque cet ensemble est vide, v_{il} garde sa valeur antérieure. Contrairement aux FCM, la mise à jour d'un centre donné ne fait pas intervenir tous les vecteurs. La deuxième condition est relative aux degrés d'appartenance :

$$u_{ik} = \frac{1}{\sum_{j=1}^c \frac{1}{\min_{v_{jl} \in Z_j} \|x_k - v_{jl}\|^2}} \quad (\text{III. 35})$$

La règle du plus proche voisin est donc utilisée pour la typicité du vecteur x_k aux différents groupes.

III.3.12. Des FCM à haut contraste

Pour des valeurs de m strictement supérieures à 1, on obtient des degrés d'appartenance gris à l'aide des FCM. Proposé par Rousseeuw, Trauwaert et Kaufman [42], donnent une interprétation élégante de l'équivalence entre la minimisation de J_1 et le processus *Isodata*, pour un ensemble X à deux groupes. J_1 est en effet minimisé pour des degrés d'appartenance binaires (noirs ou blancs), bien que ces degrés soient autorisés à prendre a priori, n'importe quelle valeur réelle dans l'intervalle $[0,1]$. Ils proposent, en outre, de remplacer, dans J_m , la quantité u_{ij}^m par une fonction $f(u_{ij})$, telle que, par exemple :

$$f(u_{ij}) = \xi u_{ij} + (1 - \xi) u_{ij}^2 \quad (\text{III. 36})$$

ξ étant un nombre réel dans l'intervalle $[0,1]$. La fonction objectif devient alors :

$$J_R = \sum_{i=1}^c \sum_{j=1}^n [\xi u_{ij} + (1 - \xi) u_{ij}^2] d_{ij}^2 \quad (\text{III. 37})$$

$$\begin{aligned} f(u_{ij}) &\rightarrow u_{ij} \\ \xi &\rightarrow 0 \end{aligned} \quad (\text{III. 38})$$

$$\begin{aligned} f(u_{ij}) &\rightarrow u_{ij}^2 \\ \xi &\rightarrow 1 \end{aligned} \quad (\text{III. 39})$$

et J_R tend respectivement vers J_1 ou J_2 . Dans le premier cas, les degrés d'appartenance sont noirs ou blancs [41], et dans le deuxième ces degrés sont gris. La valeur du paramètre ξ permet donc de moduler le contraste entre les degrés d'appartenance élevés et ceux qui sont faibles.

Cette approche peut être généralisée à d'autres techniques floues de regroupement, et les résultats peuvent correspondre aux groupes naturels si l'on dispose de la valeur (ou l'ensemble de valeurs) optimale(s) de ξ .

III.5. Conclusion :

Dans ce chapitre sont cités FCM et ses différentes variantes, où nous avons vu que plusieurs modifications sont apportées afin d'améliorer l'idée primaire de FCM. Ces méthodes sont élaborées pour éliminer les bruits d'acquisition (image IRM ou autre),...etc. afin d'améliorer la segmentation.

.

IV.1. Introduction

Ce chapitre est consacré pour l'application de FCM et certaines de ses variantes dans le cadre de la segmentation d'images. Les méthodes ont été appliquées sur des images IRM réelles de cerveaux humains, nous cherchons donc à segmenter la matière blanche, la matière grise, le liquide céphalo-rachidien. Les différents résultats seront présentés dans cette application.

IV.2. Méthodes de segmentation

Dans notre travail, nous avons utilisé les algorithmes FCM, PCM, FCM spatiale (sFCM) des figures 1, 2, 3 et deux hybridations. Dans la première les résultats de FCM sont utilisés pour initialiser PCM (figure 4) et dans la seconde, c'est les résultats de sFCM qui sont utilisés pour initialiser PCM (figure 5).

Début

Etape 1 : Fixer les paramètres.

Les entrées : $X = (x_j, j = 1 \dots N)$ l'ensemble des vecteurs forme, C : nombre de classes

ε : Seuil représentant l'erreur de convergence (par exemple $\varepsilon = 0,001$)

m : Degré de flou, $m \in [1.5, 3]$.

Etape 2 : Initialiser la matrice degrés d'appartenances U par valeurs aléatoires dans l'intervalle $[0, 1]$.

