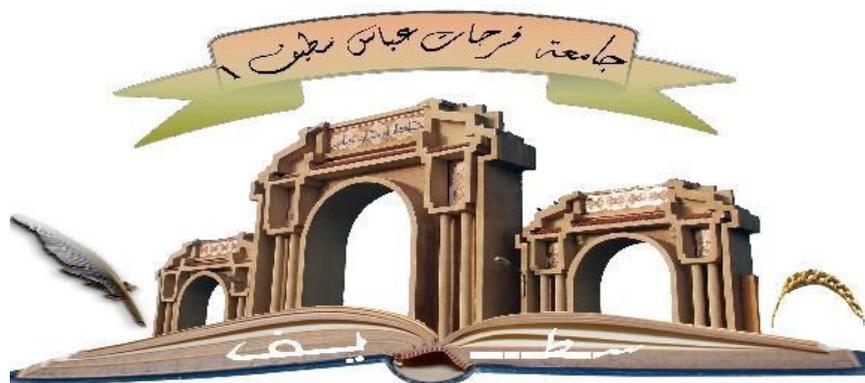


République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Ferhat Abbas – Sétif 1
Faculté des Sciences



Université Ferhat ABBAS Sétif 1

Thèse de Doctorat

En Sciences

Option: Informatique

Segmentation d'images IRM cérébrales : Application à la détection de la sclérose en plaques

Présentée par

ZOUAOUI Hakima

Devant le jury :

BACHARI Nour El-Islam	Professeur, Université Bab Ezzouar Alger	Président
MOUSSAOUI Abdelouahab	Professeur, Université Ferhat Abbas Sétif -1	Rapporteur
SAIDI Mohamed	MCA, Université Ferhat Abbas Sétif -1	Examineur
AKHROUF Samir	MCA, Université Mohamed Boudiaf M'Sila	Examineur
BOULMERKA Aïssa	MCA, Université Abdelhafid Boussouf Mila	Examineur
LAKHFIF Abdelaziz	MCA, Université Ferhat Abbas Sétif -1	Examineur

Année Universitaire 2020-2021

Remerciements

Tout d'abord, je remercie le bon dieu pour m'avoir donnée le courage et la santé pour accomplir ce travail qui n'aurait pas pu aboutir à des résultats sans l'aide, sans l'accompagnement et sans les encouragements de nombreuses personnes.

Je tiens également à remercier :

- Monsieur **MOUSSAOUI Abdelouahab**, directeur de thèse et professeur à l'université de Sétif, pour son encadrement, ses conseils et qui a toujours suivi ce travail avec un très grand intérêt.

- Monsieur **TALEB-AHMED Abdelmalik**, professeur à l'université valencienne en France, pour sa gentillesse, sa disponibilité permanente et pour les nombreux encouragements qu'il m'a prodigués.

Mes vifs remerciements accompagnés de toute ma gratitude vont ensuite à :

- Monsieur **OUSSALAH Mourad**, professeur à l'université Oulu de Finlande, pour ses conseils judicieux, sa grande disponibilité et de m'avoir suivi et orienté.

- Je remercie le Président de jury, Monsieur **BACHARI Nour El-Islam**, professeur à l'université de Bab Ezzouar Alger d'avoir accepté de présider le jury.

- Je remercie également, les membres de jury : Monsieur **SAIDI Mohamed**, maître de conférence à l'université de Sétif ; Monsieur **AKHROUF Samir**, maître de conférence à l'université de M'sila ; Monsieur **BOULMERKA Aissa**, maître de conférences à l'université de Mila et Monsieur **LAKHFIF Abdelaziz**, maître de conférences à l'université de Sétif d'avoir accepté d'examiner ce travail.

Et pour n'oublier personne, mes sincères remerciements à toutes et à tous ceux qui nous ont aidés et encouragés de près ou de loin à la concrétisation de ce projet, et qu'ils trouvent ici ma très grande gratitude et reconnaissance.

Dédicace

*A ma mère, qui m'accompagne, m'épaule, remplit ma vie de joie et illumine chaque jour
de mon existence ;*

*A mon père Mohamed, qui me manque, qui nous manque tant, depuis septembre 2014.
Toi papa qui as fait naître en moi la volonté, le dévouement, la détermination, le respect,
l'humilité et le courage, ornés d'éducation et d'un savoir-vivre, que toi seul a été capable
de m'y amener. Je t'aime papa, repose en paix ;*

A mes sœurs et mes frères ;

*A notre valeureux pays l'Algérie. Pays d'un million et demi de Chahides, pays de lutte et
d'indépendance, mon pays qui m'a offert tous les moyens pour arriver là où je veux
commencer, mon rêve et le rêve de mon papa Mohamed.*

L'important n'est pas ce que l'on regarde ...

...mais ce que l'on voit.

Henry David THOREAU

Table des matières

Introduction générale	1
1 Etat de l'art des techniques de segmentation d'images IRM	4
1.1 Introduction	4
1.2 Qu'est-ce que la segmentation?	5
1.3 Applications et objectifs de la segmentation	5
1.4 Différentes méthodes de segmentation	5
1.4.1 Approches régions	6
1.4.1.1 Seuillages	6
1.4.1.2 Croissance des régions	7
1.4.1.3 Morphologie mathématique	8
1.4.2 Approches contours	8
1.4.2.1 Méthodes dérivatives	9
1.4.2.2 Modèles déformables	9
1.4.3 Segmentation par classification	10
1.4.3.1 Méthodes supervisées	10
1.4.3.2 Méthodes non supervisées	11
1.5 Conclusion	18
2 Métaheuristiques pour la segmentation d'images IRM	20
2.1 Introduction	20
2.2 Problème d'optimisation	20
2.3 Les métaheuristiques	22
2.3.1 Les métaheuristiques à solution unique	22

2.3.1.1	La méthode du recuit simulé	22
2.3.1.2	La méthode de recherche tabou	24
2.3.1.3	La méthode de descente	25
2.3.2	Les métaheuristiques à population de solutions	27
2.3.2.1	Les algorithmes évolutionnaires	27
2.3.2.2	Les algorithmes des colonies de fourmis	29
2.3.2.3	Les algorithmes d'optimisation par essaim particulière	31
2.4	Conclusion	35
3	Systèmes et décision flous	36
3.1	Introduction	36
3.2	Structure d'un système flou	36
3.2.1	Fuzzification	37
3.2.2	Base de règles floues (Base de connaissances)	37
3.2.3	Inférence floue	38
3.2.3.1	La méthode d'inférence Mamdani	39
3.2.3.2	La méthode d'inférence Takagi-Sugeno	39
3.2.4	Défuzzification	40
3.2.4.1	Méthode du centre de gravité (COG)	40
3.2.4.2	Méthode de moyenne de maximum (MOM)	41
3.3	Conclusion	42
4	Contributions	43
4.1	Introduction	43
4.2	Contribution 1 : FCM-PSOBC	44
4.2.1	Segmentation des tissus cérébraux par l'algorithme FCM	45
4.2.1.1	Quel type de méthode?	45
4.2.1.2	Classification floue ou non floue?	46
4.2.1.3	Algorithme Fuzzy C-Means (FCM)	46
4.2.2	Segmentation de la matière blanche par PSOBC	47
4.2.2.1	Algorithme Particle Swarm Optimization (PSO)	47
4.2.2.2	PSO basé sur la segmentation d'images	48
4.2.3	Prise de décision	50

4.3	Contribution 2 : FPSO-FCM	50
4.3.1	Segmentation des tissus cérébraux par FPSO	50
4.3.2	Segmentation de la matière blanche par FCM	52
4.3.3	Prise de décision	54
4.4	Contribution 3 : FPSO-PCM	54
4.4.1	Segmentation des tissus cérébraux par FPSO	55
4.4.2	Segmentation de la matière blanche par PCM	55
4.4.3	Prise de décision	57
4.4.3.1	Fuzzification du système flou	58
4.4.3.2	Établissement de la base des règles	59
4.4.3.3	Défuzzification du système flou	61
4.5	Choix des paramètres des algorithmes	61
4.5.1	Nombre de particules P	61
4.5.2	Facteur d'inertie w	61
4.5.3	Coefficients c_1, c_2	62
4.5.4	Critères d'arrêt	62
4.5.5	Vitesse maximale v_{max}	62
4.5.6	Degré de flou m	62
4.5.7	Mesure de la distance	62
4.5.8	Détermination du nombre des classes	63
4.5.9	Choix des vecteurs forme	63
4.6	Conclusion	63
5	Résultats et évaluations	64
5.1	Introduction	64
5.2	Base d'images	64
5.2.1	Images réelles	65
5.2.2	Fantômes (image de synthèse)	65
5.2.3	Constructions des images simulées	66
5.3	Environnement matériel	68
5.4	Evaluation et étude comparative	68
5.4.1	Critères de validation	68
5.4.2	Le protocole d'évaluation	71

5.5	Résultats et Évaluations de la segmentation	71
5.5.1	Étape 1 : Segmentation des tissus par FCM et FPSO	72
5.5.2	Étape 2 : Segmentation de la matière blanche par PSOBC, FCM et PCM	74
5.5.3	Étape 3 : Prise de décision	77
5.6	Résultats expérimentaux	78
5.7	Conclusion	87
	Conclusion générale	88
	Annexe A : La sclérose en plaque et IRM	91
	A La sclérose en plaques et IRM	91
	Annexe B : Concepts fondamentaux de la logique floue	105
	B Concepts fondamentaux de la logique floue	105
	Bibliographie	111
	Productions scientifiques	122

Table des figures

2.1	Différence entre un minima et un maxima locaux et globaux d'une fonction [Betk-19].	21
2.2	(a) Les fourmis suivent un chemin entre la fourmilière et la nourriture. (b) Un obstacle apparaît sur le chemin; les fourmis choisissent entre prendre à droite et à gauche avec équiprobabilité. (c) La phéromone s'évapore sur le chemin le plus long. (d) Toutes les fourmis choisissent le chemin le plus court [Abde-11].	29
2.3	PSO - Déplacement d'une particule [Beni-14].	32
3.1	Schéma d'un système flou.	37
4.1	Les étapes de la segmentation des lésions de la SEP de nos propositions.	44
4.2	Système d'inférence flou de Mamdani de nos propositions.	58
4.3	Répartition floue de la variable d'entrée type de signal.	58
4.4	Répartition floue de la variable de sortie qui donne la décision de la SEP.	59
5.1	Exemple de cartes floues du fantôme [Kwan-96].	66
5.2	Processus de construction des images simulées	67
5.3	Comparaison d'une image segmentée avec une image de référence. TP, TN, FP et FN représentent les voxels vrai positif, vrai négatif, faux positif et faux négatif, respectivement.	69
5.4	Processus d'évaluation sur des images fantômes	71
5.5	Images originales.	72
5.6	(a) sont les images originales; (b) correspond aux résultats de la segmentation par FCM; (c) est l'extraction de la matière blanche (MB).	72

5.7	(a) sont les images originales ; (b) correspond aux résultats de la segmentation par FPSO ; (c) est l'extraction de la matière blanche (MB).	73
5.8	MB des images (T2, DP et T1) segmentées par PSOBC.	75
5.9	MB des images (T2, DP et T1) segmentées par FCM.	75
5.10	MB des images (T2, DP et T1) segmentées par PCM.	76
5.11	Résultats de segmentation.	79
5.12	Mesures de performance des résultats obtenus par des différents algorithmes.	81
5.13	Images originales : différentes coupe axiales et différentes pondérations (T1, T2, DP).	83
5.14	Segmentation par FCM-PSOBC.	84
5.15	Segmentation par FPSO-FCM.	85
5.16	Segmentation par FPSO-PCM.	86
A.1	Prévalence mondiale de la sclérose en plaques Source : Atlas of MS 2013, MS International Federation [Lepr-19]	92
A.2	Les différentes formes de SEP [Lepr-19].	95
A.3	Structures anatomiques de l'encéphale [Zoua-08].	97
A.4	Les principaux tissus cérébraux sur une IRM.	99
A.5	Les trois vues des IRM cérébrales.	100
A.6	Les séquences IRM : (a) image pondérée en T1, (b) image pondérée en T2, (c) image pondérée en DP.	103
A.7	L'effet du volume partiel en IRM.	104
A.8	L'inhomogénéité RF : (a) Image affectée par une inhomogénéité RF, (b) L'artefact RF isolé, (c) Image sans artefact	104
B.1	Comparaison d'un ensemble classique et d'un ensemble flou [Chev-98].	106
B.2	Variable linguistique [Mera-20].	109
B.3	Formes usuelles des fonctions d'appartenance [Mera-20].	110

Introduction générale

L'imagerie par résonance magnétique (IRM) est un examen qui permet d'obtenir des vues en deux ou trois dimensions de l'intérieur du corps. L'IRM donne des informations sur des lésions qui ne sont pas visibles par d'autres techniques d'imagerie médicale (radiographies, scanner, etc). Cette modalité d'imagerie est devenue un outil de plus en plus important en médecine du cerveau particulièrement (lésions infectieuses ou inflammatoires, des anomalies des vaisseaux, ainsi que des tumeurs), ou dans la recherche en neurosciences cognitives de manière générale.

L'imagerie par résonance magnétique (IRM) est portée à l'ordre des examens complémentaires dans la démarche diagnostique de la maladie sclérose en plaques (SEP), elle est primordiale pour le suivi de l'état du patient et le diagnostic d'une réponse à la prescription du traitement adéquat. L'extraction automatique de quantificateurs pour la SEP a donc de nombreuses applications potentielles, que ce soit dans le domaine clinique et/ou pour des tests pharmaceutiques. En revanche, l'interprétation de ces images est complexe du fait de la variabilité de la taille, du contraste et la localisation des lésions de la SEP. La segmentation d'image IRM est une technique importante dans la quasi-totalité des analyses pour l'évaluation radiologique ou le diagnostic de la SEP.

La segmentation d'image est le processus de partitionnement d'une image en régions, non chevauchées, homogènes vis-à-vis de certaines caractéristiques, tels que le niveau de gris, la texture, etc. Elle est applicable dans plusieurs domaines comme l'imagerie médicale, la détection d'objets, l'imagerie par satellite, etc. Le procédé de segmentation incarne une étape capitale dans les systèmes de vision par ordinateur, car les caractéristiques et décisions sont extraites et prises à partir de son résultat. Les premiers algorithmes de seg-

mentation d'image sont apparus dans les années 1970. Depuis, de nombreuses techniques et méthodes de segmentation ont été expérimentées afin d'améliorer les résultats. Cependant et jusqu'à présent, aucun algorithme de segmentation d'image n'arrive à apporter des résultats parfaits sur une large variété d'images.

Dans ce travail nous concentrons notre étude sur des images IRM cérébrales et nous soumettons des méthodes automatiques de segmentation de la maladie sclérose en plaques (SEP). Nos contributions de segmentation sont constituées de trois étapes. Dans la première, nous segmentons l'image du cerveau en régions afin d'acquérir une caractérisation des différents tissus sains (matière blanche, matière grise et liquide céphalo-rachidien). Dans la seconde, nous éradiquons les données atypiques de la matière blanche. Dans la troisième étape, une décision est prise en appliquant un modèle flou de type Mamdani pour sélectionner les lésions de la SEP parmi toutes les données aberrantes.

Ce manuscrit est organisé comme suit :

Le premier chapitre présente les différentes approches et stratégies généralement employées pour la segmentation des tissus cérébraux tout en citant les avantages et les inconvénients de chaque méthode.

Les métaheuristiques font l'objet du chapitre deux. Ainsi après l'étape de la segmentation des tissus cérébraux, nous décrivons d'abord le cadre de l'optimisation, puis nous présentons des métaheuristiques pour les problèmes à solution unique et les problèmes à population de solutions.

Dans le troisième chapitre, en commencement, nous insisterons sur la notion des règles floues et la notion des modèles flous, ensuite, nous détaillons la notion de l'inférence floue.

Dans le quatrième chapitre nous décrivons d'abord, les différents algorithmes pour la détection de la maladie sclérose en plaques tout comme leurs architectures et leurs différents paramètres. Nous présentons ensuite les étapes de nos propositions en réponse à la problématique de la segmentation des lésions de la SEP.

Le cinquième chapitre présente les résultats atteints dans cette étude et illustre le

fonctionnement du système sur des images médicales réelles et simulées.

Enfin, dans la conclusion générale de la présente thèse, nous récapitulons nos principales contributions, puis nous exposons quelques perspectives pour améliorer les performances des algorithmes déjà développés.

Etat de l'art des techniques de segmentation d'images IRM

1.1 Introduction

Face à l'accroissement du nombre d'examen pratiqué en imagerie médicale, les programmes de traitement d'image ont un rôle primordial à jouer afin de soutenir la tâche des praticiens. De tels programmes ne se limitent pas à des tâches de visualisation des images, ils ont la finalité d'aider le praticien dans ses diagnostics, en lui signalant les risques pathologiques. L'une des opérations primordiales pour tout traitement d'image est évidemment la segmentation.

En effet, cette dernière est un processus important pour le traitement d'image. Elle consiste à partitionner une image en plusieurs régions. Ce dispositif aidera à trouver des zones d'intérêt dans une image et également la rendre plus simple et plus significative à évaluer. Plus spécifiquement, la segmentation des images IRM cérébrales, permet de délimiter les différents tissus cérébraux et éventuellement les structures pathologiques.

Nous commençons ce chapitre par définir formellement la segmentation d'image et présenter la spécificité des images IRM par rapport à d'autres types des images. Puis, nous présenterons un état de l'art sur les différentes méthodes pour la segmentation des images IRM cérébrales. Toutefois, l'accent est mis sur les méthodes de segmentation par classification.

1.2 Qu'est-ce que la segmentation ?

Avec toutes les définitions de la segmentation, nous retiendrons pour notre étude la définition suivante : Segmenter une image signifie de trouver ses régions homogènes et ses contours. Ces derniers sont supposés être pertinents, c'est-à-dire que les régions doivent correspondre aux parties significatives des objets du monde réel, et les contours à leurs contours apparents [Jéré-08].

1.3 Applications et objectifs de la segmentation

Segmenter, ou délimiter les structures cérébrales est une étape fondamentale pour l'analyse d'images cérébrales. Les principales applications sont la morphométrie, la cartographie fonctionnelle et la visualisation [Semc-18].

- **Morphométrie** : est la mesure quantitative des positions, formes et tailles de structures cérébrales, elle nécessite la segmentation préalable de ces structures. Elle permet d'identifier, de comprendre et de suivre la progression des pathologies comme l'autisme, l'Alzheimer, la schizophrénie ou la sclérose en plaques.

- **Cartographie fonctionnelle** : l'essentiel de l'activité fonctionnelle mesurable est située dans le cortex dont la topologie est bidimensionnelle, la segmentation de la structure bidimensionnelle est alors nécessaire pour localiser les signaux pour les cartographier et pour les visualiser.

- **Visualisation** : la visualisation des structures anatomiques se fait naturellement à l'aide de la visualisation de leurs surfaces extérieures. Il est alors nécessaire de segmenter ces structures.

1.4 Différentes méthodes de segmentation

La segmentation est une étape essentielle en traitement d'images dans la mesure où elle conditionne l'interprétation qui va être faite de ces images. De nombreux algorithmes ont ainsi été proposés durant les dernières décennies [Cocq-95] [Frei-02]. Ils sont généralement fondés sur des principes différents. Nous proposons dans cette section de parcourir, de manière non exhaustive, différentes approches présentes dans la littérature. En les organisant selon la technique qui les régit. Ainsi, nous avons retenu trois catégories

principales : régions, contours et classification.

1.4.1 Approches régions

Les approches de segmentation régions visent à créer une partition de l'image en un ensemble de régions homogènes au sens d'un ou plusieurs critères. On recherche donc à rassembler les pixels (ou voxels) par critères de similarité. Par la suite, nous nous intéressons plus particulièrement à la méthode à base de seuillage, à la méthode par croissance de régions et à la méthode de la morphologie mathématique [Zemm-18].

1.4.1.1 Seuillages

Les méthodes de segmentation par seuillages visent à discriminer les individus (pixels ou voxels) en fonction de leurs niveaux radiométriques (niveaux de gris). Elles supposent donc, de manière implicite, que l'intensité des structures est suffisamment discriminante pour permettre leur bonne séparation. Le plus souvent, les seuils sont déterminés à l'aide d'une analyse d'histogrammes, localement ou globalement à l'image ou au volume.

Les méthodes de segmentation par seuillage ont été largement appliquées à la segmentation des IRM cérébrales. Par exemple dans [Zijd-94], Zijdenbos et al présentent une revue des méthodes de segmentation des images IRM cérébrales dans laquelle les méthodes à base de seuillages sont largement traitées. Les structures visées sont variées : cerveau, liquide céphalo-rachidien, matière blanche, matière grise. Si ces méthodes sont simples à mettre en œuvre, on remarque cependant qu'elles nécessitent bien souvent des post-traitements. Ainsi, dans [Moza-16], Mozaffari et al ont proposé une nouvelle approche de seuillage basée sur l'optimisation par essaim de particule (PSO). Les auteurs ont utilisé les deux techniques de seuillage automatique Otsu [Otsu-79] et Kapur [Kapu-85] comme fonction de PSO. Les résultats de test de cette approche, montrent la robustesse et l'efficacité de cette approche. Dans [Zaar-13], un algorithme de segmentation par seuillage est appliqué sur des images IRM, pour détecter la maladie d'Alzheimer.

Les méthodes de segmentation par seuillages sont des méthodes rapides et simples à mettre en œuvre. Néanmoins, elles échouent lorsque les régions de recherche sont insuffisamment contrastées, lorsque les niveaux radiométriques des structures anatomiques

se recouvrent ou encore lors de dérive du champ radiofréquence. Or, le recouvrement des niveaux radiométriques entre les différentes structures et le phénomène de dérive sont des défauts typiques de l'imagerie IRM (Incertitudes et imprécisions), limitant les performances de ces méthodes. Toutefois, des solutions peuvent être mises en place [Semc-18].

En dépit de leurs avantages, les méthodes de segmentation par seuillages ne semblent donc pas adaptées pour, à elles seules, segmenter les principales structures anatomiques et les éventuelles pathologies. Leur utilisation nécessite, en particulier, la prise en compte d'informations locales, liées au voisinage d'un pixel ou d'un voxel.

1.4.1.2 Croissance des régions

Les algorithmes de croissance des régions sont fondés sur l'agrégation progressive des pixels ou voxels à partir d'un point initial appelé «germe», selon un critère. Les points voisins du germe sont successivement examinés; s'ils vérifient le critère d'agrégation, ils sont inclus à la région et deviennent à leur tour un germe; dans le cas contraire, ils sont rejetés. Le critère est le plus souvent un critère local basé sur les niveaux radiométriques des points. Les méthodes fondées sur la croissance des régions permettent aussi bien la segmentation des structures saines [Thir-97] [Schn-01] que la segmentation de structures pathologiques [Warf-95] [Hojj-01].

Dans [Warf-95] Warfield et al présentent une méthode d'identification des tumeurs de la matière blanche, qui suppose la segmentation préalable du cortex, de la matière grise et de la matière blanche. En particulier, le cortex est segmenté par croissance des régions, guidée par des connaissances anatomiques a priori sur la forme de la structure, ainsi que par des contraintes d'intensité et de gradient. Les lésions sont ensuite détectées par un maximum de vraisemblance.

Dans [Hojj-01], la croissance de régions est directement utilisée pour segmenter des lésions cérébrales de faibles intensités radiométriques sur des images pondérées en T1. Le critère de croissance est basé sur une mesure de contraste. L'originalité de cette approche est l'ajout d'un critère fondé sur la taille 5 des régions de façon à éviter l'agrégation des zones anatomiques d'intensités radiométriques proches de celles de la tumeur (e.g. liquide céphalo-rachidien, os...). Si le taux de bonne classification d'environ 90% est considéré comme bon par l'auteur, notons que les tests n'ont été réalisés que sur trois volumes cérébraux. De plus, l'algorithme nécessite une forte intervention de l'opérateur pour

placer le germe initial et définir les critères sur la taille des régions, critères difficilement appréciables et dont la pertinence est fortement corrélée à l'expertise de l'opérateur.

Tout comme les méthodes à base de seuillage, les segmentations par croissance des régions sont simples et itératif [Sani-19], mais parfois le temps de calcul est long. Leur avantage demeure dans la considération des informations contextuelles par le mécanisme de croissance et dans la possibilité d'introduire des informations de plus haut-niveau. Néanmoins, leur inconvénient est lié à la disposition des germes initiaux, surtout pour la détection des tumeurs, dont l'information a priori n'est pas connue [Soph-03].

1.4.1.3 Morphologie mathématique

A l'origine, la morphologie mathématique a été développée à l'école de Mines de Paris [Paul-20]. Cette méthode permet d'étudier les objets en fonction de leur taille, forme, voisinage et de leurs intensités par des outils de base tels que l'érosion, la dilatation, la fermeture et l'ouverture.

Dans [Géra-98], Géraud propose, à la suite de la segmentation des images IRM cérébrales, de coupler seuillages et morphologie mathématique pour segmenter successivement le liquide céphalo-rachidien et la matière grise sur des images pondérées en T1. Les résultats obtenus sont jugés très corrects par l'auteur. Toutefois, il relativise ses propos du fait de la dépendance successive des segmentations et de la nécessaire connaissance des niveaux radiométriques pour la détermination des seuils.

La morphologie mathématique est un outil puissant et très répandu pour le traitement d'image [Aich-14], mais elle est rarement utilisée seule pour segmenter les structures cérébrales, il n'existe pas de méthode directe de segmentation ou de détection de sclérose en plaques (SEP) par morphologie mathématique. Cette méthode, qui s'appuie sur des informations a priori concernant la forme des objets à segmenter, ne semble donc pas adaptée à la recherche des lésions SEP, celles-ci étant, par nature, caractérisées par une grande variabilité de forme.

1.4.2 Approches contours

Contrairement aux approches régions, qui cherchent à former des zones homogènes, les approches contours travaillent sur les discontinuités des images afin de déterminer les contours des régions. Dans la suite, nous nous intéressons plus particulièrement aux

méthodes dérivatives et aux méthodes fondées sur les modèles déformables.

1.4.2.1 Méthodes dérivatives

Les méthodes dérivatives permettent de détecter de manière simple les ruptures dans une image ou un volume. Les contours (ou surfaces en 3D) sont assimilés à des points de fort gradients ou des dérivées secondes nulles. On retrouvera alors des opérateurs tels que les filtres de Roberts [Robe-65], de Sobel [Sobe-78] ou de Prewitt [Prew-70] pour le gradient et le Laplacien. Parmi la diversité des opérateurs, celui de Marr-Hildreth [Mahr-80] qui fournit des contours fermés, est plébiscité par de nombreux auteurs.

Dans [Sand-97], le cerveau est segmenté en combinant un filtrage anisotropique, une détection de contours par l'opérateur de Marr-Hildreth et des opérations de morphologie mathématique. Une procédure identique est utilisée dans [Stat-01] comme préalable à la segmentation des différents tissus du cerveau sur les images pondérées en T1.

Les méthodes dérivatives, employées pour la segmentation des images IRM cérébrales, sont relativement peu nombreuses dans la littérature. Bien que rapides, a priori, et ne nécessitant pas d'apport d'information, elles ne permettent pas, en général, d'obtenir des contours fermés. Elles sont en effet très sensibles au bruit et à la dérive du champ radiofréquence.

1.4.2.2 Modèles déformables

Les algorithmes de segmentation fondés sur les modèles déformables dérivent des méthodes des contours dynamiques introduites par Terzopoulos [Kass-88] [Mcin-96]. Ils ont l'avantage, par rapport aux méthodes dérivatives, de fournir des contours ou surfaces fermés. Le principe de base est de faire évoluer un objet d'une position initiale vers une position d'équilibre par la minimisation itérative d'une fonctionnelle. Cette dernière permet de prendre en compte, par l'intermédiaire des forces externes et internes, des informations a priori sur la forme de l'objet à détecter. Les différentes méthodes de la littérature sont généralement dédiées, non pas à la segmentation de l'ensemble des principales structures du cerveau, mais à celle d'une structure particulière.

Dans [Mara-00], Marais et al proposent un schéma de segmentation de l'arachnoïde (surface du cortex) adapté aux images anisotropiques. La méthode se fonde sur un modèle de frontière (Active Shape Model) contraint par des informations a priori

sur la frontière recherchée. Dans la même problématique, MacDonald et al [Macd-00] traitent de segmentation de la surface corticale. Des contraintes géométriques telles que la non intersection des surfaces du modèle déformable et des contraintes anatomiques sur l'épaisseur du cortex sont intégrées dans le problème de minimisation. La surface du cortex et une bonne localisation des sulcus sont ainsi obtenues, même en cas de bruit important. La méthode, testée sur plus de 150 sujets sains, a permis la création d'une carte 3D de la moyenne et l'écart-type de la surface corticale.

Les méthodes de segmentation par modèles déformables s'avèrent efficaces pour la segmentation de structures anatomiques particulières [Semc-18]. Elles permettent en effet de s'adapter à la forme complexe des structures grâce à l'enrichissement des contraintes de déformation. Cependant, ces méthodes restent relativement sensibles à leur initialisation. Face à ce problème, les auteurs tendent à inclure des procédures d'initialisation automatique de façon à réduire l'influence des opérateurs et augmenter la reproductibilité des résultats.

1.4.3 Segmentation par classification

De manière générale, les problèmes de classification s'attachent à déterminer des procédures permettant d'associer une classe à un objet (individu). Ces problèmes se déclinent essentiellement en deux variantes selon Bezdek [Bezd-93] : la classification dite " supervisée " et la classification dite " non supervisée ".

La classification des tissus cérébraux (principalement le liquide cérébro-spinal, la matière blanche et la matière grise) est un problème amplement abordé dans la littérature [Bezd-93], dans cette partie nous proposons d'explicitier quelques méthodes supervisées, puis nous étudions quelques algorithmes non supervisés en insistant tout particulièrement sur les algorithmes de classification flous.

1.4.3.1 Méthodes supervisées

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

Dans le cas qui nous intéresse, les données segmentées de l'ensemble d'apprentissage proviennent d'un étiquetage manuel des images ou des régions d'intérêt en C classes de tissus $C_1 \dots C_c$ par un ou plusieurs experts. Chaque classe C_i se voit donc affecter un ensemble d'apprentissage E_i , et les données de l'ensemble de test sont segmentées en fonction de E_i . Puisque la structure anatomique d'un cerveau est différente d'un patient à l'autre, l'étiquetage doit être renouvelé pour chaque patient ou groupe de patients analysés, ce qui représente une tâche longue et éreintante pour les spécialistes.

Parmi les méthodes de segmentation supervisées appliquées aux images IRM, on peut citer : la segmentation bayésienne [Barr-99], la segmentation markovienne [Ahma-16], l'algorithme des k plus proches voisins (KPPV) [Khal-11] et les réseaux de neurones [Pere-16]. Les approches supervisées sont trop dépendantes de l'opérateur et nécessitent de créer une base d'apprentissage pour chaque image, ce qui représente une tâche laborieuse pour les experts, puisque la structure anatomique du cerveau est différente d'un patient à l'autre. Plus généralement, des auteurs notent que des petites différences d'étiquetage de l'expert dans la phase d'apprentissage peuvent causer de grandes variations dans les résultats, nécessitant une intervention manuelle constante de l'opérateur [Barr-99].

1.4.3.2 Méthodes non supervisées

L'intérêt des méthodes "*non supervisées*" est qu'elles ne nécessitent aucune **base d'apprentissage** et par là même aucune tâche préalable d'étiquetage manuel. Elles ont pour but de découper l'espace d'individus (pixel) en zones homogènes selon un critère de ressemblance (critère de proximité de leurs vecteurs d'attributs dans l'espace de représentation entre les individus).

Les méthodes non supervisées peuvent être une simple automatisation des algorithmes proposés dans la section précédente, l'ensemble d'apprentissage peut être remplacé par l'analyse d'une image apportant des informations complémentaires. Les auteurs utilisent l'analyse d'une image IRM en tenseurs de diffusion pour extraire des paramètres permettant d'identifier les tissus cérébraux dans l'IRM classique.

Ici encore, nous ne prétendons pas être exhaustifs. Nous nous attachons plutôt à décrire les algorithmes qui nous ont paru utiles pour notre étude. En particulier, nous développons les méthodes de génération de fonction d'appartenance des voxels aux classes de tissus. La présentation détaillée d'une de ces classes des méthodes, les algorithmes de clustering,

permettra par la suite d'introduire la solution que nous avons développée.

(a) **Algorithme Fuzzy C-Means (FCM)**

L'algorithme C-Moyenne Floue appelé Fuzzy C-Means (FCM) [Bezde-81] effectue une optimisation itérative en évaluant de façon approximative les minimums d'une fonction d'erreur. Il existe toute une famille de fonction d'erreur associée à cet algorithme qui se distingue par des valeurs différentes prises par un paramètre réglable, m , appelé indice de flou "fuzzy index" et qui détermine le degré de flou de la partition obtenue. Les FCM sont un cas particulier des algorithmes basés sur la minimisation d'un critère ou d'une fonction objectif.

Dans ce cas, les x_j ne sont plus affectés à une classe unique, 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.

