

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOULOUD MAMMERI, TIZI-OUZOU



FACULTE DE GENIE ELECTRIQUE ET D'INFORMATIQUE
DEPARTEMENT AUTOMATIQUE

MEMOIRE DE MAGISTER

en Automatique

Option **Traitement d'Images et
Reconnaissance de Formes**

Présenté par

MESLOUB Karima

Ingénieur UMMTO

Analyse d'images IRM pour l'étude de la sclérose en plaques

Mémoire soutenu le

devant le jury d'examen composé de :

HAMMOUCHE Kamal

M.C.A à l'U.M.M.T.O

Président

DIAF Moussa

Professeur à l'U.M.M.T.O

Rapporteur

MAIDI Ahmed

M.C.A à l'U.M.M.T.O

Examineur

HADDAB Salah

M.C.A à l'U.M.M.T.O

Examineur

Avant-propos

Ce mémoire a été effectué au laboratoire « Robotique et Vision » du département Automatique, FGEI, l'UMTO.

Mes vifs remerciements vont, tout d'abord, à Monsieur **DIAF Moussa**, professeur à l'UMMTO pour m'avoir proposé le thème de ce mémoire et m'avoir dirigé, aidé et conseillé tout le long de notre travail.

Nous ne manquerons pas de remercier Monsieur **HAMMOUCHE Kamal**, Maître de Conférences classe A, l'UMMTO pour m'avoir fait l'honneur d'accepter de présider le jury de ce mémoire.

Nous exprimons notre reconnaissance à Monsieur **MAIDI Ahmed**, Maître de Conférences classe A, à l'UMMTO pour avoir accepté de faire partie du jury d'examen de notre mémoire.

Que Monsieur **HADDAB Salah**, Maître de Conférences classe A à l'UMMTO trouve ici, nos sincères remerciements pour avoir accepté de faire partie du jury d'examen de notre mémoire.

Sommaire

Introduction générale

Chapitre1 : La Sclérose en plaques et l'IRM

1. Introduction.....	05
2. La sclérose en plaque.....	05
2.1 Causes de la SEP.....	09
2.2 Symptômes et signes.....	09
2.4 Le diagnostic.....	11
3. IRM cérébrale et la SEP.....	12
3.1 Anatomie cérébrale.....	13
3.2 Principe de l'Imagerie par Résonance Magnétique (IRM).....	15
3.3 Les aspects de la SEP en IRM.....	17
4 Conclusion.....	21

Chapitre2 : Segmentation des images IRM

1. Introduction.....	22
2. Segmentation d'images.....	22
3. Différentes approches de segmentation.....	25
3.1 Segmentation orientée contours.....	25
3.2 Segmentation orientée régions.....	28
4. Méthodes segmentation utilisées en lésions SEP.....	31
5. La méthode de segmentation adoptée.....	32
5.1 Présentation de l'algorithme FCM.....	33
5.2 Principe FCM spatiale.....	34
5.3 Algorithme des levels sets.....	35
6. Conclusion.....	42

Chapitre3 : Segmentation automatique de lésions de la SEP

1. Introduction.....	43
2. Acquisition des images.....	43
3. Prétraitement.....	44
4. Méthode adoptée pour la segmentation des lésions de la SEP.....	45
4.1 Evaluation de la méthode classification.....	47
5. Tests et Résultats.....	49
5.1 Apport de l'algorithme des levels sets adopté.....	53
.5 Conclusion	56

Conclusion générale

Références et bibliographie

Introduction générale

A partir des années soixante-dix, les chercheurs ont considéré que la première étape de traitement visuel chez l'homme et l'animal se fait nécessairement par réflexes. En effet, les entités, les formes et les contours émergent automatiquement chez l'individu, de façon inconsciente, indépendamment d'une connaissance à priori de l'environnement. Tout ceci a donné naissance à une discipline basée sur l'automatisation de cette faculté, qui est l'analyse d'image. L'analyse d'image a pour but l'extraction de l'information caractéristique contenue dans une image. L'analyse d'images IRM du cerveau est une étape de base dans le diagnostic des pathologies, notamment la sclérose en plaque.

La sclérose en plaques (ou maladie de Charcot), décrite pour la première fois en 1868 par le docteur Jean-Martin Charcot, est définie comme étant une maladie chronique inflammatoire démyélinisante touchant le système nerveux centrale (SNC) [1]. Elle est très répandue en occident et particulièrement en France et en Bretagne, ce qui en fait un thème majeur de la recherche médicale. Cette maladie est caractérisée par l'apparition de lésions multiples démyélinisantes et axonales disséminées dans le SNC. La sclérose en plaque (sep), après l'épilepsie, est la maladie neurologique qui touche, principalement, les jeunes adultes, qui conduit progressivement à un handicap croissant, dont la cause exacte est encore inconnue actuellement [2].

C'est pour comprendre le corps humain et améliorer l'état de santé des patients que ces deux motivations ont conduit au développement d'une grande variété de systèmes d'imagerie médicale.

L'imagerie médicale a commencé avec la découverte de Roentgen du Rayon-X en 1895 et s'est poursuivie avec les diverses technologies de l'imagerie tridimensionnelles (3D) telles que la tomographie assistée par ordinateur (CT), l'IRM, l'échographie (US), la tomographie et une foule entière d'autres acronymes.

L'IRM (Imagerie par Résonance Magnétique) est différente de la plupart des autres techniques d'imagerie médicale car elle n'emploie pas la tomographie pour obtenir une image 3D. L'IRM a révolutionné notre capacité à diagnostiquer des pathologies comme la tumeur, la sclérose en plaque, etc. et particulièrement ceux impliquant les tissus mous, sa capacité à fournir de contraste est inégalée. L'IRM est basée sur un phénomène connu sous le nom de *RMN* (Magnétique Nucléaire Résonance). Les images IRM sont des mesures 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 nombre énorme de paramètres à contrôler au cours du processus de formation d'images. Il peut mesurer des choses aussi simples que la densité de protons à des choses aussi complexes telle que les cartes d'activité cérébrale et la circulation sanguine. La principale difficulté avec l'IRM est le coût. Les machines coûtent très cher et les dépenses de fonctionnement sont élevées. De plus, seuls les radiologistes qualifiés peuvent interpréter les résultats. L'IRM est employée couramment dans la détection de la sclérose en plaque dans les différents endroits du corps humain tel que le cerveau, les nerfs optique et la moelle épinière.

L'IRM offre une série d'images du patient dont l'intensité des pixels représente une propriété physique différente selon les caractéristiques des tissus concernés. Cependant, 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 les difficultés de lecture en traduisant

l'information contenue dans l'image filtré ou segmenté. L'image traité et amélioré doit être précise et fiable pour une interprétation facile et rapide. Les techniques de traitement d'images nécessaire 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 et l'interprétation. Le premier peut être considéré comme le prétraitement pour les deux évaluations. La segmentation est la division d'une image en régions. Les critères pour ce qui constitue une région cohérente, peuvent varier d'une application à l'autre. La segmentation est critique pour de nombreuses tâches d'analyse d'images médicales, y compris les calculs d'efficacité cardiaque, l'image de la chirurgie guidée, le diagnostic de schizophrénie, la détection des lésions de la tumeur, l'épilepsie, la SEP et les lésions liées au diabète.

La segmentation automatique des images IRM est devenue une étape primordiale pour les analyses quantitatives des images dans de nombreuses pathologies cérébrales telles que la maladie d'Alzheimer et la sclérose en plaques.

La segmentation consiste à rassembler les pixels entre eux suivant les critères prés définis. Les pixels sont ainsi regroupés en région, ce qui constitue une partition de l'image.

Grâce à une meilleure connaissance de l'anatomie interne du patient, les médecins sont aujourd'hui en mesure d'établir un meilleur diagnostic et de mieux planifier la thérapie la plus appropriée à un cas donné.

Le présent mémoire propose de traiter le problème de la segmentation des images IRM pour isoler les lésions de la sclérose en plaque, en utilisant la méthode de classification FCM spatiale et la méthode des levels sets. L'approche adoptée commence par la segmentation par classification floue spatiale (sFCM) dont les résultats pour initier la segmentation par l'algorithme des levels sets.

Le reste de ce manuscrit se compose de trois chapitres.

Le premier chapitre a pour objectif de présenter les aspects de la sclérose en plaques, une brève description de l'anatomie cérébrale et les notions d'imagerie IRM sont présentés

Dans le deuxième chapitre, sont montrées la difficulté de la tâche de segmentation de l'IRM est identifiée d'où la nécessité de prétraiter les images avant toute détection, ainsi que les principales méthodes de segmentation en imagerie cérébrale et dans le cas de pathologie de la SEP sont abordées. Par la suite le choix de la méthode adoptée est donné. Nous présentons la méthode de segmentation par classification spatiale ensuite la méthode des levels sets améliorée, et les estimations des paramètres de contrôle de l'évolution des levels sets.

Le dernier chapitre est consacré à l'application de méthode proposée dans le chapitre 2. Les méthodes proposées ont été appliquées sur des images IRM réelles des cerveaux humains affectés par la sclérose en plaque.

Ce mémoire termine une conclusion générale.

Chapitre 1

La Sclérose en plaques et l'IRM

1. Introduction

Ce chapitre a pour but de présenter la sclérose en plaques sous ses différents aspects et les notions d'imagerie médicale nécessaires à la compréhension de cette maladie. Dans un premier temps, nous nous sommes consacrés à l'étude générale de la sclérose en plaque en décrivant ses causes, les symptômes et les signes qu'elle peut engendrer, les différentes formes d'évolution cliniques et l'importance et la difficulté du diagnostic. Dans la seconde partie, nous nous sommes intéressés à l'imagerie médicale par résonance magnétique (IRM). Nous décrivons d'abord des brefs rappels sur l'anatomie cérébrale ensuite le principe de l'IRM et les différents aspects de la SEP en IRM. Enfin nous terminons par une conclusion.

2. La sclérose en plaques

La sclérose en plaque (SEP) est la principale des maladies démyélinisantes inflammatoires du système nerveux central constitué de l'encéphale, la moelle épinière et le liquide céphalo-rachidien. Elle est caractérisée par la présence de plaques de démyélinisation localisées de

façon prépondérante au niveau de la substance blanche du cerveau, c'est-à-dire, la destruction multifocale des gaines de myéline matures normales qui est une substance lipidique protectrice entourant les fibres nerveuses de la substance blanche, associée à un syndrome inflammatoire. Cette atteinte de la myéline est accompagnée d'un durcissement ou cicatrisation dû à un dépôt anormal de tissu conjonctif. Ce durcissement est nommé sclérose et apparaît en plusieurs endroits du cerveau et de la moelle épinière sous forme de plaques. Ces plaques apparaissent comme des foyers grisâtres visibles à l'œil nu dont la taille varie de quelques millimètres à quelques centimètres de diamètre jusqu'à de larges plaques occupant la quasi-totalité d'un hémisphère. Elles sont de forme souvent arrondies ou polycycliques et de coloration jaunâtre ou gris rosé et variables [3] [4]. (fig.1.1).




Fig.1.1 – Coupe histologique de grandes lésions. Les plaques bien limitées dans la substance blanche hémisphérique (les flèches vertes) [6].

La sclérose en plaques atteint principalement les adultes jeunes des deux sexes avec une prédominance féminine (60 % des cas). Actuellement, la sclérose en plaques affecte environ 2,5 millions de personnes dans le monde dont environ 10 000 malades la atteints en Algérie [5] et 435 cas dans la willaya de Tizi-Ouzou selon la base de données archivées du centre hospitalier de Belloua (Sanatorium) au niveau du service de neurologie.

Rappelons que le système nerveux central et périphérique est un réseau fonctionnel, composé de dizaine des milliards de cellules de neurones

(fig.1.2) qui communiquent entre elles, le long des axones, par des signaux électriques, chimiques via le système synaptique. L'axone, prolongement de neurone pouvant atteindre un mètre de long permet d'acheminer le signal électrique généré par le corps du neurone. La myéline est un constituant lipidique qui permet d'accélérer le transfert de l'information électrique le long de l'axone. Cette gaine est composée par d'autres cellules du cerveau : les oligodendrocytes (10 fois plus nombreux que les neurones) qui composent la substance blanche. Le rôle essentiel de cette dernière est d'augmenter la vitesse de transmission de l'influx nerveux. Sans elle, l'information circulerait 100 plus lentement. On comprend donc pourquoi les plaques perturbent le fonctionnement du cerveau puisque les réseaux de fibres passant par ces plaques sont temporairement hors d'usage (fig.1.3 et fig.1.4).




Fig.1.2 – structure schématique simplifiée d'un neurone [7].

L'examen microscopique montre que les fibres nerveuses n'ont pas disparu, mais elles ont été dénudées de leur manchon de myéline. Une plaque est généralement hétérogène et peut se composer de nécrose (le liquide céphalo-rachidien (LCR) vient remplir cette cavité nécrotique), d'œdème, de gliose (zone totalement démyélinisée) et d'une zone inflammatoire; tout autour de la plaque, une couronne œdémateuse peut apparaître (fig.1.5)




Fig.1.3 – les différentes étapes de la destruction neuronale. a) Le système immunitaire se défend et engendre une inflammation. b) Le manchon de myéline entourant la fibre nerveuse est atteint et devient plus fin. c) Le manchon de myéline n'existe plus (démýélinisation), la fibre nerveuse n'est plus protégée. d) La gaine de myéline ne protège plus les fibres nerveuses qui finissent par se rompre [8].




Fig.1.4 – Conséquence de la destruction de la myéline sur la transmission du signal nerveux. La gaine de myéline permet au signal nerveux d'être transmis rapidement par sauts. Lorsque la gaine de myéline est atteinte, le signal nerveux se propage linéairement et de façon très ralenti. [9]




Fig.1.5 – Une zone lésée se présente sous la forme d'une plaque sclérosée. Une plaque est généralement hétérogène et peut se composer de nécrose (le liquide céphalo-rachidien vient remplir cette cavité nécrotique), d'oedème, de gliose (zone démyélinisée totalement) et d'une zone inflammatoire; tout autour de la plaque, une couronne oedémateuse peut apparaître.