Etape 3 : Mettre à jour la matrice prototype B par relation

$$b_i \leftarrow \frac{\sum_{k=1}^n U_{ik}^m x_k}{\sum_{k=1}^n U_{ik}^m}$$

$$J^{Ancien} \leftarrow \sum_{i=1}^c \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i)$$

Etape 4 : Mettre à jour la matrice des degrés d'appartenance par la relation

$$u_{ij} \leftarrow \left[\sum_{k=1}^c \left(\frac{d^2(x_j, b_i)}{d^2(x_j, b_k)} \right)^{2/(m-1)} \right]^{-1}$$

$$J^{Nouveau} \leftarrow \sum_{i=1}^c \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i)$$

Etape 5 : Répéter les étapes 3 à 4 jusqu'à satisfaction du critère d'arrêt qui s'écrit :

$$\|J^{Ancien} - J^{Nouveau}\| \leq \varepsilon$$

Les sorties : La matrice d'appartenance U et les centres des classes B .

Algorithme de FCM

Début

Etape 1 : Fixer les paramètres.

Les entrées : $X = (x_j, j = 1 \dots N)$ l'ensemble des vecteurs forme, C : nombre de classes

ε : Seuil représentant l'erreur de convergence (par exemple $\varepsilon = 0,001$)

m : Degré de flou, $m \in [1.5, 3]$. η_i : Degré de pondération.

Etape 2 : Initialiser la matrice degrés d'appartenances U par valeurs aléatoires dans l'intervalle $[0, 1]$.

Etape 3 : Mettre à jour la matrice prototype B par relation
$$b_i \leftarrow \frac{\sum_{k=1}^n U_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}$$

$$J^{Ancien} \leftarrow \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i) + \sum_{i=1}^C \eta_i \sum_{j=1}^N (1 - u_{ij})^m$$

Etape 4 : Mettre à jour la matrice des degrés d'appartenance par la relation

$$u_{ij} \leftarrow \frac{1}{1 + \left(\frac{d^2(x_j, b_i)}{\eta_i} \right)^{\frac{1}{m-1}}}$$

$$J^{Nouveau} \leftarrow \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i) + \sum_{i=1}^C \eta_i \sum_{j=1}^N (1 - u_{ij})^m$$

Etape 5 : Répéter les étapes 3 à 4 jusqu'à satisfaction du critère d'arrêt qui s'écrit :

$$\|J^{Ancien} - J^{Nouveau}\| \leq \varepsilon$$

Les sorties : La matrice d'appartenance U et les centres des classes B .

Fin

Algorithme de PCM.

Début

Etape 1 : Fixer les paramètres.

Les entrées : Mettre la matrice d'image sous forme ensemble des vecteurs

$X = (x_j, j = 1 \dots N)$ l'ensemble des vecteurs forme ;

C : nombre de classes ;

ε : Seuil représentant l'erreur de convergence (par exemple $\varepsilon = 0,001$) ;

m : Degré de flou,

p et q : les paramètres spatiales ;

la fenêtre de voisinage est 5×5 ;

Etape 2 : Initialiser la matrice degrés d'appartenances U par valeurs aléatoires dans l'intervalle $[0,1]$.

Etape 3 : Calculer la matrice prototype B par relation

$$b_i \leftarrow \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}$$

Etape 4 : Calculer la fonction spatiale

$$h_{ij} \leftarrow \sum_{k \in NB(x_j)} u_{ik}$$

Etape 5 : Calculer la matrice des degrés d'appartenance spatiale par la relation :

$$u'_{ij} \leftarrow \frac{u_{ij}^p h_{ij}^q}{\sum_{k=1}^c u_{kj}^p h_{kj}^q}$$

$$J^{\text{Ancien}} \leftarrow \sum_{i=1}^c \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i)$$

Etape 6 : Mettre à jour la matrice des degrés d'appartenance par la relation :

$$u_{ij} \leftarrow \left[\sum_{k=1}^c \left(\frac{d^2(x_j, b_i)}{d^2(x_j, b_k)} \right)^{2/(m-1)} \right]^{-1}$$

Mettre à jour la fonction spatiale de l'étape 4 et matrice des degrés d'appartenance spatiale de l'étape 5.

$$J^{\text{Nouveau}} \leftarrow \sum_{i=1}^c \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i)$$

Etape 7 : Mettre à jour la matrice prototype B de l'étape 3

Etape 8 : Répéter les étapes 6 à 7 jusqu'à satisfaction du critère d'arrêt qui s'écrit :

$$\|J^{\text{Ancien}} - J^{\text{Nouveau}}\| \leq \varepsilon$$

Fin

Algorithme de FCM spatial

Début

Etape 1 : Fixer les paramètres.