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

$$(\forall i \in \{1..C\}) (\forall j \in \{1..N\}) u_{ij} \in [0, 1], 0 < \sum_{j=1}^N u_{ij} < N \quad (1.1)$$

$$\forall j \in \{1..N\} \sum_{i=1}^C u_{ij} = 1 \quad (1.2)$$

Bezdek a montré [Bezde-81] 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 :

$$J(B, U, X) = \sum_{i=1}^C \sum_{j=1}^N (u_{ij})^m d^2(x_j, b_i) \quad (1.3)$$

sous les contraintes (1.1) et (1.2) 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 .

- Le degré d'appartenance u_{ij} est calculé comme suit :

$$u_{ij} = \left[\sum_{k=1}^C \left(\frac{d^2(x_j, b_i)}{d^2(x_j, b_k)} \right)^{\frac{2}{m-1}} \right]^{-1} \quad (1.4)$$

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

- Les centres des classes sont calculés par la formule suivante :

$$b_i = \frac{\sum_{k=1}^N u_{ik}^m \cdot x_k}{\sum_{k=1}^N u_{ik}^m} \quad (1.5)$$

L'algorithme C-Moyenne Floue (algorithme 1.1) consiste alors en l'application itérée de (1.4) et (1.5) jusqu'à la stabilité des solutions [Zaki-17]. Le critère d'arrêt des itérations, définissant cette stabilité, peut par exemple résider à l'étude de la norme de la matrice U ou en la stabilité des centres des classes sur deux itérations successives.

Algorithme 1.1 : FCM

1. Fixer le nombre des classes C , le critère d'arrêt ϵ et le degré flou $m > 1$
 2. Initialiser aléatoirement le vecteur des centroïdes B
 3. $k \leftarrow 1$
 4. **répéter**
 5. Mettre à jour la matrice U par (Eq.1.4)
 6. Mettre à jour le vecteur des centroïdes B par (Eq.1.5)
 7. Calculer la fonction objectif J par (Eq.1.3)
 8. $k \leftarrow k + 1$
 9. **jusqu'à** $\left\| J_i^{(k)} - J_i^{(k+1)} \right\| \leq \epsilon$
 10. **Retourner** : les centres des classes c_i et les degrés d'appartenance u_{ij}
-

Simple et efficace à mettre en œuvre, la méthode FCM est amplement utilisée dans les problèmes de segmentation d'images, quelque soit la modalité et le type d'acquisition (mono ou multi-spectrale). Néanmoins, cet algorithme présente les inconvénients suivants [Beni-14] :

- L'absence de l'information spatiale dans le critère de segmentation.
- La sensibilité aux solutions initiales. En effet, l'algorithme FCM ne fournit aucune garantie de convergence vers un optimum global.

Afin de pallier ces inconvénients, plusieurs travaux ont été proposés dans la littérature ; dans les paragraphes suivants, nous citons les principaux parmi eux.

(b) **Algorithme Possibilistic C-Means (PCM)**

Krishnapuram et Keller ont proposé une approche Possibiliste C-Moyennes appelée Possibilistic C-Means, ou PCM [Kris-93] [Nikh-97]. Leur approche est supposée mener à une meilleure performance en présence de bruit. Mais leur travail est motivé essentiellement par l'envie de palier au caractère relatif des degrés d'appartenance générés par les FCM. En effet, ces derniers sont interprétés en tant que degrés de vérité relatifs décrivant l'appartenance d'un vecteur quelconque à chacune des classes possibles. Un élément à classer est donc, en quelque sorte, partagé entre ces différentes classes. A cette idée de partage Krishnapuram et Keller préfèrent remplacer la notion de typicalité. En effet, le résultat d'un regroupement devrait décrire la parenté absolue entre un objet et chacune des c classes possibles, indépendamment du lien entre cet objet et les $c - 1$ classes restantes.

Rappelons que l'algorithme des FCM minimise une somme pondérée des carrés des distances entre les vecteurs à regrouper et les centres des classes :

$$J(B, U, X) = \sum_{i=1}^C \sum_{j=1}^N (u_{ij})^m d^2(x_j, b_i) \quad (1.6)$$

Le degré d'appartenance d'un élément quelconque à une classe donnée doit naturellement être d'autant plus élevé que le vecteur en question est un élément typique de cette classe. La levée de cette condition conduirait à de fonction d'appartenance triviales identiquement nulles dans le cas des FCM. L'élimination de l'interférence entre les différents prototypes dans l'approche possibiliste, qui est beaucoup moins contraignante, et qui exige seulement qu'un, au moins, des différents degrés d'appartenance d'un vecteur quelconque ne soit pas nul, nécessite donc la définition d'un nouveau critère d'optimisation. Une nouvelle fonction erreur, à minimiser, a été proposée par Krishnapuram et Keller [Kris-93] :

$$J(B, U, X) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d_{ij}^2 + \sum_{i=1}^C \eta_i \sum_{j=1}^N (1 - u_{ij})^m \quad (1.7)$$

Où les paramètres η_i sont des nombres positifs homogènes à des distances carrées. Plus précisément, η_i est le carré de la distance séparant le centre de la classe i de l'ensemble des points dont le degré d'appartenance à cette même classe est égal à $1/2$. Il est calculé

comme suit :

$$(\forall i \in \{1..C\}) \eta_i = \frac{\sum_{j=1}^N u_{ij}^m \cdot d_{ij}^2}{\sum_{j=1}^N u_{ij}^m} \quad (1.8)$$

La convergence de l'algorithme est encore assurée à la suite d'un certain nombre d'itérations dans lesquelles les degrés d'appartenance sont mises à jour à l'aide de la formule suivante :

$$(\forall i \in \{1..C\}) () u_i(x) = \frac{1}{1 + \left(\frac{d_{ij}^2}{\eta_i}\right)^{\frac{1}{m-1}}} \quad (1.9)$$

Les centres des groupes sont toujours calculés de la même façon que dans le cas des FCM :

$$(\forall i \in \{1..C\}) v_i = \frac{\sum_{k=1}^N u_{ik}^m \cdot x_k}{\sum_{k=1}^N u_{ik}^m} \quad (1.10)$$

Comme on peut le constater sur l'équation (1.9), à chaque itération la valeur de u_{ij} ne dépend donc plus que de la distance d_{ij} , séparant le vecteur x_j du centre v_i , ce qui est conforme à la démarche de l'approche possibiliste. La position de x_j relativement aux centres des classes autres que C_i n'interfère donc plus avec le calcul de u_{ij} .

L'algorithme 1.2 résultant de l'application itérée de (1.9) et de (1.10) constitue l'algorithme de classification possibiliste, noté dans la suite PCM.

Algorithme 1.2 : PCM

1. Fixer le nombre des classes C , le critère d'arrêt ϵ et le degré flou $m > 1$
 2. Initialiser aléatoirement le vecteur des centroïdes B
 3. $k \leftarrow 1$
 4. **répéter**
 5. Mettre à jour la matrice U par (Eq.1.9)
 6. Mettre à jour le vecteur des centroïdes B par (Eq.1.10)
 7. Calculer le paramètre η_i par (Eq.1.8)
 8. Calculer la fonction objectif J par (Eq.1.7)
 9. $k \leftarrow k + 1$
 10. **jusqu'à** $\left\| J_i^{(k)} - J_i^{(k+1)} \right\| \leq \epsilon$
 11. **Retourner** : les centres des classes c_i et les degrés d'appartenance u_{ij}
-

L'usage de l'algorithme de classification possibiliste en imagerie médicale d'une manière générale et pour la caractérisation des tissus cérébraux en particulier, est peu fréquent. Masulli et Schenone ont proposé de combiner une approche par réseaux de neurones avec l'algorithme PCM pour segmenter les tissus cérébraux et des entités pathologiques (méningiomes) [Masu-99]. Barra et Boire ont également appliqué l'algorithme PCM en IRM sur des vecteurs forme x_j [Boir-00].

Contrairement à FCM, l'algorithme PCM est bien approprié à la segmentation des données aberrantes présentes dans une image IRM. Cependant, PCM souffre des inconvénients suivants [Nikh-05] [Zhen-08] : les résultats de la segmentation dépendent fortement de la sélection et/ou de l'initialisation des paramètres ; la précision de la segmentation se détériore souvent en raison du problème de coïncidence des centres.

(c) **Algorithme Fuzzy Possibilistic C-Means (FPCM)**

Pour remédier aux problèmes rencontrés par les FCM et les PCM, un nouveau algorithme Fuzzy Possibilistic C-Means (FPCM) a été proposé dans [Nikh -05], en combinant ces deux algorithmes. La valeur de la fonction d'appartenance de la partition floue est importante afin de pouvoir attribuer une étiquette pour le vecteur d'entrée à classer. Mais en même temps, il est très utile d'utiliser la typicité (possibilité) pour déplacer les centres

autour des vecteurs d'entrée, en évitant les effets indésirables dus à la présence des valeurs aberrantes.

La fonction objectif qui devrait être minimisée est :

$$J(B, U, T, X) = \sum_{i=1}^C \sum_{j=1}^N ((u_{ij})^m + (t_{ij})^\lambda) d(x_j, c_i)^2 \quad (1.11)$$

Où :

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

La minimisation de la fonction objectif $J(B, U, T, X)$ est guidée par un processus itératif dans lequel la mise à jour des degrés d'appartenance u_{ij} , des degrés de typicité t_{ij} et des centres des classes sont fait pour chaque itération par :

$$u_{ij} = \left[\sum_{k=1}^C \left(\frac{d^2(x_j, b_i)}{d^2(x_j, b_k)} \right)^{\frac{2}{(m-1)}} \right]^{-1} \quad (1.12)$$

$$t_{ij} = \left[\sum_{k=1}^C \left(\frac{d(x_j, c_i)}{d(x_j, c_k)} \right)^{\frac{2}{(\lambda-1)}} \right]^{-1} \quad (1.13)$$

avec $\lambda \in [3, 5]$.

$$c_i \leftarrow \frac{\sum_{k=1}^N (u_{ik}^m + t_{ik}^\lambda) x_k}{\sum_{k=1}^N (u_{ik}^m + t_{ik}^\lambda)} \quad (1.14)$$

avec les contraintes :

$$\forall j \in [1, N], \forall i \in [1, C] : 0 < \sum_{i=1}^N u_{ij} < N, u_{ij} \in [0, 1] \quad (1.15)$$

$$\forall j \in [1, N] : \sum_{i=1}^C u_{ij} = 1 \quad (1.16)$$

$$\forall i \in [1, C] : \sum_{j=1}^N t_{ij} = 1 \quad (1.17)$$

L'algorithme de FPCM est :

Algorithme 1.3 : FPCM

1. Fixer le nombre des classes C , le critère d'arrêt ϵ et le degré flou $m > 1$
 2. Initialiser aléatoirement le vecteur des centroïdes B
 3. $k \leftarrow 1$
 4. **répéter**
 5. Mettre à jour la matrice U par (Eq.1.12) ;
 6. Mettre à jour la matrice T par (Eq.1.13)
 7. Mettre à jour le vecteur des centroïdes B par (Eq.1.14)
 8. Calculer la fonction objectif J par (Eq.1.11)
 9. $k \leftarrow k + 1$
 10. **jusqu'à** $\left\| J_i^{(k)} - J_i^{(k+1)} \right\| \leq \epsilon$
 11. **Retourner** : les centres des classes c_i , les degrés d'appartenance u_{ij} et les degrés de typicité t_{ij}
-

Utilisées dans un cadre de segmentation, les approches floues permettent d'obtenir, en toute simplicité, une partition de l'espace des caractéristiques. L'avantage de ces méthodes par rapport aux segmentations dites dures est de graduer l'appartenance des points aux différentes classes. Ceci permet en particulier de prendre en compte les effets de volumes partiels. Cependant, ces méthodes de segmentation ne tiennent généralement pas compte des contraintes contextuelles les rendant de facto très sensibles au bruit. Utilisées dans le cadre de la gestion de connaissances, la théorie des sous-ensembles flous offre un cadre adapté au traitement et à la segmentation de nature symbolique et numérique [Chaa-13].

1.5 Conclusion

Dans ce chapitre nous avons présenté l'ensemble des méthodes de segmentation d'images IRM cérébrales. La revue qui est faite ici n'est pas exhaustive mais nous avons mis en évidence la diversité des approches abordées par les différents auteurs.

Cette diversité reflète la complexité du problème de segmentation des images IRM cérébrales, ces difficultés sont liées, d'une part, aux objets traités et, d'autre part, à la

particularité des images IRM. Pour cela nous allons présenter dans le chapitre suivant des métaheuristiques pour la segmentation d'images IRM pour tirer un système de segmentation complet.

Métaheuristiques pour la segmentation d'images IRM

2.1 Introduction

La segmentation des images et les métaheuristiques font partie des domaines les plus actifs de la recherche. Ces dernières années, plusieurs travaux ont créé la passerelle entre ces deux domaines de la recherche. Effectivement la problématique de segmentation d'images est théorisée comme un problème d'optimisation où l'utilisation des métaheuristiques comme un biais de façon à trouver des solutions acceptables dans un temps raisonnable.

Dans ce chapitre, nous nous intéressons à la segmentation d'images au moyen des métaheuristiques d'optimisation. Les métaheuristiques sont en général non-déterministes, elles peuvent ne pas trouver la solution optimale et encore moins pour prouver l'optimalité de la solution trouvée, tout comme la segmentation d'images qui ne peut mener à un résultat précis. Ainsi, nous débutons par une présentation globale du problème d'optimisation en général. Ensuite, nous passons aux différentes méthodes des métaheuristiques.

2.2 Problème d'optimisation

L'optimisation est issue des mathématiques et connaît un intérêt croissant ces derniers siècles qui est principalement résultant de la multitude d'applications possibles depuis le 20^{ème} siècle avec l'industrialisation des pays développés, puis aux nouvelles sciences du

traitement de signal, de planification, d'automatisation, d'aide à la décision, etc. Et plus récemment de l'intelligence artificielle.

Un problème d'optimisation, au sens général, consiste à minimiser ou maximiser une fonction objectif f . Le but est de trouver la (ou les) solution(s) optimale(s) x^* parmi un ensemble de solutions, noté S , appelé espace de recherche ou espace de solution, et tel que $S \in \mathfrak{R}$ l'ensemble des réels. Mathématiquement un problème de minimisation est noté ainsi [Ghou-18] :

$$f(x^*) \leq f(x), \forall x \in S, \text{ soit } \min_{x \in S} f(x) \quad (2.1)$$

De même, pour un problème de maximisation :

$$f(x^*) \geq f(x), \forall x \in S, \text{ soit } \max_{x \in S} f(x) \quad (2.2)$$

L'enjeu consiste alors à trouver l'optimum global, qui est la meilleure solution possible x^* de la fonction de coût f . La figure 2.1 montre un minima et un maxima locaux et globaux d'une fonction.

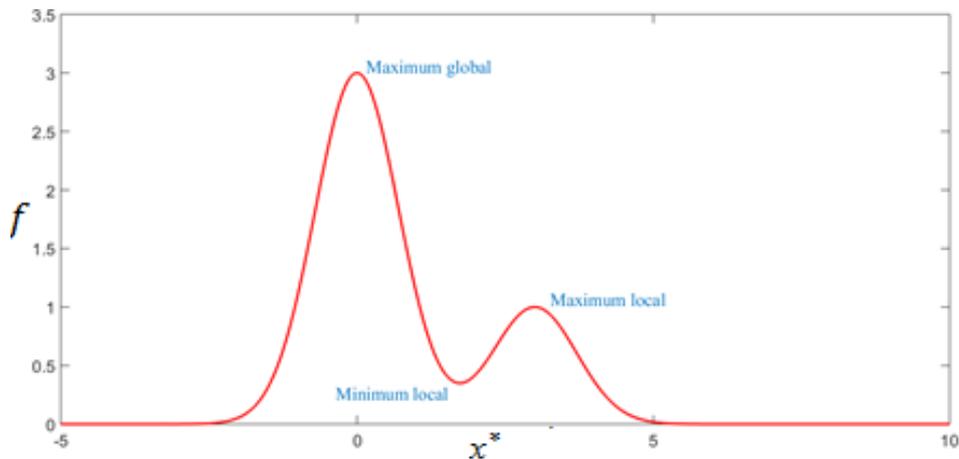


FIGURE 2.1 – Différence entre un minima et un maxima locaux et globaux d'une fonction [Betk-19].

Les problèmes d'optimisation sont actuellement des sujets de recherche importants. En effet, ils interviennent dans divers domaines d'activité très divers, comme le traitement d'images, la recherche opérationnelle, les réseaux informatiques, etc.

2.3 Les métaheuristiques

Glover [Glov-86] est le premier à introduire le terme métaheuristique, composé de deux mots grecs : heuristique qui dérive du verbe heuriskein signifiant "trouver" et le suffixe meta qui veut dire, "au-delà, dans un niveau supérieur". Avant qu'il soit plébiscité, les métaheuristiques étaient souvent appelées heuristiques modernes [Reev-95].

Les métaheuristiques sont des méthodes de haut niveau qui peuvent être adaptées à la résolution de manière approchée de n'importe quel problème d'optimisation. Elles ont été utilisées avec succès dans des applications diverses grâce à leur simplicité et robustesse. Les métaheuristiques d'optimisation sont des algorithmes généraux d'optimisation, leur application en segmentation d'images a connu un engouement particulier ces derniers temps, grâce aux avancées technologiques des machines de calculs. De plus, ils ont permis d'étudier la segmentation sous un angle différent, avec des résultats plus ou moins réussis [Khom-19].

Dans ce qui suit, nous présentons brièvement les principales métaheuristiques d'optimisation. Nous les distinguons en deux classes : métaheuristiques à solution unique et métaheuristiques à population de solutions.

2.3.1 Les métaheuristiques à solution unique

Les métaheuristiques à solution unique (les S-métaheuristiques), appelées aussi les métaheuristiques de trajectoire. Désignation due à la trajectoire formée au cours du processus de recherche par l'évolution de la solution de démarrage. En effet, ces méthodes débutent avec une solution unique et la remplace à chaque itération par une autre solution selon un certain mécanisme, le processus de recherche s'arrête dès qu'un critère d'arrêt est atteint [Ibti-19]. Dans cette section, nous présentons les méthodes les plus utilisées dans les problèmes de segmentation d'images, notamment le recuit simulé [Kirk-83], la recherche tabou [Glov-86] et la méthode de descente [Papa-82] [Beni-14].

2.3.1.1 La méthode du recuit simulé

La méthode du recuit simulé [Kirk-83] est l'une des plus datantes métaheuristique et la précurseur qui a décrit une stratégie permettant de s'échapper des optima locaux. Les origines de cette métaheuristique reviennent à l'algorithme Metropolis proposé en

1953 [**Metr-53**]. Le processus du recuit en métallurgie consiste à appliquer des cycles de chauffe et de refroidissement contrôlés à un matériau, afin de réorganiser sa structure cristallographique. La finalité est d'obtenir un matériau homogène de bonne qualité. À l'inverse de la technique de la trempe qui produit un état métastable, ce procédé permet d'éviter cet état caractéristique des minima locaux de l'énergie.

La transposition de la technique du recuit physique à la métaheuristique d'optimisation du recuit simulé est basée sur les analogies suivantes : la fonction objectif à optimiser est assimilée à l'énergie du matériau et la température est représentée par un paramètre de contrôle définissant le schéma de refroidissement [**Beni-14**]. Cette méthode est schématisée par l'algorithme 2.1

Algorithme 2.1 : Recuit simulé

1. Fixer une solution aléatoire S
2. Calculer l'énergie $f(S)$ associée à cette solution S
3. Initialiser la température T
4. Tant que la condition d'arrêt n'est pas satisfaite faire
 - 4.1. Tant que l'équilibre thermodynamique n'est pas atteint faire
 - 4.1.1. Tirer une nouvelle solution S'
 - 4.1.2. Appliquer la règle de Metropolis
 - 4.1.3. Si $f(S') < f(S)$ alors

$$S \leftarrow S'$$

$$Spot \leftarrow S$$
 - 4.1.4. Fin Si
 - 4.2. Fin tant que
 - 4.3. Décroître la température T
5. Fin tant que
6. Afficher la solution optimale

Les avantages de l'algorithme du recuit simulé sont : facilement implémentable et ils tendent théoriquement vers l'optimum global mais ils nécessitent un temps qui tire vers l'infini ce qui rend cet algorithme non utilisable en pratique [**Hach-18**].

- **Application à la segmentation d'images**

Manousakas et al [Mano-98] ont utilisé le recuit simulé dans la méthode de division/fusion, afin de réduire le nombre des régions pour la segmentation d'un volume IRM 3D. Ainsi que dans [Sham-09], Sharma et al proposent un algorithme de recuit simulé basé sur l'algorithme Fuzzy C-Means pour la segmentation des images médicales. Les résultats expérimentaux sur plus de 180 IRM et TDM témoignent de la performance de l'approche proposée.

2.3.1.2 La méthode de recherche tabou

L'algorithme de recherche tabou (en anglais "Tabu Search" (TS)) a été introduit par Fred Glover en 1986 [Glov-86]. Axé sur l'exploration du voisinage d'une position donnée en réalisant des déplacements qui n'améliorent pas forcément la solution. Pour éviter le retour en arrière, elle utilise le principe de mémoire pour sauvegarder les solutions interdites, appelée "liste tabou". Cette liste est mise à jour itérativement pour passer l'algorithme de l'exploration à l'exploitation [Betk-19]. L'algorithme de recherche tabou est résumé par l'algorithme 2.2.

Algorithme 2.2 : Recherche tabou

1. Déterminer une configuration aléatoire s
2. Initialiser une liste tabou vide
3. Tant que le critère d'arrêt n'est pas satisfait faire
 - 3.1. Perturbation de s suivant N mouvements non tabous
 - 3.2. Évaluation des N voisins
 - 3.3. Sélection du meilleur voisin t
 - 3.4. Actualisation de la meilleure position connue s^*
 - 3.5. Insertion du mouvement ($t \rightarrow s$) dans la liste tabou
 - 3.6. $s = t$
4. Fin Tant que

Dans sa forme de base, l'algorithme de recherche tabou présente l'avantage de détenir

moins de paramètres que l'algorithme du recuit simulé. Cependant, l'algorithme n'étant pas toujours performant, il est souvent adapté de lui ajouter des processus d'intensification et/ou de diversification, qui introduisent de nouveaux paramètres de contrôle [Glov-97].

- **Application à la segmentation d'images**

Jiang et Yang [Jian-02] ont utilisé la méthode évolutive mémétique avec la recherche tabou pour la segmentation d'images cellulaires. La méthode a été appliquée à la segmentation de plusieurs types d'images cellulaires. Les résultats expérimentaux montrent que le nouvel algorithme est pratique et efficace pour l'optimisation globale, il peut produire de bonnes solutions quasi optimales et offre une meilleure convergence et véracité que les autres approches d'optimisation globale.

2.3.1.3 La méthode de descente

La méthode de descente (appelée aussi "Hill Climbing") est une ancienne méthode très répandue et ceci est dû à sa simplicité et sa rapidité. Cette méthode consiste, à partir d'une solution initiale, à choisir à chaque itération un point dans le voisinage de la solution courante qui améliore strictement la fonction objectif. Il existe plusieurs moyens de choisir ce voisin : soit par le choix aléatoire d'un voisin parmi ceux qui améliorent la solution courante, autrement en choisissant le meilleur voisin qui améliore la solution courante. A chaque pas de la recherche, cette méthode évolue vers une solution voisine de meilleure qualité, elle s'arrête quand tous les voisins candidats sont moins bons que la solution courante, c'est-à-dire lorsqu'un optimum local est atteint. Plus aucune solution voisine n'améliore la solution courante [Papa-82]. La méthode de descente est présentée par l'algorithme 2.3 [Beni-14].

Algorithme 2.3 : Algorithme de descente

Nécessite : la fonction objectif f

1. Générer une solution aléatoire S
 2. Calculer la fitness $f(S)$ associée à la solution initiale S
 3. Initialiser la solution optimale : $S_{opt} \leftarrow S$
 4. Tant que la condition d'arrêt n'est pas vérifiée faire
 - 4.1. Générer la liste des solutions dans le voisinage de la solution courante
 - 4.2. Trouver la meilleure solution S' parmi les solutions voisines
 - 4.3. Si $f(S') < f(S)$ Alors
 - $S \leftarrow S'$
 - $S_{opt} \leftarrow S$
 - 4.4. Fin Si
 5. Fin Tant que
 6. Afficher la solution optimale S_{opt}
-

Le point faible de la méthode de descente est qu'elle reste piégée dans le premier optimum local rencontré. Une amélioration de cet algorithme consiste à redémarrer plusieurs fois, lorsqu'un optimum local est trouvé, à partir d'une nouvelle solution générée aléatoirement. De plus, la méthode de descente peut être utilisée comme première approche dans un problème d'optimisation pour avoir une idée sur les optima locaux du problème.

• **Application à la segmentation d'images**

Dans [Law-08], les auteurs ont proposé une méthode basée sur deux opérations : le saut et l'optimisation locale. À son tour, la phase de saut consiste en une division stochastique et une fusion déterministe, dans lesquelles la division et la fusion d'une grande zone de l'image peuvent se produire à chaque étape de cet algorithme de segmentation basé sur la région, réduisant le nombre de sauts nécessaires à la recherche pour un minimum global. Pour diviser le segment sélectionné en deux sous-segments, une méthode de seuillage [Ridl-78] est utilisée. L'étape de fractionnement et de fusion sont la contribution capitale de cet algorithme. Après la fusion, l'opérateur d'optimisation local applique la méthode

de descente. Les résultats suggèrent que le couplage des mises à jour globales et locales est une approche prometteuse pour résoudre les problèmes variationnels non convexes dans la segmentation d'images.

2.3.2 Les métaheuristiques à population de solutions

À l'inverse des méthodes à solution unique, les métaheuristiques à base d'une population de solutions (les P-métaheuristiques) manipulent non pas une seule solution, mais un ensemble des solutions à chaque itération [Ghou-18]. Ce sont des méthodes qui font évoluer simultanément un ensemble d'individus (solutions) dans l'espace de recherche d'une itération à une autre d'une manière itérative. L'intérêt est d'utiliser la population comme un facteur de diversité. On distingue dans cette catégorie, les algorithmes évolutionnaires, qui sont une famille d'algorithmes issus de la théorie de l'évolution par la sélection naturelle, énoncée par Charles Darwin [Char-59] et les algorithmes d'intelligence en essaim qui, du même type que les algorithmes évolutionnaires, proviennent d'analogies avec des phénomènes biologiques naturels.

2.3.2.1 Les algorithmes évolutionnaires

En 1859, C. Darwin [Char-59] a présenté une théorie basée sur le principe de la sélection naturelle pour expliquer l'évolution des êtres vivants. La sélection naturelle est définie par son auteur comme suit : «J'ai donné à ce principe, en vertu duquel une variation si insignifiante qu'elle soit se conserve et se perpétue, si elle est utile, le nom de sélection naturelle». Cette théorie est élaborée depuis trois principes : le principe de variation, qui est défini comme la différence entre les individus d'une population. Le second principe est celui d'adaptation, qui se solde par des variations des caractères des individus. Ces variations (mutations) donnent un avantage sélectif aux individus les plus adaptés à leur environnement. Le dernier principe est celui d'hérédité, qui nécessite que les caractères soient transmissibles à la descendance.

Les Algorithmes Evolutionnaires (appelés aussi les Algorithmes Evolutionnistes) (Evolutionary Algorithms en anglais), sont une famille d'algorithmes s'inspirant de la théorie de l'évolution pour résoudre plusieurs problèmes connus dans le domaine d'informatique. Ils font ainsi évoluer un ensemble de solutions à un problème donné, dans le but de trouver de meilleurs résultats. Ce sont des algorithmes stochastiques, car ils utilisent itérativement

des processus aléatoires. La grande majorité de ces méthodes sont utilisées pour résoudre des problèmes d'optimisation. La procédure générale de cet algorithme est présentée dans l'algorithme 2.4.

Algorithme 2.4 : Algorithme évolutionnaire

1. Initialisation de la population de μ individus
2. Evaluation des μ individus
3. Tant que le critère d'arrêt n'est pas satisfait faire
 - 3.1. Sélection de ρ individus en vue de la phase de reproduction
 - 3.2. Croisement des ρ individus sélectionnés
 - 3.3. Mutation des λ enfants obtenus
 - 3.4. Evaluation des λ enfants obtenus
 - 3.5. Sélection pour le remplacement
4. Fin Tant que

D'après les résultats récents d'application des métaheuristiques en différents domaines, il a été démontré que l'usage des algorithmes évolutionnaires fournira de nombreux avantages, ils obtiennent de meilleurs résultats que les autres métaheuristiques, dans le cas des problèmes très complexes. Cette supériorité vient du fait que des solutions distinctes de la population sont sélectionnées au hasard et ensuite combinées pour créer de nouvelles solutions. La combinaison pondérée de bonnes solutions partielles peut produire de très bons résultats globaux. Le problème de ces méthodes est que l'utilisation de plusieurs processus de mise à jour augmente le nombre d'évaluations de la fonction de fitness [Betk-19].

• **Application à la segmentation d'images**

Dans les applications de segmentation d'images, les algorithmes évolutionnaires sont principalement utilisés pour repérer les régions présentant un intérêt particulier pour une image. Bandyopadhyay et ses co-auteurs, par exemple, ont appliqué des algorithmes de segmentation évolutionnaires [Band-02] et les algorithmes de segmentation flou [Maul-00] [Pakh-05] pour distinguer les régions du paysage comme les rivières, les habitations et les zones de végétation dans les images satellites. Das et coll ont appliqué un algorithme

d'évolution différentielle à la segmentation automatique des images [Das-08] [Hrus-09].

2.3.2.2 Les algorithmes des colonies de fourmis

Les algorithmes des colonies de fourmis sont une famille des métaheuristiques d'optimisation inspirées du comportement collectif des fourmis réelles dans leur procédé de dépôt et de suivi de pistes. Ces algorithmes ont été initiés par Dorigo et al [Dori-92] [Dori-96] en s'inspirant des travaux de Deneubourg et al [Dene-83] qui ont modélisé le comportement aléatoire des fourmis.

La principale illustration de ce phénomène est donnée par la figure 2.2 : un obstacle est placé sur le trajet des fourmis qui, après une phase d'exploration, finiront par emprunter le chemin le plus court entre le nid et la source de nourriture [Goss-89]. Les fourmis qui sont retournées le plus rapidement au nid en passant par la source de nourriture sont celles qui ont emprunté le chemin le plus court. Il en résulte que la quantité de phéromones déposées par unité de temps sur ce trajet est plus importante que sur les autres. Par ailleurs, une fourmi est d'autant plus attirée à un certain endroit que le taux de phéromones y est important. De ce fait, le chemin le plus court a une probabilité plus importante d'être emprunté par les fourmis que les autres chemins et sera donc, à terme, utilisé par toutes les fourmis.

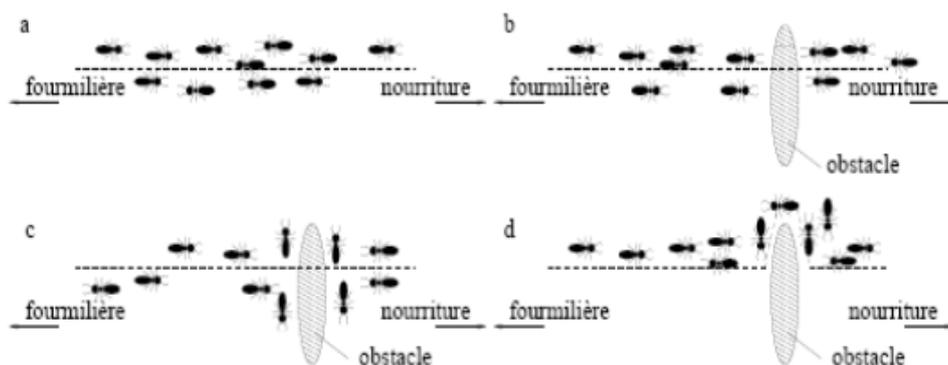


FIGURE 2.2 – (a) Les fourmis suivent un chemin entre la fourmilière et la nourriture. (b) Un obstacle apparaît sur le chemin ; les fourmis choisissent entre prendre à droite et à gauche avec équiprobabilité. (c) La phéromone s'évapore sur le chemin le plus long. (d) Toutes les fourmis choisissent le chemin le plus court [Abde-11].

Le premier algorithme d'optimisation, basé sur les colonies de fourmis, intitulé "Ant

System" (AS) a été proposé pour résoudre le problème du voyageur de commerce [Dori-96]. Depuis, plusieurs améliorations et variantes ont vu le jour et ont été appliquées dans plusieurs domaines, avec plus ou moins de succès important. cet algorithme est illustré comme suit :

Algorithme 2.5 : Algorithme de colonie de fourmis

1. Création de la matrice de phéromone τ
2. Initialiser la population de solutions X
3. Déterminer la meilleure solution T^* de la population
4. Pour le nombre d'itération fixe
 - 4.1. "Détermination de la population pop avec la matrice des phéromones Z "
 - 4.1.1. Pour tous individus j de la population pop

Si $rand \succ q_0$ alors

$$pop(j)_t_k = \operatorname{argmax}_{ik} \tau_{ik} \in i[g_{\min}g_{\max}]$$

Si non $pop(j)_t_k = \operatorname{rand}_{INT}[g_{\min}g_{\max}]$
 - 4.2. Evaluer la population pop "évaluation toute les solutions candidates"
 - 4.3. Mise à jours les meilleures solutions T^*
 - 4.4. Comparer les meilleurs individus T de pop avec T^*

Si T à une fitness meilleure que T^* , alors remplaçant T^* par T

$$F_{\max} = F(T^*)$$
 - 4.5. Mise à jour le chemin des phéromones

$$\tau_{ik} = p\tau_{ik} + (1-p)F_{\max}$$
5. Fin pour
6. Production de la meilleure solution T^* et l'enregistrée

Bien que conçu initialement pour résoudre le problème du voyageur de commerce, l'algorithme des colonies de fourmis a été adapté à plusieurs problèmes d'optimisation. Il présente plusieurs avantages, tels que le parallélisme, la fiabilité et la décentralisation [Coor-08]. L'inconvénient majeur de l'algorithme ACO demeure le problème de paramétrage.