2.1 Causes de la SEP

La cause de la SEP reste encore partiellement inconnue. Il s'agit d'une maladie multifactorielle associant principalement des facteurs exogènes environnementaux et endogène génétiques. Ils sont décrits en détail dans [2] [10]. Parmi les causes de la SEP, nous pouvons citer l'auto-immunité, la génétique et les facteurs d'environnement. Ainsi, les dommages causés à la myéline dans la SEP peuvent être dus à une réponse anormale du système immunitaire du corps qui est normalement appelé à défendre le corps contre les organismes envahissants: bactéries et virus. Un virus probablement dormant dans le corps pourrait perturber le système immunitaire ou indirectement déclencher le processus auto-immun, ce qui signifie que le système immunitaire du corps s'attaque à lui-même. Cette réponse auto-immune entraîne une inflammation de la gaine de myéline dans le cas de la SEP et par la suite, sa destruction en divers endroits du système nerveux central. Cette destruction de la myéline est dénommée démyélinisation. En matière de génétique, en faveur d'un facteur, outre la faible prévalence de la SEP chez les japonais, on relève la rareté de la maladie chez les Noirs américains au nord comme au sud des Etats-Unis. L'intervention du patrimoine génétique est confirmée par le dénombrement des familles multi cas plus fréquentes que ne donnerait le hasard. Le risque est estimé à 2% pour les frères et sœurs d'un patient. Une étude canadienne de jumeaux dont l'un est porteur de la maladie montre, à la fois, l'importance du facteur génétique dans le déterminisme de la maladie et le fait qu'il ne s'agit pas d'une maladie héréditaire. Il existe une susceptibilité d'origine génétique mais qui ne suffit pas pour que se produise la maladie. En ce qui concerne le facteur d'environnement, l'hypothèse d'un facteur est appuyée en particulier sur l'étude des migrations de populations entre des zones de prévalence inégale. Par exemple ceux qui migrent après l'âge de 15 ans ont le risque de la région d'origine, alors que ceux qui migrent avant cet âge ont le risque de la région d'arrivée.

2.2 Symptômes et signes

La SEP commence le plus souvent par une poussée au cours de laquelle les signes et symptômes apparaissent rapidement puis disparaissent en

totalité ou en partie. Les symptômes dépendent des zones du système nerveux central qui ont été affectées. La SEP ne présente pas d'évolution type et chaque patient présente un ensemble distinct de symptômes qui peuvent varier d'une période à l'autre et dont la gravité et la durée peuvent également changer [11]. Les principaux symptômes consistent en :

- troubles de la vue: névrite optique conduisant à la perte brutale de l'acuité visuelle précédée de douleurs à la mobilisation du globe oculaire et vision floue,
- troubles de l'équilibre et de la coordination: perte d'équilibre, vertiges, et tremblements
- troubles moteurs: fatigabilité à la marche,
- troubles sensitifs: picotements, engourdissements et sensations de brûlures et douleurs faciales, musculaires ou articulaires ;
- troubles de la parole avec ralentissement et modification du rythme de la parole,
- troubles de la mémoire et de la concentration.

L'évolution de la maladie est variable selon la forme mais elle mène à un handicap qui peut être sévère allant même à la grabatisation et au décès. L'échelle EDSS (Expanded Disability Status Scale), mise au point par Kurtzke [12] et présentée dans le tableau A1 de l'annexe A est le principal outil de cotation clinique commun à tous les neurologues pour juger l'évolution des patients.

En ce qui concerne les formes cliniques, en fonction de l'évolution de la maladie, on parle de quatre formes (fig.1.6). La première est la récurrente-rémittente (RR) qui atteint 55% des patients et qui est caractérisée par des poussées suivies de rémissions de symptômes après une courte période en laissant peu ou pas de handicap. La seconde est dite secondaire progressive (SP). Elle atteint 30% des patients et est caractérisée par une évolution progressive qui peut être accompagnée de poussées. La troisième est progressive-rémittente (PR) et se caractérise par une évolution progressive de la maladie qui peut être accompagnée de poussées. Elle concerne 5% des patients de SEP. La quatrième est primaire-progressif (PP). Son évolution est progressive et sans poussée et elle concerne 10% des patients de SEP.




Fig.1.6 –Schéma des différentes formes connues d'évolution clinique de sclérose en plaques. RR : Récurrente-rémittente; SP : forme secondaire-progressive ; PR : forme progressive-rémittente ; PP : forme primaire-progressive [13].

2.4 Le diagnostic

La grande diversité des symptômes neurologiques pouvant découler de la SEP explique en grande partie la difficulté à diagnostiquer cette maladie. Le diagnostic repose sur un faisceau d'arguments à savoir, l'évolution clinique, la formule de la ponction lombaire pour l'examen de liquide céphalo-rachidien et aspect IRM.

Au début de la maladie, l'apparition brutale de troubles affirmant d'une atteinte multifocale et leur régression rapide en quelques jours ou en quelques semaines, chez un jeune adulte, sont très caractéristiques de la maladie. Néanmoins, lorsqu'une atteinte multifocale clinique (dissémination spatiale) et dans le temps (plusieurs poussées) n'est pas cliniquement évidente. L'imagerie par résonance magnétique (IRM) permet de mieux visualiser les plaques et devient un outil indispensable pour le diagnostic. En effet, les critères de McDonald en 2001, actualisés en 2005, et Swanton en 2006 ont établi un diagnostic précoce de la SEP en prenant plus en compte les données IRM [10]. Ces critères sont présentés au Tableau I-1.

Notons que le diagnostic est difficile du fait de l'absence de test spécifique. Il repose sur des critères de dissémination dans le temps et dans l'espace des lésions, et d'inflammation du liquide céphalo-rachidien (LCR). Donc l'IRM et la ponction lombaire sont les principaux examens d'aide au diagnostic.

Tableau I-1: Critères IRM de dissémination spatiale et temporelle pour le diagnostic de la SEP [14].

	McDonald 2001	McDonald 2005	Swanton 2006
Dissémination spatiale	3 ou plus des critères suivant : - 9 lésions T₂ ou une lésion rehaussée. - 3 ou plus lésions périventriculaires. - 1 ou plus lésions de juxtacorticales - 1 ou plus lésions de la fosse postérieure 1 lésion dans la moelle peut remplacer 1 lésion dans le cerveau.	3 ou plus des critères suivant : - 9 lésions T₂ ou une lésion rehaussée. - 3 ou plus lésions périventriculaires. - 1 ou plus lésions de juxtacorticales - 1 ou plus lésions de la fosse postérieure 1 lésion dans la moelle peut remplacer 1 lésion sous-tentorielle. 1 lésion rehaussée dans la moelle est équivalente à une lésion rehaussée dans le cerveau. Les lésions de la moelle peuvent être incluses dans le nombre total de lésions.	1 lésion ou plus dans 2 ou plus des régions suivantes : Périventriculaires ; Juxtacorticales ; Fosse postérieure ; Moelle
Dissémination temporelle	- 1 lésion rehaussée au moins 3 mois après le premier épisode clinique. - 1 nouvelle lésion T₂ par rapport à un examen antérieur au moins 3 mois après le premier épisode clinique	- 1 lésion rehaussée au moins 3 mois après le premier épisode clinique. - 1 nouvelle lésion T₂ par rapport à un examen antérieur au moins 3 mois après le premier épisode clinique.	- 1 nouvelle lésion T₂ dans un examen IRM de suivi quelque soit le temps écoulé depuis le premier examen.

3. IRM cérébrale et la SEP

Cette section a pour objectif de présenter l'imagerie par résonance magnétique et les effets de la SEP sur l'image IRM. Mais avant tout nous

décrivons brièvement l'anatomie du système nerveux central ainsi que les terminologies nécessaires à la compréhension de ce mémoire.

3.1 Anatomie cérébrale

Le système nerveux central humain est composé de l'encéphale et la moelle épinière. L'ensemble du système nerveux flotte dans un coussin protecteur de liquide céphalo-rachidien (LCR). L'encéphale est constitué du cerveau, du cervelet et du tronc cérébral. Le cerveau est composé de trois matières principales à savoir, la matière blanche (MB), la matière grise (MG) et le liquide céphalorachidien (LCR). La matière blanche est constituée des fibres des cellules nerveuses appelées axones qui permettent la transmission de l'information traitée au niveau de la matière grise. La matière grise contient le corps des cellules nerveuses et est répartie en deux types de structures : le cortex et les noyaux. Le cortex est caractérisé par de nombreuses fissures appelées sillons. Sur la face intérieure du cortex se trouve la matière blanche et sur la face extérieure circule la matière grise. Les noyaux, constitués essentiellement de matière grise, sont des structures plus compactes au centre du cerveau. Le liquide céphalo-rachidien baigne la surface extérieure du cerveau et du cervelet et remplit le système ventriculaire. Les figures 1.7 et 1.8 illustrent cette description de l'anatomie cérébrale [15], [16], [17].




Fig.1.7 –Le système nerveux central humain [18].




Fig.1.8—Principales structures du cerveau. (a) La représentation schématique du cerveau [19], (b) une coupe histologique d'un cerveau mettant en évidence les trois matières principales [20].

Ainsi, 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 dites axiale, sagittale et frontale (Fig.1.9) et (Fig.1.10). La coupe axiale (ou transverse) représente une vue de dessus du

cerveau. Elle correspond à un plan perpendiculaire au champ magnétique statique. La coupe sagittale est relative à un plan parallèle au plan inter hémisphérique. Il s'agit de vues latérales du cerveau. La coupe frontale (ou coronale) est une vue de face du cerveau. Elle est acquise sur le plan perpendiculaire aux coupes axiale et sagittale




Fig.1.9– Les trois axes de coupe pour la visualisation du cerveau [21].




Fig.1.10 – Coupes IRM du cerveau : plan axial, coronal et sagittal (de gauche à droite) [22].

3.2 Principe de l'Imagerie par Résonance Magnétique (IRM)

L'IRM est une technique de diagnostic médical permettant d'obtenir une vue 2D, 3D, voire 4D (3D+t) d'une partie du corps, notamment du cerveau et en coupe de grande précision anatomique. Cette technique est basée sur le phénomène physique de la résonance magnétique nucléaire (RMN) dont le principe physique est exposé brièvement à travers ce paragraphe. Les détails peuvent être trouvés dans [23], [24], [25] et [26]. La résonance magnétique nucléaire est une technique en développement depuis une soixantaine d'années dont le phénomène physique a été conceptualisé en 1946 par Bloch et Purcell [27]. Cette technique a été largement utilisée par les chimistes, puis

les biologistes. L'IRM dites conventionnelles est devenue, ces dernières années, une technique majeure de l'imagerie médicale moderne. Le principe de l'IRM consiste à mesurer l'aimantation des tissus biologiques et à reconstruire une image à partir de ces aimantations. En pratique, l'aimantation mesurée est surtout induite par l'atome d'hydrogène car cet atome possède des propriétés magnétiques contrairement à d'autres et il est l'un des deux constituants de la molécule d'eau que on le trouve en grande quantité dans le corps humain, à plus de 70%. De plus, la quantité d'eau varie d'un tissu à l'autre, mais aussi à l'intérieur d'un même tissu selon son état physiologique, ce qui est utilisé pour établir une cartographie du corps humain et de ses pathologies. Le champ magnétique produit en IRM permet d'orienter tous les protons d'hydrogène (spins) dans la même direction. Les protons sont ensuite excités par des ondes radiofréquence (RF) qui modifient leur orientation. Dès l'arrêt de l'impulsion RF, les protons retournent à l'état d'équilibre (phase de relaxation). L'acquisition des signaux RMN émis permet de reconstruire l'image. Le signal RMN ne permet pas directement de localiser les sources de ces ondes. En effet les dimensions de l'objet d'intérêt sont petites devant sa longueur d'onde qui est de l'ordre de quelques mètres. On peut, en revanche, connaître avec une grande précision les fréquences qui lui sont associées. En codant l'espace en fréquence et en phase des signaux émis, il devient possible de reconstruire une image par application d'une transformée de Fourier inverse. L'IRM permet l'acquisition d'un volume complet, soit par acquisition de coupes 2D successives, soit par l'acquisition d'un volume 3D.

Ainsi, en variant les paramètres d'acquisition, on obtient des images portant des informations variées, appelées modalités. On peut ainsi pondérer l'image en T1 ou T2, ou en densité de protons. Chaque modalité contient des informations spécifiques ne se retrouvant pas dans les autres. Pour les images pondérées en T1, on peut, par exemple, distinguer les différents tissus cérébraux comme la matière blanche, la matière grise et le liquide céphalo-rachidien. Quant aux images pondérées en T2, elles mettent plus facilement en évidence certaines anomalies telles les lésions de la SEP. Comme dans les images FLAIR (Fluid Attenuated Inversion Recovery), le

signal du liquide est supprimé, permettant ainsi de distinguer des anomalies telles les lésions de la SEP par rapport au liquide (fig.1.11).



Fig.1.11 – Différentes modalités d'images IRM :
(a) pondérée en T1, (b) pondérée en T2, (c) séquence FLAIR

3.5 Les aspects de la SEP en IRM

Dans la SEP, les altérations de la composition du tissu cérébral sont responsables d'une augmentation des temps de relaxation T2. L'IRM permet de détecter les lésions de la SEP dans 100 % des cas si l'on explore le cerveau, la moelle épinière et les nerfs optiques [28].

Les séquences pondérées en T2 sont les plus sensibles aux modifications du parenchyme pathologique de la SEP du fait du T2 allongé dans les lésions par rapport à la substance blanche (SB normale) [29]. Les lésions aiguës ainsi que chroniques apparaissent comme des plages de signal hyperintense (zone hyper signal T2). Cette hyperintensité n'est pas spécifique et représente une large gamme de tissus pathologiques incluant l'inflammation, l'œdème, la démyélinisation, la perte axonale. Elles sont relativement bien délimitées, de forme généralement ronde ou ovoïde, et mesurent de quelques millimètres à plus d'un centimètre de diamètre mais peuvent être entourées d'un halo de signal moins hyperintense probablement dû à l'œdème dans la phase très aiguë de l'inflammation. Elles sont irrégulières lorsqu'elles deviennent confluentes (fig.1.12-a). Cependant, la distinction des lésions hyperintenses dans les zones périventriculaires ou juxta-corticales du LCR de signal également élevé en pondération T2, peut être difficile. Tandis qu'une séquence pondérée en densité de protons (DP) permet de mieux visualiser ces lésions en diminuant le signal du LCR (fig.1.12-b). La plupart des lésions visibles en T2 ou DP persistent avec éventuellement une modification de la taille ou de l'intensité. Elles disparaissent rarement.