Les entrées : $X = (x_j, j = 1 \dots N)$ l'ensemble des vecteurs forme, C : nombre de classes

ε : Seuil représentant l'erreur de convergence (par exemple $\varepsilon = 0,001$)

m : Degré de flou, $m \in [1.5, 3]$. η_i : Degré de pondération.

Etape 2 : Lancer l'algorithme FCM.

Etape 3 : Récupérer la matrice degré d'appartenance U de sortie FCM

Etape 4 : Lancer l'algorithme PCM

Les sorties : Image résultante

Algorithme de FCM+PCM.

Début

Etape 1 : Fixer les paramètres.

Les entrées : $X = (x_j, j = 1 \dots N)$ l'ensemble des vecteurs forme, C : nombre de classes

ε : Seuil représentant l'erreur de convergence (par exemple $\varepsilon = 0,001$)

m : Degré de flou, $m \in [1.5, 3]$. p, q : Paramètres spatiales

Etape 2 : Lancer l'algorithme S-FCM.

Etape 3 : Récupérer la matrice degré d'appartenance U de sortie sFCM

Etape 4 : Lancer l'algorithme PCM

Les sorties : Image résultante

Algorithme de sFCM+PCM.

Après la fin de chaque algorithme on ajoute une étape de déffuzzification.

Deux paramètres importants interviennent dans la segmentation d'images avec nos méthodes, le premier est le choix du vecteur forme, le deuxième est le choix des paramètres des méthodes de classification utilisé pour cette segmentation.

IV.2.1. Le choix du vecteur forme

Le choix des vecteurs forme est fondamental puisque leur pertinence va permettre de discriminer les pixels entre eux. Ce choix est défini suivant le type de modalité.

L'image anatomique que nous utilisons dans les protocoles du chapitre IV est une IRM. L'imagerie par résonance magnétique est une modalité d'imagerie multi spectrale donnant accès à un grand nombre de paramètres et donc de vecteurs forme. La première caractéristique qui peut être exploitée est le signal lui-même, principalement par l'intermédiaire d'images pondérées en T1, T2 et en densité de protons. Le vecteur forme x_j d'un pixel j est alors formé des niveaux de gris de ce pixel dans toutes les images. Cette information est très largement utilisée en segmentation d'images, en particulier dans un cadre flou ou non.

IV.2.2. Choix des paramètres des méthodes utilisées

Dans notre approche nous avons utilisé des algorithmes de classification flous (FCM, PCM, sFCM et deux hybridation FCM+PCM, sFCM+PCM) pour segmenter les tissus cérébraux des images IRM. Pour cela il est nécessaire de fixer chaque paramètre de chaque algorithme.

Détermination du nombre de classes : Notre étude est de séparer les différentes parties du cerveau (matière grise, matière blanche et le liquide céphalo-rachidien), pour des images saines on a choisis trois classes, et pour une image affectée d'une maladie on a ajouté une autre classe (donc 4 classes).

Choix du degré de flou m : ce paramètre contrôle le degré de flou de la partition floue U , vari entre 1.5 et 3. Plus il est proche de 1, U résultant est quasiment non floue et l'inverse augmente le degré de flou de U . Notre choix est fixé à 2, car c'est la meilleure pour assurer la convergence de l'algorithme.

Choix des paramètres de pondération η : on a fixé les paramètres de pondérations à partir de l'algorithme FCM et sFCM pour les deux hybridations, par l'équation suivante :

$$\eta_i = \frac{\sum_{j=1}^N u_{ij}^m d^2(x_j, b_i)}{\sum_{j=1}^N u_{ij}^m}$$

Choix des paramètres spatiaux p et q : ils sont choisis d'une manière à rendre l'algorithme plus robuste aux bruits. Dans notre cas $p=1$ et $q=2$,

Choix des seuils ε : Les choix ont été choisis après avoir effectué plusieurs tests et les meilleurs résultats sont acquis par les choix suivants :

- pour FCM, PCM, sFCM, $\varepsilon = 0.001$,
- pour les hybridations FCM, sFCM ($\varepsilon = 0.2$) et PCM ($\varepsilon = 0.001$) .