- **Application à la segmentation d'images**

Xiao et al ont proposé une nouvelle méthode de segmentation d'images basée sur les contours actifs utilisant l'algorithme de colonie de fourmis pour obtenir un contour précis dans une région [Xiao-05]. En outre, une nouvelle règle de mise à jour de phéromone est introduite pour optimiser le temps d'exécution. Dans [Liu-14], Liu et al ont développé l'algorithme de colonie de fourmis conventionnel pour la détection des contours dans une image. Les expériences montrent l'efficacité, la rapidité et la précision de cette approche.

2.3.2.3 Les algorithmes d'optimisation par essaim particulaire

L'optimisation par essaim particulaire (OEP) (Particle Swarm Optimization (PSO), en anglais) est une métaheuristique d'optimisation proposée pour la première fois par J. Kennedy et R. Eberhart en 1995 [Kenn-95] en s'inspirant des modélisations statistiques développées par [Reyn-87] [Hepp-90], qui permettent de simuler le déplacement de volées d'oiseaux et de banc de poissons.

L'essaim particulaire correspond à une population d'agents appelés «particules». Chaque particule, modélisée comme une solution potentielle au problème d'optimisation, parcourt l'espace de recherche, en quête de l'optimum global. Le déplacement d'une particule est influencé par trois composantes (cf. figure 2.3) : (1) *une composante physique* : la particule tend à suivre sa direction courante de déplacement ; (2) *une composante cognitive* : la particule tend à se diriger vers le meilleur site par lequel elle est déjà passée ; (3) *une composante sociale* : la particule tend à se fier à l'expérience de ses congénères et, ainsi, à se diriger vers le meilleur site déjà atteint par ses voisins.

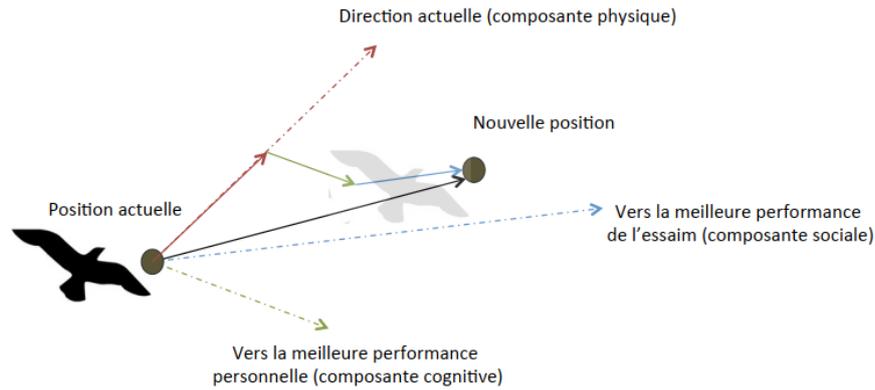


FIGURE 2.3 – PSO - Déplacement d'une particule [Beni-14].

L'algorithme commence avec une initialisation aléatoire de l'essaim de particule dans l'espace de recherche. Chaque particule est modélisée par sa position dans l'espace de recherche et par sa vitesse. A chaque instant, toutes les particules ajustent leurs positions et leurs vitesses, donc leurs trajectoires, par rapport :

1. à leurs meilleures positions,
2. à la particule ayant la meilleure position dans l'essaim,
3. à leur position actuelle.

Dans l'algorithme d'essaim particulaire, la recherche s'effectue par une population d'individus appelés particules. Chaque particule survolant l'espace de recherche en quête de l'optimum global est considérée comme une solution potentielle du problème. Afin de définir sa direction de vol, une particule se base sur deux types d'informations : une information tirée de sa propre expérience et une information tirée de l'expérience de l'essaim. Le mouvement des particules est régi par les équations suivantes :

$$V^{(k+1)} = w.V^{(k)} + c_1.rand_1.(Pbest^{(k)} - X^{(k)}) + c_2.rand_2.(Gbest^{(k)} - X^{(k)}) \quad (2.3)$$

$$X^{(k+1)} = X^{(k)} + V^{(k+1)} \quad (2.4)$$

Où :

X : est la position des particules,

V : est la vitesse des particules,

w : est le paramètre d'inertie,

P_{best} : est la meilleure position personnelle,

G_{best} : est la meilleure solution de l'essaim,

$rand1, rand2$: sont des variables aléatoires entre 0 et 1,

$c1, c2$: sont des constantes positives,

k : est la variable d'itération.

La procédure générale des algorithmes d'optimisation par essaim particulaire utilisée est présentée dans l'algorithme suivant. Plusieurs améliorations de l'OEP ont été proposées dans la littérature, pour plus de détails, se référer à [Cler-10] [Siar-14].

Algorithme 2.6 : Algorithme de l'optimisation par essaim particule

1. Initialiser aléatoirement la population
2. Générer pour chaque particule une position et une vitesse initiale
3. Evaluer pour chaque particule la fitness de la fonction objectif
4. Accepter la meilleure solution personnelle de chaque particule à sa position
5. Déterminer la meilleure solution globale
6. Tant que la condition d'arrêt n'est pas vérifiée Faire
7. Déplacer les particules selon les équations (2.3) et (2.4)
8. Evaluer la fonction objectif pour les nouvelles positions des particules
9. Mettre à jour les meilleures solutions personnelles des particules
et la meilleure solution globale
10. Fin tant que
- 11 **Retourner** : La meilleure solution globale

Méthode à fort succès auprès de la communauté d'optimisation. Ses bonnes performances dans différentes applications et la possibilité d'hybridation avec d'autres métaheuristiques ont contribué à cet emballement. Malgré son "jeune âge" en comparaison des autres métaheuristiques, un nombre important de travaux ont été publiés [Naki-07] [Semc-18].

• **Application à la segmentation d'images**

L'algorithme PSO a été largement utilisé pour résoudre des problèmes d'optimisation variés pour la segmentation d'images grâce à sa simplicité d'usage et sa performance [Semc-18]. Par exemple, dans [Yin-07], la métaheuristique PSO a été utilisée pour minimiser la distance de Kullback entre les distributions, représentant chacune une région, pour segmenter de manière supervisée des images. Zahara et al [Zaha-04] ont proposé une approche basée sur l'algorithme PSO hybridé avec un algorithme de recherche locale Simplex. L'algorithme d'optimisation est utilisé pour désigner les paramètres des gaussiennes permettant d'aller vers l'histogramme de l'image pour la segmentation d'images [Dréo-03].

2.4 Conclusion

Dans ce chapitre, nous avons présenté des métaheuristiques. Tout d'abord, nous avons donné la définition d'optimisation et de métaheuristique. Puis, nous avons distingué les deux types de métaheuristiques : les métaheuristiques à solution unique, les métaheuristiques à population de solutions et leur exploitation en segmentation d'images. Ces algorithmes ont rencontré un vif succès grâce à leur simplicité, leur adaptabilité et leur capacité à trouver des solutions presque optimales. Dans le prochain chapitre, nous allons présenter la structure d'un système d'inférence flou et ses phases pour la prise de décision.

Systemes et décision flous

3.1 Introduction

Aujourd'hui, la logique floue est d'une grande actualité. L'option courante est qu'il s'agit d'une nouvelle méthode de traitement des problèmes de segmentation d'images et de prise de décision. En effet les bases théoriques de la logique floue ont été établies en 1965 par le professeur Lotfi A Zadah de l'université de Californie aux USA [Zade-65]. La logique floue a pour objectif l'étude de la représentation des connaissances imprécises, des raisonnements approchés [Huer-08]. Les sous-ensembles flous sont une manière mathématique de représenter l'imprécision de la langue naturelle, ils peuvent être considérés comme une généralisation de la théorie des ensembles classiques. Ses détails sont mentionnés dans l'annexe B.

Dans ce chapitre, nous présentons la structure d'un système d'inférence floue, ainsi que celui du modèle Mamdani pour la décision. Nous présentons également un aperçu de l'utilisation de la logique floue en segmentation d'images.

3.2 Structure d'un système flou

Un système flou est ainsi formé de trois étapes comme indiqué sur la figure 3.1. La première, l'étape de fuzzification transforme les valeurs numériques en degrés d'appartenance aux différents ensembles flous de la partition. La seconde étape concerne le module d'inférence, qui est constitué de deux blocs, le moteur d'inférence et la base des règles. Enfin, l'étape de défuzzification qui permet d'inférer une valeur nette (précise), utilisable

en commande par exemple, à partir du résultat de l'agrégation des règles.

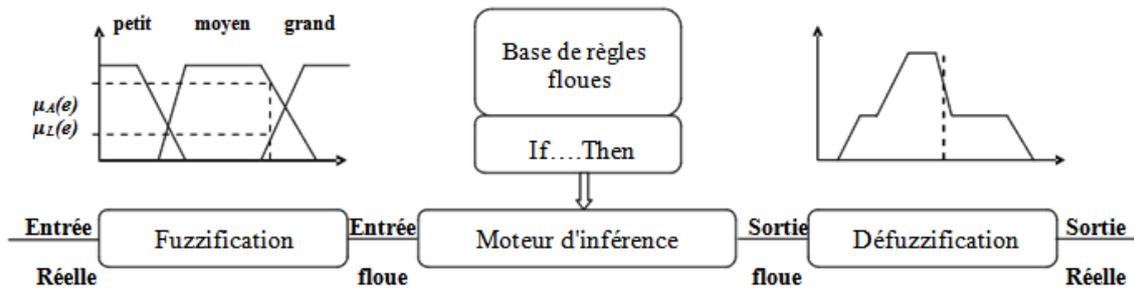


FIGURE 3.1 – Schéma d'un système flou.

3.2.1 Fuzzification

La fuzzification est le premier traitement qui entre en compte dans la structure d'un système flou. Elle consiste à donner un degré d'appartenance à une valeur réelle d'entrée en fonction des ensembles flous. Dans un système flou, il faut rendre flous (fuzzifier) les entrées et les sorties du système. Pour le système flou, la fuzzification des variables est une étape cruciale du processus de mise en œuvre. Les caractéristiques de cette étape sont habituellement déterminées par des experts ou des opérateurs qualifiés travaillant sur le processus et recourant le plus souvent à leurs connaissances. De plus, les performances du système flou seront influencées par la fuzzification [Flau-94].

Pour fuzzifier, il faut [Mera-20] :

1. Etablir les variables linguistiques.
2. Établir les quantificateurs flous (nombre de valeurs linguistiques).
3. Transformer ces valeurs numériques en valeurs linguistiques en utilisant des fonctions d'appartenance qui ont pour but de subdiviser l'espace d'entrée de l'univers de discours en sous-ensembles flous.

3.2.2 Base de règles floues (Base de connaissances)

La finalité de la logique floue est de formaliser et de déclencher la façon de raisonner d'un être humain. En cela, elle peut être classée dans le domaine de l'intelligence artificielle. L'outil le plus utilisé dans les applications de la logique floue est la base de règles

floues. Cette dernière est composée de règles qui sont généralement utilisées en parallèle, mais peuvent également être enchaînées dans certaines applications [Chev-98].

Une règle est du type : **SI** «situation» **ALORS** «conclusion». La situation, appelée prémisses, antécédent ou condition de la règle, est définie comme une combinaison de relations telles que "x est A" pour chaque composante du vecteur d'entrée. La partie conclusion est appelée conséquence ou conclusion. La forme générale d'une règle se formalise de la façon suivante :

Si (un ensemble de conditions est satisfait) alors (un ensemble de conséquences peut être exécuté).

Les bases de règles floues, tout comme les systèmes experts classiques, fonctionnent en s'appuyant sur une base de connaissances issue de l'expertise humaine. Il y a néanmoins de grandes différences dans les caractéristiques et le traitement de cette connaissance.

3.2.3 Inférence floue

Le mécanisme d'inférence est l'élément clé dans l'algorithme de la logique floue qui émule la prise de décision de l'expert dans l'interprétation et l'application de connaissances sur la meilleure façon de contrôler le système. Le module d'inférence est constitué de deux blocs, la base des règles et le moteur d'inférence.

La première étape consiste à créer des règles dont la syntaxe est très stricte bien que les termes utilisés paraissent naturels. La création de l'ensemble des règles de contrôle linguistique fait appel plus souvent aux connaissances d'experts ou d'opérateurs qualifiés travaillant sur le processus.

Afin d'utiliser cette base de règles, nous avons besoin de trois opérateurs, mathématiques, la conjonction (ET) qui s'applique aux variables à l'intérieur d'une règle tandis que l'opérateur ; l'implication (Si ...Alors) et l'agrégation (Sinon).

Il existe deux méthodes fondamentales qui permettent de calculer ces degrés d'appartenance. Les autres méthodes permettant d'y parvenir sont nombreuses, la différence entre elles se déterminent essentiellement par la façon d'effectuer les opérateurs flous (ET, OU et NON) [Bouk-15].

3.2.3.1 La méthode d'inférence Mamdani

Historiquement, la méthode de Mamdani, datant de 1975, est la première à avoir été proposée. Elle est beaucoup plus répandue dans la théorie du contrôle des procédés [Harr-19]. Dans cette méthode, les degrés d'appartenance de la variable de sortie, sont calculés à l'aide des opérateurs ET et OU réalisés par les deux fonctions Min et Max respectivement [Bouk-15].

Nous avons vu qu'on définit l'intersection (conjonction) et l'union (disjonction) à l'aide de deux relations floues, la t-norme et la t-conorme. Leurs définitions ne sont pas uniques [Alat-01]. Dans le modèle de Mamdani, la conjonction (des antécédents) est usuellement interprétée par l'opération min (Zadeh) et la disjonction (des règles) comme le max, appelée la méthode max-min. La t-norme et la t-conorme, selon le modèle de Mamdani sont définies comme suit :

$$t - norme : \mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x)) \quad (3.1)$$

$$t - conorme : \mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x)) \quad (3.2)$$

Où

\cap est l'opérateur d'intersection représentant la conjonction min (t-norme).

\cup est l'opérateur d'union représentant la disjonction max (t-conorme).

Ainsi, l'implication utilise l'opérateur min et l'agrégation l'opérateur max.

L'avantage majeur du modèle Mamdani est que les prémisses et les conclusions des règles sont de nature entièrement linguistique. Ceci les rend facilement compréhensibles, et donne une interprétation sémantique claire au modèle. En revanche, un grand nombre de règles est souvent nécessaire pour approcher le comportement global d'un système.

3.2.3.2 La méthode d'inférence Takagi-Sugeno

Dans cette section, nous discuterons du processus d'inférence floue de type Sugeno, ou Takagi-Sugeno-Kang (TSK). Introduite en 1985 par les chercheurs Takagi, Sugeno et Kang [Taka-85], elle est semblable à la méthode Mamdani à plusieurs points de vue [Zahr-05]. Les deux premières parties de l'inférence floue, qui traitent de la fuzzification des entrées et de l'application de l'opérateur flou, sont exactement les mêmes. La différence majeure entre les méthodes de Mamdani et Sugeno est que les fonctions d'appartenance des sorties

de type Sugeno sont soit linéaires ou soit constantes. Une règle typique dans un processus d'inférence floue de type Sugeno a la forme suivante :

Si $antcdent1 = x$ **ET** $antcdent2 = y$ **ALORS** $= ax + by + c$.

Le modèle Takagi-Sugeno peut être perçu comme une correspondance (mapping) entre l'espace de l'antécédent (entrée) et une région convexe (polytope) dans l'espace des paramètres d'un système quasi-linéaire. Cette propriété a certains avantages qui facilitent l'analyse des systèmes flous Takagi-Sugeno dans le cadre des systèmes polytopiques [Boyd-94].

3.2.4 Défuzzification

C'est l'étape finale de la logique floue. Avant que les sorties du moteur d'inférence soient appliquées sur le processus à contrôler, ces dernières qui sont représentées comme des degrés d'appartenance aux fonctions de la sortie, doivent être converties [Oliv-10]. Alors l'étape de la défuzzification demeure dans la conversion de valeurs floues en variables réelles qui peuvent être utilisées. Dépendamment de la forme de la sortie voulue, du type de contrôle, du type des fonctions d'appartenance de la sortie, il existe deux méthodes fondamentales de défuzzification [Sahr-16].

3.2.4.1 Méthode du centre de gravité (COG)

C'est une des méthodes la plus utilisée pour sa haute précision qu'elle offre. Elle calcule la totalité de l'espace actif sous les fonctions d'appartenance. Mais le fait de calculer plusieurs surfaces présente un inconvénient côté complexité et temps de calcul [Belo-16].

Le calcul de la solution précise, z_0 , d'une solution floue à l'aide de la méthode du centre de gravité est défini par :

$$Z = \frac{\sum_{i=1}^N \mu_i Z_i}{\sum_{i=1}^N \mu_i} \quad (3.3)$$

Où N est le nombre de niveaux de quantification, Z_i la valeur de sortie pour le niveau i et μ_i sa valeur d'appartenance.

3.2.4.2 Méthode de moyenne de maximum (MOM)

Dans cette méthode, le résultat de sortie correspond à la moyenne entre les maximums de chaque fonction d'appartenance. Elle est utilisée beaucoup plus dans les cas où la grandeur de sortie a des valeurs fixes et discontinues.

$$Z = \sum_{i=1}^I \frac{r_i}{I} \quad (3.4)$$

Où I est le nombre de valeurs quantifiées r pour lesquelles l'appartenance est maximale [Belo-16].

La théorie des sous-ensembles flous a été largement utilisée en traitement d'images médicales en raison de sa capacité de représentation des connaissances imprécises. En revanche, la logique floue ouvre des possibilités remarquables de codification des connaissances des experts. Cependant, les applications utilisant la logique floue ne sont pas fondamentalement plus performantes. Elles sont tout simplement plus faciles à réaliser et à utiliser. L'utilisation faite par la logique floue d'expressions du langage courant permet au système flou de demeurer compréhensible pour les personnes non expertes. C'est ainsi que des machines complexes peuvent devenir interactives grâce à l'utilisation de la logique floue.

- **Application à la segmentation d'images**

Dans les applications de segmentation d'images, Olivier et al [Oliv-15] ont étudié l'introduction de la logique floue dans les processus de segmentation d'images multi-spectrales de frottis sanguin. Cette approche s'appuie sur l'utilisation de l'analyse en composante principale (ACP), suivi de l'utilisation de la logique floue sur la première composante principale des images, comme méthode de segmentation des globules rouges. Baharuddin et al [Baha-16] ont développé un modèle de segmentation des mammographies suivant le système BIRADS. Cette segmentation est basée sur la logique, la génération des règles est effectuée par l'expert. Son avantage demeure dans sa capacité à réduire l'incertitude des données. Par ailleurs, l'implication d'un expert dans le traitement d'images médicales favorise la fiabilité des résultats. [Mezh-12] a proposé une méthode de segmentation basée sur les modèles, dans le but de segmenter une image médicale en régions homogènes.

3.3 Conclusion

Dans ce chapitre, nous avons présenté la structure d'un système flou qui se compose de trois parties essentielles : la fuzzification, l'inférence et la défuzzification. Après quoi, nous avons définie les deux classes de modèles flous. La première classe ou modèles de Mamdani sont des modèles dont la partie conclusion est purement linguistique. La seconde classe ou modèles de Takagi-Sugeno sont caractérisés par une conclusion à structure fonctionnelle. Tous ces outils amélioreront la solution des problèmes rencontrés lors du diagnostic médical. Dans la suite de ce manuscrit, nous allons présenter nos contributions en justifiant le choix des algorithmes de segmentation adoptés, ainsi que les outils et les paramètres de chaque algorithme.

Contributions

4.1 Introduction

La segmentation d'images est le processus de partitionnement d'une image en un ensemble de régions connexes, homogènes et bien séparées. Ces régions possèdent une certaine uniformité pour une ou plusieurs caractéristiques, telles que le niveau de gris, la texture, le mouvement, etc. Et sont différentes pour au moins une de ses caractéristiques des régions voisines [Frei-02]. Donc la grande difficulté est de segmenter les images IRM cérébrales afin d'obtenir une cartographie des lésions de la maladie SEP. Dans le choix de la méthode, il faudra un modèle particulièrement fiable à la qualité des images et à la présence des points aberrants (les lésions de la SEP), mais aussi un modèle qui alimente par des informations directement exploitables dans la détection des lésions de la SEP.

Dans ce chapitre, nous allons exposer trois méthodes, toutes reprises depuis nos publications.

- La première est la publication dans le journal Bio-inspired Computing – Theories and Applications en 2016. Réf : [Zoua-16].
- La seconde est la publication dans le journal of Medical Imaging and Health Informatics en 2019. Réf : [Zoua-19].
- Et la troisième et dernière est la publication dans le journal of International Journal of Swarm Intelligence Research en 2020. Réf : [Zoua-20].

Chacune de ces méthodes est analysée et étudiée de la manière suivante :

1. Segmentation des tissus cérébraux en trois classes (MB, MG, LCR).

2. Segmentation de la matière blanche pour l'extraction des données atypiques.
3. Prise de décision.

Si, lors de l'étude individualisée de chaque méthode, les points 1 et 2 divergent, le point 3, qui est la prise de décision, reste le même. Il est applicable dans toute son intégralité pour les trois démarches. Les différentes étapes de la segmentation d'images de nos approches sont schématisées dans la figure 4.1.

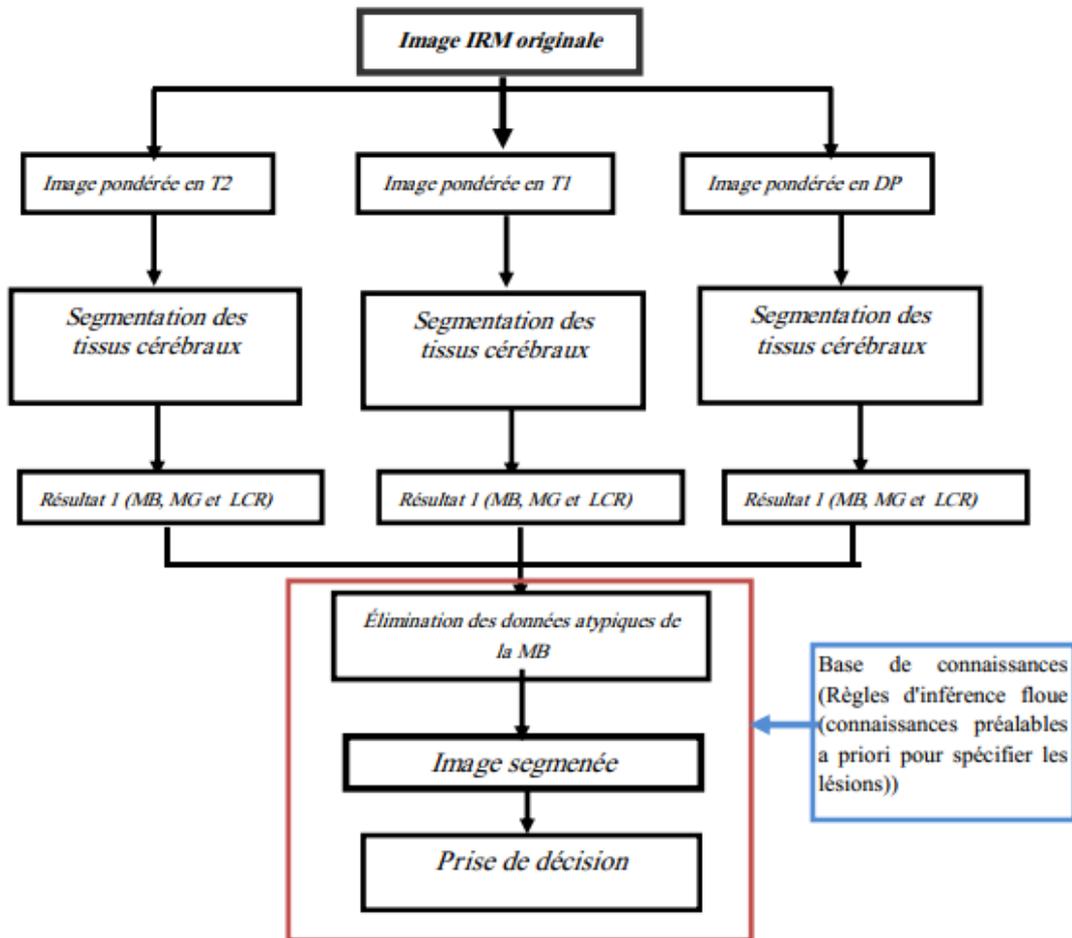


FIGURE 4.1 – Les étapes de la segmentation des lésions de la SEP de nos propositions.

4.2 Contribution 1 : FCM-PSOBC

Dans cette contribution nous proposons une nouvelle approche de la segmentation d'images IRM de la sclérose en plaques qui est une maladie inflammatoire auto-immune du système nerveux central. En vue d'automatiser un processus long et fastidieux pour

le clinicien, nous proposons de segmenter de façon automatique les lésions de la SEP. Cette approche est déclinée en trois étapes : segmentation du cerveau en régions grâce à l'algorithme FCM (Fuzzy C-Means) afin d'obtenir une caractérisation des différents tissus sains (matière blanche, matière grise et liquide céphalo-rachidien), élimination des données atypiques (outliers) de la matière blanche par l'algorithme d'optimisation PSOBC (Particle Swarm Optimization Based image Clustering) et en dernier, l'utilisation d'un modèle flou de type Mamdani pour extraire les lésions de la SEP parmi toutes les données aberrantes.

4.2.1 Segmentation des tissus cérébraux par l'algorithme FCM

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

4.2.1.1 Quel type de méthode ?

En reprenant la taxinomie de Bezdek et al [Bez93]. Nous devons au préalable préciser si l'algorithme doit être supervisé ou non. L'utilisation d'un algorithme supervisé nécessite, comme mentionné dans la section (cf 1.4.3.1), une base d'apprentissage pour chaque classe. Cela constitue un premier inconvénient de ce type de méthode [Barr99]. Pour notre approche, puisque nous aurons dans la suite à segmenter des images IRM, la création de cette base peut s'avérer fastidieuse pour les experts. De plus, les méthodes supervisées en segmentation d'images médicales peuvent être très dépendantes de la base d'apprentissage [Barr99]. Clarke et al [Clar93] ont par exemple comparé les méthodes de k plus proches voisins avec réseau de neurones sur la segmentation d'images IRM de cerveau, ont remarqué que les différences entre les segmentations sont faibles lorsque les tissus sont bien différenciés par leurs paramètres.

L'intérêt des méthodes non supervisées est qu'elles ne nécessitent aucune phase d'apprentissage ou d'étiquetage manuel préalable. La seule supervision de l'expert demeure en fin du processus pour identifier les classes calculées avec les classes biologiques.

Ce sont plutôt ces raisons qui nous ont poussées à adopter une méthode non supervisée. Parmi cette classe d'algorithmes, nous nous sommes intéressés aux algorithmes de

classification [Barr-00] [Fren-04].

4.2.1.2 Classification floue ou non floue ?

Gesu et Romeo [Gesu-94] ont comparé la segmentation d'images IRM obtenue à l'aide de quatre algorithmes non flous (analyse d'histogramme, k plus proches voisins, méthode de division/fusion et partitionnement simple), ont déduit que la classification non floue est inconvenable dans le cas où les nuages de points se chevauchent ou lorsque l'information disponible est vague et incertaine [Barr-00]. Les images du cerveau de la maladie SEP traitées dans cette thèse présentent ces deux caractéristiques, que ce soit dans les zones de transition entre tissus (effet de volume partiel, information imprécise et vague) ou en raison du bruit présent dans l'image (information incertaine). Donc, nous avons choisi une approche floue pour segmenter les tissus cérébraux.

Notre but dans cette partie est la segmentation de l'image en trois classes (MB, MG et LCR). Pour cela nous proposons d'utiliser l'algorithme de segmentation FCM (Fuzzy C-Means) car il a été largement appliqué en segmentation d'images IRM cérébrales, quels que soient la modalité et le type d'acquisition (mono ou multi-spectrale). Au regard de son adaptation et de son efficacité à traiter des données de nature imprécise et incertaine et de nombreux travaux ont notamment été effectués en imagerie par résonance magnétique [Barr-00] [Prem-08] [Bena-13] [Semc-18].

4.2.1.3 Algorithme Fuzzy C-Means (FCM)

Fuzzy C-Means (FCM) se basant sur la théorie de la logique floue introduite par L. Zadeh [Zade-65]. Bezdek a proposé pour la première fois l'algorithme Fuzzy C-Means [Bezd-81]. Directement, cet algorithme a trouvé un large succès dans diverses applications [Gath-83] [Gran-84] [Hunt-85]. La méthode des C-Moyennes Floues a pour objectif de déterminer les centres des différentes classes, ainsi que les degrés d'appartenance de chaque pixel aux différentes classes. Les centres des différentes classes sont déterminés à ce que la distance entre un centre de classe et les pixels appartenant à cette classe soit minimale.

Les degrés d'appartenance doivent contrôler les contraintes de logique floue. À savoir, un degré d'appartenance à une classe donnée est positif et ne peut dépasser 1 et la somme des degrés d'appartenance d'un pixel aux différentes classes vaut 1.

À cause de son efficacité et de sa simplicité de mise en œuvre, la méthode FCM est largement utilisée dans les problèmes de segmentation d'images.

Parmi les autres avantages de l'algorithme, sa complexité algorithmique est relativement réduite par rapport à d'autres algorithmes de segmentation non supervisée, cela le rend plus facilement exploitable pour traiter des problèmes de taille importante (avec beaucoup de données) [Mekh-08].

4.2.2 Segmentation de la matière blanche par PSOBC

L'essentiel attendu du processus de segmentation de la matière blanche est la détection des lésions de la maladie sclérose en plaques. Dans notre cas, nous allons utiliser un outil semblable, Particle Swarm Optimization Based image Clustering (PSOBC) en segmentation d'images, en introduisant les particularités nécessaires de notre problème et en essayant de les lui approprier. L'algorithme PSOBC est actuellement très utilisé dans différents domaines et de multiples applications. Dans notre proposition nous considérons le problème de segmentation comme un problème d'optimisation.

4.2.2.1 Algorithme Particle Swarm Optimization (PSO)

Particle Swarm Optimization (PSO) est une métaheuristique d'optimisation suggérée pour la première fois par J. Kennedy et R. Eberhart en 1995 [Kenn-95] en s'inspirant des modélisations statistiques développées par [Reyn-87] [Hepp-90], qui permettent de simuler le déplacement des volées d'oiseaux et des bancs de poissons.

Dans l'algorithme d'essaim particulaire, la recherche s'effectue par une population d'individus appelés particules. Chaque particule survolant l'espace de recherche en quête de l'optimum global est considérée comme solution potentielle du problème. Pour tracer sa direction de vol, une particule se base sur deux types d'informations : une information inspirée de sa propre expérience et une information calquée de l'expérience de l'essaim. Le mouvement des particules est régi par les équations suivantes :

$$V^{(k+1)} = w.V^{(k)} + c_1.rand_1.(Pbest^{(k)} - X^{(k)}) + c_2.rand_2.(Gbest^{(k)} - X^{(k)}) \quad (4.1)$$

$$X^{(k+1)} = X^{(k)} + V^{(k+1)} \quad (4.2)$$

Où :

X : est la position des particules ;

V : est la vitesse des particules ;

w : est le paramètre d'inertie ;

$Pbest$: est la meilleure position personnelle ;

$Gbest$: est la meilleure solution de l'essaim ;

$rand1, rand2$: sont des variables aléatoires entre 0 et 1 ;

c_1, c_2 : sont des constantes positives ;

k : est la variable d'itération.

4.2.2.2 PSO basé sur la segmentation d'images

Dans le contexte de la segmentation, une seule particule représente N_c centre de cluster de vecteurs. Chaque particule x_i est construite comme suit [Omra-04] :

$$X_i = (m_{i1}, \dots, m_{ij}, \dots, m_{iN_c}) \quad (4.3)$$

Où m_{i1} désigne le j -ème centre de cluster de particule i dans la classe C_{ij} , Par conséquent, un essaim présente un nombre de candidats de classification pour le vecteur de données en cours. La fonction de fitness des particules est facilement mesurée comme l'erreur de quantification,

$$J_e = \frac{\sum_{j=1}^{N_c} [\sum_{\forall Z_p \in C_{ij}} d(Z_p, m_j) / |C_{ij}|]}{N_c} \quad (4.4)$$

Où

$$d(Z_p, m_j) = \sqrt{\sum_{k=1}^{N_d} (z_{pk} - m_{jk})^2} \quad (4.5)$$

Et

N_d indique la dimension d'entrée, c'est-à-dire le nombre de paramètres de chaque vecteur de données,

N_p désignent le nombre de pixels de l'image,

N_c désigne le nombre de cluster (tel que fourni par l'utilisateur),

Z_p désignent les composants de pixel de p ,

m_j indiquent les moyens de cluster j ,

$|C_{ij}|$ est le nombre de vecteurs de données appartenant au cluster C_{ij} , c'est-à-dire la fréquence de ce cluster.