Fig.1.12 – les lésions caractéristiques de la SEP dans les séquences en T2 et en DP. (a) Les lésions apparaissent comme des zones ovoïdes hyperintenses en T2. (b) Les lésions à proximité du LCR sont mieux visualisées en DP.

Une autre approche pour faciliter la distinction des lésions à proximité du LCR est la réalisation d'une séquence FL AIR qui supprime le signal de l'eau libre sur une image fortement pondérée en T2. La séquence FLAIR améliore ainsi la délimitation des signaux hyperintenses dans les zones périventriculaires et juxta -corticales [30] (fig.1.13).




Fig.1.13 – Séquence axiale pondérée T2 (haut) et séquence FLAIR (bas). Ces images du cerveau d'un patient atteint de SEP illustrent l'augmentation de la sensibilité pour la détection des lésions sur des images FLAIR. Grâce à l'annulation du signal du LCR, l'image FLAIR montre plus clairement les limites des lésions périventriculaires et juxta corticales (flèche) que les images pondérées T2.

Certaines lésions hyperintenses en T2 (10- 20 %) sont également visibles sur les images pondérées en T1 comme des aires de signal hypointense, trous noirs, en comparaison avec la SB normale. A la phase aiguë, les trous noirs sont probablement la conséquence d'un œdème marqué avec ou sans destruction tissulaire et peuvent disparaître quand l'inflammation diminue

[31]. Les lésions hypointenses chroniques persistantes indiquent une destruction tissulaire plus sévère avec réduction de la densité axonale [32] (fig.1.14).




Fig.1.14 –Séquences axiales pondérées T1, sur l'image de gauche, une lésion hypointense frontale droite est visible (flèche du haut) mais disparaît 8 mois plus tard sur l'image de droite, révélant ainsi un œdème passager et une remyélinisation.

Un produit de contraste (le gadolinium) est injecté par voie intra veineuse afin d'augmenter le signal de certaines lésions de la SEP sur des images pondérées en T1. Elle permet de séparer les lésions « actives » des lésions « inactives » [33]. La prise de contraste de nouvelles lésions est la preuve de la rupture de la barrière hémato-encéphalique, signe d'une inflammation aiguë [34]. Le rehaussement des lésions peut également indiquer la récurrence de l'inflammation dans des lésions préexistantes. Le nombre de lésions rehaussées est le paramètre IRM le plus pertinent pour mesurer l'activité inflammatoire de la maladie [35] (fig.1.15).




Fig.1.15–les images en T1 et en T1gadolinium (gauche à droite): la lésion active est rehaussée par le gadolinium et apparaît comme une zone d'hypersignal (la flèche).

Plusieurs variantes de Sclérose en plaques existent, chacune ayant une signature différente en IRM. Pour les formes aiguës de la SEP, le diagnostic est encore différent. Par exemple, pour les scléroses en plaques à révélation tardive touchant des patients de 60ans et plus, la coexistence de pathologies

fréquentes (hypertension artérielle) associées à la SEP rend l'interprétation de l'IRM et des potentiels évoqués délicate et le diagnostic n'en est que plus difficile. Les SEP progressives, qui se caractérisent par une aggravation relativement continue de l'état général du patient, doivent être traitées différemment du point de vue de l'IRM : le signal de la matière blanche n'est plus uniforme et les lésions sont plus difficiles à identifier.

Les lésions périventriculaires, caractéristiques de la maladie, sont le plus souvent assez grosses (de 5 à 10 mm de diamètre), de forme variable, avec un contraste important dans la zone centrale. Ce sont les lésions qui respectent la structure en couronne présentée dans la figure 1.5. Souvent faciles à détecter par le contraste de la partie centrale, elles sont difficiles à contourner car leur forme peut être complexe.

Les lésions juxtacorticales sont généralement petites et peu contrastées et de forme approximativement sphérique ou ellipsoïdale. Leur détection n'est pas toujours facile, car si la lésion est plus petite que l'épaisseur de coupe de la séquence que l'on regarde, il en résulte un contraste médiocre. Ce problème survient tout particulièrement en IRM FLAIR. Une bonne détection de ces lésions est très importante car l'apparition d'une lésion juxtacorticale est un critère important pour l'établissement d'une SEP cliniquement définie.

Les lésions corticales sont des lésions juxtacorticales qui se sont étendues à la matière grise environnante, ou des lésions nées dans le cortex. Le contraste de ces lésions est variable en IRM conventionnelle, mais elles sont très bien détectées en IRM de diffusion. Ce ne sont pas des lésions de matière blanche, mais elles sont prises en compte pour la SEP dans le calcul des charges lésionnelles.

Les lésions nécrotiques sont des lésions anciennes dont la partie centrale s'est nécrosée au point de devenir liquide. Ceci a pour conséquence principale que la partie nécrosée de la lésion possède alors un signal analogue à celui du LCR, ce qui rend plus difficile la détection basée sur l'information fournie par l'intensité en premier lieu. Quand la lésion est périventriculaire, la partie nécrosée n'est pas matériellement distinguable des ventricules, et est généralement ignorée.

Cette description nous permet de caractériser les différentes lésions dans l'espace des images (fig.1.16).




Fig.1.6 Différentes séquences des images (coupes axiales) du cerveau représentent différentes lésions de la SEP : (a) nécrotique, (b) corticale, (c) périventriculaire, (d) juxta-corticale. Chacune de ces lésions va avoir un signal différent [2].

4 Conclusion

Les quelques éléments présentés dans ce chapitre ne donnent pas toutes les subtilités de la maladie mais ils permettent de prendre conscience de la complexité de la sclérose en plaques. Les causes de la maladie sont encore ignorées. Les symptômes sont très nombreux et très variés selon la localisation des plaques et le patient.

Le principe de l'imagerie par résonance magnétique et son apport dans le cadre de la sclérose en plaques ont été présentés. Nous pouvons ainsi mieux prendre conscience des difficultés d'une segmentation Automatique des lésions de la SEP en terme de traitement d'image d'une part et en terme de choix des données à utiliser d'autre part.

Cependant, bien que l'IRM ait nettement amélioré la compréhension des mécanismes de la SEP, elle fournit une information limitée en termes de précision et de spécificité.

Le chapitre suivant présente les principales méthodes existantes pour la segmentation des images IRM et des lésions de sclérose en plaques et permet ainsi de situer notre méthode par rapport à la littérature.

Chapitre 2

Segmentation des images IRM

1. Introduction

La segmentation est une des étapes primordiale de l'analyse d'images qui a pour but de regrouper les pixels entre eux suivant des critères prédéfinis aboutissant à une partition de l'image traitée. En imagerie médicale, la segmentation permet d'associer une structure anatomique à chaque position dans l'espace. En IRM cérébrale, elle permet de différencier les tissus (matière grise (MG), matière blanche (MB) et liquide céphalo-rachidien (LCR)), les structures anatomiques, et/ou les nombreuses pathologies cérébrales telles que la tumeur, l'Alzheimer et les lésions de la sclérose en plaques.

Ce chapitre vise à identifier la difficulté de la tâche de segmentation en IRM et citer les diverses méthodes de la segmentation d'images IRM en détaillant, en particulier, les approches par classification ainsi que les différentes approches appliquées aux lésions de la SEP, puis donner la méthode utilisée.

2. Segmentation d'images

La segmentation consiste à diviser ou partitionner l'image en zones homogènes par rapport aux niveaux de gris, texture ou couleur selon un

critère choisi afin d'en extraire l'information utile [37]. C'est ce que les médecins font quotidiennement lorsqu'ils observent, sur un examen IRM, la substance blanche, la substance grise, le liquide céphalo-rachidien et les lésions. Schématiquement, on distingue d'une part la segmentation des lésions focales et d'autre part celle des tissus. La première est dichotomique, séparant les lésions et les tissus sains. La deuxième permet une segmentation en plusieurs classes en fonction du nombre de tissus connus a priori. Un exemple est la séparation de la substance grise de la substance blanche normale, des lésions focales et du LCR. On peut segmenter un tissu pour isoler des lésions focales de sclérose en plaques puisqu'il s'agit en fait d'un tissu altéré caractérisé par un œdème, une démyélinisation, une perte axonale et une gliose [38]. Lors d'une segmentation, on cherche la précision, la robustesse, l'automatisation et la vitesse d'exécution. La précision des résultats est le premier critère utilisé dans une méthode de segmentation. Cela implique de fournir une validation quantitative convaincante des méthodes proposées. Les algorithmes doivent être robustes à tout bruit et toutes perturbations. En effet, en imagerie médicale, la notion de robustesse prend un sens particulier car, lorsque l'on traite un ensemble de sujets, il arrive souvent que les histogrammes des volumes ou en 3D varient fortement d'un sujet à l'autre [10]. Ainsi, il est préférable que la méthode utilisée fonctionne quelque soit le sujet. Un algorithme qui produit peu ou pas de cas d'échec et une moyenne de résultats acceptable sera alors considéré plus robuste qu'un algorithme produisant d'excellents résultats sur certains sujets, et donc une meilleure moyenne, mais générant des cas d'échecs plus nombreux. L'automatisation complète est importante pour éviter les opérations manuelles qui sont longues, fastidieuses, ce qui peut rendre les résultats incertains. Il est donc important de réduire l'interactivité avec l'utilisateur. L'automatisation complète joue un rôle surtout pour le traitement de grandes bases d'images. Pour ce type de base de données, la vitesse d'exécution doit être suffisamment réduite. De plus, comme il s'agit souvent de problèmes complexes à traiter, on est souvent appelé à concevoir des algorithmes sophistiqués, donc qui peuvent être lents. Pour ce type de

problèmes, il est considéré acceptable des traitements durant jusqu'à quelques heures.

Dans tous les cas, en imagerie médicale, la segmentation est utilisée donc pour l'extraction de paramètres ou pour des mesures sur les images. La représentation et la visualisation sont aussi importantes. On cherche souvent à séparer différentes régions anatomiques comme la graisse, les os, les muscles, les vaisseaux sanguins. Mais, plus encore, on cherche à détecter des zones pathologiques comme les tumeurs ou des lésions cérébrales. Dans ce chapitre, nous nous intéressons principalement à la segmentation des tissus cérébraux et particulièrement la matière blanche, la matière grise, le liquide céphalo-rachidien et les lésions de la SEP.

La difficulté de la tâche de segmentation est liée au bruit, l'effet de volume partiel, les hétérogénéités d'intensité et d'autres artefacts. Le bruit est souvent aléatoire et suit donc une distribution gaussienne dans les zones où l'intensité n'est pas proche de zéro. Dans les zones où l'intensité est proche de zéro, elle est proche d'une distribution de Raleigh [6]. Un autre problème de la segmentation d'images IRM est l'effet de volume partiel qui apparaît lorsque plusieurs types de tissus contribuent au même voxel. Ce problème est de plus en plus pris en compte dans les algorithmes de segmentation. En raison d'une résolution du système d'acquisition limitée, les voxels situés à la frontière entre plusieurs tissus sont composés de deux ou plusieurs tissus (fig.1.1). Il est donc nécessaire de prendre en compte ces effets de volume partiel pour obtenir une segmentation fiable des tissus cérébraux [39].




Fig.1.1–Effet de volume partiel d'après [40].

La présence d'un artefact d'hétérogénéité d'intensité spatiale pour un même tissu cérébral est l'une des principales difficultés de la segmentation

d'images IRM. Les inhomogénéités du champ radiofréquence RF sont en effet responsables de ces variations spatiales lentes de l'intensité des images [41]. Ce biais peut poser des problèmes de classification pour des techniques de segmentation basées sur l'intensité, si on suppose que l'intensité d'une classe est constante sur toute l'image. Dans ce type d'images, on rencontre souvent des artefacts de mouvement dus aux déplacements du patient pendant l'examen ainsi à d'autres mouvements comme la respiration, le flux sanguin etc.). L'impact de ces artefacts varie selon le moment de l'acquisition mais il se traduit généralement par l'apparition d'images fantômes de la structure en mouvement.

3. Différentes approches de segmentation

Dans la littérature, il existe plusieurs techniques de segmentation. On peut considérer trois types d'approches à savoir l'approche orientée contours et l'approche orientée régions [42] et l'hybridation entre ces deux approches.

3.1 Approche orientée contours

La segmentation orientée approche contours permet de délimiter les objets selon leurs contours en se basant sur les intensités et leurs variations significatives aux différentes frontières. Plusieurs méthodes ont été proposées dans la littérature comme les méthodes dérivatives, les méthodes par morphologie mathématique, les méthodes par modèles déformables etc. Les méthodes dérivatives se basent sur la détection des transitions d'intensités lumineuses au niveau des frontières entre objets, par différenciation numérique. Elles utilisent le Gradient (calcul des premières dérivées partielles) ou le Laplacien (calcul des deuxièmes dérivées partielles). Parmi les operateurs gradient, on trouve le masque de Roberts [43], de Prewitt [44], de Sobel [45], et de Kirsh [46]. Le problème majeur de ces techniques est la sensibilité au bruit et elles sont peu exploitables car elles donnent des contours non fermés et épais [47].

Dans le cadre de la segmentation des images médicales, les méthodes dérivatives sont surtout utilisées comme la première étape de détection des contours avant d'utiliser des modèles déformables. Montagnat utilise les

filtres de Canny et Deriche pour détecter les contours vers lesquels un modèle déformable 3D est attiré [48].

Pour les méthodes par morphologie mathématique, les contours peuvent être détectés via des opérations de morphologie mathématique. Ces opérateurs permettent d'étudier les caractéristiques morphologiques des objets dans l'image (forme, taille...) grâce à des éléments structurants. Basées sur la dilatation, l'érosion, ces méthodes permettent la construction d'autres opérateurs comme l'ouverture, la fermeture. Un exemple d'application à des images médicales pour segmenter des structures anatomiques est présenté par [49].