IV.3. Les différents résultats

Nous présentons dans cette partie les résultats obtenus à partir de différentes approches qui ont été implémentés sous Matlab R2009 et exécutés sur un PC (système d'exploitation windows7 64bits, CPU Dual Core 2.4 Ghz, Ram 2GO).

IV.3.1. Résultats obtenus sur la première image pondérée en T1 :




Fig.1. Résultat obtenu par FCM




Fig.2. Résultat obtenu par PCM




Fig.3. Résultat obtenu par sFCM




Fig.4. Résultat obtenu par sFCM+PCM






Fig.5. Résultat obtenu par FCM+PCM

En remarque des bruits sur l'image originale. Notre approche a permet de diminuer au maximum les bruits, et éliminé les bruits (fig/4/5).

IV.3.2. Résultats obtenus sur la deuxième image pondérée en T2:**Fig.6.** Résultat obtenu par FCM**Fig.7.** Résultat obtenu par PCM




Fig.8. Résultat obtenu par sFCM




Fig.9. Résultat obtenu par FCM+PCM






Fig.10. Résultat obtenu par sFCM+PCM

Remarque :

L'application de PCM (**Fig.7**) sur ce genre d'image n'est pas bénéfique car il élimine complètement quelque partie de l'image, et cela enlève la possibilité de détecter des tumeurs. Cette image pour les médecins ne représente rien. Si on veut éliminer les bruits avec sFCM et les points aberrant avec PCM au même temps sans autant détérioré notre image, ici l'approche proposé sFCM+PCM démontre son vrai rôle et son efficacité (**Fig.10**)

IV.3.3. Résultats obtenus sur la troisième image coupe sagittal pondéré T2:**Fig.11. Résultat obtenu par FCM****Fig.12. Résultat obtenu par PCM**




Fig.13. Résultat obtenu par sFCM




Fig.14. Résultat obtenu par FCM+PCM




Fig.15. Résultat obtenu par sFCM+PCM

En remarque dans le traitement de cette image que les deux approches proposé (FCMandPCM et sFCMandPCM), éclaircies les zones sombre, par contre FCM, PCM et sFCM transforme ces derniers en une autre classe.




Fig.16. Comparaisons entre FCM(a), sFCM(b), PCM(c) , FCM+PCM(d) et sFCM+PCM

IV.3.4. Résultats obtenus sur la quatrième image pondérée T2:

Ici le traitement est réalisé sur une image IRM cérébral atteinte d'une tumeur nommé **Neoplastic disease (brain tumor)**, et segmenter sur quatre classes.




Fig.17. Résultat obtenu par FCM




Fig.18. Résultat obtenu par PCM




Fig.19. Résultat obtenu par sFCM




Fig.20. Résultat obtenu par FCM+PCM

Sur cet exemple ci dessus (**Fig.20**), on remarque l'utilité de l'algorithme FCM+PCM a bien démontré les contours des différentes parties de l'image, on aperçoit sa, sur le point orange situé sur le bord de la matière blanche, entouré en couleur marron foncé. Ce dernier représente la tumeur.




Fig.21. Résultat obtenu par sFCM+PCM

Ici la tumeur est coloriée en vert entouré en marron.

IV.4. Evaluation de la méthode de classification :

Les fonctions de validation des classes obtenues du partitionnement flou sont souvent utilisées pour évaluer les performances des différentes méthodes de classification. Ces fonctions sont les suivantes :

La fonction de partition

$$V_{pc} = \frac{\sum_j^N \sum_i^c u_{ij}^2}{N}$$

La fonction d'entropie de partition

$$V_{pe} = \frac{-\sum_j^N \sum_i^c (u_{ij} \log u_{ij})}{N}$$

L'idée de la validité de ces fonctions est que la partition avec moins de flou signifie de meilleures performances. En conséquence le meilleur résultat ou regroupement est atteint quand V_{pe} est minimale et V_{pc} est maximal.