L'algorithme FCM-PSOBC appliqué à la segmentation de la maladie SEP est résumé comme suit :

Algorithme 4.1 : Algorithme FCM-PSOBC

Données image IRM originale

/* **Algorithme FCM** */

1. Fixer les paramètres : $P, c1, c2, w, m, C, \varepsilon$ et $itermax$
2. Initialiser aléatoirement les centres des classes c_i^0
3. $k \rightarrow 1$
4. Répéter
5. Calculer les degrés d'appartenance $U^{(k)}$ en utilisant les centres $C_i^{(k-1)}$

$$u_{ij}^{(k)} \leftarrow \left[\sum_{l=1}^C \left(\frac{d(x_j, c_j^{(k-1)})}{d(x_j, c_l^{(k-1)})} \right)^{\frac{2}{(m-1)}} \right]^{-1}$$

6. Mettre à jour les centres des classes $C_i^{(k)}$ en utilisant $U^{(k)}$

$$c_i^{(k)} \leftarrow \frac{\sum_{j=1}^N (u_{ij}^{(k)})^m \cdot x_j}{\sum_{j=1}^N (u_{ij}^{(k)})^m}$$

7. $k \rightarrow k + 1$
8. Jusqu'à ce que $\|C_i^{(k)} - C_i^{(k+1)}\| \leq \varepsilon$
9. Retourner : les centres des classes c_i et les degrés d'appartenance u_{ij}

/* **Algorithme PSOBC** */

10. Pour t de 1 à $itermax$ faire
11. Pour chaque particule i faire
12. Pour chaque pixel Z_P de la MB
13. Calculer la distance $d(Z_P, m_{ij})$ à tous les centres des classes C_{ij} selon l'équation (4.5)
14. Classifier le pixel Z_P à la classe C_{ij} où

$$d(Z_P, m_{ij}) = \min_{\forall c=1, \dots, N_c} d(z_p, m_{ic})$$

15. Calculer la fitness de la particule courante selon l'équation (4.4)
16. Trouver la meilleure solution globale

17. Mettre à jour les centres des classes selon les équations (4.1) et (4.2)

Où *itermax* est le nombre maximum d'itérations.

4.2.3 Prise de décision

La dernière étape détermine si un voxel donné de la MB désigne une lésion SEP ou non. Par conséquent, un système d'inférence floue de type Mamdani a été adopté. Dans ce but, la prise de décision sera illustrée et détaillée dans la section (*cf.* 4.4.3) qui va suivre.

4.3 Contribution 2 : FPSO-FCM

L'imagerie par résonance magnétique (IRM) permet la visualisation du cerveau et est largement utilisée dans le diagnostic et le suivi des patients atteints de la SEP. Dans le but d'automatiser un processus long et fastidieux pour le clinicien, nous proposons la segmentation automatique des lésions de la SEP. Notre algorithme de segmentation est composé de trois étapes : la segmentation du cerveau en régions à l'aide de l'algorithme Fuzzy Particle Swarm Optimization (FPSO) afin d'obtenir la caractérisation des différents tissus sains (matière blanche, matière grise et liquide céphalo-rachidien (LCR)). Après, l'extraction de la matière blanche (MB), l'élimination des données atypiques (outliers) de la matière blanche par l'algorithme Fuzzy C-Means (FCM) et enfin, l'utilisation d'un modèle flou de type Mamdani pour extraire les lésions de la SEP parmi toutes les données absurdes.

4.3.1 Segmentation des tissus cérébraux par FPSO

La segmentation des tissus cérébraux en trois classes (matière blanche (MB), matière grise (MG) et liquide céphalo-rachidien (LCR)) est une étape clé de notre étude. Son résultat sert de base à la mise en œuvre de stratégies basées sur la gestion des lésions de la SEP. À cette fin, une approche basée sur l'optimisation utilisant l'algorithme Fuzzy Particle Swarm Optimization (FPSO) a été adoptée dans notre approche. Ceci est justifié pour sa simplicité, sa capacité à traiter des ensembles de données de grande dimension, ainsi que son efficacité démontrée dans d'autres tâches de segmentation similaires, comme

indiqué dans [Izak-11] [Semc-18]. L'application de l'algorithme FPSO pour la segmentation dans notre cas donne trois classes distinctes correspondant à la MB, MG et LCR.

PSO est un outil d'optimisation basé sur la population, qui pourrait être implémenté et appliqué facilement pour résoudre divers problèmes d'optimisation [Reha-11]. Cependant, l'algorithme PSO souffre d'un problème en ce que toutes les particules sont susceptibles d'être piégées dans le minimum local dans la phase ultérieure de convergence. La valeur optimale trouvée est souvent un minimum local au lieu d'un minimum global [Reha-11]. Pang et coll [Pang-04] ont proposé une version d'algorithme PSO pour le problème du voyageur de commerce appelée Fuzzy Particle Swarm Optimization (FPSO).

L'algorithme FPSO (Fuzzy Particle Swarm Optimisation) est proposé par Pang et al [Pang-04] pour résoudre le problème du voyageur de commerce. Cet algorithme a été appliqué avec succès pour la segmentation des données par Izakian et Abraham [Izak-11].

Dans l'algorithme FPSO la position de chaque particule est représentée dans une matrice X qui contient les degrés d'appartenance des pixels $\{o_1, o_2, \dots, o_N\}$ aux centres des classes $\{Z_1, Z_2, \dots, Z_c\}$, la matrice X est décrite comme suit :

$$X = \begin{bmatrix} u_{11} & \cdots & u_{1c} \\ \vdots & \ddots & \vdots \\ u_{N1} & \cdots & u_{Nc} \end{bmatrix} \quad (4.6)$$

Où u_{ij} est le degré d'appartenance du pixel i au centre de la classe j , avec les conditions définies dans les équations (Eq.1.1) et (Eq.1.2). Donc, la matrice de position X de chaque particule est similaire à la matrice des degrés d'appartenance U dans l'algorithme FCM. De plus, la vitesse de chaque particule est représentée dans la matrice V ($N * C$). Les équations Eq. 4.7 et Eq.4.8 sont utilisés pour mettre à jour la position et la vitesse [Izak-11].

$$V(t+1) = \omega \otimes V(t) \oplus (c_1 r_1) \otimes (y_i(t) \ominus X(t)) \oplus (c_2 r_2) \otimes (\hat{y}(t) \ominus X(t)) \quad (4.7)$$

$$X(t+1) = X(t) \oplus V(t+1) \quad (4.8)$$

Où

—Les symboles \oplus et \ominus désignent respectivement l'addition et la soustraction entre les matrices. Le symbole \otimes désigne une multiplication de tous les éléments de la matrice par un nombre réel.

— $y_i(t)$ (*Pbest*) est la meilleure position déjà visitée par la particule i (Eq.4.9) et $\hat{y}(t)$ (*Gbest*) est la meilleure position de tout l'essaim (Eq.4.10).

$$y_i(t+1) = \begin{cases} y_i(t) & \text{if } f(x_i(t+1)) \geq f(y_i(t)) \\ x_i(t+1) & \text{if } f(x_i(t+1)) < f(y_i(t)) \end{cases} \quad (4.9)$$

$$\hat{y}(t) \in \{y_1, y_2, \dots, y_p\} = \min\{f(y_1(t)), f(y_2(t)), \dots, f(y_p(t))\} \quad (4.10)$$

Après la mise à jour de la matrice X et pour respecter les contraintes données dans les équations (Eq.1.1) et (Eq.1.2), il est donc nécessaire de normaliser la matrice X [Izak-11]. Tout d'abord, tous les éléments négatifs de la matrice X sont mis à 0. Si tous les éléments d'une ligne de la matrice X sont égaux à 0, on les recalcule en affectant des nombres aléatoires dans l'intervalle $[0, 1]$ et la matrice subit les transformations suivantes :

$$X_{normal} = \begin{bmatrix} u_{11}/\sum_{j=1}^c u_{1j} & \cdots & u_{1c}/\sum_{j=1}^c u_{1j} \\ \vdots & \ddots & \vdots \\ u_{N1}/\sum_{j=1}^c u_{Nj} & \cdots & u_{Nc}/\sum_{j=1}^c u_{Nj} \end{bmatrix} \quad (4.11)$$

En FPSO, comme dans l'algorithme PSO, nous avons besoin d'une fonction pour évaluer les solutions trouvées appelée fonction de fitness. Dans notre approche, nous avons défini une fonction décrite par l'équation suivante :

$$f(X) = K/J_m \quad (4.12)$$

Où K est une constante et J_m est la fonction objectif de l'algorithme FCM.

4.3.2 Segmentation de la matière blanche par FCM

La prochaine étape de notre approche consiste à éliminer les données atypiques dans les voxels de la MB précédemment identifiés afin de mettre en évidence les différentes lésions de la SEP. En effet, ses lésions ne sont pas bien contrastées en raison du volume partiel dans les tissus environnants, ce qui rend leur segmentation plutôt difficile. Motivé par le manque d'une base de données étiquetée entièrement complète comme indiqué dans [Bezd-93], une stratégie similaire non supervisée basée sur un algorithme de FCM a été préconisée. L'avantage principal de cet algorithme est son adaptation où les données

manipulées se chevauchent ou lorsque l'information à traiter est imprécise et incertaine, ce qui est le cas des images IRM de la maladie SEP. Cependant, son inconvénient majeur est lié à l'initialisation aléatoire des centres des classes qui provoquent une convergence prématurée et peut conduire l'algorithme à rester piégé dans des optima locaux, sans atteindre l'optimum global. Afin d'optimiser l'étape d'initialisation de l'algorithme de FCM, une métaheuristique FPSO est utilisée pour trouver les meilleures positions initiales des centres des classes.

Le Fuzzy C-Means est un algorithme de classification non supervisée, issu de l'algorithme K-means. Son apport par rapport à ce dernier est l'introduction de la notion du flou, afin de prendre en compte l'imprécision des données [Bezd-81] [Sbil-15]. Les détails de cet algorithme sont illustrés dans la section (*cf.* 4.2.1.3).

L'algorithme FPSO-FCM appliqué à la segmentation de la maladie SEP est comme suit :

Algorithme 4.2 : FPSO-FCM

Données image IRM originale

1. Fixer les paramètres : P , c_1 , c_2 , w , m , C , ε et $itermax$

/*

Algorithme FPSO

*/

2. Créer un essaim particule P (X , $pbest$, $gbest$ et V sont des matrices $n * c$)
3. Initialiser les centres des classes
4. Calculer les centres des classes de chaque particule en utilisant Eq. (1,5)
5. Calculer la Fitness de chaque particule en utilisant Eq. (4.12)
6. Calculer $pbest$ par l'Eq. (4,9)
7. Calculer $gbest$ par l'Eq. (4.10)
8. Mettre à jour la vitesse de chaque particule à l'aide de l'Eq. (4,7)
9. Mettre à jour la position de chaque particule à l'aide de l'Eq. (4,8)
10. Si la condition n'est pas vérifiée, reprendre depuis l'étape 4

Retourner MB, MG et LCR

/*

Algorithme FCM

*/

11. Initialiser aléatoirement les centres des classes c_i^0
12. $k \leftarrow 1$
13. Répéter

14. Calculer les degrés d'appartenance $U^{(k)}$ en utilisant les centres $C_i^{(k-1)}$

$$u_{ij}^{(k)} = \left[\sum_{l=1}^C \left(\frac{d(x_j, c_l^{(k-1)})}{d(x_j, c_l^{(k-1)})} \right)^{\frac{2}{(m-1)}} \right]^{-1}$$

15. Mettre à jour les centres des classes $C_i^{(k)}$ en utilisant $U^{(k)}$

$$C_i^{(k)} = \frac{\sum_{j=1}^N (u_{ij}^{(k)})^m \cdot x_j}{\sum_{j=1}^N (u_{ij}^{(k)})^m}$$

16. $k \leftarrow k + 1$

17. Jusqu'à ce que $\|C_i^{(k)} - C_i^{(k+1)}\| \leq \varepsilon$

18. **Retourner** : les centres des classes c_i et les degrés d'appartenance u_{ij}

4.3.3 Prise de décision

La dernière étape détermine si un voxel de la MB donné est une lésion SEP ou non. Par conséquent, un système d'inférence floue de type Mamdani a été adopté. Dans ce but, la prise de décision sera illustrée et détaillée dans la section (cf. 4.4.3) qui va suivre.

4.4 Contribution 3 : FPSO-PCM

En raison de l'importance de la segmentation des images aux différentes étapes du diagnostic de la maladie SEP, il est devenu nécessaire d'élaborer des algorithmes de segmentation efficaces et solides pour cette maladie. En effet, la détection et la segmentation automatisées de la SEP à partir des images IRM doivent principalement, comme son nom l'indique, utiliser une approche de segmentation de la SEP entièrement automatisée pour l'extraction des lésions, d'autre part fournir une bonne classification de ces lésions et enfin, offrir une détection précoce et précise de la sclérose en plaques. Dans cette contribution, nous proposons une nouvelle approche pour améliorer la détection et la segmentation de la SEP. Notre approche repose sur trois étapes principales, à savoir : la segmentation initiale du tissu cérébral en MG, MB et LCR est effectuée à l'aide de l'algorithme Fuzzy Particle Swarm Optimization (FPSO). Ceci est suivi d'une deuxième étape où les lésions sont segmentées en tant que valeurs aberrantes par rapport au tissu cérébral apparent normal de la MB à l'aide d'un algorithme Possibilistic C-Means (PCM) et enfin, nous intégrons un système de prise de décision utilisant un modèle d'inférence flou de type Mamdani pour identifier les lésions de la SEP.

4.4.1 Segmentation des tissus cérébraux par FPSO

La segmentation est une des étapes primordiales 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, la sclérose en plaques, etc.

Notre but dans cette partie est la segmentation de l'image en trois classes (MB, MG, LCR). Donc Afin de concevoir un système de segmentation qui permet d'avoir une meilleure qualité de la segmentation sur une grande variété d'images, nous abordons la segmentation comme un problème d'optimisation. Pour cela nous avons choisi l'algorithme d'optimisation FPSO, en tenant compte de ses avantages à résoudre les problèmes d'optimisation à variables continues. Ceci est motivé par sa simplicité, capacité à traiter avec un jeu de données de grande dimension et son efficacité prouvée dans d'autres segmentations similaires comme indiqué dans [Izak-11] [Semc-18]. La brève description de l'algorithme FPSO est illustrée dans la section(cf. 4.3.1) .

4.4.2 Segmentation de la matière blanche par PCM

Après avoir identifié les trois principaux types de tissus, nous nous concentrons sur la segmentation de la matière blanche (MB) afin d'éliminer les voxels aberrants dans les voxels de la matière blanche précédemment identifiés et de faire ressortir les lésions de la SEP. Pour y remédier, la segmentation possibiliste, qui est lancée par l'algorithme Possibiliste C-Means (PCM) [Kris-93], est développée et s'est prouvée plus efficacement aux données aberrantes [Xuan-11] [Vinc-07]. Le PCM peut révéler la distribution des données plus efficacement que d'autres techniques de segmentation (par exemple K-means). En outre, PCM a des propriétés bien comprises et est bien mises en œuvre en raison de sa simplicité et efficacité [Zhan-15]. Par conséquent, le PCM a été largement utilisé dans la segmentation d'images, la détection des défauts et l'exploration des données [Xena-16].

Krishnapuram et Keller ont proposé une approche possibiliste appelée Possibilistic C-Means, ou PCM [Kris-93] [Bezd-97]. Elle appartient à la famille des classifications non supervisées. Elle se différencie de l'approche des C-Moyennes Floues, par une définition

plus souple du concept de partition floue ainsi qu'en caractérisant les classes, non plus de manière relative les unes par rapport aux autres, mais au contraire de façon absolue [Mekh-08].

L'algorithme PCM introduit la notion de possibilité très voisine du flou. Le degré d'appartenance d'une observation à une classe est considéré comme une possibilité d'appartenir à une classe. Contrairement à l'algorithme FCM, la somme des degrés d'appartenance d'un pixel à toutes les classes n'est pas égale à 1.

L'algorithme FPSO-PCM appliqué à la segmentation de la maladie SEP est comme suit :

Algorithme 4.3 : FPSO-PCM

Données image IRM originale

1. Fixer les paramètres : P , $c1$, $c2$, w , m , C , ε et $itermax$

/* **Algorithme FPSO** */

2. Créer un essaim particule P (X , $pbest$, $gbest$ et V sont des matrices $n * c$)
3. Initialiser les centres des classes
4. Calculer les centres des classes de chaque particule en utilisant Eq. (1,5)
5. Calculer la Fitness de chaque particule en utilisant Eq. (4.12).
6. Calculer $pbest$ par l'Eq. (4,9)
7. Calculer $gbest$ par l'Eq. (4.10)
8. Mettre à jour la vitesse de chaque particule à l'aide de l'Eq. (4,7)
9. Mettre à jour la position de chaque particule à l'aide de l'Eq. (4,8)
10. Si la condition n'est pas vérifiée, reprendre depuis l'étape 4

Retourner MB, MG et LCR

/* **Algorithme PCM** */

11. Initialiser aléatoirement le vecteur des centroïdes B
12. $k \leftarrow 1$
13. **répéter**
14. Mettre à jour la matrice U par la relation

$$u_i(x) = \frac{1}{1 + \left(\frac{d^2(x_j, v_i)}{n_i} \right)^{\frac{1}{m-1}}}$$

15. Mettre à jour le vecteur des centroides B par la relation

$$v_i = \frac{\sum_{k=1}^N u_{ik}^m \cdot x_k}{\sum_{k=1}^N u_{ik}^m}$$

16. Calculer le paramètre η_i par

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

17. Calculer la fonction objectif J par la relation

$$J(B, U, X) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d_{ij}^2 + \sum_{i=1}^C \eta_i \sum_{j=1}^N (1 - u_{ij})^m$$

18. $k \leftarrow k + 1$

19. **jusqu'à** $\left\| J_i^{(k)} - J_i^{(k+1)} \right\| \leq \epsilon$

20. **Retourner** : les centres des classes v_i et les degrés d'appartenance u_{ij}

4.4.3 Prise de décision

La prise de décision suivante qui va être détaillée, est valable pour toutes les contributions respectivement (4.2, 4.3 et 4.4).

Cette dernière étape consiste à prendre la décision quant à l'appartenance d'un voxel de la matière blanche à une classe de la maladie SEP. Les lésions de la SEP apparaissent en hypo- ou hyper-signal par rapport à la MB selon les modalités d'IRM. Les images pondérées en T2 et DP mettent en évidence la composante myélinique dans les lésions caractérisées par des œdèmes qui apparaissent comme hyper-intenses par rapport à la matière blanche. Par ailleurs, la modalité T1 met en évidence la destruction irréversible des tissus avec l'apparition dans la matière blanche de "trous noirs" (hypo-signal) persistants [Ait-06]. Dans ce cas nous proposons d'utiliser un processus d'inférence floue de type Mamdani, ce mécanisme comprend les étapes résumées dans la figure suivante :

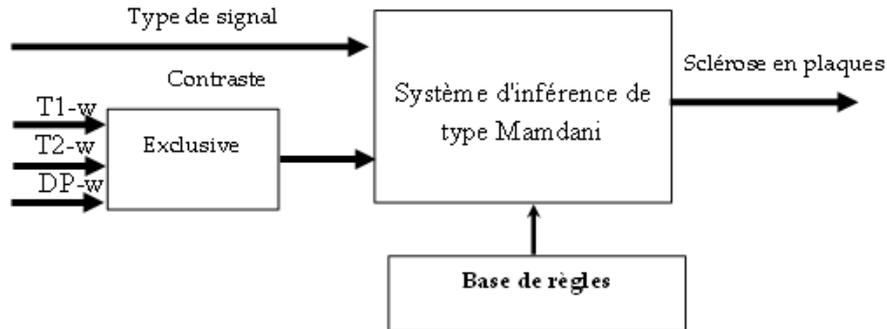


FIGURE 4.2 – Système d’inférence flou de Mamdani de nos propositions.

Le système a deux entrées, le contraste de pondération des images IRM et le type de signal des voxels. Et un signal de sortie qui diagnostique la maladie sclérose en plaques.

4.4.3.1 Fuzzification du système flou

Au préalable, nous établissons les quantificateurs flous et les fonctions d’appartenance pour les entrées du système. Pour la fuzzification de type de signal, nous choisissons deux intervalles flous et des fonctions d’appartenance de type gaussienne. La figure suivante illustre la répartition floue de la variable d’entrée du type de signal.

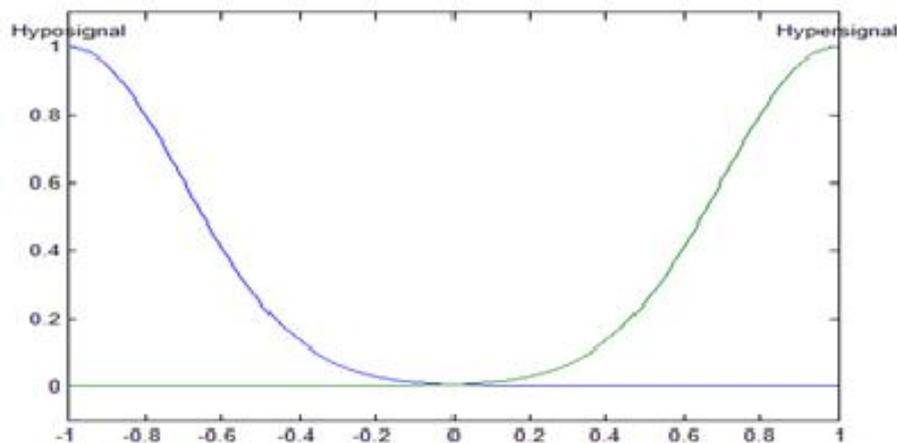


FIGURE 4.3 – Répartition floue de la variable d’entrée type de signal.

Par la suite, nous établissons les quantificateurs flous et les fonctions d'appartenance pour la sortie du système. Nous choisissons trois intervalles flous et des fonctions d'appartenance de type gaussienne en définissant les prédicats : faible, normale et élevé de la maladie SEP par rapport à la matière blanche. La figure suivante illustre la répartition floue de la variable de sortie : la décision de la maladie SEP.

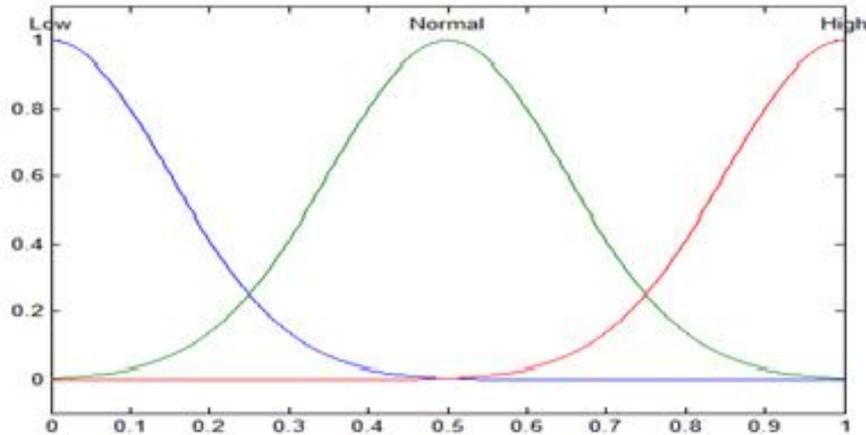


FIGURE 4.4 – Répartition floue de la variable de sortie qui donne la décision de la SEP.

4.4.3.2 Établissement de la base des règles

La prise de décision dans le domaine du diagnostic médical dépend également de l'expérience, de l'expertise et de la perception des médecins. Dans ce travail, les connaissances des experts ont été utilisées pour générer la base des règles floues. La connaissance est représentée sous la forme de règles SI-ALORS. Ces connaissances peuvent être incorporées sous la forme d'un système expert flou dans la détection et le diagnostic précis des maladies de la SEP. Dans cette étude, l'expert a défini dix règles floues par des observations faites sur les données. Une instance de ces règles floues pour notre système est décrite ci-dessous :

1. **Si** [(le contraste des images est T1-w active) **et** (le signal est hyperintense)] **Alors** (la SEP est faible).
2. **Si** [(contraste des images est T1-w active) **et** (le signal est hyperintense)] **Alors** (la SEP est normale).
3. **Si** [(le contraste des images est T2-w active) **et** (le signal est hyperintense)] **Alors** (la SEP est élevée).

4. **Si** [(le contraste des images est DP-w active) **et** (le signal est hyperintense)] **Alors** (la SEP est élevée).
5. **Si** [(le contraste des images est T1-w active) **et** (le signal est hypointense)] **Alors** (la SEP est faible).
6. **Si** [(le contraste des images est T2-w active) **et** (le signal est hypointense)] **Alors** (la SEP est élevée).
7. **Si** [(le contraste des images est DP-w active) **et** (le signal est hypointense)] **Alors** (la SEP est élevée).
8. **Si** [(le contraste des images est T1-w active) **et** (le signal est hyperintense après injection du gadolinium)] **Alors** (la SEP est normale).
9. **Si** [(le contraste des images est T2-w active) **et** (le signal est hyperintense après injection du gadolinium)] **Alors** (la SEP est élevée).
10. **Si** [(le contraste des images est DP-w active) **et** (le signal est hyperintense après injection du gadolinium)] **Alors** (la SEP est élevée).

Nous pouvons représenter la base des règles sous la forme de tableau ou de matrice. La base des règles complète est la suivante :

TABLE 4.1 – Base des règles sous forme de matrice.

	T1-w	T2-w	PD-w
Hypersignal	Faible/Normale	Elevé	Elevé
Hopersignal	Faible	Elevé	Elevé
Hypersignal after injection of gadolinium	Normale	Elevé	Elevé

La méthode d'inférence choisie est celle de Mamdani. Par conséquent, l'opérateur ET est réalisé par le calcul du minimum, tandis que l'opérateur OU est réalisé par le calcul du maximum.

4.4.3.3 Défuzzification du système flou

L'étape de défuzzification s'exécute avec le calcul du centre de gravité. En général, la méthode du centre de gravité (CDG) est basée sur le calcul de l'abscisse correspondant au centre de gravité de la surface du sous-ensemble flou de la solution déterminée par l'agrégation de l'action des règles floues. Une solution floue dont la solution précise, Z_0 , est donnée par la méthode du centre de gravité suivante.

$$Z = \frac{\sum_{i=1}^N \mu_i Z_i}{\sum_{i=1}^N \mu_i} \quad (4.13)$$

Où N est le nombre de niveaux de quantification, Z_i la valeur de sortie pour le niveau i et μ_i sa valeur d'appartenance.

4.5 Choix des paramètres des algorithmes

Nous utilisons deux familles de segmentation pour détecter la maladie SEP : les algorithmes d'optimisation et les algorithmes de classification. Pour cela, il nous faut définir au préalable les différents paramètres encadrant la méthode à savoir.

4.5.1 Nombre de particules P

Le nombre des particules allouées à la résolution d'un problème d'optimisation, dépend essentiellement de la taille de l'espace de recherche. Il n'y a pas de règle pour déterminer ce paramètre, faire de nombreux essais permet d'avoir la bonne valeur. En général, l'augmentation du nombre de particules augmente la diversité, ce qui réduit la possibilité d'être piégé dans des minima locaux [Omra-04]. Selon Shi and Eberhart [Eber-98], la valeur de P , ne doit pas être trop petite.

4.5.2 Facteur d'inertie w

Le facteur d'inertie w , introduit par Shi et Eberhart [Eber-98] contrôle l'influence de la direction actuelle de la particule sur le déplacement futur. Ce paramètre a été introduit pour réaliser un compromis entre la recherche locale (exploitation) et la recherche globale (exploration). Une grande valeur du facteur d'inertie provoque une grande exploration

de l'espace de recherche alors qu'une petite valeur concentre la recherche localement sur un petit espace [Dor-12]. Les études menées dans [Eber-00] indiquent une meilleure convergence pour $w \in [0.7, 1.2]$.

4.5.3 Coefficients c_1, c_2

La combinaison des paramètres w, c_1 et c_2 permet de régler la balance entre une recherche locale et globale. Dans [Cler-02] les auteurs ont choisi les valeurs expérimentales suivantes : $w = 0.7298, c_1 = c_2 = 1.496$. Toutefois, d'autres valeurs ont été utilisées dans la littérature.

4.5.4 Critères d'arrêt

Dans tous les algorithmes, nous avons utilisé deux critères d'arrêt qui sont : le nombre maximum d'itérations $itermax = 150$ et l'erreur $\varepsilon = 10^{-3}$.

4.5.5 Vitesse maximale v_{max}

La valeur de v_{max} est généralement dépendante de l'échelle du problème. Dans le cas d'un problème de segmentation des images, v_{max} prend la valeur 255, qui représente le plus grand niveau de gris dans une image.

4.5.6 Degré de flou m

Ce paramètre ($m > 1$) contrôle le degré de flou de la matrice U . Si $m = 1$ alors l'algorithme n'est pas flou. Le paramètre m n'a pas une influence majeure sur le résultat de la segmentation [Madh-15]. Nous avons fixé $m = 2$, valeur qui est souvent choisie dans la littérature.

4.5.7 Mesure de la distance

Nous avons choisi la distance euclidienne qui est la plus simple et la plus rapide à calculer.

4.5.8 Détermination du nombre des classes

Notre objectif consiste à segmenter les images de la maladie sclérose en plaques, ce qui nous pousse à fixer à quatre le nombre des classes à identifier ($C=4$) correspondant aux trois tissus cérébraux présents dans l'encéphale à savoir la matière blanche (MB), la matière grise (MG), le liquide céphalo-rachidien(LCR) et la sclérose en plaques (SEP).

4.5.9 Choix des vecteurs forme

Le choix des vecteurs forme est essentiel puisque leur pertinence va permettre de distinguer les pixels entre eux. Ce choix est défini suivant le type de modalité. L'image anatomique que nous utilisons est une IRM. L'imagerie par résonance magnétique est une modalité d'imagerie multi spectrale (multimodale) donnant accès à un grand nombre de paramètres et donc de vecteurs forme. La première caractéristique qui peut être exploitée est le signal lui-même, principalement à travers d'images pondérées en T_1 , T_2 et en densité de protons. Le vecteur forme x_j d'un pixel j est alors formé des niveaux de gris de ce pixel dans toutes les modalités. Cette information est très largement utilisée en segmentation d'images [Barr-99].

4.6 Conclusion

Dans ce chapitre nous avons décrit les étapes de la segmentation d'images citée dans nos contributions pour répondre à la problématique de la détection de la maladie SEP, avec la présentation de l'architecture générale et des paramètres utilisés par chaque algorithme.

Nous avons remarqué à partir d'une étude que les problèmes majeurs de l'algorithme FCM sont sa sensibilité aux points aberrants (éloignés) qui peuvent avoir des valeurs d'appartenance élevées et ils peuvent affecter fortement l'estimation des centres des classes et son initialisation aléatoire qui provoque une convergence prématurée. Les démarches que nous avons utilisées consistent à réaliser l'hybridation entre les algorithmes de classification automatique et les algorithmes d'optimisation pour segmenter les lésions de la SEP. Par la suite, ces démarches seront implémentées par un système flou de type Mamdani pour nous aider à la prise de décision.

Dans le chapitre suivant nous allons présenter les résultats, afin d'évaluer l'efficacité du système développé.

Résultats et évaluations

5.1 Introduction

La segmentation d'images est un procédé utilisé pour partitionner les images en classes distinctes, c'est une tâche décisive dans de nombreuses applications, comme l'interprétation des images de la SEP. Dans le cas de la segmentation des lésions de SEP, le problème est encore plus complexe. Les finalités d'un système de segmentation automatique d'IRM cérébrales pour la SEP sont nombreuses : aide au diagnostic, suivi de l'évolution de l'état du patient, test clinique, etc.

Ce chapitre est destiné à l'application des méthodes proposées dans les chapitres précédents et à leurs évaluations quantitativement et qualitativement à partir des différents critères proposés. Les méthodes proposées ont été appliquée sur des images IRM réelles et fantômes de cerveaux humains atteints par la sclérose en plaques. Au début, l'évaluation a été appliquée pour la segmentation de tissus sains, c'est à dire la matière blanche, la matière grise et le LCR. Nous supposons dans la suite que les diverses images à segmenter sont déjà recalées et spatialement normalisées, c'est-à-dire placées dans un même repère géométrique.

5.2 Base d'images

Deux bases des images IRM sont employées dans nos expérimentations :

5.2.1 Images réelles

Une image réelle est obtenue depuis un signal continu bidimensionnel comme par exemple un appareil photo ou une caméra, etc. Sur un ordinateur, nous ne pouvons pas représenter des signaux continus, par conséquent, nous travaillons sur des valeurs discrètes.

Les images réelles sur lesquelles nous avons travaillé ont été acquises dans le cadre de la collaboration entre le laboratoire LSI (Laboratoire Systèmes Intelligents : équipe image et signaux) de l'université Ferhat Abbas de Sétif (Algérie) et le laboratoire LAMIH UMR CNRS 8201 (Laboratory of Industrial and Human Automation control, Mechanical engineering and Computer Science) de université Valenciennes (France).

Il s'agit d'images pondérées en T1, T2 et en densité de proton pour des patients de différents âges atteints de la sclérose en plaques (taille pixel =1mm, taille de matrice $256 * 256$). Les images sont en format DICOM (Digital Imaging and communications in médecine).