Quant aux méthodes par modèles déformables, elles font évoluer un contour initialement défini vers les frontières des objets. Il existe deux types de modèles déformables : les modèles explicites et les modèles implicites. Les modèles explicites ou « snakes », proposés par Kass et al. [50] consistent à déformer une représentation paramétrique du contour ou courbe continue en se basant sur la minimisation d'une fonction d'énergie E . Cette fonction d'énergie est exprimée comme la somme d'un terme d'attache aux données E_{im} lié à l'image, d'un terme de régularisation E_{int} lié à l'élasticité et la rigidité du contour (c'est l'énergie interne) et d'un terme un terme fixé par l'utilisateur E_{ext} (l'énergie externe). Les inconvénients majeurs de ces méthodes sont liés au fait que l'énergie à minimiser dépend de la paramétrisation du contour. En effet, les changements topologiques simples du contour, comme la fusion ou la séparation, sont difficiles à réaliser [23]. Quant aux modèles implicites ou level sets proposée par Osher et setian [51], ils permettent d'intégrer les changements topologiques. Dans ces méthodes, le contour n'est pas paramétré mais implicitement caractérisé par une fonction de dimension supérieure $\emptyset$. Le contour $C(t)$ à un instant t est alors défini par la ligne de niveau de valeur zéro, soit (fig.II.1) :

$$C(t) = \{(x,y): \phi(x,y) = 0\}, \forall (x,y) \in \Omega$$

où Ω est plan entier de l'image et $\phi(x,y)$ la fonction level sets




Fig. II.1- la définition de la fonction de level sets

Le principe d'évolution du contour sous cette représentation provient des travaux en théorie de propagation dont l'équation d'évolution est formalisée sous forme d'équations aux dérivées partielles (EDP). Elle est contrainte par un champ de vitesse construit de manière à attirer le modèle vers les objets à extraire avec certaines contraintes de régularisation. Différentes constructions du champ de vitesse ont été proposées comme dans les « levels sets » géométriques [52] et les « levels sets » géodésiques [53]. Ces approches dont la formulation est d'une grande complexité algorithmique utilisent des algorithmes comme celui de « Fast Marching Level Set Method » [54] pour leur implémentation pratique. Le gros inconvénient de ces méthodes est que le bruit dans les images perturbe les informations de variation d'intensité et il est alors nécessaire de procéder à un filtrage sur les données. Ces méthodes sont aussi sensibles à l'initialisation puisque le contour initial ne doit pas être trop éloigné des objets considérés. Ainsi, des approches par gradient vector flow (GVF) [55] ont toutefois été proposées pour étendre la zone de capture du modèle déformable. De plus, ces approches mettent donc en jeu un nombre important de paramètres à savoir la vitesse d'évolution, la méthode pour obtenir le contour initial, les paramètres de rigidité et d'élasticité, les paramètres de rehaussement des contours, les paramètres dans le terme d'attache aux données.

Dans les images IRM, notons que le rehaussement des contours est une étape importante surtout que le contraste est faible dans ce type d'images [56].

3.2 Approche orientée régions

Les approches régions visent à créer une partition de l'image en un ensemble de régions homogènes au sens d'un ou de plusieurs critères au niveau des pixels. Différentes approches ont été proposées dans la littérature comme celles basées sur le seuillage, la croissance de régions. Le mean-shift, la classification etc.

La méthode par seuillage l'une des méthodes les plus simples. Elle permet d'extraire des régions dont l'intensité lumineuse est supérieure à seuil fixé du fond de l'image. Le seuillage se base sur l'étude de la distribution des niveaux de gris des pixels. Ces méthodes ne prennent en compte ni l'effet d'inhomogénéités d'intensité, ni le bruit et elles sont peu adaptées pour la segmentation d'IRM cérébrales.

Le principe des méthodes par croissance de région consiste à étiqueter un objet en faisant croître une région à partir d'un ou de plusieurs pixels appelés germes. Le critère de propagation peut être basé sur les intensités mais aussi sur des critères géométriques et topologiques. Cependant, la pertinence de ce critère ainsi que le choix des germes conditionnent en grande partie la qualité de la segmentation obtenue. Les méthodes par croissance de région sont en général combinées avec d'autres méthodes de segmentation. Par exemple Richard et al. [57] les combinent avec une approche par mixture de gaussiennes pour segmenter les tissus.

L'algorithme mean-shift [58] est une méthode qui permet de chercher les modes ou maxima locaux d'une distribution des pixels qui correspondent au centre des classes. Cette méthode consiste à estimer la fonction de densité de probabilité sous jacente à l'ensemble des pixels puis à localiser ses maxima locaux en cherchant les zéros de son gradient. Son inconvénient majeur est qu'elle est lourde en calculs.

Pour les méthodes basées sur la classification, consistent à partitionner l'image en un nombre fini de régions ou classes de pixels. De nos jours, la classification est une démarche qui est appliquée dans d'innombrables domaines [60] et notamment dans la segmentation d'image IRM. Rappelons que les méthodes de classification automatique sont supervisées ou non supervisées. Les approches supervisées nécessitent une étape

d'apprentissage sur un échantillon avant de pouvoir être appliquées sur de nouvelles données. On répertorie par exemple dans ce type d'approche les réseaux de neurones, les support vector machine (SVM), les K-plus proche voisins. Ces méthodes sont peu adaptées à la segmentation automatique des IRM cérébrales car les caractéristiques des images peuvent changer d'un imageur à l'autre, d'un patient à l'autre ou d'un jour d'acquisition à l'autre. Les approches supervisées nécessitent généralement une interaction avec l'utilisateur pour le choix de l'échantillon d'apprentissage, source de variabilité et de non reproductibilité des résultats. Ce type de méthodes est cependant intégré dans des approches combinées. Song et al [61] combinent, par exemple, un réseau de neurones avec un algorithme EM pour segmenter les tissus.

Quant aux méthodes non supervisées, elles ne nécessitent aucune base d'apprentissage et aucune tâche préalable d'étiquetage manuel. La seule intervention de l'expert se situe à la fin du processus pour identifier les classes trouvées. Parmi ces méthodes, on peut, notamment, mentionner l'algorithme C-moyennes (« Hard C-Means » ou « HCM ») et des C-moyennes floues. Dans la méthode des c-moyennes (HCM) [62], [63], un élément de X est attribué à une classe et une seule parmi les C proposées. Dans ce cas, la fonctionnelle à minimiser est :

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

, Notons $X=(x_j, j=1..N)$ l'ensemble des vecteurs forme de R^p , avec $x_j=[x_{j1}, x_{j2}, \dots, x_{jp}]^T$, $B=(b_1, \dots, b_c)$ un ensemble de vecteurs prototypes inconnus, où b_i caractérise la classe i , u_{ij} , le degré d'appartenance d'un élément x_j à une classe i et $d^2(x_j, b_i)$: la distance euclidien entre (pixel) l'élément de la classe et le centre de la classe.

La solution du problème s'écrit de façon suivante :

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

$$\text{où } b_i = \frac{\sum_{j=1}^N u_{ij} x_j}{\sum_{j=1}^N u_{ij}} \quad (\text{II.3})$$

La classification des éléments de X s'effectue de manière itérative en alternant l'étape de classification (II.2) et l'étape de mise à jour des centres (II.3), jusqu'à stabilisation de la segmentation ou de la fonction objectif. Dans une variante nommée ILSC (Iterative Least Squares Clustering) [64], les vecteurs b_i sont recalculés à chaque ajout d'un élément dans une classe. Ces auteurs rapportent un bon taux de reconnaissance des tissus cérébraux en IRM, mais 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 [65]. 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). La méthode présentée dans le paragraphe suivant permet d'obtenir une segmentation floue qui prend en compte ces aspects imprécis et incertains. De son côté, l'algorithme des C-moyennes floues [63] 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. Le FCM est un cas particulier d'algorithmes basés sur la minimisation d'un critère ou d'une fonction objectif. Il permet d'obtenir une partition floue de l'image en donnant à chaque pixel un degré d'appartenance (compris entre 0 et 1) à une classe donnée. La classe à laquelle est associé un pixel est celle dont le degré d'appartenance sera le plus élevé. Dans ce cas, les x_j 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. L'algorithme FCM a été largement utilisé pour la segmentation des images de cerveau, quels que soient la modalité et le type d'acquisition (mono ou multi-spectrale). De nombreux travaux ont notamment été effectués en imagerie par résonance magnétique [66]. Les pixels étant représentés par leur niveau de gris, les

auteurs ont montré non seulement que l'algorithme avait des performances comparables à l'analyse de corrélation standard (avec l'avantage de ne nécessiter aucune connaissance *a priori* sur le paradigme), mais aussi que FCM détectait des zones effectivement activées qui restaient silencieuses avec la corrélation [66]. D'autres méthodes non supervisées sont également utilisées pour la caractérisation des tissus cérébraux et la détection des lésions de la SEP. Citons les approches probabilistes et les algorithmes espérance maximisation (EM).

4. Méthodes de segmentation utilisées en lésions SEP

La plupart des méthodes de segmentation de lésions SEP décrites dans la littérature sont des méthodes semi-automatiques destinées à faciliter la tâche fastidieuse de délimitation manuelle des lésions par des médecins et à réduire la variabilité inter et intra-experts associée à ces segmentations manuelles. Dans ces approches, l'interaction de l'utilisateur peut comporter à accepter ou rejeter des lésions segmentées automatiquement. Ainsi, Udupa et al. [67] ont utilisé le concept de connectivité pour détecter les objets flous représentant la matière blanche, la matière grise et le liquide céphalo-rachidien. Les zones de trous restantes entre les différents tissus cérébraux représentent les localisations des lésions potentielles [67]. L'inconvénient de cette méthode est qu'elle requière l'intervention manuelle d'un opérateur pour éliminer les faux positifs. La connectivité floue est basée sur l'interaction entre les différentes structures de l'image. La force de la connexion entre pixels est déterminée à la fois par leur distance dans l'image et leurs niveaux de gris. Kamber et al. utilisent un modèle probabiliste des tissus cérébraux [68]. Ce modèle est utilisé à la fois comme un masque pour enfermer la recherche des lésions à l'intérieur de la matière blanche et pour fournir des propriétés géométriques permettant de classifier les lésions : par exemple la probabilité du LCR ventriculaire peut s'avérer utile pour détecter des lésions périventriculaires. Les lésions SEP sont souvent détectées comme pixels atypiques par rapport à un modèle statistique d'images cérébrales "normales". Schroeter et al. utilisent des mélanges de gaussiennes pour modéliser la présence de différentes composantes en chaque voxel [69]. A chaque itération, les pixels excédant une distance de Mahalanobis prédéfinie

par rapport à chaque distribution gaussienne sont rejetés et la mise à jour des paramètres du modèle est uniquement basée sur les voxels qui n'ont pas été rejetés. La méthode de Van Leemput et al. [70] est proche d'un point de vue algorithmique de celle proposée par Schroeter et al. mais prend aussi en compte l'information sur le voisinage. Ils introduisent également des poids reflétant le caractère plus ou moins atypique de chaque voxel et l'utilisation d'un atlas probabiliste du cerveau permet de rendre la méthode totalement automatique. L'approche proposée par Dugas-Phocion utilise directement la distance de Mahalanobis au sein des itérations de l'EM pour le rendre plus robuste aux données atypiques et emploie les différentes séquences d'IRM de façon hiérarchique [71], [2]. Ait-ali propose un EM robuste spatio-temporel fournissant une segmentation longitudinale d'IRM multi-séquences [10]. L'estimation robuste des classes est basée sur l'estimateur de vraisemblance tamisée. Les lésions sont détectées en utilisant la distance de Mahalanobis puis classifiées en utilisant des contraintes a priori sur l'intensité des manifestations de la SEP en IRM. L'inconvénient de ces deux méthodes provient du fait qu'elles ne prennent pas en compte l'information sur le voisinage spatial. D. Garcia-Lorenzo [72] combine l'algorithme mean-shift avec un algorithme de type EM par pour la segmentation des lésions de sclérose en plaque. Il a l'avantage de ne pas définir a priori le nombre de classes et de ne pas contraindre la forme des distributions des classes. Il est cependant lourd en calculs et exige une étape cruciale de fusion des classes dans le cadre de la segmentation des IRM cérébrales.

5. La méthode de segmentation adoptée

L'intérêt des méthodes non supervisées ne nécessitant pas de connaissances a priori, dans notre application, nous avons appliqué l'algorithme FCM dans laquelle est intégrée l'information spatiale voisine aux pixels d'intérêt. Ainsi, dans le but d'isoler la pathologie nous avons introduit l'algorithme des levels sets et pour rendre cet algorithme robuste au bruit et rapide, nous avons implanté l'algorithme sFCM dans l'initialisation et les paramètres de contrôle de l'algorithme des levels sets sont estimés à partir des résultats de cette méthode.

5.1 Présentation de l'algorithme FCM

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

$(\forall i \in \{1..C\}) (\forall j \in \{1..N\}) u_{ij} \in [0,1]$, C est le nombre de classes et N le nombre de vecteurs forme.

$$0 < \sum_{j=1}^N u_{ij} < N, \quad (II.4)$$

$$\forall j \in \{1..N\} \sum_{i=1}^C u_{ij} = 1. \quad (II.5)$$

Bezdek a montré [27] 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 :

$$J(B, U, X) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i) \quad (II.6)$$

sous les contraintes (II.4) et (II.5), 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 .

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 :

$$H(x_j) = \sum_{i=1}^C u_{ij}^m d^2(x_j, b_i) - \alpha \left(\sum_{i=1}^C u_{ij} - 1 \right), \alpha \neq 0,$$

α est un multiplicateur lagrangien.

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

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

De telle sorte que, si $d^2(x_j, b_i) \neq 0$: $u_{ij} = \left(\frac{\alpha}{m \cdot d^2(x_j, b_i)} \right)^{\frac{1}{m-1}}$ avec :

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

et finalement

$$u_{ij} = \left[\sum_{k=1}^C \left(\frac{d^2(x_j, b_i)}{d^2(x_j, b_k)} \right)^{\frac{2}{(m-1)}} \right]^{-1} \quad (\text{II.7})$$

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 :

$$b_i = \frac{\sum_{k=1}^N u_{ik}^m x_k}{\sum_{k=1}^N u_{ik}} \quad (\text{II.8})$$

L'algorithme des C-moyenne floues(FCM) consiste alors en l'application itérée de(II.7) et (II.8) jusqu'à la stabilité des solutions. Le critère d'arrêt des itérations, définissant cette stabilité, peut par exemple consister en l'étude de la norme la matrice U ou en la stabilité des centres de classe sur deux itérations successives.