IV.5. Analyses et Interprétations :




Image	Méthode utilisé	V_{pc}	V_{pe}
	FCM	0.9095	0.1687
	sFCM	0.9911	0.0149
	PCM	0.7458	0.4796
	FCM+PCM	0.7436	0.4774
	sFCM+PCM	0.9862	0.0232
	FCM	0.9887	0.0187
	sFCM	0.9919	0.0138
	PCM	0.6433	0.5839
	FCM+PCM	0.7536	0.4497
	sFCM+PCM	0.9970	0.0120
	FCM	0.8435	0.2863
	sFCM	0.9769	0.0379
	PCM	0.6722	0.5992
	FCM+PCM	0.7576	0.4462
	sFCM+PCM	0.9542	0.1157
	FCM	0.9059	0.1808
	sFCM	0.9381	0.1258
	PCM	0.6964	0.5768
	FCM+PCM	0.7526	0.4516
	sFCM+PCM	0.9384	0.1196

Tableau des fonctions de validation

En remarque dans le tableau ci dessus, que l'efficacité des méthodes que sa soit FCM, sFCM, PCM où les deux hybridations, dépend des images et des paramètres d'initialisation. sFCM et nos deux méthodes sont les plus performantes. Malgré la petite différence entre sFCM et nos deux méthodes, la visibilité de cette dernière est la plus performante.

D'après le tableau si dessus, sFCM est plus efficace sur les images 3 et 4. Et notre approche et meilleur sur les images 3 et 4. Et PCM elle représente le plus mauvais résultat.

	FCM	sFCM	PCM	FCM+PCM	sFCM+PCM
Image 128*128	3 ses	2min	47sec	1.02min	2.58min
Image 256*256	10s	30min	21min	24min	35min

Tableau des temps d'exécution des algorithmes

Le temps d'exécution diffère d'une image à une autre, cela dépend des paramètres d'initialisation et des images elle-même.

Les résultats de la segmentation montrent l'efficacité des deux méthodes ; les différentes parties du cerveau sont nettement segmentées. On peut voir clairement la qualité et la précision sur certains images notamment les figures (**Fig.10/15/21**).

IV.6.Conclusion :

Dans ce chapitre une étude comparative détaillé des cinq algorithmes réalisé, et on a évalué la performance de la meilleur méthode. Durand notre travail nous avons effectué plusieurs essais sur plusieurs images, et on a vu que chaque méthode a ces propres performance, cela différent d'une image a une autre. Sur ce, l'hybridation de deux méthodes apporte un résultat plus performant et efficace.

Conclusion générale

De nos jours l'étude d'image IRM ne cesse d'évolué, les médecins cherchent toujours des résultats plus précis et mieux segmentés pour détecter la moindre anomalie qui présente une maladie chez les patients. Donc la segmentation d'image IRM cérébrale est aujourd'hui très importante aux yeux des médecins, car elle leur offre une visibilité plus nette pour un bon diagnostic des maladies au niveau du cerveau humain. Cela est clairement bénéfique aux médecins et aussi a nous.

Dans notre travail, nous avons, donc, proposé une démarche qui segmente automatiquement les parties du cerveau toutes en éliminant les bruits de l'acquisition et les points aberrant du traitement flou (un pixel qui a le même degré d'appartenance pour deux classe). Et cela permettra à l'expert une meilleure visibilité de l'image cérébrale afin de détecter la moindre maladie du cerveau.

Les résultats obtenus, présentés dans le dernier chapitre, montrent une bonne segmentation pour l'ensemble des images. La méthode proposée ici devrait pouvoir être utilisé dans divers segmentation d'image tel que l'image satellite où elle sera très efficace, car elle élimine les zone d'ombre tel que les ombres causé par le soleil sur les différents constructions et des nuages, et aussi élimine les bruits. Nous pouvons être satisfaits des résultats de l'approche adoptée.

En effet en guise de perspective, nous allons utiliser des paramètres de texture pour améliorer nos résultats. Et nous souhaitons aussi évoluer dans ce domaine de traitement d'images tel que la segmentation des volumes 3D et des images acquises des réseaux souterrains, plaques tectoniques et des recherches de matière première (Gaz, pétrole etc....).