5.2.2 Fantômes (image de synthèse)

Nous avons utilisé un fantôme qui est ici une base de données synthétique qui permet de construire des images IRM.

Pour valider les techniques de segmentation, les chercheurs ont présenté divers fantômes imitant le cerveau. Cependant, ils sont relativement simples par rapport à la complexité du cerveau. Depuis quelques années, le centre d'imagerie cérébrale de l'institut Neurologique de l'université McGill à Montréal, met à la disposition de la communauté des chercheurs le fantôme dénommé Brainweb qui est devenu une référence très utilisée pour valider les méthodes de segmentation du cerveau. Le modèle anatomique du fantôme consiste en un ensemble de volumes flous représentant des degrés d'appartenance aux différents tissus constituant l'image IRM (matière blanche, matière grise, liquide céphalo-rachidien, peau, crâne, etc.).

La conception du fantôme est fondée sur un ensemble de 27 volumes IRM de taille $181 * 127 * 181$ voxels par volume et de haute résolution (1 mm / voxel). Ces images ont été recalées et un volume IRM a été créé par moyennage de ces 27 volumes recalés. Les voxels du volume moyen, ont été étiquetés par un neuroradiologue en matière blanche, matière grise, liquide céphalo-rachidien, graisse, etc. Les algorithmes de classification floue ont été réalisés sur ce volume. Après corrections manuelles des résultats obtenus, les cartes floues

de tissu sont finalement construites. En illustration, figure 5.1 présente une coupe des cartes floues de matière blanche, matière grise, liquide céphalo-rachidien et du crâne.

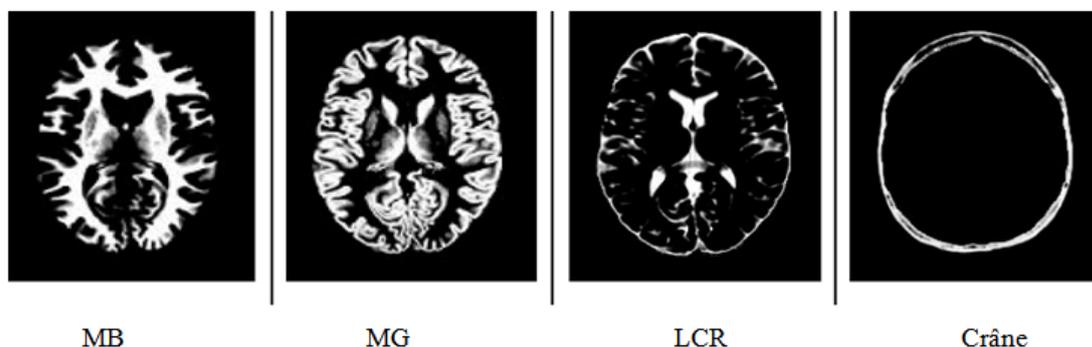


FIGURE 5.1 – Exemple de cartes floues du fantôme [Kwan-96].

5.2.3 Constructions des images simulées

A partir des cartes floues de tissu du fantôme et à l'aide des équations de Bloch [Bloc-46], des images IRM peuvent être simulées en différentes pondérations, telles que T1, T2 et aussi être bruitées à volonté afin d'obtenir des images réalistes. Le bruit dans l'image est un bruit blanc gaussien qui est exprimé comme un pourcentage de son écart type à l'intensité moyenne du signal. Chaque volume de données est constitué de 181 images de taille 181*217 pixels tout comme le fantôme.

Les principales étapes mises en œuvre pour transformer le volume initial en un fantôme permettant de générer des simulations, sont les suivantes :

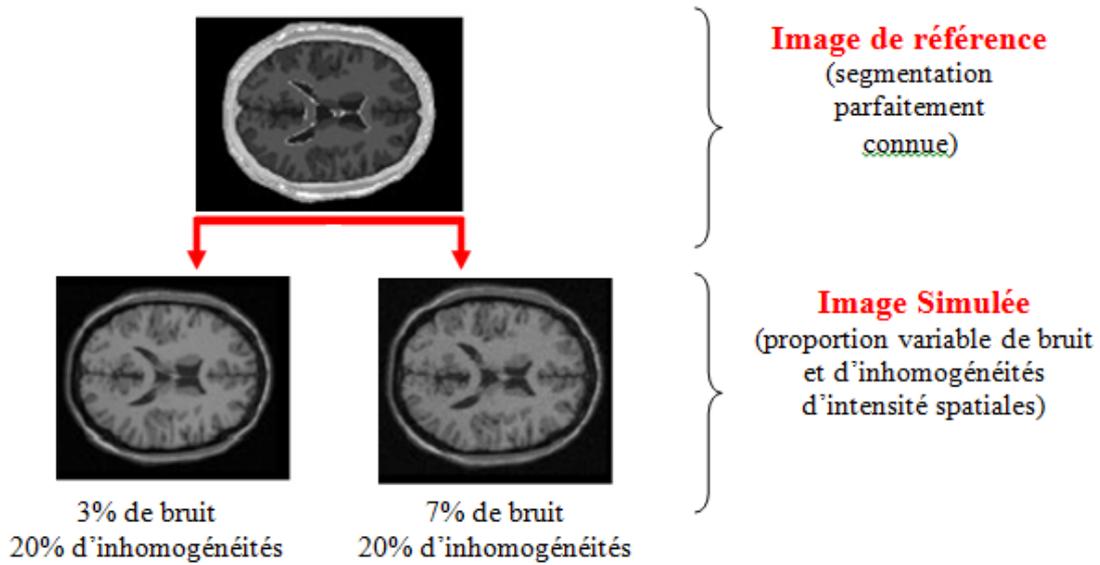


FIGURE 5.2 – Processus de construction des images simulées

- **La correction des non-uniformités** : Avant tout traitement du volume initial, un algorithme de correction des non-uniformités des niveaux de gris a été appliqué afin de réduire au maximum les risques d'erreurs de classification.

- **La classification** : La classification a été réalisée à partir d'un ensemble d'apprentissage décrivant des exemples de pixels appartenant aux différents tissus recherchés et marqués par un expert. Plusieurs algorithmes de classification ont été testés et le principe des moyennes les plus proches a été retenu comme délivrant le meilleur résultat [Germ-99]. Afin de construire un fantôme réaliste, les effets de volume partiel sont pris en compte. Ainsi pour chaque pixel du volume, un vecteur décrit la proportion de chacun des tissus qui le constituent. Le résultat de la classification est finalement constitué de 9 volumes décrivant chacun l'un des tissus recherchés (matière blanche et grise, liquide céphalo-rachidien, graisse, muscles, crâne, air, etc.). Au sein de chaque volume, l'intensité d'un pixel représente sa fraction pour le tissu correspondant.

- **Les corrections manuelles** : Un ensemble de corrections manuelles ou semi-automatiques a été réalisé afin d'améliorer le résultat de la segmentation. Ainsi, le fantôme final est composé de 9 volumes de tissus corrigés et la carte de référence qui lui est associée correspond en chaque pixel au tissu le plus représenté. Ce fantôme permet de décrire une géométrie réaliste du cerveau humain.

- **Les simulations** : Les niveaux de gris simulés pour chaque pixel du volume ont

été obtenus par résolution des équations de Bloch [**Germ-99**].

Nous avons choisi des volumes avec une coupe épaisse de 1 mm, taille couramment utilisée pour générer des images anatomiques. Le choix du bruit proposé sur le site BrainWeb est compris entre 0% et 9% et celui des valeurs du paramétrage d'hétérogénéité entre 0% et 40%. Pour des raisons de réalisme, la valeur de 0% n'a pas été retenue. De même, la valeur de 9% produit des images à l'allure très artificielle et nous l'avons écartée. Nous avons utilisé dans nos simulations la valeur de 3%. Les valeurs du paramètre d'inhomogénéité ont été choisies entre 0% et 20%. La valeur de 40% a été écartée car elle perturbe trop les distributions des niveaux de gris dans les images et que dans la réalité l'inhomogénéité se situe plutôt aux environs de 10%.

5.3 Environnement matériel

L'intégralité des expérimentations décrites dans cette thèse a été réalisée sous l'environnement NetBeans IDE 8.2 et exécutée sur un ordinateur personnel équipé : d'un processeur Intel (R) Core (TM) i5-4210U à 2,40 GHz et d'une mémoire vive de 4 Go. Le système d'exploitation était Windows 8.1 de 64 bits.

5.4 Evaluation et étude comparative

Les performances de nos contributions nous ont conduits à réfléchir à la validité de la segmentation obtenue. Il n'existe pas de "bonne" segmentation. Seule l'appréciation de l'utilisateur (qualité visuelle) et le but recherché permettent de définir une bonne segmentation pour un type de données. C'est pour cette raison que nous avons mesuré et quantifié les performances de notre segmentation de l'ensemble de l'encéphale.

5.4.1 Critères de validation

Pour tester nos contributions de façon pertinente, nous jugeons la qualité de la segmentation obtenue par rapport à plusieurs estimateurs souvent utilisés dans la littérature [**Rich-04**].

On considère une région de l'image de référence et une région de l'image segmentée. Les pixels sont classés en 4 catégories (voir Figure 5.3) :

- TP : vrais positifs (true positive), quand la méthode de segmentation a trouvé des pixels qui ne figurent pas dans l'image de référence.
- FP : faux positifs (false positive), où l'image de référence a indiqué des pixels que la méthode de segmentation n'a pas trouvés.
- TN : vrais négatifs (true negative), où l'image de référence possède des pixels que la méthode de segmentation indique aussi.
- FN : faux négatifs (false negative), où l'image de référence n'a pas indiqué des pixels et la méthode de segmentation non plus.

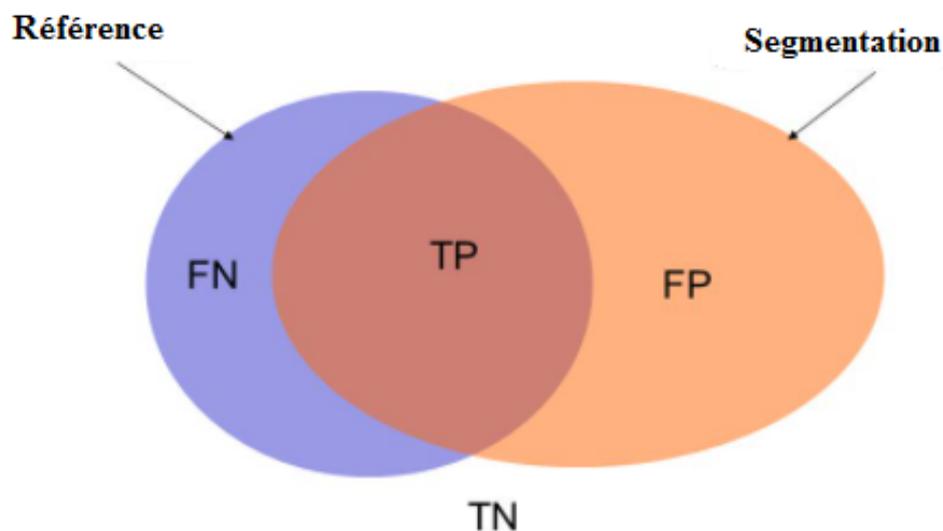


FIGURE 5.3 – Comparaison d’une image segmentée avec une image de référence. TP, TN, FP et FN représentent les voxels vrai positif, vrai négatif, faux positif et faux négatif, respectivement.

Nous avons choisi les critères d’évaluation les plus utilisés dans le domaine de la segmentation d’images, à savoir :

- **Sensibilité (SE)** : elle correspond à la proportion de vrais positifs par rapport à l’ensemble des structures qui devraient être segmentées :

$$SE = \frac{TP}{TP + FN} \quad (5.1)$$

La sensibilité tend vers 1 (resp. 0) s'il y a peu (resp. beaucoup) de faux négatifs. Cet indicateur permet d'évaluer dans quelle mesure l'intégralité d'une structure recherchée est segmentée.

- **Spécificité (SP)** : elle correspond à la proportion de vrais négatifs par rapport à l'ensemble des structures qui ne devraient pas être segmentées :

$$SP = \frac{TN}{TN + FP}. \quad (5.2)$$

La spécificité tend vers 1 (resp. 0) s'il y a peu (resp. beaucoup) de faux positifs. Cet indicateur permet d'évaluer dans quelle mesure l'intégralité du complémentaire d'une structure recherchée n'est pas segmentée.

- **Recouvrement (RE)** : il correspond la proportion de vrais positifs par rapport à l'ensemble des structures qui ont été ou devraient avoir été segmentées :

$$RE = \frac{TP}{TP + FP + FN} \quad (5.3)$$

Le recouvrement tend vers 1 (resp. 0) s'il y a peu (resp. beaucoup) de faux positifs et de faux négatifs. Cet indicateur permet d'évaluer dans quelle mesure la structure recherchée correspond quantitativement et qualitativement à la segmentation.

- **Similarité (SI)** : elle correspond à la proportion de vrais positifs par rapport à l'ensemble des structures qui ont été et devraient avoir été segmentées :

$$SI = \frac{2.TP}{2.TP + FP + FN} \quad (5.4)$$

La similarité tend vers 1 (resp. 0) s'il y a peu (resp. beaucoup) de faux positifs et de faux négatifs. A l'instar du recouvrement, cet indicateur permet d'évaluer dans quelle mesure la structure recherchée correspond quantitativement et qualitativement à la segmentation.

5.4.2 Le protocole d'évaluation

L'évaluation objective et quantitative des résultats jouent un rôle important dans la segmentation d'image [Zhan-94]. L'utilisation d'image de synthèse permet de comparer quantitativement la segmentation obtenue par rapport à un référentiel (Talairach) (Figure 5.4). La robustesse des systèmes de segmentation peut ainsi être étudiée et comparée pour différents niveaux de bruit et d'hétérogénéité d'intensité des images simulées. Il est également possible pour un même système de segmentation de tester quantitativement l'influence du choix de certains paramètres sur les résultats de la segmentation.

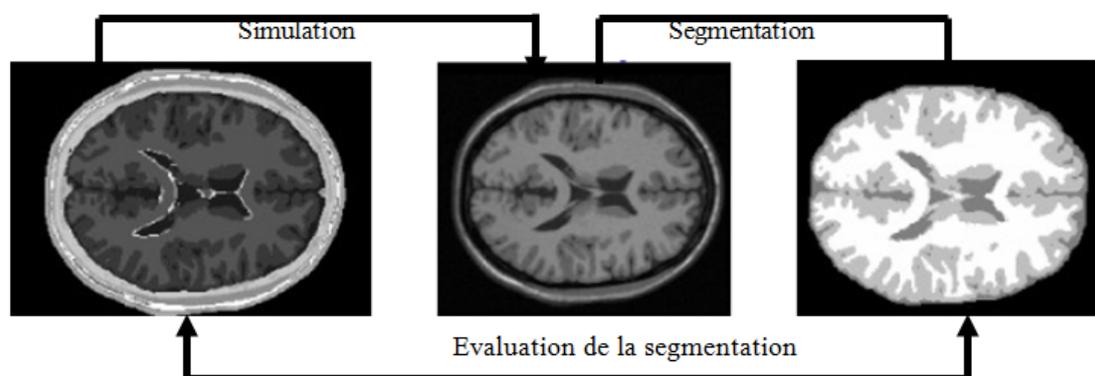


FIGURE 5.4 – Processus d'évaluation sur des images fantômes

5.5 Résultats et Évaluations de la segmentation

Dans cette section, les approches proposées FCM-PSOBC [Zoua-16], FPSO-FCM [Zoua-19] et FPSO-PCM [Zoua-20] sont mises en œuvre et évaluées dans l'environnement de la segmentation des images IRM cérébrales de la maladie sclérose en plaque (SEP). Nous allons débuter par la description des différentes images IRM simulées et réelles, qu'on a utilisées pour évaluer les résultats de la segmentation. Ensuite, une évaluation qualitative et quantitative de la segmentation est présentée selon différents critères. Enfin, nous allons comparer l'algorithme FCM-PSOBC, FPSO-FCM avec FPSO-PCM.

Les différentes images sur lesquelles nous avons travaillé ont été en pondérée T1, T2 et DP correspondant à des patients atteints de la sclérose en plaques de différents âges. Elles sont sous la forme de DICOM (Digital Imaging et communications en médecine). La segmentation a été appliquée avec succès sur certaines images réelles (figure 5.5).

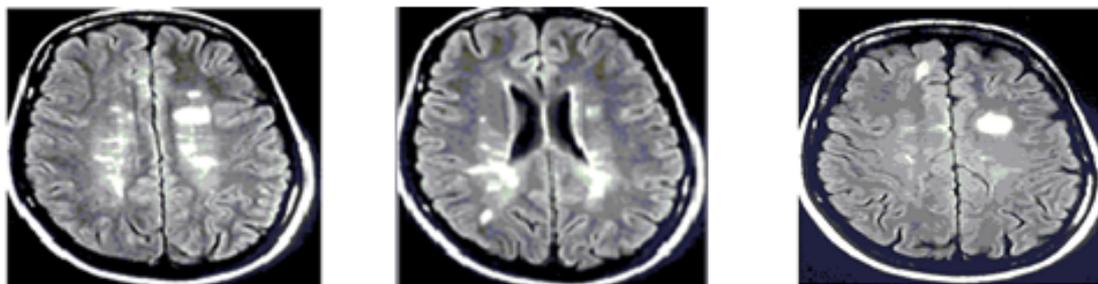


Image pondérée en T2 Image pondérée en DP Image pondérée en T1

FIGURE 5.5 – Images originales.

5.5.1 Étape 1 : Segmentation des tissus par FCM et FPSO

Les figures 5.6 et 5.7 montrent la segmentation par les algorithmes FCM et FPSO pour les images pondérées T2-w, DP-w et T1 afin d'obtenir une caractérisation des différents tissus sains de la substance blanche, substance grise et du liquide céphalo-rachidien et après la segmentation par les algorithmes FCM et FPSO, nous avons extrait la substance blanche pour chaque image.

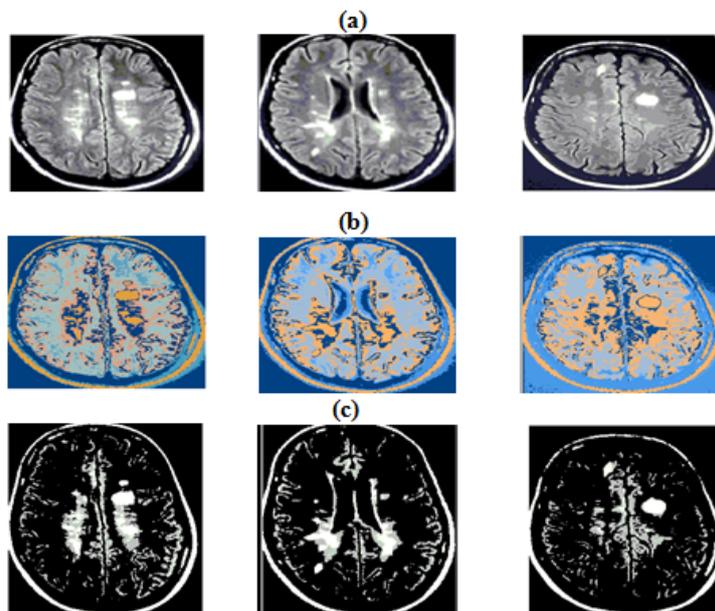


FIGURE 5.6 – (a) sont les images originales ; (b) correspond aux résultats de la segmentation par FCM ; (c) est l'extraction de la matière blanche (MB).

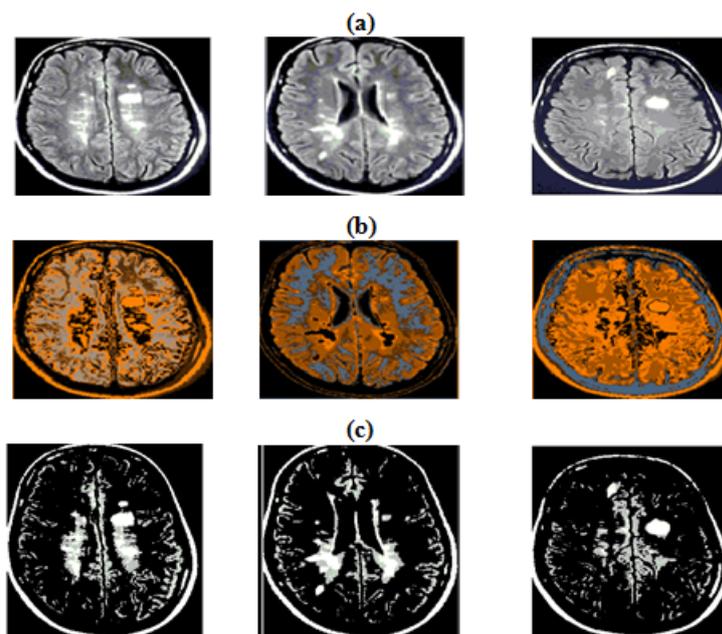


FIGURE 5.7 – (a) sont les images originales ; (b) correspond aux résultats de la segmentation par FPSO ; (c) est l'extraction de la matière blanche (MB).

Les résultats comparatifs sont présentés dans le tableau 5.1 ci-dessous :

TABLE 5.1 – Comparaison des résultats obtenus par les algorithmes FCM et FPSO

		FCM (MB)	FPSO (MB)
T1-w	<i>SI</i>	0.83	0.90
	<i>RE</i>	0.77	0.79
	<i>SE</i>	0.83	0.86
	<i>SP</i>	0.86	0.87
T2-w	<i>SI</i>	0.94	0.96
	<i>RE</i>	0.93	0.95
	<i>SE</i>	0.91	0.95
	<i>SP</i>	0.96	0.98
DP-w	<i>SI</i>	0.90	0.91
	<i>RE</i>	0.88	0.90
	<i>SE</i>	0.89	0.91
	<i>SP</i>	0.88	0.90

A la lecture du tableau, nous pouvons noter que la segmentation des images IRM T2-w produit une meilleure performance par rapport aux deux autres modalités. Par exemple, les résultats de la segmentation du tissu MB présentent dans T2-w en utilisant le FCM et FPSO avaient une similarité de 0,94 et 0,96, un recouvrement de 0,93 et 0,95, une sensibilité de 0,91 et 0,95 et une spécificité de 0,96 et 0,98 respectivement surpassant les deux autres segmentations effectuées sur les séquences T1-w et PD . En outre, les résultats d'évaluation lors de la segmentation de chaque algorithme, y compris la similarité, variaient de 0,83 à 0,90, de 0,94 à 0,96 et de 0,90 à 0,91 pour T1-w, T2-w et PD segmentés, respectivement. Les résultats de recouvrement allaient de 0,77 à 0,79, de 0,93 à 0,95 et de 0,88 à 0,90 pour les images T1-w, T2-w et PD, respectivement. De plus, la sensibilité a des valeurs allant de 0,83 à 0,86, de 0,91 à 0,95 et de 0,89 à 0,91 pour les segments T1-w, T2-w et PD, respectivement. Enfin, la spécificité avait des valeurs allant de 0,86 à 0,87, de 0,96 à 0,98, de 0,88 à 0,90 pour les images T1-w, T2-w et PD, respectivement. Donc Les résultats du tableau 5.1 démontrent une optimisation considérable pour tous les tissus utilisant T2-w que T1-w et PD-w de chaque algorithme.

5.5.2 Étape 2 : Segmentation de la matière blanche par PSOBC, FCM et PCM

Les figure 5.8, 5.9 et 5.10 illustrent la segmentation de la matière blanche par les algorithmes PSOBC, FCM et PCM pour les images pondérées T2-w, DP-w et T1 respectivement afin d'écartier les données atypiques.

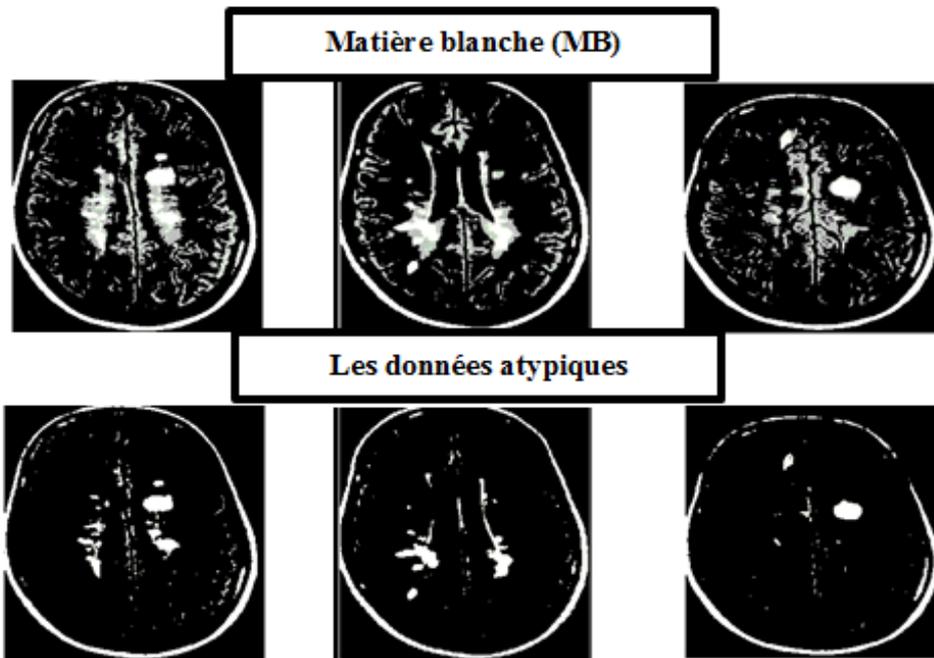


FIGURE 5.8 – MB des images (T2, DP et T1) segmentées par PSOBC.

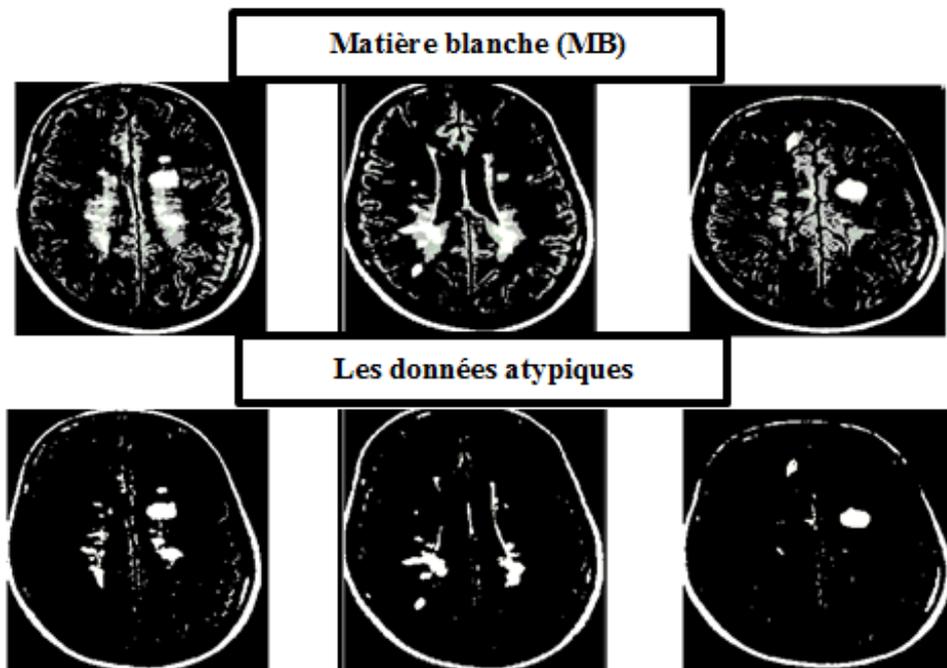


FIGURE 5.9 – MB des images (T2, DP et T1) segmentées par FCM.

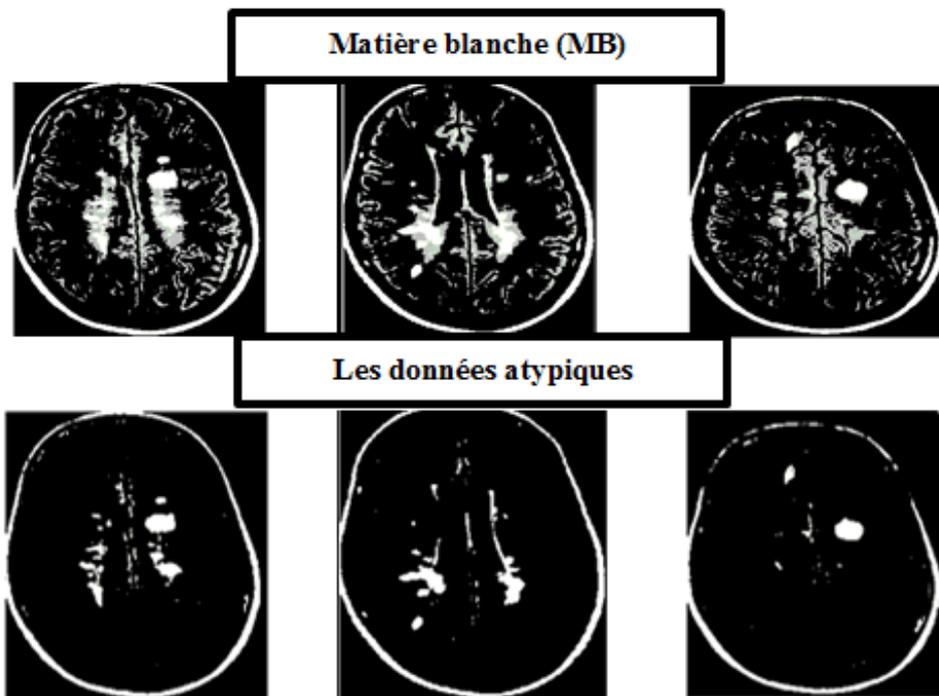


FIGURE 5.10 – MB des images (T2, DP et T1) segmentées par PCM.

La similarité, le recouvrement, la sensibilité et la spécificité des données atypique (SEP) pour les algorithmes PSOBC, FCM et PCM sont indiqués dans le tableau 5.2.

TABLE 5.2 – Comparaison des résultats obtenus par les algorithmes PSOBC, FCM et PCM.

		PSOBC	FCM	PCM
T1-w	SI	0.80	0.87	0.93
	RE	0.81	0.90	0.94
	SE	0.79	0.88	0.91
	SP	0.84	0.90	0.93
T2-w	SI	0.88	0.94	0.96
	RE	0.87	0.93	0.95
	SE	0.90	0.92	0.94
	SP	0.92	0.97	0.99
DP-w	SI	0.85	0.90	0.93
	RE	0.86	0.91	0.95
	SE	0.83	0.91	0.92
	SP	0.82	0.92	0.96

Dans cette étude, les méthodes basées sur l'IRM cérébrale se révèlent être un moyen important pour détecter la sclérose en plaque. La méthodologie de combinaison de l'algorithme Fuzzy Particle Swarm Optimization (FPSO) et l'algorithme Possibilistic C-Means (PCM) pour la segmentation donne des résultats précis pour détecter la maladie SEP. Comme le mentionne le tableau 5.2, l'indice de similarité varie de 93% à 96% avec une moyenne de 94%. L'indice de recouvrement varie de 94% à 95% avec une moyenne de 94,66%, l'indice de sensibilité varie de 91% à 94% avec une moyenne de 92,33% et la spécificité est comprise entre 93% à 99% avec une moyenne de 96%.

5.5.3 Étape 3 : Prise de décision

La méthode d'inférence choisie est celle de Mamdani. Par conséquent, l'opérateur ET est réalisé par le calcul du minimum, tandis que l'opérateur OU est réalisé par le calcul du maximum. Le tableau suivant présente les résultats de défuzzification :

TABLE 5.3 – Résultat de la défuzzification des données atypiques des différentes séquences

	T1-w (%)	T2-w (%)	DP-w (%)
FCM-PSOBC	48.76	56.79	49.56
FPSO-FCM	49.03	57.89	49.16
FPSO-PCM	49.64	59.53	51.71

La contribution proactive des personnes atteintes de SEP à la prise de décision et à la prise en charge de leur maladie est également essentielle à une prise en charge réussie de la SEP. En pratique clinique, une telle prise de décision est intimement liée à l'expertise, il ressort du tableau 5.3 que le patient est clairement atteint de SEP et que les lésions sont identifiées dans les trois séquences IRM pour toutes les approches proposées avec une représentation normale ou élevée.

5.6 Résultats expérimentaux

Dans cette section, nous comparons les performances du FPSO-PCM avec les algorithmes FPSO-FCM, FPSO-PCM lorsqu'ils sont appliqués pour segmenter les lésions SEP. Ces trois méthodes sont comparées à la segmentation originale sur un ensemble d'images cérébrales IRM. Afin d'étudier la robustesse du FPSO-PCM pour la segmentation cérébrale IRM, nous avons utilisé des images de test de taille 256x256, corrompues par différents niveaux de bruit gaussien blanc (0%, 3%, 4%) et de non-uniformité d'intensité (RF) (0%, 20%, 40%). Plus de 120 images IRM cérébrales de patients ont été utilisées pour le test dans nos approches proposées.

La figure 5.11 illustre les résultats obtenus après segmentation des différents tissus cérébraux d'images (a), (b) et (c) pondérées en T2, DP et en T1 sur des coupes axiales. Les images (d), (e), (f), (g), (h), (i), (j), (k) et (l) sont les résultats de la segmentation réalisé par FCM-PSOBC, FPSO-FCM et FPSO-PCM successivement.