5.2 Principe FCM spatiale

Une des particularités importantes de l'image, c'est que les pixels voisins sont fortement corrélés. En d'autres termes, la probabilité qu'ils appartiennent à la même classe est grande. Cette relation spatiale est importante dans le regroupement, mais elle n'est pas utilisée dans un algorithme FCM standard. Chuang et al. [73] ont proposé un algorithme FCM spatiale, dans laquelle l'information spatiale peut être intégrée dans la fonction d'appartenance floue. Une fonction spatiale est définie comme suit :

$$h_{ij} = \sum_{k \in \text{NB}(x_j)} u_{ik} \quad (\text{II.9})$$

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

La fonction spatiale d'un pixel est grande si la majorité de son voisinage appartient à la même classe. La fonction spatiale est incluse dans la fonction d'appartenance comme suit:

$$u'_{ij} = \frac{u_{ij}^p h_{ij}^q}{\sum_{k=1}^c u_{kj}^p h_{kj}^q} \quad (\text{II.10})$$

où p et q sont des paramètres pour contrôler l'importance de la relativité de ces deux fonctions.

Dans une région homogène, la fonction spatiale renforce la fonction des degrés d'appartenance initiale, et le résultat de classification reste inchangé. Cependant, pour le pixel parasite dans une classe, la formule (II.10) permet de réduire la pondération du bruit de cette classe par pixels voisins. Par conséquent, les pixels mal classés par le bruit ou les parasites peuvent être facilement corrigés. La FCM spatiale avec les paramètres p et q est nommée par $sFCM_{p,q}$. on remarque que $sFCM_{1,0}$ est identique à la FCM conventionnel.

Le regroupement est un processus à deux étapes à chaque itération. La première est la même que celui de FCM conventionnel pour calculer la fonction d'appartenance dans le domaine spectral. Dans la deuxième, les informations d'appartenance de chaque pixel sont classées dans le domaine spatial, et la fonction spatiale est calculée à partir de cela. L'algorithme $sFCM$ consiste alors en l'application itérée de (II.9) et (II.10) jusqu'à stabilité des solutions.

5.3 Algorithme des levels sets

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

$$\begin{aligned} \phi(x,y): \Omega &\rightarrow \mathbb{R} \\ \begin{cases} \phi(x,y) < 0 & \text{si } (x,y) \text{ intérieur de } C(t) \\ \phi(x,y) = 0 & \text{si } (x,y) \text{ dans de } C(t) \\ \phi(x,y) > 0 & \text{si } (x,y) \text{ extérieur de de } C(t) \end{cases} \end{aligned} \quad (\text{II.11})$$

où Ω désigne le plan entier de l'image.




Fig.II.2- L'évolution de la fonction de level set et la propagation du contour correspondant : (a) la vue topologique de l'évolution de $\phi(x,y)$, (b) les changements du level set initiale $C : \phi(x,y) = 0$.

Comme la fonction des levels sets $\phi(x,y)$ sur le plan de l'image Ω s'accroît depuis son étape initiale, l'ensemble correspondant du contour C c'est-à-dire le contour rouge sur la figure (II.2) se propage vers l'extérieur. Avec cette définition, l'évolution du contour est équivalente à l'évolution de la fonction level set, c'est à-dire $\frac{\partial C(t)}{\partial t} = \frac{\partial \phi(x,y,t)}{\partial t}$. L'avantage de l'utilisation du niveau zéro est qu'un contour peut être défini comme les frontières entre une surface positive et une surface négative (l'équation(II.11)). Ainsi le contour peut être identifié par la vérification du signe de la fonction level set $\phi(x,y)$. L'évolution de fonction ϕ est totalement déterminée par l'équation de level set qui est donnée par :

$$\begin{cases} \frac{\partial \phi}{\partial t} + F|\nabla \phi| = 0 \\ \phi(x,y,0) = \phi_0(x,y) \end{cases} \quad (\text{II.12})$$

où $\phi_0(x,y)$ est la fonction du Level set initiale peut être donnée par la distance signée du contour initial [74] comme suit

$$\phi_0(x,y) \equiv \{\phi(x,y)/t=0\} \equiv \pm D((x,y), N_{x,y}(C_0)) \quad (\text{II.13})$$

où $\pm D(a,b)$ est la distance signée entre a et b , et $N_{x,y}(C_0)$ est le pixel voisin le plus proche sur le contour initial $C_0 \equiv C(t=0)$ de (x,y) .

$|\nabla \phi|$ désigne la norme directionnelle et F représente la force globale, y compris la force interne de l'interface, c'est à-dire la courbure moyenne, la longueur de contour et la surface, et la force extérieure, c'est-à-dire le gradient de l'image [75].

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

$$g = \frac{1}{1+|\nabla(G_\sigma * I)|^2} \quad (\text{II.14})$$

où I est l'intensité de l'image, ∇ est l'opérateur gradient de l'image, et $G_\sigma * I$ est la convolution de l'image d'intensité I par le filtre gaussien G_σ d'écart type σ . La fonction g positive est décroissante du gradient de l'image et proche de zéro dans les limites variationnelles. La formulation populaire pour la segmentation par levels sets proposée par Malladi et Sethian [76] est donnée par

$$\frac{\partial \phi}{\partial t} = g|\nabla \phi| \left(\text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \nu \right) \quad (\text{II.15})$$

où $\text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) = K$ est la courbure moyenne de la fonction de level set et ν est la force de ballon pour pousser ou tirer le contour.

$$K = \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) = \frac{\phi_{xx} \phi_y^2 - 2\phi_x \phi_y \phi_{xy} + \phi_{yy} \phi_x^2}{(\phi_x^2 + \phi_y^2)^{3/2}} \quad (\text{II.16})$$

où ϕ_x et ϕ_{xx} désignent la première et la seconde dérivée partielle de $\phi(x, y)$ par rapport à x , ϕ_y et ϕ_{yy} désignent la première et la seconde dérivée partielle de $\phi(x, y)$ par rapport à y .

Le rôle du terme de courbure K est de contrôler la régularité des contours tandis que le terme constant ν accélère et conserve l'évolution du contour en minimisant les zones ci-joint [76]. Une des plus grandes difficultés dans la segmentation par level set est le calcul intensif. La fonction de level set ϕ convertit le problème d'image en 2D en un problème de segmentation 3D et la fonction de level set ϕ devrait être réinitialisée périodiquement comme une fonction distance signée au cours de son évolution. Il existe dans la littérature plusieurs méthodes de réinitialisation [77], la plupart d'entre elles sont des variantes de la méthode basée sur les équations aux dérivées partielles (EDP) [78]. La réinitialisation du processus est très compliquée et coûteuse, car il devrait répéter chaque itération pour éviter des erreurs. Afin de surmonter ces difficultés, nous avons implémenté une nouvelle formulation de level set qui est proposée par Chunming Li et al. [79], donnée par :

$$\frac{\partial \phi}{\partial t} = \mu \xi(\phi) + \xi(g, \phi) \quad (\text{II.17})$$

telle que

$$\xi(\phi) = \Delta \phi - \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \quad (\text{II.18})$$

et

$$\xi(g, \phi) = \lambda \delta(\phi) \text{div} \left(g \frac{\nabla \phi}{|\nabla \phi|} \right) + \nu g \delta(\phi) \quad (\text{II.19})$$

où Δ est l'opérateur Laplacien, μ , λ et ν Sont des constantes, contrôlent les termes de l'équation (II.17) et $\delta(\phi)$ désigne la fonction de Dirac.

Le premier terme de l'équation (II.17) $\mu \xi(\phi)$ est une limite d'énergie interne qui pénalise la déviation de la fonction level set par une fonction de distance signée. Le second terme $\xi(g, \phi)$ est une limite de l'énergie externe qui intègre l'information gradient de l'image. Le terme $\xi(g, \phi)$ est responsable de la contrainte du contour vers les frontières de l'objet de l'image, qui est semblable aux méthodes classique des levels sets. Cependant, le terme de pénalité $\xi(\phi)$ force la fonction ϕ à s'approcher automatiquement à la fonction de distance signée, qui a plusieurs avantages. Premièrement, le nouvel algorithme élimine les calculs longs en réinitialisation des fonctions de distance signée. Deuxièmement, il peut commencer à partir d'une région binaire arbitraire [79].

$$\phi_0(x, y) = \begin{cases} -D, & \phi_0(x, y) < 0 \\ D, & \text{si non} \end{cases} \quad (\text{II.20})$$

où D est une constante limitée. Enfin, il décroît le pas temps τ pour l'évolution de s set, mais il assure toujours la stabilité [79].

Pour obtenir un problème discret nous remplaçons les dérivées partielles de l'équation (II.17) par les différences finis nous obtenons cette équation

$$\phi^{k+1}(x, y) = \phi^k(x, y) + \tau [\mu \xi(\phi^k) + \xi(g, \phi^k)] \quad (\text{II.21})$$

où τ est le pas de temps.

En ce qui concerne l'influence des paramètres, il y a un nombre de paramètres (tableau II.1) jouent un rôle vital dans le contrôle du fonctionnement de la méthode des levels sets, alors ils sont tous important pour la segmentation des lésions de la SEP présentes sur des images IRM. Il est nécessaire de les configurer de manière appropriée, ce qui varie. Actuellement, il ya quelque règles générales pour guider la configuration de

ces paramètres [77]. Par exemple, pour un σ grand conduit à une image lisse, mais manque de détail de l'image, un pas de temps τ grand peut accélérer l'évolution de level set, mais risque de fuite de frontière. Par ailleurs, il est nécessaire de choisir ν positif si ϕ_0 est à l'extérieur de l'objet d'intérêt et vice versa.

Tableau II.1 Différents paramètres contrôlant l'évolution de level set.

paramètre	Signification
σ	Commande la propagation de la fonction de lissage Gaussienne
D	Commande la force gradient de la fonction level set initiale ϕ_0
ε	Régulateur pour la fonction de Dirac $\delta(\phi)$
μ	Coefficient de pondération du terme de pénalité $\xi(\phi)$
λ	Coefficient de la longueur de contour
ν	force de ballon artificiel
τ	le pas de temps pour l'évolution de level set
T	nombre maximum d'itération de l'évolution de level set

En outre, par essais et erreurs, plusieurs règles de base ont été proposées pour une segmentation par levels sets optimale [77], [79], par exemple le produit de pas de temps et le terme de pénalité doit être inférieur à 0.25 ($\tau \times \mu < 0.25$) pour l'évolution stable et le paramètre D doit être supérieur à 2ε ($D > 2\varepsilon$), tandis qu'une valeur de D trop grande ralentit l'évolution de level set. Une valeur de λ plus grande mène à étouffer les contours et un plus grand ν accélère l'évolution de level set. Cependant, il ya risque de fuite de frontière. Les orientations générales ci-dessus, tout étant utiles, sont insuffisantes pour déterminer la configuration optimale pour les images IRM. Il est intéressant de déterminer ces paramètres de commande d'une manière adaptative à l'image IRM.

Notre méthode commence par la segmentation par classification floue spatiale (sFCM), dont les résultats pour initier la segmentation par l'algorithme des levels sets. L'estimation des paramètres contrôlant

l'évolution et de régulariser l'algorithme des levels sets. La méthode proposée automatise la configuration des paramètres d'initialisation et de la segmentation par levels sets, en utilisant classification floue spatiale. Elle emploie la sFCM afin de déterminer les contours approximatifs de l'intérêt dans une image IRM. Profitant de l'initialisation flexible comme dans l'équation (II.20), la fonction des levels sets peut accueillir des résultats de la sFCM directement pour l'évolution. Supposons que la composante d'intérêt (région d'intérêt) dans les résultats sFCM est R_k il est alors facile de lancer la fonction des levels sets comme suit

$$\phi_0(x, y) = -4\varepsilon(0.5 - B_k) \quad (\text{II.22})$$

Où ε est la constante régularise la fonction de Dirac. La fonction de Dirac est alors définie par

$$\delta_\varepsilon(x) = \begin{cases} 0, & |x| > \varepsilon \\ \frac{1}{2\varepsilon} \left[1 + \cos\left(\frac{\pi x}{\varepsilon}\right) \right], & |x| \leq \varepsilon \end{cases} \quad (\text{II.23})$$

B_k est une image binaire obtenue à partir de

$$B_k = R_k \geq b_0 \quad (\text{II.24})$$

où b_0 ($b_0 \in [0, 1]$) est seuil réglable obtenue de résultat de la classification floue (la région d'intérêt).

La fonction des levels sets initiale ϕ_0 est donnée à partir de résultat de classification floue spatiale (sFCM), l'équation (II.22), il est facile d'estimations de la longueur du contour l sur le plan de l'image et de la surface α par

$$l = \iint_I \delta(\phi_0) dx dy \quad (\text{II.25})$$

$$\alpha = \iint_I H(\phi_0) dx dy \quad (\text{II.26})$$

où $H(\phi_0)$ désigne la forme régularisée de la fonction d'unité de mesure (fonction Heaviside) donner par

$$H(\phi_0) = \begin{cases} 1, & \phi_0 \geq 0 \\ 0, & \phi_0 < 0 \end{cases} \quad (\text{II.27})$$

L'évolution de niveau d'ensemble sera plus rapide si le composant d'intérêt est grand. Dans ce cas, le rapport $r = \alpha/l$ doit être grand. Donc il est raisonnable de donner $\tau = r$ dans l'algorithme proposé. Le coefficient de pénalité μ sera fixé par $\mu = 0.2/r$, pour assurer la condition ($\tau \times \mu < 0.25$).

La fonction des levels sets initiale ϕ_0 obtenue par la classification floue spatiale (sFCM), l'équation (II.22), l'évolution de ϕ se rapprochera aux véritables limites. Par conséquent, une conservatrice $\lambda = 0.1r$ est utilisée pour contrôler les changements topologiques.

La force du ballon ν possède deux rôles dans l'évolution des levels sets : il donne la direction d'avancement de la fonction des levels sets ($\nu > 0$ pour le rétrécissement du contour ϕ_0 vers la région d'intérêt et $\nu < 0$ pour l'expansion du contour ϕ_0 vers la région d'intérêt), et accélère l'évolution de levels sets (plus ν est grand, plus les levels sets évoluent rapidement. La force du ballon ν est souvent considérée comme une constante dans l'algorithme standard. Il est intéressant de faire fonctionner les levels sets d'évoluer plus rapidement si ϕ est encore loin de la frontière réelle et de se ralentir si ϕ approche de cette limite. Par ailleurs la fonction de level set devrait modifier son orientation automatique, en passant par la frontière d'intérêt.