BIBLIOGRAPHIE

- [1] S. MIRI, « *Segmentation des structures cérébrales en IRM : intégration de contraintes topologiques* », Rapport de stage, Master 2. Spécialité PARI, option IRMC Université Louis Pasteur, Strasbourg, France, 2007.
- [2] G. LAURENCE, « *Trois Principes de Coopération pour la Segmentation en Imagerie de Résonance Magnétique Cérébrale* », Thèse de doctorat, spécialité : Informatique, Université Joseph Fourier – Grenoble 1. France, 1999.
- [3] M. Cyril JAGGI, « *Segmentation par Méthode Markovienne de L'encéphale Humain en Imagerie par Résonance Magnétique : Théorie, Mise en œuvre et Évaluation* », Thèse de doctorat, spécialité : Traitement du Signal et des Images, Université de CAEN/BASSE-NORMANDIE, 1992.
- [4] A-S. Capelle, « *Segmentation d'images IRM multi-échos tridimensionnelles pour la détection des tumeurs cérébrales par la théorie de l'évidence* ». Thèse de doctorat, Faculté des Sciences Fondamentales et Appliquées, Université de Poitiers, 2004.
- [5] ARAR C et KHEROUBI G, « *Traitement d'images médicales : Application à la segmentation* », Mémoire d'ingénieur en Electronique, UMMTO, 2011.
- [6] MELIANI M, « *Segmentation d'Image par Coopération Régions-Contours* », Mémoire de Magister en Informatique, ESI, 2012.
- [7] Mme. SLIMANI K, « *Segmentation d'images IRM par une technique basée sur le détecteur multi échelles de Canny* », Mémoire de Magister en Electronique, UMMTO, 2010.
- [8] A-S CAPELLE, « *Segmentation d'images IRM multi-échos tridimensionnelles pour la détection des tumeurs cérébrales par la théorie de l'évidence* », Thèse de doctorat, spécialité : Traitement du signal et des images, Université de Poitiers.
- [9] Zouaoui H, « *Clustering par fusion floue de données appliqué à la segmentation d'images IRM* », Mémoire de Magister, Spécialité : Système informatique et génie des logiciels, Université M'hamed BOUGARA de BOUMERDES, 2007.
- [10] P.Simpson : “*Artificial neural systems : foundations, paradigms, applications, and implementations*”. Pergamon Press, 1990.
- [11] S. Haykin : “*Neural networks : a comprehensive foundation - 2nd Edition*”. Prentice Hall, 1998.

- [12] R. Hult : “*Grey-level morphology combined with an artificial neural networks approach for multimodal segmentation of the hippocampus*”. Dans International Conference on Image Analysis and Processing, pages 277–282, 2003.
- [13] R. Sammouda, N. Niki et H. Nishitani : “*A comparison of Hopfield neural network and Boltzmann machine in segmenting MR images of the brain*”. IEEE Transactions on Nuclear Science, 43(6):3361–3369, décembre 1996.
- [14] Semchedine M, Toumi L, Moussaoui A, «*Système Coopératif de Classification Floue Possibiliste avec Rejet d’Ambiguïté, Application à la segmentation d’images IRM*», Département d’Informatique – Université Ferhat Abbas de Sétif, 2007.
- [15] K. Fukunaga et L. Hostler. “*The estimation of the gradient of a density function with IEEE Transaction on information Théory*”, 6:721-741. 1984.
- [16] D. Comaniciu et P. MEER : Mean Shift : “*robust approach Toward feature space analysis. IEEE Transaction on Pattern Analysis and Machine Intelligence*”, 24(5) : 603-619. Mai 2002.
- [17] Rajesh N. Davé, “*Characterization and detection of noise in clustering*”P, Pattern Recognition Letters, Vol. 12, n. 11, pp. 657-664, 1991.
- [18] W Pedrycz, “*Conditional fuzzy c-means*”, Pattern Recognition Letters 17, pp. 625-631, 1996.
- [19] R. Krishnapuram and J. Keller, “*A possibilistic Approach to Clustering*”, IEEE Trans. on Fuzzy Systems, vol. 1, n. 2, May 1993.
- [20] Kamel M.S. & Selim S.Z., “*A threshold fuzzy c-means algorithm for semi-fuzzy clustering*” P. Pattern Recognition 24, 1991, pp. 825-833.
- [21] N. Kehtarnavaz, M. Chung, L.A. Hayman & R.E. Wendt III, “*Magnetic resonance image segmentation by contextual fuzzy clustering*”, Journal of Intelligent and Fuzzy Systems, Vol. 1, 1994, pp. 295-305.
- [22] I. Gath and A. B. Geva, “*Unsupervised Optimal Fuzzy Clustering*”, IEEE Trans. Pattern Anal. Machine Intell., vol. PAMI-11, no. 7, pp. 773-781, July 1989.
- [23] Pedrycz W., “*Algorithms of fuzzy clustering with partial supervision*”P, Pattern Recognition Letters 3, pp. 13-20, 1985.
- [24] Rajesh N. Davé, “*Fuzzy c-shells clustering and applications to circle detection in digital images*”In J. General Systems, vol. 16, n. 4, pp. 343-355, 1990.
- [25] Robert L. Cannon, Jitendra V. Dave, and James C. Bezdek, “*Efficient implementation of the fuzzy c-means clustering algorithms*”, IEEE Trans. Pattern Anal. Machine Intell., vol. PAMI-8, no. 2, pp. 248- 255, March 1986.
- [26] Peter J. Rousseeuw, E. Trauwert, and L. Kaufman, “*Fuzzy clustering with high contrast*” Journal of Computational and Applied Mathematics, 64, pp. 81-90, 1995.