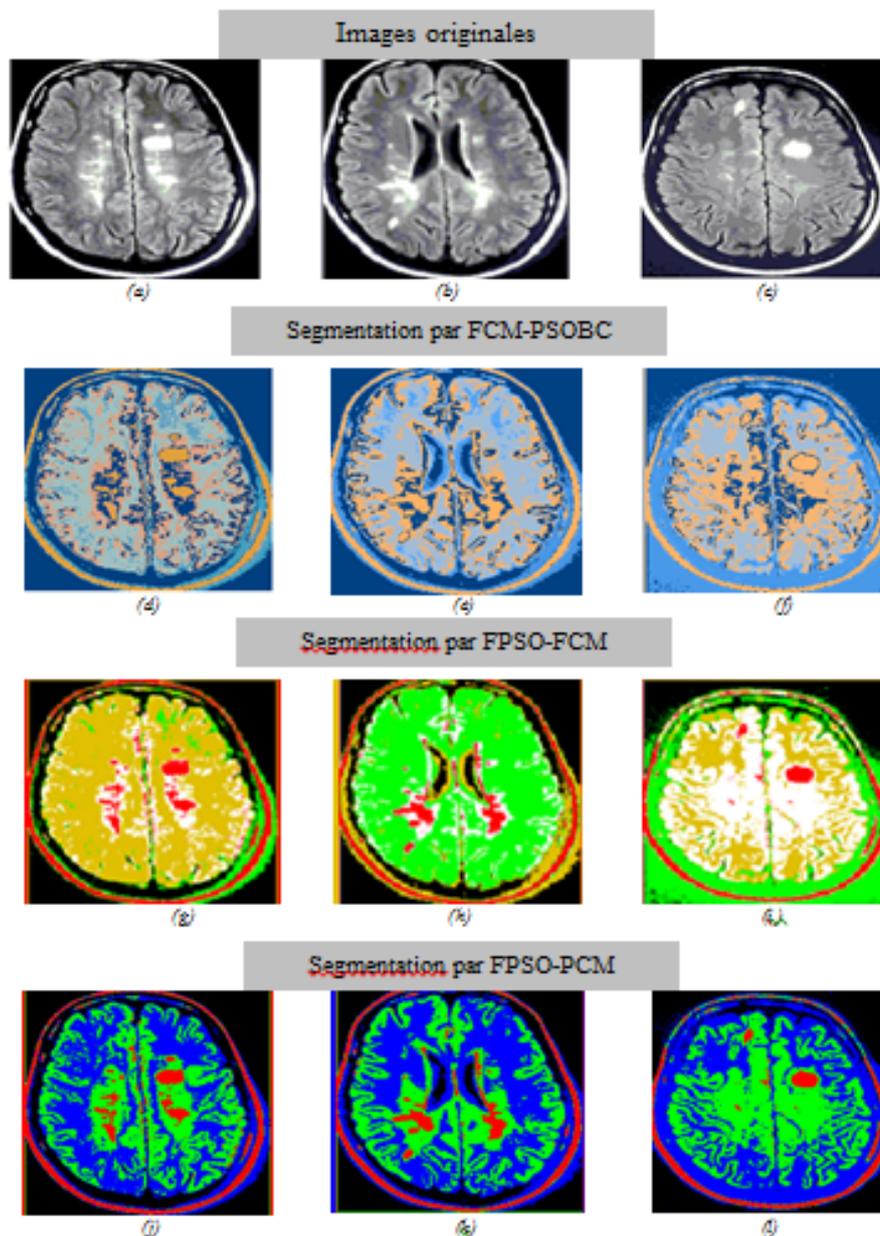


FIGURE 5.11 – Résultats de segmentation.

Les résultats de chaque étape de la segmentation sont présentés sur un niveau de coupe (Figure 5.5) dont la localisation permet de distinguer les trois classes de tissus à séparer :

- MG (pallidum, putamen, noyaux caudés, thalamus et cortex).
- MB (parenchyme cérébral).
- LCS (espaces sous-arachnoïdiens, ventricules latéraux et V3).

L'interprétation de nos résultats est déclarée par un expert (centre hospitalier d'Ain Naadja Alger). Toutes les lésions cérébrales ont été identifiées par des neurologues expé-

rimentés. En analysant les images de la figure 5.11, l'expert a établi l'énoncé suivant :

- Image (d) : FCM-PSOBC n'est pas approprié dans cette segmentation par rapport à l'image dans la ligne des résultats présentés par l'approche FPSO-PCM.
- Image (g) : Le résultat de l'algorithme FPSO-FCM n'apporte pas grand-chose par rapport à la segmentation par algorithme FCM-PSOBC.
- Image (j) : FPSO-PCM montre une performance notable dans la segmentation des trois classes et plus particulièrement la quatrième classe, qui est la pathologie qui précise bien la forme et les détails à ce sujet plus tard.

Ensuite, nous avons comparé dans le tableau 5.4 la segmentation de l'image T2-w réalisée par FCM-PSOBC, FPSO-FCM et FPSO-PCM pour une période d'acquisition donnée.

TABLE 5.4 – Comparaison des résultats obtenus par différents algorithmes

	Sensibilité (%)	Similarité (%)	Spécificité (%)
FCM-PSOBC[Zoua-16]	88.10	83.23	87.56
FPSO-FCM[Zoua-19]	91.21	90.36	91.81
FPSO-PCM[Zoua-20]	97.45	95.7	98.62

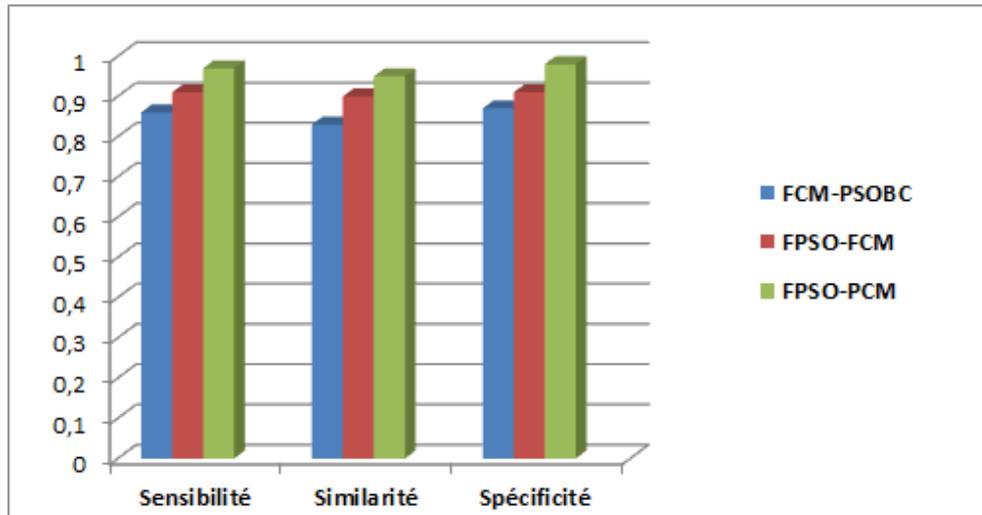


FIGURE 5.12 – Mesures de performance des résultats obtenus par des différents algorithmes.

D'après les résultats présentés dans le tableau 5.4, nous constatons que l'approche FPSO-PCM a donné les meilleurs résultats en utilisant différentes métriques : sensibilité, similarité et spécificité. Les résultats mis en évidence dans le tableau 5.5 et la figure 5.12 soulignent les avantages de l'approche FPSO-PCM par rapport à la segmentation par FCM-PSOBC et FPSO-FCM car les résultats de performance de la sensibilité pour la détection de la SEP étaient de 88,10%, 91,21% et 97,45% réalisés par FCM-PSOBC, FPSO-FCM et FPSO-PCM montrant une performance grandement améliorée de l'approche FPSO-PCM. De plus, les performances de similarité avaient des valeurs de 87,20%, 90,36% et 95,7% pour le FCM-PSOBC, le FPSO-FCM et FPSO-PCM. La spécificité pour la détection de SEP avait des performances légèrement supérieures par rapport à la sensibilité et similitude de la détection de SEP. Le FCM-PSOBC, le FPSO-FCM et FPSO-PCM ont obtenu des résultats de performance concernant la spécificité pour la détection de la SEP de 88,56%, 91,91% et 98,62% respectivement.

La segmentation du cerveau a été appliquée avec succès sur quelques images réelles (format DICOM). Les résultats sont illustrés sur les figures 5.14, 5.15 et 5.16.

TABLE 5.5 – Propriétés des images utilisées.

Nature	Images IRM Cérébrales
Pondérations	T1, T2, densité de proton
Coupes	Axiales, sagittales, coronales
Taille	256*256
Patients	Enfants, Hommes, Femmes
Formats	DICOM

Nous avons préféré présenter les images segmentées sur des coupes différentes afin de prouver l'efficacité des approches proposées.

Pendant tout le processus de segmentation des images, nous avons remarqué que le temps nécessaire pour segmenter une image (nombre d'itérations de chaque algorithme ≥ 50 , taille 256*256) est très élevé. C'est pour ça qu'on a choisi $\varepsilon = 0,02$

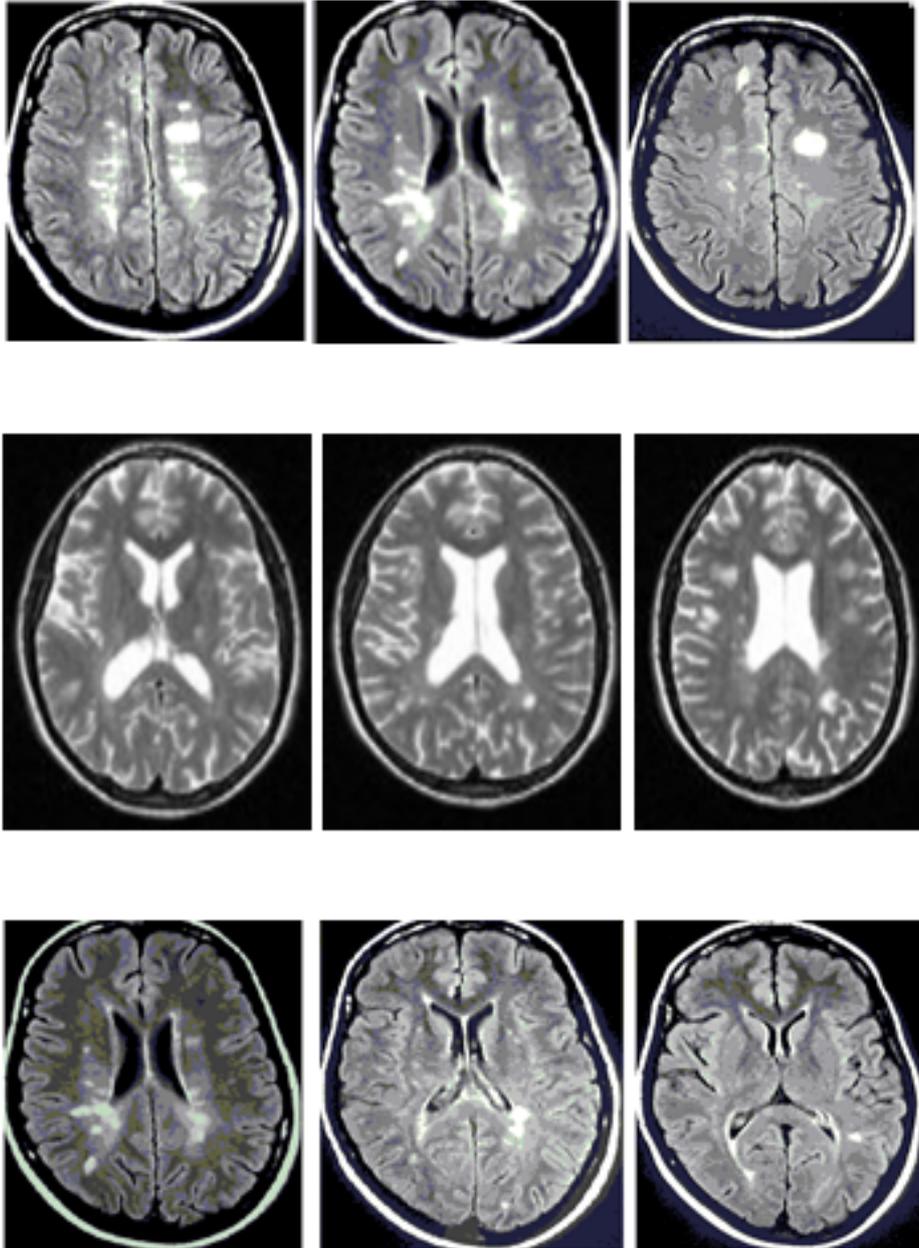


FIGURE 5.13 – Images originales : différentes coupe axiales et différentes pondérations (T1, T2, DP).

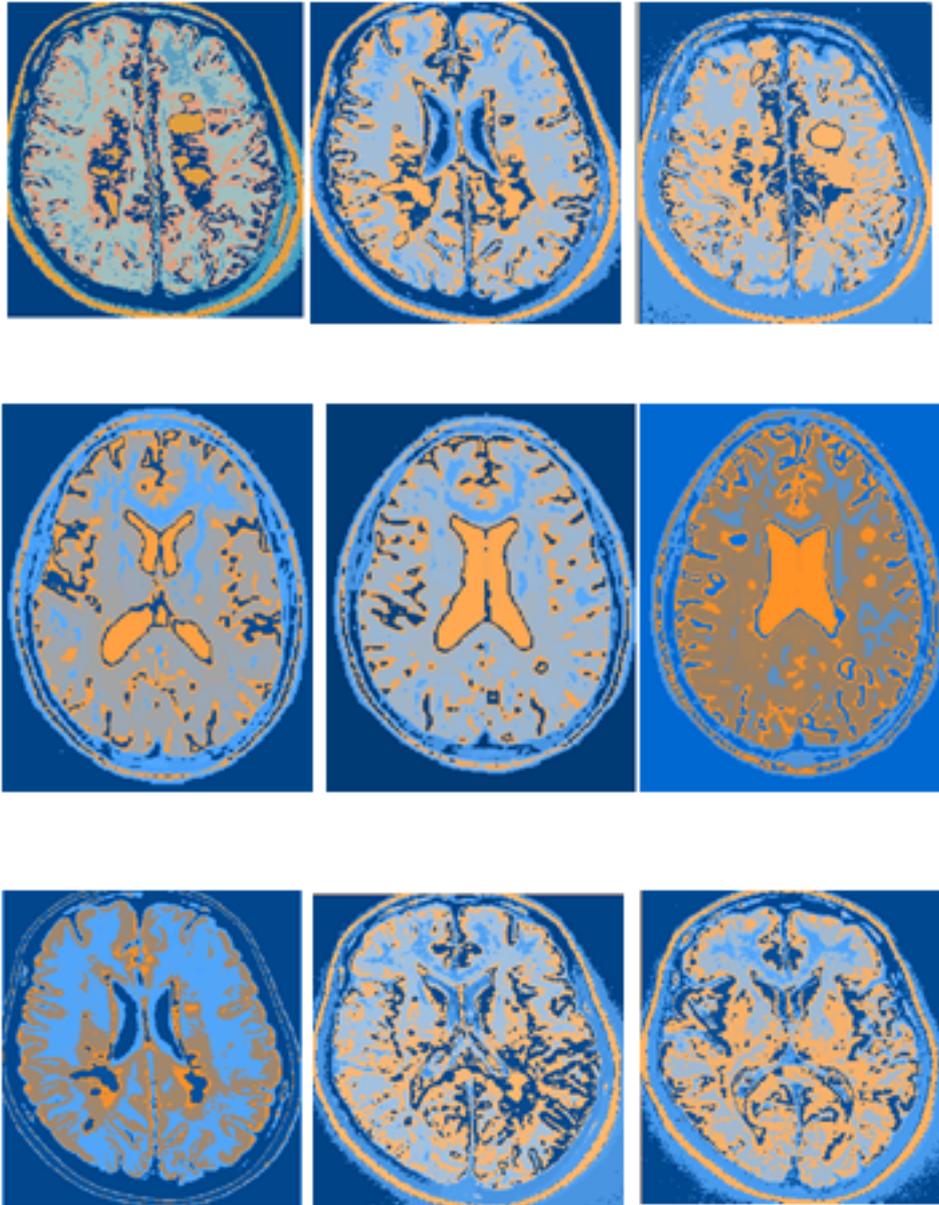


FIGURE 5.14 – Segmentation par FCM-PSOBC.

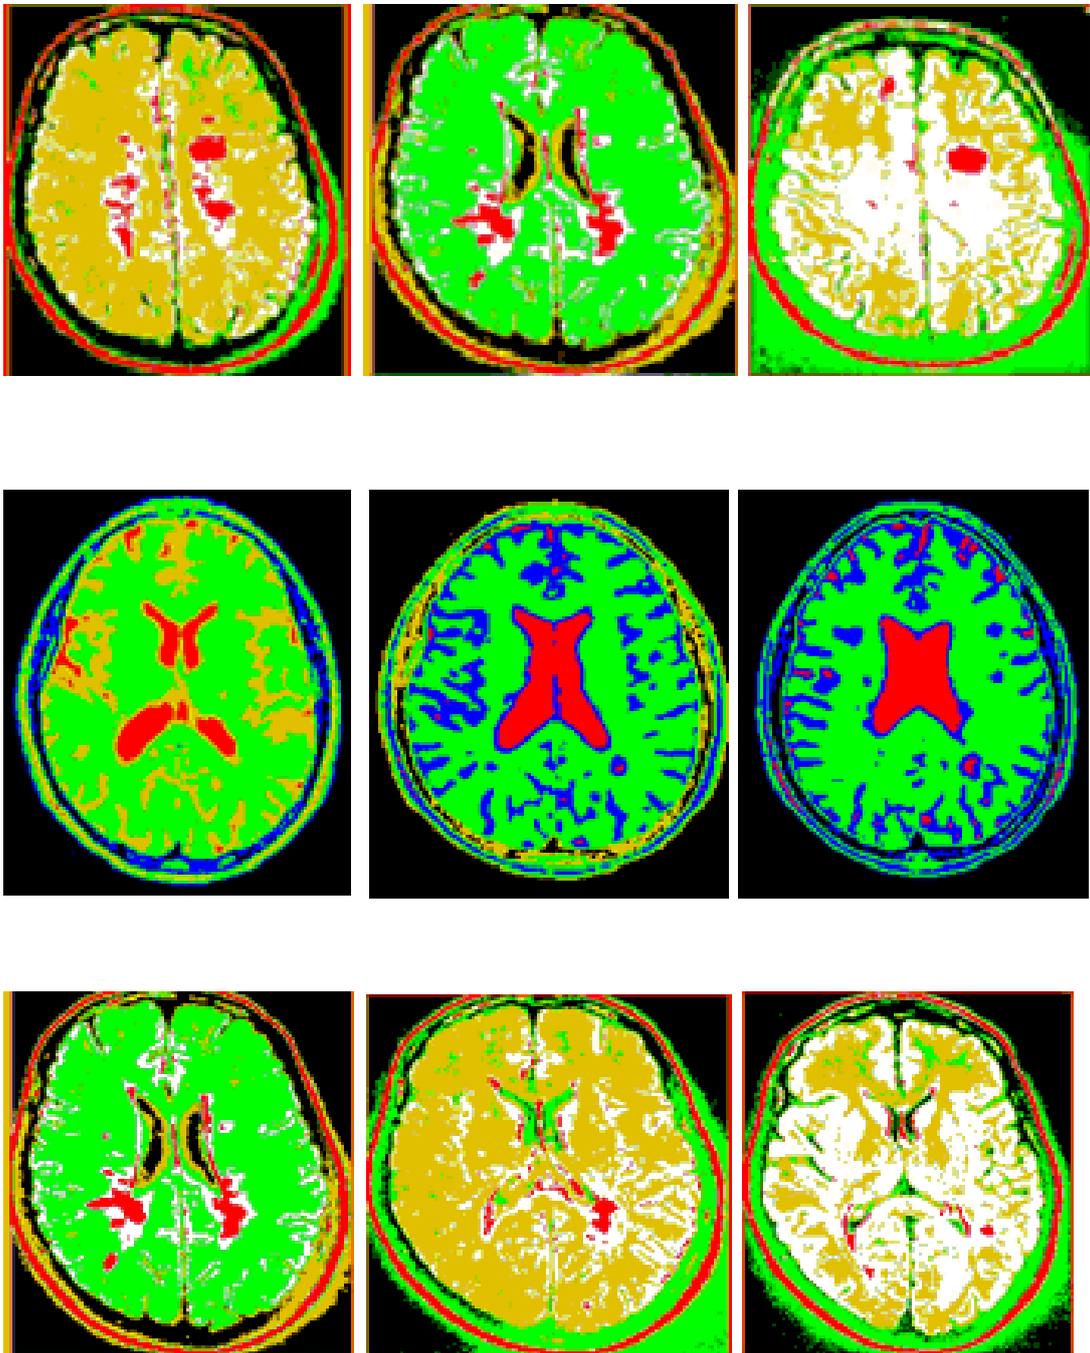


FIGURE 5.15 – Segmentation par FPSO-FCM.

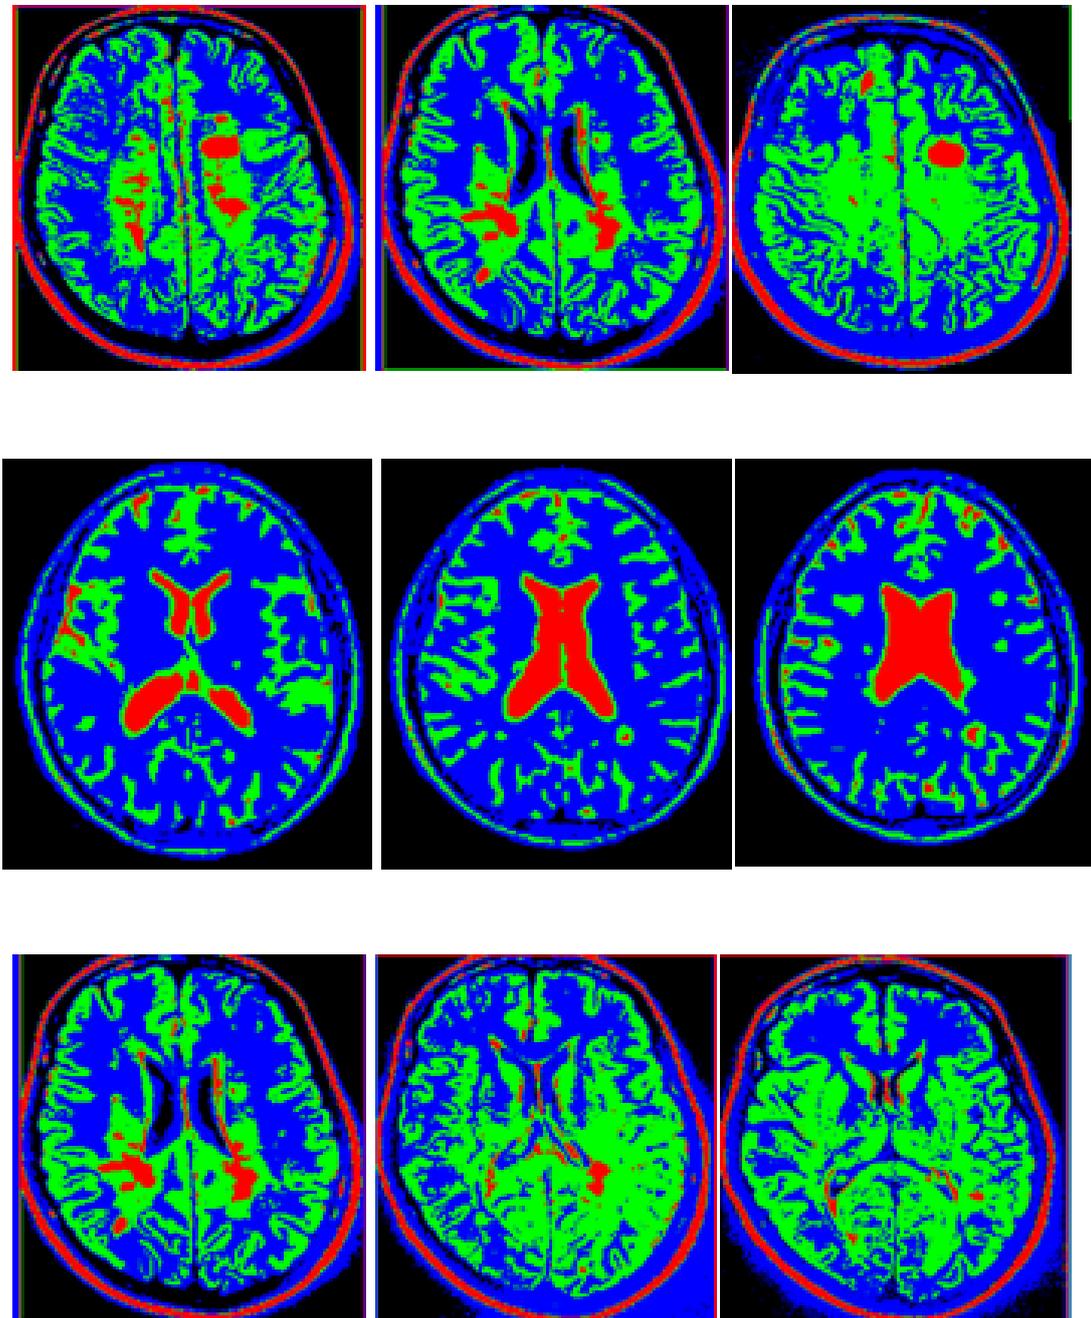


FIGURE 5.16 – Segmentation par FPSO-PCM.

5.7 Conclusion

Dans ce chapitre, nous avons tout d'abord évalué la méthode de segmentation des tissus cérébraux proposée. Nous avons appliqué nos contributions sur des images de synthèses et des images réelles pour la segmentation des classes normales (MG, MB, LCR) et de classe pathologique (la sclérose en plaque).

Les avantages de nos approches sont les suivants :

1. Ils sont totalement automatique.
2. Ils aident au diagnostic d'une maladie.
3. Ils répondent aux contraintes de l'application.
4. Ils sont efficace en présence des points aberrants.
5. Ses performances sont meilleures que celle de la méthode supervisée.
6. Ce sont des systèmes à base de la théorie floue et d'optimisation.
7. Ils sont efficace sur au moins deux types de tissus.

Conclusion générale

La localisation et la quantification des structures cérébrales font appel à la synthèse de diverses informations issues non seulement de l'imagerie, mais également des connaissances anatomiques et fonctionnelles relatives à ces structures et la pathologie qui les affectent. Le clinicien compile et réalise la synthèse de ces différentes informations pour livrer un diagnostic fiable et précis. Le but étant, à travers la modélisation de ce processus par des méthodes de segmentation, de fournir un outil de classification et de quantification volumique et fonctionnelle des structures cérébrales.

Après avoir opéré une revue bibliographique sur la segmentation dans les chapitres précédents, nous avons établi l'importance et les difficultés de ces 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 et 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 émane du fait que la donnée issue de l'acquisition IRM est sensible au bruit de fond et à l'échantillonnage. Ainsi un voxel peut appartenir à des tissus de différentes natures ce qui cause l'effet dit de volume partiel.

Cette thèse porte sur les méthodes automatiques de segmentation des lésions de la SEP dans des images par résonance magnétique. Cette segmentation joue un rôle très important dans les études cliniques où la mesure précise du volume des lésions est utilisée comme biomarqueur. De ce fait, nous nous sommes intéressés dans notre travail à l'évolution de la méthode de segmentation par l'exploitation des métaheuristiques d'optimisation. De

notre étude trois méthodes ont vu le jour : une approche FCM-PSOBC, une approche FPSO-FCM et finalement une approche FPSO-PCM.

La première méthode proposée porte sur l'amélioration de la méthode de segmentation d'images de la maladie SEP par l'algorithme des Fuzzy C-Means (FCM). Ce dernier est largement utilisé pour son efficacité qui est due principalement à son caractère flou. D'abord, Nous avons commencé notre travail par l'algorithme FCM pour segmenter l'image afin d'extraire la matière blanche (MB). Ensuite, nous avons adopté les métaheuristiques d'optimisation PSOBC pour écarter les données atypiques (outliers) de la matière blanche. Enfin, nous avons généré un système flou de type Mamdani pour la prise de décision de la maladie SEP.

La deuxième méthode proposée est une extension de la première. Nous polarisons continuellement notre étude sur la segmentation automatique des images IRM cérébrales de la maladie SEP. Parmi les méthodes non supervisées présentées, nous nous sommes intéressés à l'algorithme Fuzzy C-Means (FCM). Son principal avantage est son adaptation où les données manipulées se chevauchent ou lorsque l'information à traiter est imprécise et incertaine, ce qui est le cas des images IRM cérébrales de la maladie SEP. Cependant, son inconvénient majeur est lié à l'initialisation aléatoire des centres des classes. Pour corriger ce dernier, nous avons proposé d'utiliser l'algorithme d'optimisation FPSO pour segmenter l'image IRM afin d'obtenir la matière blanche. Puis, nous avons adopté l'algorithme FCM pour extraire les données aberrantes de cette dernière. Enfin, nous avons intégré un modèle flou de type Mamdani pour la prise de décision de la maladie SEP.

La dernière méthode proposée est une extension de la deuxième. Nous focalisons encore notre travail sur la segmentation automatique des images IRM cérébrales de la maladie SEP. Parmi les méthodes non supervisées présentées, nous nous sommes intéressés à l'algorithme Possibilistic C-Means (PCM) car contrairement à FCM, l'algorithme PCM est bien adapté à la segmentation des données aberrantes (bruit) présentes dans une image IRM de la maladie SEP. La méthode proposée se déroule en trois étapes. Premièrement, une segmentation du tissu cérébral en MG, MB et LCR est effectuée à l'aide de l'algorithme Fuzzy Particle Swarm Optimization (FPSO). Ceci est suivi d'une deuxième étape où les lésions sont segmentées en tant que valeurs aberrantes par rapport au tissu cérébral apparent normal de la MB à l'aide d'un algorithme Possibilistic C-Means (PCM). Enfin,

nous avons intégré un système de prise de décision utilisant un modèle d'inférence floue de type Mamdani pour identifier les lésions de la SEP.

Nous avons présenté les résultats de notre travail qui consiste à utiliser plus d'un algorithme pour segmenter des images médicales en vue d'améliorer la véracité de la détection des lésions de la SEP. La segmentation a été réalisée sur des images IRM cérébrales bidimensionnelles, les résultats obtenus après segmentation sur un ensemble de données sont satisfaisants.

Le choix de nos solutions tient au fait que :

- Ce sont des méthodes totalement automatique grâce aux modélisations des connaissances a priori des experts neuroradiologues. La théorie floue est importante pour modéliser les connaissances humaines en utilisant les fonctions mathématiques et pour résoudre l'effet de volume partiel d'IRM.

- Ses performances sont meilleures que celle de la méthode supervisée.
- Ce sont des systèmes basés sur la théorie floue et des métaheuristiques.

Les débouchés d'amélioration et de développement de ce travail sont multiples :

Nous pouvons envisager d'améliorer les post-traitements effectués après la détection de valeurs aberrantes afin de ne préserver que les lésions de la SEP. À l'heure actuelle, seules les valeurs aberrantes pour lesquelles la segmentation de la substance blanche donnée par nos algorithmes seront conservées. L'inconvénient de ces méthodes est qu'elles dépendent de la méthode employée de l'enregistrement. Une autre solution peut consister à utiliser la segmentation obtenue de tissus. Ainsi, nous pouvons garder les valeurs aberrantes situées dans le masque de la segmentation obtenue de la substance blanche.

La sclérose en plaques et IRM

L'objectif de cette annexe est de fixer le cadre applicatif que nous avons considéré. Dans une première partie, nous nous sommes attachés à l'étude générale de la sclérose en plaques (SEP) en traduisant ses causes, les symptômes et les signes qu'elle peut générer, 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 IRM. Nous y décrivons dans un premier temps des brefs rappels sur l'anatomie cérébrale et la formation des images. Enfin une description des différentes caractéristiques des images IRM est illustrée.

La sclérose en plaques

La sclérose en plaques est une maladie neurodégénérative chronique, inflammatoire et démyélinisante affectant le système nerveux central, où le système immunitaire est mis en cause. C'est la première cause de l'handicap non traumatique chez le jeune adulte. 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 demeure inconnue.

Fréquence

La zone dénombrant le plus haut risque de prévalence, la prévalence étant le risque que la maladie survienne à n'importe quel moment de la vie, est observée au nord de

l'Ecosse avec 250 cas pour 100 000 habitants, ce risque similaire est retrouvé au Nord de l'Europe et au Nord du continent américain, qui sont les zones les plus fortement touchées (Figure A.2). Les zones recensant le plus faible risque de prévalence (avec 6 cas pour 100 000 habitants) sont le Japon, l'Afrique du Nord et le Moyen Orient. Ainsi, on observe que le dispatching de la maladie n'est pas uniforme : géographiquement, on note un gradient Nord-Sud avec les pays les plus éloignés de l'équateur étant ceux avec le plus grand risque. Les pays industrialisés ainsi que les pays du nord de l'Europe sont plus fréquemment touchés. Cependant, il convient de noter un manque total de données pour une grande partie du continent africain, ainsi que pour plusieurs pays du Moyen-Orient.