La force du ballon amélioré est proposée ici de tirer ou pousser l'interface dynamique vers de l'objet de l'intérêt et donnée par

$$\nu = G(R_k) = 1 - 2R_k \quad (\text{II.28})$$

La force de ballon résultante $G(R_k)$ ($G(R_k) \in [-1, 1]$) est une matrice avec une force variable de traction ou de poussée à chaque pixel d'image. En d'autre terme, la fonction des levels sets sera attirée vers l'objet d'intérêt quelque soit sa position initiale. Ensuite, l'équation des levels sets de l'évolution (équation (II.19)) se transforme en

$$\xi(g, \phi) = \lambda \delta(\phi) \operatorname{div} \left(g \frac{\nabla \phi}{|\nabla \phi|} \right) + g G(R_k) \delta(\phi) \quad (\text{II.29})$$

L'amélioration proposée permet d'atteindre plusieurs d'avantages pratiques. La force du ballon peut être issus directement de sFCM. D'ailleurs la fonction level set est maintenant adaptée à la distance d'objet réel. Une fois fonction level set approche de l'objet, elle va se ralentir automatiquement et devenir totalement dépendant de terme de lissage. Dès que la conservatrice λ est adoptée, l'évolution de level set se stabilise automatiquement.

6. Conclusion

Nous avons exposés dans ce chapitre un état d'art des méthodes de segmentation cérébrale et les méthodes utilisées dans le cas de pathologie, les lésions de la SEP. Nous avons, ensuite présenté l'étude des méthodes utilisées dans notre travail. Nous avons présenté aussi le modèle robuste au bruit par la segmentation initiale par sFCM des images IRM pour détecter les lésions de la SEP sans bruit et sans artefact et une méthode des levels sets rapide et automatique destinés aux images IRM. Les résultats de la segmentation seront présentés dans le chapitre suivant.

Chapitre 3

Segmentation automatique de lésions de la SEP

1.Introduction

Ce chapitre est consacré à l'application de l'approche adoptée. Les méthodes proposées ont été appliquées sur des images IRM réelles de cerveaux humains affectés par la sclérose en plaques. L'information apportée par ce type d'images est d'un apport considérable en matière de diagnostic. Notre méthode repose sur l'application des algorithmes FCM, FCM spatiale (sFCM) et levels sets pour obtenir de bons résultats dans la détection de lésions. Afin de montrer l'intérêt de l'approche proposée, nous avons comparé les résultats de classification obtenus par l'algorithme sFCM avec ceux obtenus par l'algorithme FCM. Ensuite nous avons utilisé les résultats de la sFCM pour l'initialisation de l'algorithme des levels sets pour isoler des lésions de la SEP.

2.Acquisition des images

Des images réelles sur lesquelles nous avons travaillé sont obtenues à partir de l'appareil IRM avec un champ magnétique de 1,5 Tesla au niveau du service neurologie de l'hôpital BELLOUA, Tizi ousou. Ces images sont acquises sur des patients de différents âges et ont été stockées sur des CDROM sous forme JPEG. Chaque patient possède sa propre base d'images

de différentes séquences (T1, T2, T2 flair et DP (densité de proton)) et selon différentes coupes (axiales, coronales et sagittales) (fig.3.1).




Fig.3.1- Différentes images traitées, de gauche à droite: image axiale en T2 Flair, image coronale en T2 Flair, image sagittale en T2 Flair et image axial en T2

3.Prétraitement

Avant d'entamer la phase de segmentation, nous faisons d'abord subir à ces images des prétraitements qui consistent au filtrage pour éliminer les bruits et les défauts surchargeant l'image dus aux artefacts de l'IRM. Ce filtrage permet de ne garder que les pixels dont les propriétés quantitatives sont dans un intervalle donné. Il permet d'éliminer les bruits et défauts qui surchargent l'image dus à l'éclairage et au processus d'acquisition. Cela doit se faire sans perte d'information utile. Pour ce faire, plusieurs filtres parmi lesquels on peut citer le filtrage linéaire et le filtrage non linéaire peuvent être utilisés. Dans notre étude nous avons appliqué le filtre de Wiener qui est un filtre adaptatif spatial qui se comporte comme un filtre passe-bas sur les zones uniformes tout en conservant les discontinuités et qui est adapté, particulièrement, aux images IRM d'intensité dégradée. Ce filtre utilise le voisinage d'un pixel d'intérêt de fenêtre $M \times N$ dans le domaine spatial. Dans notre cas, ce voisinage est une fenêtre 5×5 .




Fig.3.2 - Filtrage d'image IRM par filtre de Wiener

4. Méthode adoptée pour la segmentation des lésions de la SEP

Après l'opération de filtrage, nous procédons à la segmentation par classification utilisant la méthode sFCM, pour, ensuite, utiliser ses résultats (la région d'intérêt) pour initialiser l'algorithme des levels sets. Pour ce faire, nous utilisons l'algorithme sFCM en introduisant l'influence du voisinage dans le degré d'appartenance de chaque pixel conformément à l'équation (II.10). Pour cela, il nous faut définir les différents paramètres gouvernant cette méthode, à savoir les valeurs de m , C et les paramètres spatiaux p et q . La méthode sFCM constitue une excellente manière d'initialiser les données, puisqu'elle donne accès à une première estimation de U et de B . Le paramètre m contrôle le degré de flou de la partition floue U . Si m est proche de 1, la partition résultante est quasiment non floue. Chaque vecteur x_j est assigné à une classe i et une seule avec un degré d'appartenance $u_{ij}=1$ et, inversement, les degrés d'appartenance de x_j à chacune des C classes sont égaux à $1/C$ lorsque m tend vers l'infini. Pour cela, une valeur comprise dans l'intervalle $[1.5; 3]$ est généralement acceptée afin d'assurer la convergence de l'algorithme. Nous prenons donc $m=2$ pour la rapidité des calculs. Le nombre de classe C est choisi selon les images segmenter (le nombre des tissus qu'elle contient ainsi que les classes de la pathologie). Pour les paramètres spatiaux p et q , ils sont choisis d'une manière à rendre l'algorithme plus robuste aux bruits. Dans notre cas, nous utilisons $p=q=1$ et $p=1, q=2$.

La méthode des levels sets permet de propager une courbe qui est présentée par ϕ lorsque $\phi = 0$. Pour cela, une nouvelle image I de même taille que l'image à traiter est créée. Dans cette nouvelle image, un point appartient au contour C si $\phi = 0$. Il est à l'intérieur du contour C si $\phi < 0$ et est à l'extérieur si $\phi > 0$. Nous rappelons que ϕ est initialement évaluée par l'équation (II.22). Afin d'estimer les paramètres $(\tau, \mu, \lambda, \nu)$ contrôlant l'évolution et de régulariser l'algorithme des levels sets, nous avons calculé la longueur du contour l , périmètre de la région d'intérêt, et la surface α , somme des pixels de l'image R_k , de cette région obtenue par sFCM. Ces paramètres $(\tau, \mu, \lambda, \nu)$ sont calculés comme suit :

- le rapport $r = \alpha/l$,
- le pas de temps $\tau = r$,
- le coefficient de pénalité $\mu = 0.2/r$,
- le coefficient de la longueur de contour $\lambda = 0.1\tau$
- la force du ballon $\nu = G(R_k) = 1 - 2R_k$

Lors du processus d'évolution, la fonction de distance ϕ est mise à jour, à chaque itération, selon l'expression suivante :

$$\phi^{k+1} = \phi^k + \tau \underbrace{\left[\mu[\Delta\phi^k - K] + \lambda\delta(\phi^k)\text{div}\left(g \frac{\nabla\phi^k}{|\nabla\phi^k|}\right) + gG(R_k)\delta(\phi^k) \right]}_{\text{vitesse d'évolution}} \quad (\text{III.1})$$

où :

- la courbure : $K = \text{div}\left(\frac{\nabla\phi}{|\nabla\phi|}\right)$ (III.2)

- la fonction de Dirac $\delta_\varepsilon(x) = \begin{cases} 0, & |x| > \varepsilon \\ \frac{1}{2\varepsilon} \left[1 + \cos\left(\frac{\pi x}{\varepsilon}\right) \right], & |x| \leq \varepsilon \end{cases}$ (III.3)

avec ε fixé à 1,5 et :

$$g = \frac{1}{1 + |\nabla(G_\sigma * I)|^2} \quad (\text{III.4})$$

A chaque itération k , la fonction ϕ est évaluée d'une manière récurrente. Ce processus est réitéré jusqu'à ce que la valeur de ϕ reste inchangée. Ceci se produit lorsque le second terme de son expression ou vitesse d'évolution s'annule, c'est-à-dire, lorsque les vrais limites de l'objet (les lésions) sont atteintes.

Les figures 3.3, 3.4 et 3.5 montrent les algorithmes des méthodes que nous avons programmées.

4.1 Evaluation de la méthode classification

Les fonctions de validation des classes obtenue du partitionnement flou sont souvent utilisées pour évaluer les performances des différentes méthodes de classification. Ces fonctions sont la fonction de coefficient de partition V_{pc} [80] et la fonction d'entropie de partition V_{pe} [81]. Elles sont définies comme suit :

$$V_{pc} = \frac{\sum_j^N \sum_i^C u_{ij}^2}{N} \quad (\text{III.5})$$

$$V_{pe} = \frac{-\sum_j^N \sum_i^C [u_{ij} \log u_{ij}]}{N} \quad (\text{III.6})$$

L'idée de la validité de ces fonctions est que la partition avec moins de flou signifie de meilleures performances. En conséquence, le meilleur regroupement est atteint lorsque la valeur V_{pc} est maximale et V_{pe} est minimale.

Début

Etape1 : Fixer les paramètres.

Les entrées : Mettre la matrice d'image sous forme ensemble des vecteurs $X = (x_j, j = 1..N)$;

C : le nombre de classes ;

ε : seuil représentant l'erreur de convergence (on prend $\varepsilon = 0.01$) ;

m : degré de flou, ici $m = 2$

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

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

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

Fin

Fig.3.3 Algorithme de FCM

Début

Etape1 : Fixer les paramètres.

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

vecteurs $X = (x_j, j = 1..N)$;

C : le nombre de classes ;

ε : seuil représentant l'erreur de convergence (on prend $\varepsilon = 0.01$) ;

m : degré de flou, ici $m = 2$;

p et q : les paramètres spatiales ;

la fenêtre de voisinage est de 5x5

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

Etape 3 : calculer la matrice prototype B par la relation

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

Etape4 : 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 :

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

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

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.

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

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 :

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

Fin

Fig 3.4 Algorithme de FCM spatial

Début

Etape1 : Fixer les paramètres.

Les entrées :

I: Image initiale au niveau de gris

I_R : Image binaire résultante de segmentation par sFCM

σ : Le facteur de lissage gaussien (l'écart type gaussienne), ici $\sigma = 2$;

ε : Le régulateur de la fonction de Dirac, $\varepsilon=0.5$;

Les sorties :

I_s : Image résultante de segmentation par level set.

Etape1 : Calculer la longueur l , la surface α à partir de I_R et les paramètres suivants :

$$r = \alpha / l ;$$

$$\tau = r$$

$$\lambda = 0.1r ;$$

$$\mu = 0.2/r ; \text{ pour assurer la stabilité } \tau * \mu < 0,25.$$

Etape2 : Calculer la fonction d'indication de contour g

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

Etape3 : Définir la fonction levels sets initiale

$$\phi_0(x, y) = -4\varepsilon(0.5 - I_R)$$

-Calculer la force de ballon

$$v = G(I_R) = 1 - 2I_R$$

-Calculer la fonction de Dirac :

$$\delta_\varepsilon(x) = \begin{cases} 0, & |x| > \varepsilon \\ \frac{1}{2\varepsilon} \left[1 + \cos\left(\frac{\pi x}{\varepsilon}\right) \right], & |x| \leq \varepsilon \end{cases}$$

-Calculer le terme de courbure moyenne K :

$$K = \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right)$$

- Calculer ϕ^{k+1} avec l'équation (III.2)

Fin

Fig 3.5 Algorithme des levels sets

5. Tests et Résultats

Nous présentons dans cette partie quelques exemples de résultats expérimentaux obtenus à partir des méthodes étudiées. Les tests ont été implémentés avec Matlab R2008, et exécutés sur un PC (HP: Intel Core 2 Duo, 1.66 GHz ; 2 GB/Go).

Pour mettre en valeur nos résultats, nous les avons affichés comme suit :

- L'affichage des images segmentées par FCM spatiale de la région d'intérêt, là où se trouvent les lésions de la SEP comparées avec celles obtenues par FCM de la région d'intérêt.
- L'affichage des images segmentées par notre algorithme level sets initialiser par FCM spatiale, celles initialiser par seuillage et celles initialiser manuellement.

- L'affichage des images segmentées par l'algorithme des levels sets comparées avec celles obtenues par la méthode de Malladi et Sethian [76] (fig3.6, 3.7, 3.8).




Fig.3.6- Segmentation de la région d'intérêt des lésions de la SEP (coupe axial en T2 Flair) par FCM et sFCM, avec le nombre de classe $C=3$: (a) image initiale; (b) résultat de FCM; (c) résultat de sFCM_{1,1}; (d) résultat de sFCM_{1,2}.




Fig.3.7- Segmentation de la région d'intérêt des lésions de la SEP (coupe sagittal en T2 Flair) par FCM et sFCM, avec le nombre de classe $C=6$: (a) image initiale; (b) résultat de FCM; (c) résultat de sFCM_{1,1}; (d) résultat de sFCM_{1,2}.




Fig.3.8- Segmentation de la région d'intérêt des lésions de la SEP (coupe axial en DP) par FCM et sFCM, avec le nombre de classe $C=7$: (a) image initiale; (b) résultat de FCM; (c) résultat de sFCM_{1,1}; (d) résultat de sFCM_{1,2}.