- [27] MESLOUB K, « *Analyse d'images IRM pour l'étude de la sclérose en plaques* », Mémoire de Magister en Automatique, Option : Traitement d'Images et Reconnaissance de Formes, UMMTO.
- [28] R. Krishnapuram and J. Keller, "A possibilistic Approach to Clustering", IEEE Trans. on Fuzzy Systems, vol. 1, n. 2, May 1993.
- [29] R Nikhil, Pal and Kuhu Pal, J Bezdek, "AMixed C-Means Clustering Model", 0-7803-3796-4/1997IEEE.
- [30] Rajesh N. Davé, "Fuzzy c-shells clustering and applications to circle detection in digital images", Int. J. General Systems, vol. 16, n. 4, pp. 343-355, 1990.
- [31] R. N. Davé, "Generalized fuzzy c-shells clustering and detection of circular and elliptical boudaries", Pattern Recognition, Vol. 25, n. 7, pp. 713-721, 1992.
- [32] Rajesh N. Davé and K. Bhaswan, "Adaptive fuzzy c-shells clustering and detection of ellipses", IEEE Trans. on Neural Networks, vol. 3, n. 5, pp. 643-662, 1992.
- [33] Bezdek J. C. and R. J. Hathaway, "Numerical convergence and interpretation of the fuzzy c-shells clustering algorithm", IEEE Trans. on Neural Networks, vol. 3, n. 5, pp. 787-793, 1992.
- [34] R. Krishnapuram, O. Nasraoui and H. Frigui, "The fuzzy c spherical shells algorithm : A new approach", IEEE Trans. on Neural Networks, vol. 3, n. 5, pp. 663-671, 1992.
- [35] I. Gath and A. B. Geva, "Unsupervised Optimal Fuzzy Clustering", IEEE Trans. Pattern Anal. Machine Intell., vol. PAMI-11, no. 7, pp. 773-781, July 1989.
- [46] Kamel M.S. & Selim S.Z., "A threshold fuzzy c-means algorithm for semi-fuzzy clustering". Pattern Recognition 24, 1991, pp. 825-833.
- [37] D. Gustafson and W. Kessel, "Fuzzy clustering with a fuzzy covariance matrix", Proc. IEEE CDC, San Diego, CA, pp. 761-766, January 10-12, 1979.
- [38] Pedrycz W., "Algorithms of fuzzy clustering with partial supervision", Pattern Recognition Letters 3, pp. 13-20, 1985.
- [39] Witold Pedrycz, "Conditional fuzzy c-means", Pattern Recognition Letters 17, pp. 625-631, 1996.
- [40] Robert L. Cannon, Jitendra V. Dave, and James C. Bezdek, "Efficient implementation of the fuzzy c-means clustering algorithms", IEEE Trans. Pattern Anal. Machine Intell., vol. PAMI-8, no. 2, pp. 248-255, March 1986.
- [41] Dunn J. C., "A Fuzzy Relative of the ISODATA Process and its Use in Detecting Compact Well-Separated Clusters", J. Cybernetics, vol. 3, No. 3, pp. 32-57, 1973. Proceedings of the 2nd EUFIT Conference, pp. 539-543, Aachen 1994.
- [42] Peter J. Rousseeuw, E. Trauwert, and L. Kaufman, "Fuzzy clustering with high contrast", Journal of Computational and Applied Mathematics, 64, pp. 81-90, 1995.