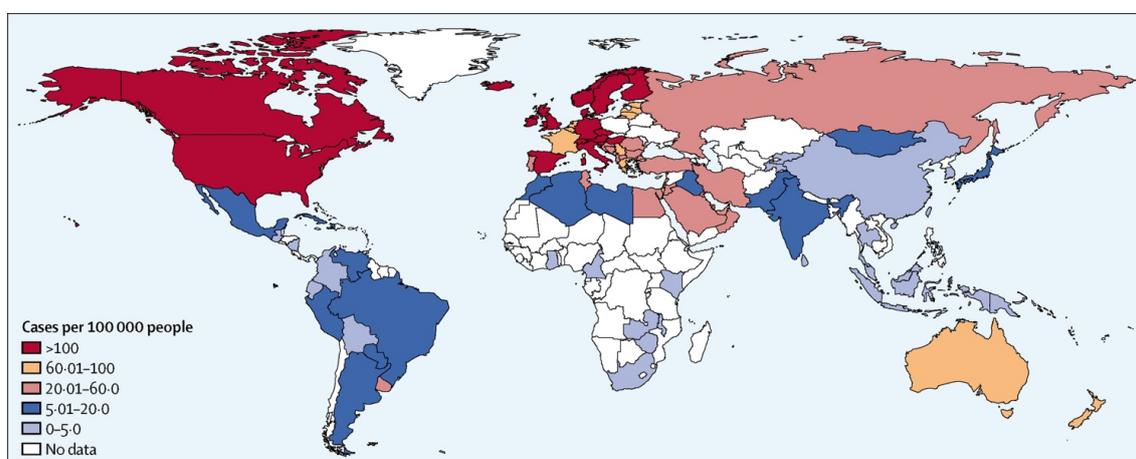


FIGURE A.1 – Prévalence mondiale de la sclérose en plaques Source : Atlas of MS 2013, MS International Federation [Lepr-19]

Causes

La cause de la SEP reste encore partiellement inconnue. Il s'agirait plutôt d'une maladie multifactorielle associant principalement des facteurs environnementaux et génétiques :

- **auto-immunité** : les dégâts 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). Le corps s'attaquerait à ses propres cellules et tissus, soit à la myéline dans le cadre de la SEP. Un virus probablement dormant dans le corps pourrait perturber le système immunitaire ou indirectement déclencher le processus auto-immun.

- **génétique** : en faveur d'un facteur génétique, 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 : on estime le risque 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 déclencher la maladie.

- **facteur d'environnement** : l'hypothèse d'un facteur d'environnement est appuyée particulièrement sur l'étude des migrations des 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, or que ceux qui migrent avant cet âge sont sujet de la région de destination [Bric-08].

Les symptômes

La SEP commence le plus souvent par une poussée au cours de laquelle les signes et symptômes apparaissent rapidement puis disparaissent en totalité ou partiellement. 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. Les principaux symptômes consistent en [Bric-08] :

- **Troubles de la vue :**

- Névrite optique : perte brutale de l'acuité visuelle précédée de douleurs à la mobilisation du globe oculaire.
- Vision floue.

- **Troubles de l'équilibre et de la coordination :**

- Perte d'équilibre, vertiges.
- Tremblements.

- **Troubles moteurs :**

- Fatigabilité à la marche.

- **Troubles sensitifs :**

- Picotements, engourdissements, sensations de brûlures.
- Douleurs faciales, musculaires ou articulaires.
- Troubles de la parole avec ralentissement et modification de sa cadence.
- Troubles génito-sphinctériens (soit incontinence, soit rétention).
- Troubles de la mémoire et de la concentration.

Les différentes formes évolutives de la SEP

Cette classification divise la maladie en plusieurs phénotypes cliniques, comme détaillé en Figure A. 2 [Lepr-19] :

— La forme rémittente-récurrente (SEP-RR)

La forme rémittente-récurrente est la plus répandue avec environ 85% des patients nouvellement diagnostiqués en sont atteints. Elle commence par une première poussée. Cette forme est caractérisée par des périodes de poussées définies par l'apparition des symptômes neurologiques connus ou nouveaux alternées avec des périodes où ces signes pourront disparaître en partie (SEP rémittente avec séquelles) ou en totalité (SCI avec récupération complète). Lors de ces phases de repos de la maladie, le handicap ne progresse pas.

— La forme secondairement progressive (SEP-SP)

La forme initialement par poussées, la SEP-RR, est quasi régulièrement suivie par une phase de progression secondaire. En effet, 50% des patients ayant été diagnostiqués avec une forme rémittente-récurrente voient leur maladie passer sur un mode secondairement progressif après dix ans d'évolution et 90% après 25 ans (57). La forme progressive se caractérise par une progression du handicap sur plus de 6 mois et cela en dehors de toute poussée. En moyenne, la conversion de la SEP-RR en SEP-SP a lieu 7 à 14 ans l'apparition de la maladie. Cet intervalle de conversion pourrait devenir plus long grâce aux derniers nombreux progrès thérapeutiques effectués. Cette forme de la maladie peut s'accompagner ou non de poussées.

— La forme primaire progressive sans poussées (SEP-PP)

Cette forme concerne 10 à 15% des patients. La progression de la maladie se fait d'emblée sur un mode lent et continu et peut comporter des phases d'amélioration minime ou non. La progression du handicap est constante.

— **La forme rémittente progressive ou progressive à rechutes (SEP-PR)**

De même que pour la SEP-PP, il existe dès le début une progression continue de la maladie mais avec des poussées surajoutées. Il peut exister ou non une récupération après les poussées, avec toutefois une aggravation lente et sans interruption entre ces poussées.

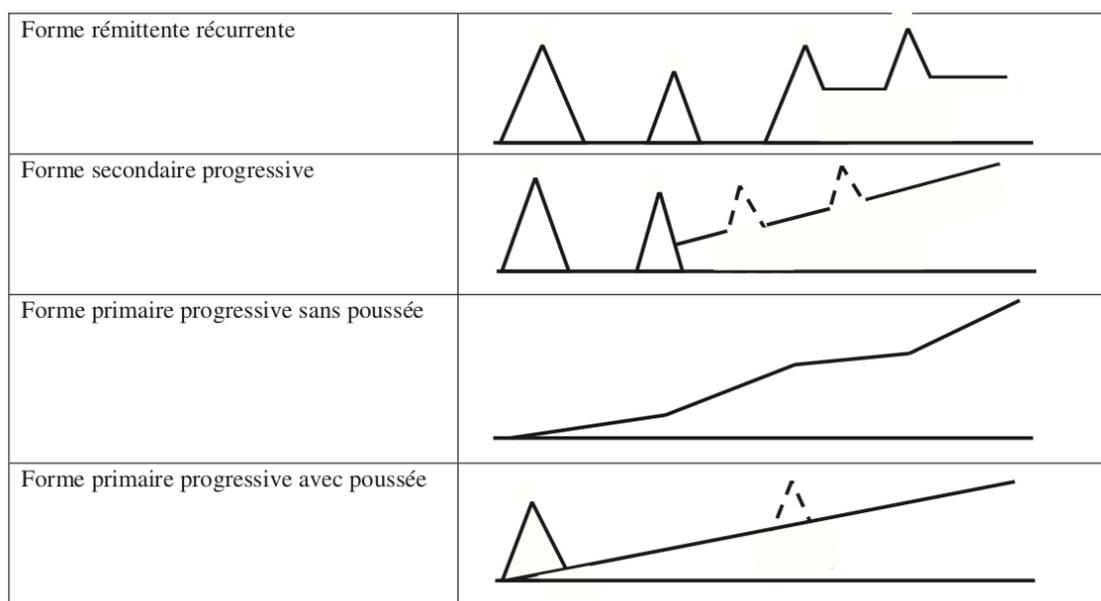


FIGURE A.2 – Les différentes formes de SEP [Lepr-19].

Diagnostic de la sclérose en plaques

Ces dernières années, le diagnostic de la sclérose en plaques s'est largement amélioré. Dans 70 % des cas, la SEP se déclare en moyenne à partir de 30 ans, et plus généralement entre l'âge de 20 et 40 ans. Comme il n'existe pas de marqueurs biologiques de la maladie, visualisables dans le sang par exemple, les médecins fondent leur diagnostic sur un ensemble d'arguments cliniques, paracliniques et évolutifs [Duti-15].

A. L'examen Clinique : évolution des symptômes

C'est l'examen Clinique (c'est-à-dire l'examen pendant la consultation) qui peut mettre à jour le diagnostic de SEP. Certains symptômes (Les symptômes de la SEP) ressentis par le patient peuvent alerter : les troubles moteurs (comme l'apparition d'une faiblesse musculaire, qui crée une gêne à la marche, ou encore des pertes d'équilibre) ; les troubles sensitifs (engourdissements, fourmillements. . .), les troubles visuels, les pertes de mémoire, une incontinence, l'impuissance sexuelle. . .

Cet examen clinique des symptômes permet aussi au neurologue d'écartier toute autre affection entraînant des symptômes similaires. D'où l'importance de faire part de tous ces troubles à son médecin, de lui expliquer l'impact qu'ils ont sur le quotidien. En cas de doute sur la sclérose en plaques, le médecin demandera des examens complémentaires (IRM, ponction lombaire).

B. Les examens complémentaires

Plusieurs processus sont nécessaires pour asseoir un diagnostic certains. Les signes variant d'un patient à l'autre, divers examens sont possibles :

- L'imagerie par résonance magnétique (IRM) permet de visualiser le système nerveux central et d'avoir ainsi des images précises des lésions du cerveau et de la moelle épinière provoquées par la sclérose en plaques. Elle permet également de localiser ces lésions.
- La ponction lombaire permet de rechercher des signes d'inflammation dans le liquide céphalo-rachidien (LCR, liquide dans lequel baignent le cerveau et la moelle épinière). Dans la sclérose en plaques, on retrouve souvent une production anormale d'anticorps répartis sous la forme de « bandes oligoclonales ». L'analyse du LCR permet également d'éliminer d'autres causes que la SEP.

Dans cette étude, nous nous intéressons aux images cérébrales acquises par l'imagerie par résonance magnétique nucléaire (IRM), car elle nous permet d'obtenir d'excellentes images du cerveau. Dans ce qui suit nous présentons le principe général d'IRM. Mais avant tout nous décrivons brièvement l'anatomie du système nerveux central ainsi que les terminologies nécessaires à la compréhension de cette thèse.

Eléments d'anatomie cérébrale

L'encéphale

C'est la partie supérieure du système nerveux central, constitué du tronc cérébral, du cervelet et du cerveau. Il assure le contrôle de l'ensemble de l'organisme [Semc-18]. L'encéphale est contenu à l'intérieur de la boîte crânienne (Figure A.3).

– **Le cerveau** : c'est la partie la plus élevée, la plus volumineuse et la plus complexe de l'encéphale. Il se situe au-dessus du tronc cérébral et du cervelet. Le cerveau est partagé en deux hémisphères droit et gauche réunis par le cerveau moyen, ou diencephale, et par le corps calleux. Le cerveau est constitué, comme le reste du système nerveux central, de matière grise (corps des neurones et des synapses) et de matière blanche (fibres myélinisées). Le cerveau baigne dans un liquide jouant le rôle d'un amortisseur appelé liquide céphalo-rachidien (LCR).

– **Le cervelet** : partie de l'encéphale située à la base du crâne, en arrière du tronc cérébral, est responsable de la coordination de l'activité musculaire nécessaire à l'équilibre et aux mouvements.

– **Le tronc cérébral** : il forme la transition entre le cerveau et la moelle épinière. Il est responsable du contrôle de la respiration, de la fréquence cardiaque et de la pression sanguine. Le tronc cérébral est aussi impliqué dans les réflexes de vomissements et le contrôle de la douleur.

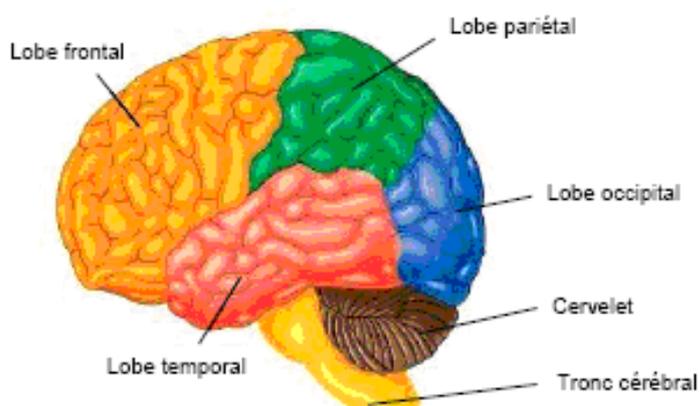


FIGURE A.3 – Structures anatomiques de l'encéphale [Zoua-08].

Les principaux tissus cérébraux

Le liquide céphalo-rachidien (LCR)

Le liquide céphalo-rachidien ou cérébro-spinal (en anglais cérébro-spinal fluid) entoure le cerveau et remplit les ventricules cérébraux. Il permet de protéger le cerveau des chocs en jouant un rôle d'amortisseur, et assure des fonctions importantes dans le transport des hormones entre les diverses régions du cerveau [Semc-18].

La matière grise (MG)

La matière grise constitue la partie des tissus du système nerveux central concentrant les corps cellulaires des neurones et des cellules gliales. Elle apparaît plus foncée que le reste du tissu et elle est présente principalement au niveau du cortex cérébral, du cortex cérébelleux, dans les noyaux gris centraux, dans les noyaux du tronc cérébral et à l'intérieur de la moelle épinière. La matière grise constitue le cœur du traitement de l'information nerveuse : réception des messages, élaboration des réponses et l'analyse complexe des informations [Semc-18].

La matière blanche (MB)

la partie interne du cerveau qui contient des fibres nerveuses myélinisées, elle est de couleur blanchâtre et brillante (couleur de la myéline). Le rôle de la substance blanche est de garantir la bonne circulation des informations entre les différentes parties du système nerveux.

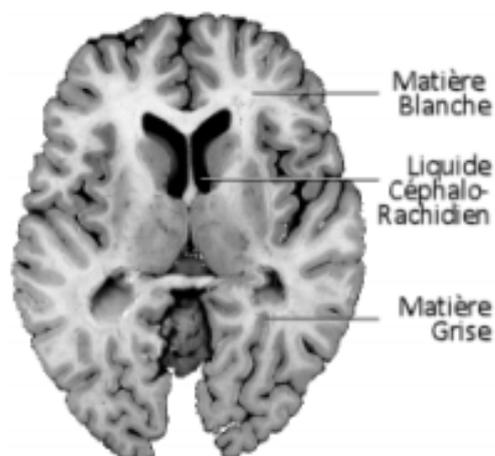


FIGURE A.4 – Les principaux tissus cérébraux sur une IRM.

Observation du cerveau

La visualisation du cerveau par des coupes en deux dimensions peut être effectuée selon plusieurs angles de vue. Ainsi, on distingue trois axes anatomiques pour réaliser les différentes coupes (Figure A. 5).

1. Coupes axiales : ces coupes correspondent à un plan horizontal. En IRM, elles correspondent à un plan perpendiculaire à l'axe du champ magnétique principal.

2. Coupes sagittales : ces coupes sont effectuées dans des plans parallèles au plan inter hémisphérique. Il s'agit des vues latérales du cerveau.

3. Coupes coronales : ce sont des coupes verticales aux coupes axiales et sagittales. Il s'agit des vues frontales du cerveau.

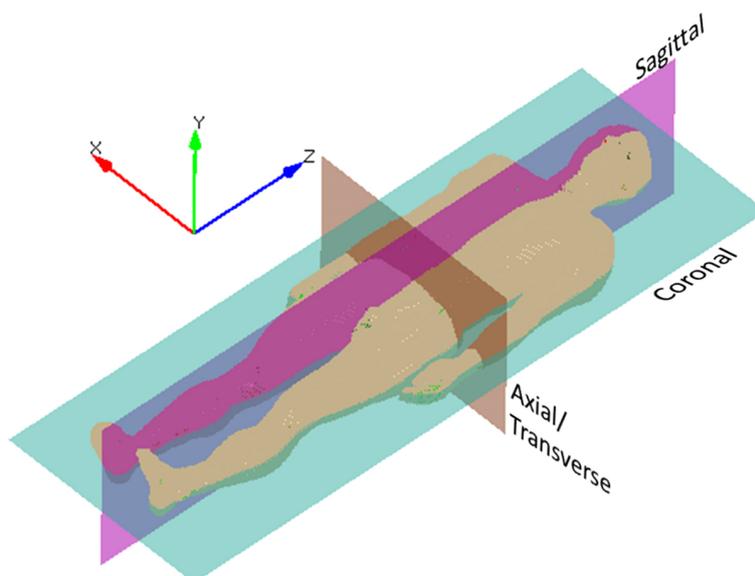


FIGURE A.5 – Les trois vues des IRM cérébrales.

Imagerie par Résonance Magnétique (IRM)

L'imagerie par résonance magnétique est une technique récente qui permet de produire des images anatomiques dans des plans multiples et qui peut fournir des informations sur la composition des tissus. La première acquisition d'IRM a été produite en 1973 par Lauterbur et Damadian. L'IRM est souvent utilisée pour la détection, le diagnostic et la surveillance de l'évolution des maladies présentes dans les tissus mous. C'est l'examen complémentaire le plus souvent anormal dans la SEP [Beny-15].

1. Elle montre de nombreuses petites zones arrondies, hypo signaux en T1 et hyper signaux en T2 (mieux visibles en séquences FLAIR), siégeant dans la substance blanche, notamment péri ventriculaire; des lésions en hypo signal en T1 et prenant le contraste (gadolinium) sont en général récentes; les lésions médullaires sont aussi visualisées.

2. La sensibilité de l'IRM est grande, révélant de nombreuses lésions cliniquement silencieuses, mais en revanche sa spécificité est faible. Il n'existe pas de corrélations entre l'importance ou le nombre des lésions visibles et les signes cliniques.

3. La spectroscopie par résonance magnétique peut apporter des arguments en faveur d'une démyélinisation, mais cette nouvelle méthode est encore en évaluation.

4. L'IRM est donc une aide au diagnostic de SEP, en étayant le caractère multiple des lésions, en montrant des lésions relativement suggestives par leur aspect et leur to-

pographie, et en éliminant d'autres diagnostics. Il est cependant inutile de faire des IRM répétées dans le suivi évolutif, en dehors des essais thérapeutiques contrôlés.

Principe général

L'IRM est une technique d'investigation très performante, parfaitement indolore et sans danger. L'IRM n'utilise pas de rayons X, elle est basée sur le principe de la résonance magnétique des protons du corps humain au sein d'un champ électromagnétique. Ce dernier est créé par un aimant géant en forme de tunnel où le patient est placé. Des ondes électromagnétiques provoquent une aimantation spécifique des noyaux d'hydrogène présents en proportions diverses dans les tissus selon leur teneur en eau. Le signal émis par les protons, lors de leur retour à leur état de base, est à l'origine de la création des images. Qui sont traitées par de puissants logiciels qui permettent de reconstruire les différentes coupes. Ces images sont visualisées sur un écran puis transformées en clichés radiographiques [Semc-12]. L'examen IRM peut être réalisé sans ou avec l'injection d'un produit de contraste dans la veine du patient afin d'optimiser la visualisation de l'organe visé.

Principe physique

Quand un corps humain est placé dans un champ magnétique puissant B_0 , les noyaux d'hydrogène libres s'alignent dans la direction de B_0 . Le moment magnétique d'un proton va tourner très rapidement autour d'un axe en décrivant un cône de révolution.

– *Phénomène de la résonance* : c'est le transfert d'énergie entre deux systèmes oscillant à la même fréquence. Le proton d'hydrogène bascule d'un état d'énergie E_1 à un état E_2 par l'application d'une onde radiofréquence RF.

– *Relaxation et temps de relaxation* : la relaxation est le retour à l'état d'équilibre de départ de l'aimantation tissulaire après l'arrêt de l'émission de la radiofréquence RF. Elle s'accompagne d'une émission d'énergie sous la forme d'ondes RF qui constituent le signal enregistré en IRM. Plus le signal émis du corps est intense, plus le point correspondant de l'image finale est blanc et inversement. Le temps de relaxation est le retour à l'équilibre des atomes d'hydrogène après leur résonance (excitation) par la radiofréquence RF. Pour chaque tissu, on distingue deux temps de relaxation : la relaxation longitudinale (T1) et la relaxation transversale (T2).

Paramètres de séquence

Les paramètres de séquence sont ceux que l'opérateur renseigne sur la console pour générer la séquence IRM correspondante.

– **Temps d'écho** : le temps d'écho (TE) indique le temps entre l'application de l'impulsion d'excitation radiofréquence RF et le sommet du signal induit dans la bobine. Il est mesuré en millisecondes.

– **Temps de répétition** : le temps de répétition (TR) est calculé par l'application d'une impulsion d'excitation et à l'application de la prochaine impulsion. Il détermine la quantité d'aimantation longitudinale qui se rétablit entre chaque impulsion. Il est mesuré en millisecondes. Le TR, comme le TE, est un facteur de contraste.

– **Angle de basculement** : l'angle de basculement α est un paramètre par lequel l'axe du proton d'hydrogène passe de son axe longitudinal (axe magnétique statique B_0) à son axe transversal par excitation à l'aide d'impulsions radiofréquences (RF). L'angle de basculement est mesuré en degrés ($^\circ$). Plus α est grand, plus les images en T1 sont contrastées.

Les séquences IRM

En changeant les valeurs des différents paramètres de séquence (TE, TR, α), une grande diversité de volumes variant par le contraste peuvent être générés.

– **Image pondérée en densité de protons (DP)** : pour un TR long et un TE court, on obtient une séquence pondérée en densité de protons DP. Les tissus sont ordonnés par niveaux de gris croissants en MB, MG et LCR.

– **Image pondérée en T2** : pour un TR long et un TE long, on obtient une image pondérée en T2. Les tissus sont ordonnés par niveaux de gris croissants en MB, MG et LCR.

– **Image pondérée en T1** : pour un TR court et un TE court, l'image obtenue est pondérée en T1. Les tissus sont ordonnés par niveaux de gris croissants en LCR, MG et MB.

Chaque séquence IRM contient des informations spécifiques, donc, le choix entre les différentes séquences dépend de la structure à étudier.

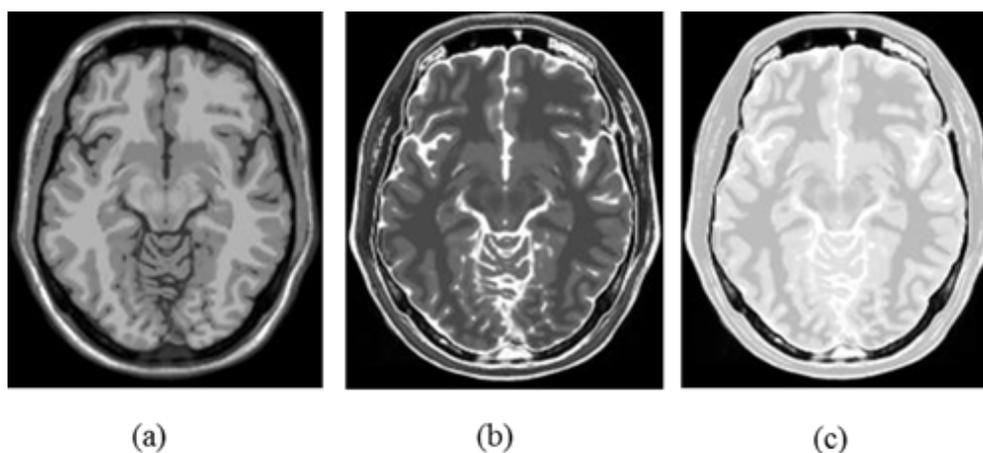


FIGURE A.6 – Les séquences IRM : (a) image pondérée en T1, (b) image pondérée en T2, (c) image pondérée en DP.

Artefacts des images IRM

Les sources d'artefacts (erreurs) en IRM sont nombreuses et de nature variée. Elles sont différentes de celles observées dans d'autres domaines du traitement d'images. Parfois, l'image IRM contient des structures qui ne sont pas réellement présentes. Ces artefacts peuvent imiter les pathologies, orientant à des diagnostics erronés. On distingue essentiellement trois types d'artefacts. Les artefacts physiologiques qui sont causés par le mouvement du patient, (la respiration, le rythme cardiaque et le flux sanguin). Les artefacts qui peuvent résulter de la physique inhérente de l'IRM, comme la présence de métal ou de changement chimique. Enfin, ceux liés aux matériels et logiciels dans la construction d'images IRM. On présente dans la suite de cette section, les principaux artefacts [Semc-18] :

– **Le bruit** : le bruit en IRM a des origines variées, liées en grande partie aux propriétés physiques, au contexte d'acquisition et au patient lui-même (mouvement, agitation, etc.). Tous les constructeurs d'appareillage d'imagerie médicale, visent l'amélioration du rapport signal/bruit tout en maintenant une bonne résolution.

– **Effet du volume partiel** : l'effet du volume partiel se produit pendant le processus de numérisation du signal dans le cas où la résolution spatiale (voxel) dépasse la taille des objets présents dans l'image ou lorsque les structures cérébrales se chevauchent. Ainsi, le niveau de gris de ce voxel sera un mélange des niveaux de gris de chaque objet (Figure A.7).

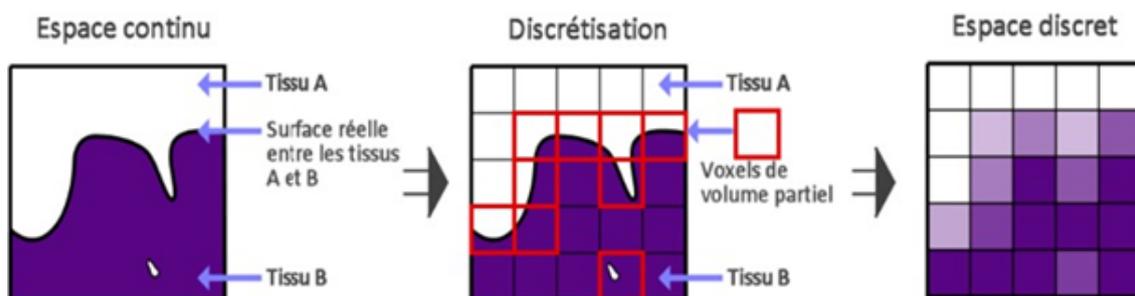


FIGURE A.7 – L'effet du volume partiel en IRM.

En IRM cérébrale, cet artefact se manifeste principalement aux frontières entre les substances cérébrales (MG, MB, LCR, graisse, os). L'effet du volume partiel est atténué par l'usage d'une taille de voxel plus petite.

– **Inhomogénéité de la radio fréquence (RF)** : la variation de l'intensité d'un même tissu à travers l'image peut être due à la défaillance de la bobine RF, au champ RF non uniforme spatialement et temporellement, ou à la sensibilité non uniforme de la bobine de réception.

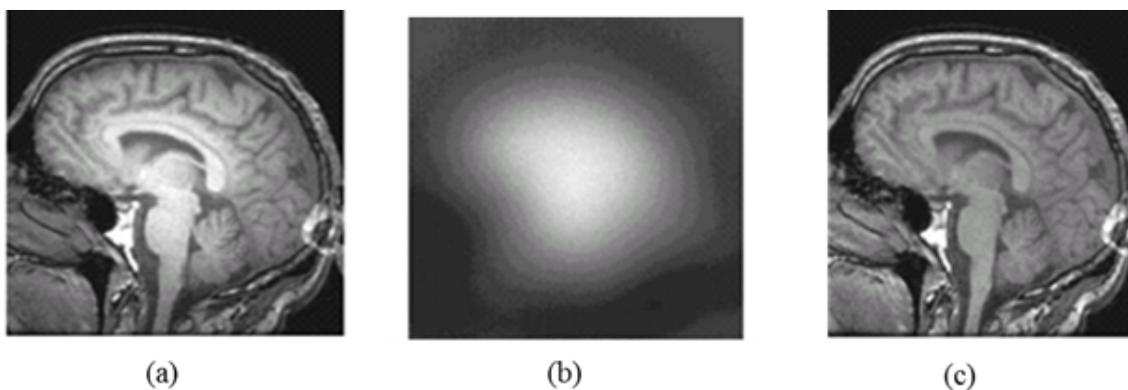


FIGURE A.8 – L'inhomogénéité RF : (a) Image affectée par une inhomogénéité RF, (b) L'artefact RF isolé, (c) Image sans artefact .

Concepts fondamentaux de la logique floue

Traiter facilement les connaissances imprécises et/ou incertaines, selon la logique classique, n'est pas autorisé. La logique floue a été proposée et introduite par [Zade-65] pour modéliser le langage naturel et pour gérer l'imprécis et l'incertain.

Dans cette annexe, nous présentons un aperçu de la théorie des sous-ensembles flous en présentant ses concepts de base ainsi que ses principales caractéristiques.

La logique floue

La logique floue s'appuie sur la théorie mathématique des ensembles flous. C'est une théorie formelle et mathématique dans le sens où Zadeh, en partant du concept de fonction d'appartenance pour modéliser la définition d'un sous ensemble d'un univers donné, a élaboré un modèle complet de propriétés et de définitions formelles. Il a aussi montré que la logique floue est une théorie qui intègre l'expérience, l'intuition, la connaissance et la nature imprécise de la prise de décision humaine depuis un ensemble de règles. Une caractéristique très intéressante des systèmes flous est leur capacité à traiter le même cadre les informations numériques et linguistiques. Cette caractéristique a rendu ces systèmes très utiles pour traiter les tâches de contrôle des experts [Kiiy-20].

La théorie des sous-ensembles flous

Selon la théorie des ensembles, un élément doit être inclus ou exclu d'un ensemble. L'idée de l'ensemble est à l'origine de nombreuses théories mathématiques. Ce concept élémentaire ne permet cependant pas de rendre compte des situations simples et régulières.

Nous pouvons aisément identifier des pommes dans un tas de fruit. Cependant, il sera plus complexe d'identifier l'ensemble des pommes mûres. Il est admis que la pomme mûrit progressivement, la notion de pomme mûre est donc graduelle. C'est pour la prise en compte de telles situations qu'a été créée la notion d'ensemble flou. La théorie des ensembles flous repose sur la notion d'appartenance partielle : chaque élément appartient partiellement ou graduellement aux ensembles flous qui ont été définis. Les contours de chaque ensemble flou ne sont pas « nets », mais « flous » ou « graduels » [Chev-98].

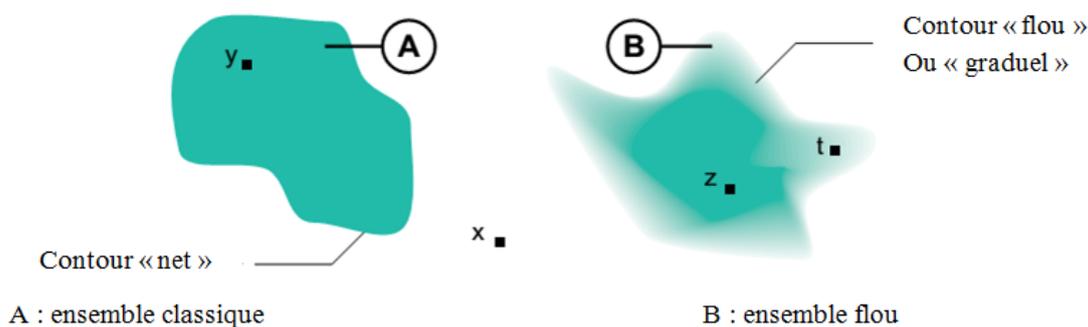


FIGURE B.1 – Comparaison d'un ensemble classique et d'un ensemble flou [Chev-98].

- X n'appartient ni à A ni à B
- Y appartient totalement à A
- Z appartient totalement à B
- T appartient partiellement à B

Opérations de base sur les sous-ensembles flous

Supposons que A et B sont deux sous-ensembles flous définis dans un univers du discours X par les fonctions d'appartenance μ_A et μ_B . On peut définir des opérations ensemblistes telles que l'inclusion, l'intersection, l'union et le complément grâce à des opérations sur les fonctions d'appartenance [Mera-08].