Le tableau 3.1 montre les fonctions de validité des classes pour les deux algorithmes implémentés FCM et sFCM appliqués sur les différents types d'images IRM de patients atteint de la SEP. Nous constatons que la fonction de coefficient de partition V_{pc} est maximale et la fonction d'entropie de partition V_{pe} est minimale en appliquant l'algorithme sFCM_{1,2}, ce qui signifie que le meilleur regroupement est atteint. Ceci montre que notre algorithme donne des résultats meilleurs que l'algorithme FCM standard. Visuellement dans les images données par la FCM de la figure 3.6, 3.7 et 3.8, on ne trouve pas uniquement les lésions, mais aussi le bruit et les artefacts. Par contre dans les résultats sFCM, les lésions sont nettement détectées.

Tableau 3.1 Les fonctions de validation des méthodes FCM et sFCM

Image	algorithme	V_{pc}	V_{pe}
Coupe axial en T2 Flair	FCM	0.791	0.171
	sFCM _{1,1}	0.971	0.071
	sFCM _{1,2}	0.978	0.051
Coupe sagittal en T2 Flair	FCM	0.824	0.511
	sFCM _{1,1}	0.945	0.135
	sFCM _{1,2}	0.962	0.091
Coupe axial en DP	FCM	0.866	0.371
	sFCM _{1,1}	0.924	0.194
	sFCM _{1,2}	0.945	0.137

Compte tenu de nos tests et, suite aux fonctions d'évaluation, nous prendrons la méthode sFCM_{1,2} comme l'initialisation des level sets.

Les résultats de la segmentation sont donnés aux les figures 3.9, 3.10 et 3.11 afin de montrer l'efficacité de notre méthode face à plusieurs initialisations et pour l'estimation des paramètres à partir de résultat de la sFCM. Le meilleur résultat est obtenu pour l'initialisation par FCM spatial (fig.3.9 et fig.3.11) et avec un temps d'exécution réduit (fig.3.10) par rapport à l'initialisation de la sFCM avec des paramètres fixés (fig.3.9, 3.10, 3.11).




Fig.3.9-Segmentation des lésions de la SEP, après 100 itérations, par level set : a) initialisé par seuillage (120-255), b) le résultat de segmentation par seuillage, c) initialisé par FCM spatiale et d) le résultat de segmentation FCM spatiale. Avec les paramètres $\mu=0.1, \lambda=5, \nu=-1.5$ et $\tau=0.02$. (le contour initial en violet, le contour finale en vert).




Fig.3.10 -Segmentation des lésions de la SEP, après 100 itérations, level set : a) initialisé par FCM spatiale et b) le résultat de segmentation. Avec l'estimation des paramètres à partir de résultat de sFCM : $\mu=0.3127, \lambda=3.1979, \nu=G(R_k)$ et $\tau=0.6396$. (le contour initial en violet, le contour finale en vert).




Fig.3.11 : Segmentation des lésions de la SEP par notre level set par: (a) initialisation manuelle ; (b) le résultat de segmentation après 2300 itération ; (c) initialisation par seuillage (150-250) ; (d) le résultat de segmentation après 100 itérations ; (e) initialisation sFCM_{1,1}, (f) le résultat de segmentation après 100 itérations. Avec les paramètres $\mu=0.1, \lambda=5, \nu=-1.5$ et $\tau=0.02$. (le contour initial en violet, le contour finale en vert).

5.1 Apport de l'algorithme des levels sets adopté

Afin d'évaluer notre algorithme des levels sets adopté, nous le comparons avec celui de Malladi et Sethian [76] sur les deux types images : coupes axiale et coronale de la séquence T2 FLAIR, et coupes axiales en densité de proton (DP), avec les paramètres suivants : $\mu=0.1, \lambda=5, \nu=-1.5$ et un pas $\tau=0.02$. En effet, et afin de montrer l'efficacité de notre méthode face à la méthode de Malladi et Sethian, plusieurs expérimentations (Fig. 3.12, 3.13 et 3.14) comparant les temps de calcul des deux modèles sont effectués.

Les images des figures Fig.3.12 à Fig.3.14 montrent les résultats de la segmentation des deux modèles en utilisant les mêmes images et les mêmes initialisations.




Fig.3.12 : Comparaison des résultats d'une coupe axial de la segmentation obtenue : a)image initiale, b) image segmentée par sFCM, c)la méthode de Malladi et Sethian et d) la méthode proposée.




Fig.3.13- Comparaison des résultats d'une coupe coronal de la segmentation obtenue : a)image initiale, b) image segmentée par sFCM, c)la méthode de Malladi et Sethian et d) la méthode proposée.




Fig.3.14- Comparaison des résultats d'une coupe axial de la segmentation obtenue : a)image initiale, b) image segmentée par sFCM, c)la méthode de Malladi et Sethian et d) la méthode proposée.

Les temps d'exécution, pour ces images, sont énumérés dans le tableau 3.2. Ils ont été enregistrés à partir de nos expériences. Les expériences ont prouvé que notre modèle est d'environ 2 fois plus rapide que le modèle de Malladi et Sethian. Cela démontre l'avantage non négligeable de notre modèle en termes d'efficacité de calcul.

Tableau. 3.2– Temps d'exécution (en secondes) pour la méthode proposée et du modèle de Malladi et Sethian pour les images des figures Fig. 3.12 à Fig. 3.14 respectivement

	Image1 (coupe axiale, T2 flair)	Image2 (coupe coronal, T2 flair)	Image3 (coupe axiale, DP)
Taille de l'image	448X512	448X512	128X128
Méthode proposée	27.131	40.233	3.000
Méthode de Malladi et Sethian	31.901	56.655	4.436

Les résultats de la segmentation montrent l'efficacité des deux méthodes; les différentes lésions sont nettement bien segmentées. Les résultats de la segmentation montrent que notre méthode est supérieure en terme de précision cela est évident sur l'image de la figure Fig. 3.14 où les lésions sont mieux détectées par la méthode proposée que par celle de Malladi et Sethian.

5. Conclusion

Dans ce chapitre nous avons détaillé et appliqué la méthode proposée. Cette méthode automatise la configuration des paramètres d'initialisation et de la segmentation par les levels sets, en utilisant la classification floue spatiale (sFCM). L'intérêt de cette dernière est qu'elle permet d'utiliser les informations spatiales, grâce auxquelles chaque pixel tente d'attirer son voisin vers la classe de plus grand degré d'appartenance, créant ainsi des régions homogènes.

De meilleurs résultats pour toutes les images testées ont été obtenus par la méthode proposée, justifiant sa performance par rapport au temps d'exécution et à la précision des résultats selon les experts.

Conclusion générale

La sclérose en plaque (SEP) est la principale des maladies démyélinisantes inflammatoires du système nerveux central constitué de l'encéphale, la moelle épinière et le liquide céphalo-rachidien. Elle est caractérisée par la présence de plaques de démyélinisation localisées de façon prépondérante au niveau de la substance blanche du cerveau. Les causes de la maladie sont encore ignorées. Les symptômes sont très nombreux et très variés selon la localisation des plaques et le patient. Le chapitre 1 en a fait une description détaillée de cette maladie et a présenté le principe de l'imagerie par résonance magnétique et son apport dans le cadre de la sclérose en plaques. Nous pouvons ainsi mieux prendre conscience des difficultés d'une segmentation automatique des lésions de la SEP en termes de traitement d'images d'une part, et en termes de choix des données à utiliser, d'autre part.

Après avoir effectué une revue bibliographie sur les méthodes de segmentation d'images IRM, dans le chapitre 2, nous avons constaté l'importance et les difficultés des travaux de segmentation d'images IRM. Deux raisons expliquent ces difficultés. La première est qu'il existe une très grande variété de tissus anormaux qui diffèrent par leur taille, leur forme, leur position, leur composition (nature et homogénéité). En outre, dans certains cas, les formes des structures sont difficiles à délimiter même par des experts. La seconde raison vient de ce que la donnée issue de l'acquisition IRM est sensible au bruit de fond et à l'échantillonnage. Ainsi, un pixel peut appartenir à des tissus de différentes natures, ce qui cause l'effet dit de « volume partiel ».

Dans notre travail, nous avons, donc, proposé une démarche de détection automatique des lésions de la sclérose en plaque pour aider et faciliter un

processus long et fastidieux aux experts radiologues et les neurologues dans le cas de pathologies SEP.

Dans le but d'une segmentation automatique des images IRM, nous avons utilisé l'algorithme des levels sets qui est rapide et évoluant, directement, à partir de la segmentation initiale par classification floue spatiale (sFCM). Une initialisation du contour plus proche de la segmentation finale permettrait de diminuer le temps de convergence. Cette initialisation permettrait de plus d'avoir une méthode totalement automatique sans interaction de l'utilisateur pour initialiser l'algorithme.

Les résultats obtenus, présentés dans le chapitre 3, montrent une bonne segmentation pour l'ensemble des données, à savoir la taille et la position des lésions, même si l'évaluation est faite de manière visuelle par des experts médicaux. La méthode proposée ici devrait pouvoir être appliquée dans le cas d'autre pathologie tel que la maladie d'Alzheimer et les tumeurs cérébrales. Nous pouvons être satisfaits des résultats de l'approche adoptée.

En effet, en guise de perspectives, nous allons utiliser les paramètres de texture dans la classification pour améliorer nos résultats. Il est envisageable, aussi, d'aborder la dimension 3D et, éventuellement, le 4D, et faire une segmentation permettant d'extraire le volume d'intérêt.

Annexe

La sclérose en plaque

Le diagnostic clinique de la sclérose en plaque

L'Echelle de Cotation du Handicap EDSS (Expanded Disability Status Scale) présentée dans le tableau 1 est le principal outil de cotation clinique commun à tous les neurologues pour juger l'évolution des patients. Un score chiffré de sévérité croissante (0 à 6 ou 7) est donné à chaque paramètre fonctionnel (PF). Le score global de l'échelle se mesure sur une échelle de 20 niveaux (0 à 10 par demi-points). Jusqu'au niveau 3,5, le score obtenu dans chaque PF et le nombre de PF atteints déterminent automatiquement le score EDSS. De 4 à 7, la définition de chaque niveau est aussi donnée par l'incapacité de marche.

Tableau 1. L'échelle EDSS mise au point par Kurtzke [12] .

scores	symptômes
0	Examen neurologique normal.
1,0	Pas de handicap, signes minimes d'un des paramètres fonctionnels (PF).
1,5	Pas de handicap, signes minimes dans plus d'un des PF.
2,0	Handicap minime d'un des PF.
2,5	Handicap minime dans deux PF.
3,0	Handicap modéré d'un PF sans problème déambulation.
3,5	Handicap modéré dans un PF sans problème de déambulation.
4,0	Indépendant, debout 12 heures par jour en dépit d'un handicap relativement sévère, capable de marcher 500 mètres sans aide et sans repos.
4,5	Déambulation sans aide, debout la plupart du temps durant la journée, capable de travailler une journée entière, peut cependant avoir une limitation dans une activité complète ou réclamer une assistance minimale handicap relativement sévère. Capable de marcher 300 mètres sans aide et sans repos.
5,0	Déambulation sans aide ou repos sur une distance d'environ 200 mètres, handicap suffisamment sévère pour altérer les activités de tous les jours.
5,5	Déambulation sans aide ou repos sur une distance d'environ 100 mètres, handicap suffisant pour exclure toute activité complète au cours de la journée.
6,0	Aide unilatérale (canne, canne anglaise, béquille), constante ou intermittente, nécessaire pour parcourir environ 100 mètres avec ou sans repos intermédiaire.
6,5	Aide permanente et bilatérale (cannes, cannes anglaises, béquilles) nécessaire pour marcher 20 m sans s'arrêter.
7,0	Ne peut marcher plus de 5 m avec aide ; essentiellement confiné au fauteuil roulant ; fait avancer lui-même son fauteuil et effectue le transfert ; est au fauteuil roulant au moins 12 h par jour. Ce score est important le patient ne peut plus déplacer debout.
7,5	Incapable de faire quelques pas ; strictement confiné au fauteuil roulant a parfois besoin d'une aide pour le transfert ; peut faire avancer lui-même son fauteuil ; ne peut y rester toute la journée ; peut avoir besoin d'un fauteuil électrique.
8,0	Essentiellement confiné au lit ou au fauteuil, ou promené en fauteuil par une autre personne ; peut rester hors du lit la majeure partie de la journée ; conserve la plupart des fonctions élémentaires; conserve en général l'usage effectif des bras.
8,5	Confiné au lit la majeure partie de la journée, garde un usage partiel des bras ; conserve quelques fonctions élémentaires.
9,0	Patient grabataire ; peut communiquer et manger
9,5	Patient totalement impotent, ne peut plus manger ou avaler ni communiquer
10,0	Décès lié à la SEP

Références et Bibliographie

- [1] J. M. Charcot, « *Histologie de la sclérose en plaques* », Gazette des Hôpitaux, 141:554–558, 1868.
- [2] G. Dugas-Phocion, « *Segmentation d'IRM Cérébrales Multi-Séquences et Application à la Sclérose en Plaques* », Thèse de doctorat, École des Mines de Paris, France, 2006.
- [3] B. Ferguson, M.K. Matyszak, M.M. Esiri et V.H. Perry, « *Axonal damage in acute multiple sclerosis lesions Brain* », 120(Pt 3):393–399, 1997.
- [4] B.D. Trapp, J. Peterson et R.M. Ransohoff, « *Axonal transection in the lesions of multiple sclerosis* ». N Engl J Med, vol338, pages 278–285, 1998.
- [5] source www.doctissimo.fr
- [6] M. Bosc, « *Contribution à la détection de changements dans des séquences IRM 3D multimodales* », Thèse de doctorat, Université de Louis Pasteur – Strasbourg I, France, 2003.
- [7] H. Boigontier, « *Détection automatique de changements en IRM de diffusion : Application à la sclérose en plaques* », Thèse de doctorat, Université de Strasbourg, 2010.
- [8] Source www.msdecisions.org
- [9] Source www.ms-gateway.com
- [10] L. Ait-Ali, « *Analyse spatio-temporelle pour le suivi de structures évolutives en imagerie cérébrale multi-séquences* ». Thèse de doctorat, Université de Rennes 1, 2006.
- [11] P. O'Connor « *La sclérose en plaques, un guide indispensable* », Collection Santé, pages 11-142, 2003.
- [12] J.F. Kurtzke. « *Rating neurological impairment in multiple sclerosis: an expanded disability status scale (EDSS)* ». Neurology, vol. 33, pages 1444–452, 1983.
- [13] Source www.mssociety.ca/fr/informations/formes.
- [14] A. Rovira et A. Leon, « *MR in the diagnosis and monitoring of multiple sclerosis: An overview* ». European Journal of Radiology, 2008.

- [15] J. Nolte, "*The Human Brain: An Introduction to Its Functional Anatomy*" 5th edition, revised. Elsevier Science, 2001.
- [16] H. Rouvière et A. Delmas, « *Anatomie humaine : descriptive, topographique et fonctionnelle* », Masson, 2002.
- [17] Source www.vh.org/adult/provider/anatomy/BrainAnatomy.html
- [18] F.H. Netter, "*The Ciba collection of medical illustrations, nervous system*", (Vol.1) part I and II. Summit, NJ : Hoechstetter printing, 1995.
- [19] E.N. Mariab, "*Essentials of human anatomy and physiology*", Redwood City, Calif, Benjamin/Cummings Pub, 1991.
- [20] Source www.esil.univ-mrs.fr
- [21] L. Germond, « *Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale* », Thèse de doctorat, Université Joseph FOURIER-Grenoble 1, 1999.
- [22] 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, Université de Poitiers, 2003.
- [23] B. Scherrer. « *Segmentation des tissus et structures sur les IRM cérébrales : agents markoviens locaux coopératifs et formulation bayésienne* », Thèse de doctorat en Mathématiques Appliquées et Informatique de l'INPG, 2008.
- [24] L. Cinotti, « *Imagerie médicale, cours de PCEM2 (CERMP)* », <http://www.cermep.fr/docs/cinotti/iùimagep2.pdf>
- [25] E. Feroux, « *Applications et validation de méthodologies de fusion de données en imagerie cérébrale* ». Thèse de doctorat, Université d'Auvergne, 2004.
- [26] D. Sappey-Mariner. « *Résonance Magnétique Nucléaire* », Cours de l'université Claude Bernard6Lyon.
[http //wwwcism.univ-lyon1.fr/domininc/enseignement.html](http://wwwcism.univ-lyon1.fr/domininc/enseignement.html)
- [27] F. Bloch, "*Nuclear Induction, Physical Review*", Vol70,pages 460-474, 1946.
- [28] A . Tourbah. « *L'IRM de la SEP: État des lieux* ». Service de Neurologie CHU de Reims. Centre de Recherche en RMN, Groupe Hospitalier Pitié Salpêtrière et Faculté de Médecine Pierre et Marie Curie, Paris.

- [29] S. S. Gebarski, T. O. Gabrielsen, S. Gilman, J. E. Knake, J. T. Latack, A. M. Aisen. "*The initial diagnosis of multiple sclerosis : clinical impact of magnetic resonance imaging*". Annals of Neurology, vol 17, pages 469-474, 1985.
- [30] M. Filippi, T. Yousry, C. Baratti, M. A. Horsfield, S. Mammi, C. Becker, R. Voltz, S. Spuler, A. Campi, M. F. Reiser, G. Comi, "*Quantitative assessment of MRI lesion load in Multiple Sclerosis. A comparison of conventional spin-echo with fast fluid-attenuated inversion recovery*", Brain, Vol 119, pages 1349-1355, 1996.
- [31] M. A. Van Valderveen, W. Kamphorst, P. Scheltens, J. H. Van Waesberghe, R. Ravid, J. Valk, C. H. Polman, F. Barkhof, "*Histopathologic correlate of hypointense lesions on T1-weighted spin-echo MRI in multiple sclerosis*". Neurology, vol 5, pages 1282-1288, 1998.
- [32] A. Bitsch, T. Kuhlmann, C. Stadelmann, H. Lassman, C. Lucchinetti, W. Bruck. "*A longitudinal MRI study of histopathologically Defined Hypointense Multiple Sclerosis Lesions*". Annals of Neurology, Vol 49, pages 793-796, 2001.
- [33] R. I. Grossman, F. Gonzalez-Scarano, S. W. Atlas, S. Galetta, D. H. Silbergberg, "*Multiple Sclerosis : Gadolinium Enhancement in MR Imaging*", Radiology, vol 161, pages 721-725, 1986.
- [34] D. H. Miller, F. Barkhof, J. J. P. Nauta. "*Gadolinium enhancement increases the sensitivity of MRI in detecting disease activity in multiple sclerosis*". Brain, vol 116, p.1077-1094, 1993.
- [35] R. Bakshi, G. Hutton, J. Miller, E. W. Radue. "*The use of magnetic resonance imaging in the diagnosis and long-term management of multiple sclerosis*", Neurology, Vol 63, pages S 5. S3-S11, 2004.
- [36] J. Lecoœur, C. Barillot, "*Segmentation d'images cérébrales : Etat de l'art*", Thème BIO - Systèmes biologiques. Projet VisAGeS. Rapport de recherche. Unité de recherche INRIA Rennes, Campus universitaire de Beaulieu, Juillet 2007.

- [37] Y. ROLLAND, R. COLLOREC, A. BRUNO, A. RAME, N.MORCET, P.HAIGRON. « *Lexique des termes utilisés dans le traitement des images à l'usage des médecins radiologues* ». *Ann Radiol*, Vol 38, pages 349-384, 1995.
- [38] J. Grimaud, Y.M. Zhu, M. Rombaut. « *Les techniques d'analyse quantitative des IRM cérébrales : application à la sclérose en plaques* ». Centre de Recherche et d'Applications en Traitement de l'Image et du Signal, UMR CNRS 5515, INSA-Lyon.
- [39] M. A. Gonzalez Ballester, A. P. Zisserman, and M. Brady. “*Estimation of the partial volume effect*”. *Medical Image Analysis*, Vol 6 pages 389–405, 2002.
- [40] C. Jaggi, « *Segmentation par méthode markovienne de l'encéphale humain en imagerie par résonance magnétique : théorie, mise en œuvre et évaluation* », Thèse de doctorat, Université de Caen/Basse-Normandie, 1998.
- [41] N. Richard. « *Une approche située, coopérative et décentralisée pour l'interprétation d'images cérébrales par RMN* ». Thèse de doctorat, Institut National Polytechnique de GRENOBLE, 2004.
- [42] J.P. Cocquerez et S. Philipp, « *Analyse d'images: filtrage et segmentation* ». Masson, Paris, 1995.
- [43] L. G. Roberts, “*Machine perception of three dimensional solids*”, In J. T. and al. Tippet, editor, *Optical and Electro-optical Information Processing*, pages 159-197. MIT Press, Cambridge, 1965.
- [44] J. M. S. Prewitt, “*Object enhancement and extraction*”. In *PPP70*, pages 75-149, 1970.
- [45] I. Sobel, “*Neighbourhood coding of binary images for fast contour following and general array binary processing*”, *Computer Graphics and Image Processing*, vol. 8, pages 127-135, 1978.
- [46] R. Kirsch, “*Computer determination of the constituent structures of biomedical images*”, *Computer and Biomedical Research*, vol. 4, pages 315-328. USA, 1971.

- [47] A. Hammouche. « *Système multi-agent appliquées en segmentation d'image* ». Université Mouloud Mammeri de Tizi-Ouzou, Algérie. 2008.
- [48] J. Montagnat, M. Sermesant, H. Delingette, G. Malandain, and N. Ayache, « *anisotropic filtering for model-based segmentation of 4d cylindrical echo-cardiographic images*», Pattern Recognition Letters - Special Issue on Ultrasonic Image Processing and Analysis, Vol 24, pages 815–828, 2003.
- [49] K.H.Hohne et W. Hanson. « *Interactive 3D segmentation of MR and CT volumes using morphological operations*», Journal of computer Assisted Tomography, 16 (2): 285-294, April 1992
- [50] M. Kass, , A. Witkin, , D. Terzopoulos,. “*Snakes : Active contour models*”. International Journal of Computer Vision ,Vol 4,pages 321–31, 1988.
- [51] S. Osher , J. A. Sethian. “ *Fronts propagating with curvature-dependant speed: Algorithms based on Hamilton-Jacobi formulations*”. Journal of Computational Physics, Vol 19, pages 12–49, 1988.
- [52] V.Caselles, F.Catte, T. Coll, F. Dibos. “*A geometric model for active contours in image processing*”. Numerische Mathematic Vol 66,pages 1–31, 1993.
- [53] V.Caselles, R. Kimmel, G. Sapiro, “*Geodesic active contours*”, International Journal of Computer Vision, Vol 22, pages 61–79, 1997.
- [54] J. A.Sethian. “*A fast marching level set method for monotonically advancing fronts*”, In : Proceedings of the National Academy of Sciences. Vol 93, pages 1591–1595, 1996.
- [55] Xu, C., J. L. Prince. « *Snakes, shapes and gradient vector flow*”. IEEE Transactions on Image Processing, Vol 7, pages 359–369, 1998.
- [56] S. M. Smith. “*Fast robust automated brain extraction*”. Human Brain Mapping 17 (3), 143–155. 28, 31, 103, 2002.

- [57] N. Richard, M. Dojat, C. Garbay. “*Automated segmentation of human brain MR images using a multi-agent approach*”. Artificial Intelligence in Medicine, Vol 30, pages 153–175, 2004.
- [58] K. Fukunaga, L. Hostetler. “*The estimation of the gradient of a density function with applications in pattern recognition*”. IEEE Transactions on Information Theory, Vol 21, pages 32–40, 1975.
- [59] J. Bezdek, L. Hall, L. Clarke. “*Review of MR Image Segmentation Techniques using Pattern Recognition*”. Medical Physics, Vol 20, pages 1033–1048, 1993.
- [60] L. Khodja, « *Contribution à la classification floue non supervisée* ». Thèse de doctorat, Université de Savoie, France, 1997.
- [61] T. Song, C. Gasparovic, N. Andreasen, J. Bockholt, M. Jamshidi, R. Lee, M. Huang. “*A hybrid tissue segmentation approach for brain MR images*”. Medical and Biological Engineering and Computing, 2006.
- [62] J. Dunn, “*A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters*”, Journal of cybernetic, Vol 3, pages 32–57, 1974.
- [63] J. Bezdek, “*Pattern Recognition with Fuzzy Objective Function Algorithms*”, Plenum Press, New York, 1981.
- [64] B. C. Vemuri, S. Rahman, J. Li. « *Multiresolution adaptive K-means algorithm for segmentation of brain MR* ». Proceedings of the International Computer Science Conference on Image Analysis Applications and Computer Graphics. Vol. 1024 of Lecture Notes in Computer Science. Springer-Verlag Heidelberg, pages 347–354, 1995.

- [65] J. Peña, J. Lozano, P. Larrañaga, « *An empirical Comparison of four Initialization Methods for the k-means Algorithm* », Pattern Recognition Letters, Vol 20, pages 1027-1040, 1999.
- [66] V. Barra. « *Fusion d'Images 3D du Cerveau : Etude de Modèles et Applications* ».Thèse de doctorat, Université d'Auvergne, 2000.
- [67] J.K. Udupa, L. Wei, S. Samarasekera, Y. Miki, M.A. van Buchem & R.I. Grossman. « *Multiple sclerosis lesion quantification using fuzzy connectedness principles* ». IEEE Transactions on Medical Imaging, vol. 16, pages 598–609, 1997.
- [68] M. Kamber, R. Shinghal, D.L. Collins, G.S. Francis & A.C. Evans. « *Model-based 3-D segmentation of multiple sclerosis lesions in magnetic resonance brain images* ». IEEE Transactions on Medical Imaging, vol. 14, , pages 442–453, 1995
- [69] P. Schroeter, J.-M. Vesin, T. Langenberger & R. Meuli. « *Robust Parameter Estimation of Intensity Distributions for Brain Magnetic Resonance Images* ». IEEE Transactions on Medical Imaging, vol. 17, pages 172–186, April 1998.
- [70] K. Van Leemput, F. Maes, D. Vandermeulen, A. Colchester & P. Suetens. « *Automated Segmentation of Multiple Sclerosis Lesions by Model Outlier Detection* ». IEEE Transactions on Medical Imaging, vol. 20, pages 677–688, August 2001.
- [71] G. Dugas-Phocion, M.A. González Ballester, G. Malandain, C. Lebrun & N. Ayache. « *Improved EM-Based Tissue Segmentation and Partial Volume Effect Quantification in Multi-Sequence Brain MRI* ». In Proc. of MICCAI'04, Lecture Notes in Computer Science, Saint-Malo, France, September 2004. Springer
- [72] D. Garcia-Lorenzo, « *Robust Segmentation of Focal Lesions on Multi-sequence MRI in Multiple Sclerosis* », Thèse de doctorat, Université de Rennes 1, 2010.

- [73] K.S. Chuang, H.L. T. S Chen, J. Wu, T.Chen, “*Fuzzy c-means clustering with spatial information for image segmentation*”, Elsevier - Computerized Medical Imaging and Graphics, vol. 30,pages 9-15, 2006.
- [74] T. Radjmana. « *Segmentation d’images bruitée et faiblement contrastée selon une approche par level set* ».Rapport de DEA, Université Pierre Marie Curie, France, Septembre 2005.
- [75] Y. Chen, H.D. Tagare, S. Thiruventkadam, F. Huang, D.Wilson, K.S.Gopinath. “*Using prior shapes in geometric active contours in a variational framework*”, International Journal of computer,pages 315-328,2002.
- [76] R. Malladi and J. Sethian, “*Image processing via level set curvature flow*”, in Proc. Of National Academy of Science, pages 7046–7050, 1995.
- [77] Bing Nan Li, Chee Kong Chui, Stephen Chang, S.H.Ong, “*Integrating Spatial Fuzzy Clustering with Level Set Methods for Automated Medical Image Segmentation*”, Computers in Biology and Medecine. Février 2011.
- [78] N.Paragioset, R.Derriche, “*A PDE-based level set approach for detection and trading of moving objects*”. Rapport de recherché n°3173, Unité de recherché INRIA, Université de Renne, France, Mai 1997.
- [79] Chunming Li, Chenyang Xu , Changfeng Gui , and Martin D. Fox, “*Level Set Evolution Without Re-initialization: A New Variational Formulation*”, Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05),pages 430-436, 2005.
- [80] J. C. Bezdek, “*Cluster validity with fuzzy sets*”. Cybernetics and Systems, pages 58–73, 1973.

[81] J. C. Bezdek, “*Mathematical models for systematic and taxonomy*” Proc. of Eight International Conference on Numerical Taxonomy, San Francisco, pages 143–166, 1975.