Inclusion

A est dit inclus dans B , propriété que l'on note $B \subseteq A$, si tout élément x de X qui appartient à A appartient aussi à B avec un degré au moins aussi grand :

$$\forall x \in X : \mu_A(x) \leq \mu_B(x). \quad (\text{B.1})$$

Intersection

L'intersection de A et B , que l'on note $B \cap A$, est le sous-ensemble flou constitué des éléments de X affectés du plus petit des deux degrés d'appartenance μ_A et μ_B :

$$\forall x \in X : \mu_{A \cap B} = \min(\mu_A(x), \mu_B(x)). \quad (\text{B.2})$$

Union

L'union de A et B , que l'on note $B \cup A$, est le sous-ensemble flou constitué des éléments de X affectés du plus grand des deux degrés d'appartenance μ_A et μ_B :

$$\forall x \in X : \mu_{A \cup B} = \max(\mu_A(x), \mu_B(x)). \quad (\text{B.3})$$

Complément

Le complément de A , que l'on note A^c , est le sous-ensemble flou de X constitué des éléments x lui appartenant d'autant plus qu'ils appartiennent peu à A :

$$\forall x \in X : \mu_{A^c} = 1 - \mu_A(x). \quad (\text{B.4})$$

Les caractéristiques d'un sous ensemble flou

Un ensemble flou F de l'univers X est caractérisé par [Mezh-12] :

Le noyau

Noté $\text{noy}(F)$, qui représente l'ensemble des éléments de X pour lesquels la fonction d'appartenance $\mu_F(x)$ vaut 1 :

$$\text{Noy}(F) = \{x \in X / \mu_F(x) = 1\} \quad (\text{B.5})$$

Le support

Noté $\text{supp}(F)$, qui représente l'ensemble des éléments de X appartenant, même très peu, à F , c.-à-d., ayant $\mu_F(x)$ qui n'est pas nulle :

$$\text{Supp}(F) = \{x \in X / \mu_F(x) \neq 1\} \quad (\text{B.6})$$

La hauteur

Notée $h(F)$, qui représente la plus grande valeur prise par sa fonction d'appartenance :

$$h(F) = \sup_{x \in X} \mu_F(x). \quad (\text{B.7})$$

α - coupe

Qui représentent l'ensemble contenant les éléments ayant un degré d'appartenance Supérieur ou égal à a :

$$\alpha - \text{coupe}(F) = \{x \in X / \mu_F(x) \geq a\} \quad (\text{B.8})$$

Variables linguistiques

La variable linguistique représente un phénomène ou une grandeur, par des termes linguistique : « quelque, beaucoup, souvent », « négative, environ zéro et positive » ce sont les valeurs linguistiques [Assa-13]. En outre, une variable linguistique est la variable dont les valeurs sont des termes, des mots ou des phrases de langage naturel. La figure B.2 illustre un exemple de la variable linguistique avec cinq termes linguistiques : très petite, petite, moyenne, grande et très grande.

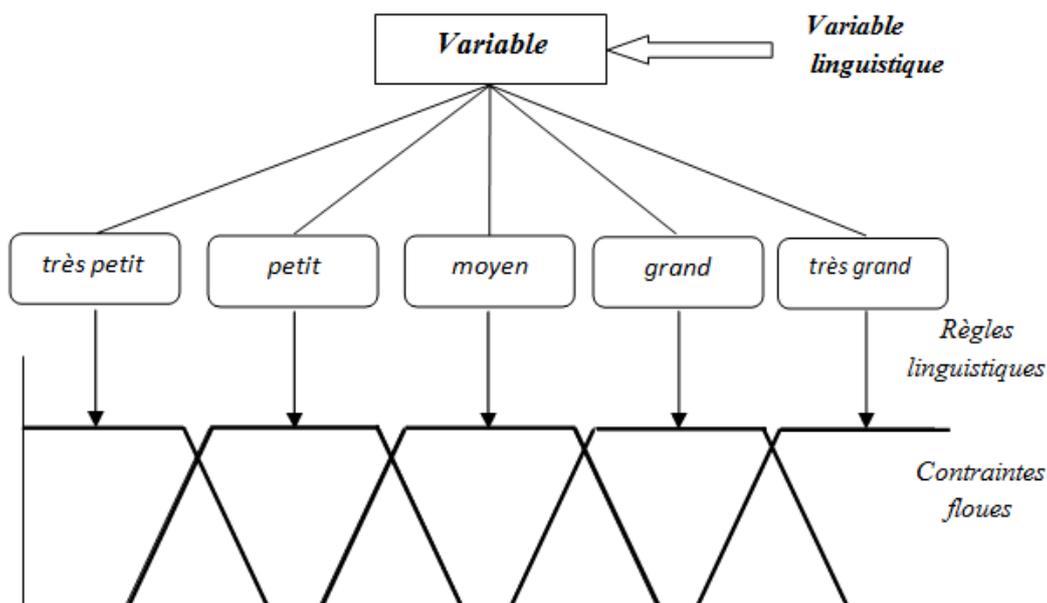


FIGURE B.2 – Variable linguistique [Mera-20].

Fonctions d'appartenance

Une fonction d'appartenance d'un ensemble flou A définie sur l'univers de discours X , notée $\mu_A(x)$ tel que $x \in X$, est une courbe qui définit comment chaque point dans l'univers de discours est tracé avec une valeur d'appartenance comprise dans l'intervalle $[0, 1]$ [Mera-20] :

Le plus souvent, nous utilisons pour les fonctions d'appartenance les fonctions suivantes (Figure B.3) [Kart-04] [Sahr-16].

- **Fonction triangulaire** : elle est définie par trois paramètres a, b, c qui déterminent les coordonnées des trois sommets (Figure B.3 (a)).

$$\mu_A(x) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right) \quad (\text{B.9})$$

- **Fonction trapézoïdale** : elle est définie par quatre paramètres a, b, c, d (Figure B.3 (b)) :

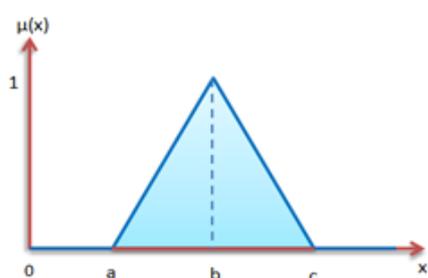
$$\mu_A(x) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{c-x}{d-x}\right), 0\right) \quad (\text{B.10})$$

- **Fonction gaussienne** : elle est définie par deux paramètres σ , m (Figure B.3 (c)) :

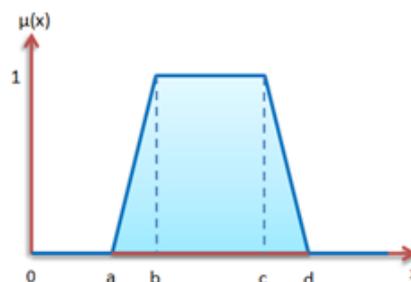
$$\mu_A(x) = \exp\left(-\frac{(x - m)^2}{2\sigma^2}\right) \quad (\text{B.11})$$

m : centre de la gaussienne

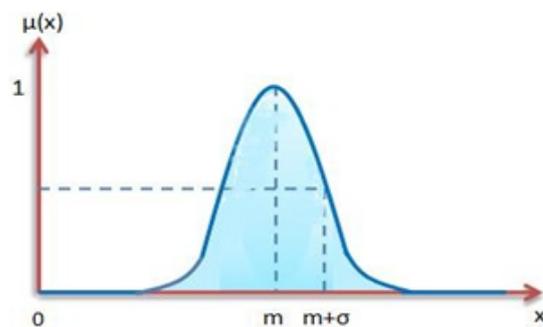
σ : sa largeur



a) Triangulaire



b) Trapézoïdale



c) Gaussienne

FIGURE B.3 – Formes usuelles des fonctions d'appartenance [Mera-20].

Bibliographie

- [Ahma-16] A. Ahmadvand and P. Kabiri. Multispectral MRI Image Segmentation using Markov Random Field Model. *Signal, Image and Video Processing*, vol. 10, no. 2, pp. 251–258, 2016.
- [Aich-14] B. Aicha. Segmentation d'images et Morphologie Mathématique: Application à l'imagerie Médicale de l'abdomen. Thèse de doctorat à l'université Abou Bekr Belkaid Tlemcen (Algérie), 2014.
- [Ait-06] L-S. Ait-Ali. Analyse Spatio-Temporelle pour le suivi de Structures Evolutives en Imagerie Cérébrale Multi Séquences. Thèse de doctorat à l'université de Rennes 1, Spécialité: Traitement du Signal et Télécommunications, 2006.
- [Alat-01] M. Alata. Control of nonlinear Systems using Sugeno Fuzzy Approximates. PhD. Canada, Concordia university (Canada), 2001.
- [Assa-13] O. Assas. Classification Floue des images. Thèse de doctorat en sciences à l'université de Batna (Algérie), 2013.
- [Baha-16] W. N. A. Baharuddin, S. N. H. S. Abdullah, S. A. Sahran, Qasem, A. bin Abdullah, R. Iqbal and F. Ismail. Type 2 Fuzzy Logic for Mammogram Breast Tissue Classification. In *Industrial Informatics and Computer Systems (CIICS)*. International Conference on, pp. 1–6. IEEE. 2016.
- [Band-02] S. Bandyopadhyay, U. Maulik. An Evolutionary Technique Based on K-Means Algorithm for Optimal Clustering in RN. *Information Sciences*, vol. 146, pp. 221–237, 2002.
- [Barr-00] V. Barra. Fusion d'Images 3D du Cerveau: Etude de Modèles et Applications. Ph.D. Thèse à l'université d'Auvergne, Clermont-Ferrand (France), 2000.
- [Barr-99] V. Barra. Segmentation floue des tissus cérébraux en IRM 3D: une approche possibiliste versus autres méthodes. PhD à l'université Blaise Pascal, 1999.
- [Belo-16] F. Beloufa. Conception d'un classifieur à base des règles floues. Thèse de doctorat à l'université Abou-Bekr Belkaid – Tlemcen (Algérie), 2016.
- [Bena-13] A. N. Benaichouche, H. Oulhadj and P. Siarry. Improved Spatial Fuzzy C-Means Clustering for Image Segmentation using PSO Initialization, Mahalanobis distance and post segmentation correction. *Digital Signal Processing* 23 1390–1400. 2013.
- [Beni-14] A. N. Benaichouche. Conception de Métaheuristiques d'optimisation pour la Segmentation d'images. Application aux Images IRM du Cerveau et aux Images de Tomographie Par Emission De Positons. Thèse de doctorat à l'université Paris-EST. 2014.
- [Beny-15] F. Z. Benyoussef. Profile Epidémiologique de la Sclérose en Plaques Au Service De Neurologie. Mémoire de fin d'étude pour l'obtention du diplôme de docteur en médecine. 2015.
- [Batk-19] A. Betka. Estimation de Mouvement par les Techniques Métaheuristique, PhD à l'université Mohamed Khider-Biskra (Algérie), 2019.

- [Bezde-81] J. Bezdek. Pattern Recognition with Fuzzy Objective Function Algorithms. Plenum Press, New York, 1981.
- [Bezde-93] J. C. Bezdek, I. Hall, L. Clarke. Review of MR image Segmentation Techniques using Pattern Recognition. Medical Physics, vol. 20, Issue 4, pp. 1033–1048, 1993.
- [Bloc-46] F. Bloch, Nuclear Induction. Physical Review. 70:460–474, 1946.
- [Boir-00] V. Barra, J. Y. Boire. Tissue Characterization on MR Images by a Possibilistic Clustering on a 3D Wavelet Representation. Journal of Magnetic Resonance Imaging, 11: 267–278, 2000.
- [Boyd-94] S. Boyd, L. Ghaoui, E. Feron. Linear Matrix Inequalities in Systems and Control Theory. SIAM, Philadelphia, 1994.
- [Bric-08] S. Bricq. Segmentation d’images IRM Anatomiques par Inférence Bayésienne Multimodale et Détection de Lésions. Thèse de doctorat à l’université Louis Pasteur - Strasbourg I (France), 2008.
- [Bouk-15] S. Boukaka. Réalisation d’une Bibliothèque de Lois de Commande Adaptative pour MSAP. Thèse à l’université du Québec à Trois-Rivières. 2015.
- [Chaa-13] L. Chaabane. Fusion et Fouille de Données Guidées par les Connaissances: Application à l’analyse d’image. Thèse de doctorat à l’université Mohamed Khider – Biskra (Algérie), 2013.
- [Char-59] D. Charles. On the Origin of Species by Means of Natural Selection, or the Preservation of Favoured Races in the Struggle for Life. Murray, London, 1859.
- [Chev-98] F. Chevré, F. Guély. La logique floue. Cahier technique n°191, 1998.
- [Clar-93] L. Clarke, R. Velthuizen, S. Phuphanich, J. Schellenberg, J. Arrington and M. Silbiger. MRI: Stability of three Supervised Segmentation Techniques. Magnetic Resonance Imaging, 11:95–106, 1993.
- [Cler-02] M. Clerc and J. Kennedy. The Particle Swarm Explosion, Stability and Convergence in a Multidimensional Complex Space. IEEE Transactions on Evolutionary Computation, 6(1): 58–73, 2002.
- [Cler-10] M. Clerc. Particle swarm optimization, vol. 93. John Wiley & Sons, 2010.
- [Cocq-95] J. Cocquerez and S. Philips. Analyse d’Images: Filtrage et Segmentation, Masson, 1995.
- [Coor-08] Y. Cooren. Improvement of an Adaptive Algorithm of Particulate Swarm Optimization: application in medical engineering and electronics. PhD à l’université Paris-Est, 2008.
- [Das-08] S. Das, A. Abraham and A. Konar. Automatic Clustering using an Improved Differential Evolution Algorithm. IEEE Transactions on Systems, Man and Cybernetics – Part A: Systems and Humans, vol. 38, n.1, January, 2008.

- [Dene-83] J.-L. Deneubourg, J. M. Pasteels and J.-C. Verhaeghe. Probabilistic Behaviour in Ants: A Strategy of Errors. *Journal of Theoretical Biology*, 105(2): 259–271, 1983.
- [Dori-92] M. Dorigo. Optimization, Learning and Natural Algorithms. PhD. Thesis, Politecnico di Milano, Italy, 1992.
- [Dori-96] M. Dorigo, V. Maniezzo and A. Coloni. Ant system: Optimization by a Colony of Cooperating Agents. *Systems, Man and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 26(1): 29–41, 1996.
- [Dor-12] A. El Dor. Perfectionnement des Algorithmes d’Optimisation par Essaim Particulaire. Applications en Segmentation d’images et en Electronique. Thèse de doctorat à l’université de Paris-e-Est (France), 2012.
- [Dréo-03] J. Dréo, A. Petrowski, É. D. Taillard and P. Siarry. Métaheuristiques pour l’optimisation difficile. Eyrolles (Editions), 2003.
- [Duti-15] C. Dutilleul. Evaluation de Traitement de la Sclérose en Plaques par Analyses Morphométriques de Données d’imagerie par Résonance Magnétique. Thèse de doctorat à l’université Toulouse 3 Paul Sabatier. 2015.
- [Eber-98] Y. Shi and R. Eberhart. A Modified Particle Swarm Optimizer. In *IEEE International Conference on Evolutionary Computation*, pages 69–73, 1998.
- [Eber-00] R. C. Eberhart and Y. Shi. Comparing Inertia Weights and Constriction Factors in Particle Swarm Optimization. In *Proceedings of the 2000 Congress on Evolutionary Computation. CEC00 (Cat. No.00TH8512)*, pp. 84–88 vol. 1, 2000.
- [Flau-94] J. M. Flaus. La Régulation Industrielle: Régulateurs PID, Prédicatifs et Fious. Coll. *Traité des nouvelles technologies*. Paris: Hermès, 348 p. 1994.
- [Frei-02] J. Freixenet, X. Munoz, D. Raba, J. Marti and X. Cufi. Yet another Survey on Image Segmentation: Region and Boundary Information Interaction. *Proceedings of 7th European Conference on Computer Vision, Part III*, pp. 408–422, 2002.
- [Fren-04] E. Frenoux. Applications et Validation de Méthodologies de Fusion de Données en Imagerie Cérébrale. Thèse à l’université d’Auvergne, 2004.
- [Gath-83] I. Gath, D. Lehmann and E. Bar-On. Fuzzy Clustering of EEG Signal and Vigilance Performance. *International journal of neuroscience*, 20(3-4): 303–312, 1983.
- [Germ-99] L. Germond. Trois Principes de Coopération pour la Segmentation en Imagerie de Résonance Magnétique Cérébrale. Thèse de doctorat à l’université Joseph Fourier 1999.
- [Gesu-94] V. D. I. Gesu, L. Romeo. An Application of Integrated Clustering to MRI Segmentation. *Pattern Recognition Letters*, 45:731–738, 1994.
- [Géra-98] T. Géraud. Segmentation des Structures Internes du Cerveau en Imagerie par Résonance Magnétique Tridimensionnelle. Thèses de doctorat, École Nationale Supérieure des Télécommunications, France, 1998.

- [Ghou-18] A. Ghoumari. Métaheuristiques Adaptatives d'optimisation Continue Basées sur des Méthodes D'apprentissage. Thèse de doctorat en informatique à l'université Paris-Est. 2018.
- [Glov-86] F. Glover. Future Paths for Integer Programming and Links to Artificial Intelligence. *Computers and Operations Research*, vol. 13, pp. 533–549, 1986.
- [Glov-97] F. Glover and M. Laguna. *Tabu Search*. Kluwer Academic Publishers, 1997.
- [Goss-89] S. Goss, S. Aron, J-L. Deneubourg and J. M. Pasteels. Self-organized shortcuts in the Argentine ant. *Naturwissenschaften*, 76(12): 579–581, 1989.
- [Gran-84] G. Granath. Application of Fuzzy Clustering and Fuzzy Classification to Evaluate the Provenance of Glacial Till. *Journal of the International Association for Mathematical Geology*, 16(3): 283–301, 1984.
- [Hach-18] M. G. El-hachemi. Performances dans la Segmentation d'images Médicales. Thèse de doctorat, école nationale Supérieure en Informatique (Algérie), 2018.
- [Hepp-90] F. Heppner and U. Grenander. A Stochastic Nonlinear Model for Coordinated Bird Flocks. In *the ubiquity of chaos*, pp. 233–238. 1990.
- [Hojj-01] A. Hojjatoleslami and F. Kruggel, Segmentation of Large Brain Lesions. *IEEE Transactions on Medical Imaging*, 20(7):660–669, July 2001.
- [Hrus-09] E. R. Hruschka, R. JGB. Campello, A. A. Freitas and others. A Survey Of Evolutionary Algorithms for Clustering. *IEEE Transactions on Systems, Man and Cybernetics, Part C Applications and Reviews*, vol. 39, no. 2, pp. 133–155, 2009.
- [Huer-08] E. B. Huerta. Logique floue et Algorithmes Génétiques pour le Pré-traitement de Données de Biopuces et la Sélection de Gènes. Thèse de doctorat à l'université d'Angers. 2008.
- [Hunt-85] T. L. Huntsherger, CL Jacobs & Robert L Cannon. Iterative Fuzzy Image Segmentation. *Pattern recognition*, 18(2): 131–138, 1985.
- [Ibti-19] A. Ibtissam. Une Nouvelle Métaheuristique pour les Problèmes d'optimisation Combinatoire la Monarchie Métaheuristique. Thèse de doctorat à l'université Houari Boumédiène (Algérie), 2019.
- [Izak-11] H. Izakian and A. Ajith. Fuzzy C-Means and Fuzzy Swarm for Fuzzy Clustering Problem. *Expert Systems with Applications*, 38(3): 1835–1838, 2011.
- [Jéré-08] L. Jérémy and B. Christian. BIO-Systèmes biologiques. Rapport de Recherche N°6306, Institut National de Recherche en Informatique et en Automatique – INRIA-, Renne (France), version 3, 2008.
- [Jian-02] T. Jiang and F. Yang. An Evolutionary Tabu Search for Cell Image Segmentation, *IEEE Transactions on Systems, Man and Cybernetics – Part B: Cybernetics* 32 (5) 675–678. 2002.
- [Kart-04] S. V. Kartalopoulos. *Understanding Neural Networks and Fuzzy Logic Basic Concepts and Applications*. IEEE Press - PHI. 2004.

- [Kass-88] M. Kass, A. Witkin and D. Terzopoulos. Snakes: Active Contour Models. *International Journal of Computer Vision*, pp. 321–331, 1988.
- [Kenn-95] J. Kennedy and R. Eberhart. Particle Swarm Optimization. In *Neural Networks. Proceedings. IEEE International Conference on*, vol. 4, pp. 1942–1948. 1995.
- [Khal-11] N. E. A. Khalid and P. N. M. M. Haniff. MRI Brain Abnormalities Segmentation using K-Nearest Neighbors (K-NN). *Int. J. Comput. Sci. Eng*, 3(2): 980, 2011.
- [Khom-19] B. Khomri. Apprentissage et Optimisation Intelligente pour une Segmentation Robuste d'image. Thèse de doctorat à l'université Mohamed Khider Biskra (Algérie), 2019.
- [Kirk-83] S. Kirkpatrick, C. D. Gelatt and M. P. Vecchi. Optimization by Simulated Annealing. *Science*, vol. 220, 4598, pp. 671–680, 1983.
- [Kiyy-20] B. Kiyyour. Contribution à la Commande d'une Machine Asynchrone Double Etoile. Thèse de doctorat à l'université Mohamed Khider-Biskra (Algérie), 2020.
- [Kris-93] R. Krish napuram and J.M. Keller. A Possibility Approach to Clustering. *IEEE Transactions of Fuzzy Systems*, vol. 1, No. 2 pp. 98–110, 1993.
- [Law-08] Y. N. Law, H. K. Lee and A. M. Yip. A Multiresolution Stochastic Level Set Method for Mumford-Shah Image Segmentation, *IEEE Trans. on Image Processing*, 17 (12). 2289–2300. 2008.
- [Lepr-19] A. Leprieu. Sclérose en Plaques : La Maladie et les Avancées Thérapeutiques. Thèse de doctorat en Pharmacie à l'université de Caen Normandie, 2019.
- [Liu-14] N. S. X. Liu, X. Wang and C. Li. Image Segmentation Algorithm Based on Improved Ant Colony Algorithm. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 7(3): 433–442, 2014.
- [Macd-00] D. MacDonald, N. Kabani, D. Avis and A.C. Evans. Automated 3-D extraction of Inner and Outer Surfaces of Cerebral Cortex From MRI. *NeuroImage*, vol. 12, pp. 340–356, 2000.
- [Madh-15] S. Madhukumar and N. Santhiyakumari. Evaluation of K-Means and Fuzzy C-Means Segmentation on MR Images of Brain. *The Egyptian Journal of Radiology and Nuclear Medicine*, 46(2):475–479, 2015.
- [Mano-98] IN. Manousakas, PE. Undrill, GG. Cameron and TW. Redpath. Split-and-Merge Segmentation of Magnetic Resonance Medical Images: Performance Evaluation and Extension to Three Dimensions. *Computers and Biomedical Research*, 31 (6): 393–412, 1998.
- [Mara-00] P. Marais and J. M. Brady. Detecting the Brain Surface In Sparse MRI using Boundary Models. *Medical Image Analysis*, vol. 4, pp. 283–302, 2000.
- [Masu-99] F. Masulli, A. Schenone. A Fuzzy Clustering Based Segmentation System as Support to Diagnosis in Medical Imaging, *Artificial Intelligence in Medicine*. 16:129–147, 1999.

- [Mcin-96] T. McInerney and D. Terzopoulos. Deformable Models in Medical Image Analysis: A Survey. *Medical Image Analysis*, vol. 1, no. 2, pp. 91–108, 1996.
- [Mekh-08] A. Mekhmoukh. Segmentation d'images par Classifieurs non Supervisés Application à l'imagerie par Résonance Magnétique (IRM). Mémoire de Magister à l'université d'Abderrahmane Mira Bejaia (Algérie). 2008.
- [Mera-08] H. Merabti. Etude des Systèmes Flous à Intervalle. Mémoire de magistère à l'université de Mentouri- Constantine (Algérie), 2008.
- [Mera-20] M. Merabet. Test des Circuits Analogiques à Base de la Logique Floue par Voie de Simulation. Thèse de doctorat à l'université Farhat Abbas Sétif (Algérie), 2020.
- [Metr-53] N. Metropolis, A. W Rosenbluth, M. N Rosenbluth, A. H. Teller and E. Teller. Equation of State Calculations by Fast Computing Machines. *The journal of chemical physics*, 21(6): 1087–1092, 1953.
- [Mezh-12] N. Mezhoud. Une Approche Hybride pour la Segmentation d'images Application aux Images Médicales. Thèse de doctorat à l'université de Mentouri-Constantine (Algérie), 2012.
- [Moza-16] M. H. Mozaffari and W-S. Lee. Multilevel Thresholding Segmentation of T2 Weighted Brain MRI images using Convergent Heterogeneous Particle Swarm Optimization. *CoRR*, abs/1605.04806, 2016.
- [Naki-07] A. Nakib. Conception de Métaheuristiques d'optimisation pour la Segmentation d'images. Application à des Images Biomédicales. Thèse de doctorat à l'université de Paris 12- Val de marne UFR de sciences et technologie, Spécialité: Traitement d'images et optimisation, 2007.
- [Nikh-97] P. R. Nikhil, P. Kuhu and J. C. Bezdek. A Mixed C-Means Clustering Model. 0-7803-3796-4/IEEE, 1997.
- [Nikh-05] P. R. Nikhil, P. Kuhu, K. M. James and J. C. Bezdek. A Possibilistic Fuzzy C-Means Clustering Algorithm, *IEEE Transactions on Fuzzy Systems*, 13(4), pp. 517–530, 2005.
- [Oliv-10] D.N. Oliveira, G.A. de Lima Henn and O. da Mota Almeida, Design and Implementation of a Mamdani Fuzzy Inference System on an FPGA using VHDL, in *Fuzzy Information Processing Society (NAFIPS), 2010 Annual Meeting of the North American*, pp. 1–6. 2010.
- [Oliv-15] B. k. Olivier, JT. Zoueu and E. Megnassan. Segmentation par Logique Floue pour l'estimation du Nombre de Globules Rouges dans des Images Multi-Spectrales de Frottis Sanguin non Marqué. *Afrique Science: Revue Internationale des Sciences et Technologie*, vol. 11, no. 3, pp. 27–36, 2015.
- [Omra-04] M. Omran. Particle Swarm Optimization Methods for Pattern Recognition and Image Processing. PhD of university of Pretoria, Pretoria, South Africa, 2004.
- [Otsu-79] N. Otsu. A Threshold Selection Method From Gray-Level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1). 62–66, 1979.

- [Pakh-05] M. K. Pakhira, S. Bandyopadhyay and U. Maulik. A Study of some Fuzzy Cluster Validity Indices, Genetic Clustering and Application to Pixel Classification. *Fuzzy Sets and Systems*, vol. 155, pp. 191–214, 2005.
- [Pang-04] W. Pang, K. P. Wang, C. G. Zhou and L. J. Dong. Fuzzy Discrete Particle Swarm Optimization for Solving Traveling Salesman Problem. In the Fourth International Conference on Computer and Information Technology, pp. 796–800, 2004.
- [Papa-82] C. Papademetriou and K. Steiglitz. *Combinatorial Optimization*. Englewood Clis, NJ: Prentice Hall. 1982.
- [Paul-20] L. Paul, B. Isabelle and A. Carlos. Analyse de Représentations Spatiales de la Musique par des Opérateurs Simples de Morphologie Mathématique. *Journées d'Informatique Musicale*, pp. 1–8. 2020.
- [Pere-16] S. Pereira, A. Pinto, V. Alves and C. A. Silva. Brain Tumor Segmentation using Convolutional Neural Networks in MRI Images. *IEEE Transactions on Medical Imaging*, 35(5): 1240–1251, 2016. Combinatorial
- [Prem-08] K. Premalatha. A. M. Natarajan. A New Approach for Data Clustering Based on PSO with Local Search. *Computer and Information Science*, vol. 1, no. 4, 2008.
- [Prew-70] J. M. S. Prewitt. *Picture Processing and Psychophysics*, chapter Object Enhancement and Extraction, Academic Press: New York, pp. 75–149. 1970.
- [Reev-95] C. R. Reeves. *Modern Heuristic Techniques for Combinatorial Problems*. Advanced Topics In Computer Science. Mc Graw-Hill, 1995.
- [Reha-11] F. Rehab, A. Kader. Fuzzy Particle Swarm Optimization with Simulated Annealing and Neighborhood Information Communication for Solving TSP, (IJACSA) *International Journal of Advanced Computer Science and Applications*, vol. 2, no. 5, pp. 15–21, 2011.
- [Reyn-87] C. W Reynolds. Flocks, Herds and Schools: A Distributed Behavioral Model. *ACM SIGGRAPH Computer Graphics*, 21(4): 25–34, 1987.
- [Ridl-78] T. W. Ridler and E. S. Calvard. Picture Thresholding using an Iterative Selection Method, *IEEE Trans. On Systems, Man and Cybernetics* 8 (8) 630–632, 1978.
- [Robe-65] L.G. Roberts. *Machine Perception of Three-Dimensional Solids*, MIT Press: Cambridge, pp. 159–197, 1965.
- [Sahr-16] M. Sahraoui. *Contrôle Robuste des Systèmes non Linéaires par les Approches de l'intelligence Artificielle*. Thèse de doctorat à l'université d'Oran (Algérie). 2016.
- [Sand-97] S. Sandor and R. Leahy. Surface-Based Labelling of Cortical Anatomy using a Deformable Database. *IEEE Transactions on Medical Imaging*, 16:41–54, 1997.
- [Sani-19] S. M. Sani Chaibou. *Segmentation d'image par Intégration Itérative de Connaissances*. Thèse de doctorat à l'école Nationale Supérieure Mines-Telecom Atlantique Bretagne Pays De La Loire - IMT Atlantique. 2019.
- [Sbil-15] L. Sbili. *Segmentation d'images par Classification Floue*. Mémoire de Magister à l'université à Tizi Ouzou-Mouloud Mammeri (Algérie), 2015.

- [Schn-01] H. G. Schnack, H. E. HulshoffPol, W. F. C. Baare, M. A. Viergever and R. S. Kahn. Automatic Segmentation of the Ventricular System from MR Images of the Human Brain. *NeuroImage*, vol. 14, pp. 95–104, 2001.
- [Semc-12] M. Semchedine. *Système Coopératif Hybride de Classification dans un SMA: Application à la segmentation d'images IRM*. Mémoire de Magister à l'université Farhat abbas-Sétif (Algérie), 2012.
- [Semc-18] M. Semchedine. *Contribution à la Segmentation d'image Médicale par les Algorithmes Bio-inspirés*. Thèse de doctorat à l'université Farhat Abbas Sétif (Algérie), 2018.
- [Sham-09] N. Sharma, A. K. Ray, Shiru Sharma, K. K. Shukla, L. Aggarwal and S. Pradhan. Segmentation of Medical Images using Simulated Annealing Based Fuzzy C-Means Algorithm. *International Journal of Biomedical Engineering and Technology*, 2(3): 260–278, 2009.
- [Siar-14] P. Siarry (Ed.). *Métaheuristiques: Recuit Simulé, Recherche avec Tabous, Recherche a Voisinages Variables, Méthodes GRASP, Algorithmes Evolutionnaires, Fourmis Artificielles, Essaims Particulaires et autres Méthodes d'optimisation*. Editions Eyrolles, 2014.
- [Sobe-78] I. Sobel. Neighbourhood Coding of Binary Images for Fast Contour Following and General Array Binary Processing. *Computer Graphics and Image Processing*, vol. 8, pp. 127–135, 1978. Of brain Tumors by Evidence Theory
- [Soph-03] A. Sophie Capelle-Laizé. *Three Dimensional Multi-Echoes MR Segmentation for the Detection of brain Tumors by Evidence Theory*. PhD of university Poitiers, 2003.
- [Stat-01] D. W. Stattuck, S. R. Sandor-Leahy, K. A. Schaper, D. A. Rottenberg and R. M. Leahy. Magnetic Resonance Image Tissue Classification using a Partial Volume Model. *NeuroImage*, pp. 856–876, 2001.
- [Thir-97] J. P. Thiran, V. Warscott and B. Macq. A Queue-Based Region Growing Algorithm for Accurate Segmentation of Multi-Dimensional Digital Images. *Signal Processing*, vol. 60, pp. 1–10, 1997.
- [Vinc-07] S. Vincent, Tseng and K. Ching-Pin. A Novel Similarity-Based Fuzzy Clustering Algorithm by Integrating PCM and Mountain Method. *IEEE Transactions on Fuzzy Systems*, vol. 15, no. 6, 1188–1196. 2007.
- [Warf-95] S. Warfield, J. Dengler, J. Zaers, C. Guttman, W. Wells III, G.J. Ettinger, J. Hiller and R. Kikinis. Automatic Identification of Grey Matter Structures From MRI to Improve the Segmentation of White Matter Lesions. *The Journal of Image Guided Surgery*, vol. 1, pp. 326–338, 1995.
- [Xena-16] S. D. Xenaki, K. D. Koutroumbas and A. A. Rontogiannis. A Novel Adaptive Possibilistic Clustering Algorithm, *IEEE Transactions on Fuzzy Systems*, 24(4) 791–810. 2016.

- [Xiao-05] W. Xiao-Nian, F. Yuan-Jing and F. Zu-Ren. Ant Colony Optimization for Image Segmentation. In International Conference on Machine Learning and Cybernetics, vol. 9, pp. 5355–5360, 2005.
- [Xuan-11] J. Ze-Xuan, S. Quan-Sen and X. De-Shen. A Modified Possibilistic Fuzzy C-Means Clustering Algorithm for Bias Field Estimation and Segmentation of Brain MR Image. Computerized Medical Imaging and Graphics, vol. 35, no. 5, 383-397, 2011.
- [Yin-07] P. Yin. Multilevel Minimum Cross Entropy Threshold Selection Based on Particle Swarm Optimization. Applied Mathematics and Computation, vol. 184, no. 2, pp. 503-513, 2007.
- [Zaar-13] A. El-Zaart and A. A.Ghosn. MR Images Thresholding for Alzheimer Detection. International Journal of Computer Science and Information Technology (CS & IT), 2013.
- [Zade-65] L. A. Zadeh. Fuzzy Sets. Information and Control, 8(3): 338–353, 1965.
- [Zaha-04] E. Zahara, S. Fan and D. Tsai. Optimal Multi-Thresholding using a Hybrid Optimization Approach. Pattern Recognition Letters, vol. 26, no. 8, pp. 1082–1095. 2005.
- [Zahr-05] M. Al-Zahrani, M. Khalid. Fuzzy Takagi-Sugeno and LMS Based Control Techniques. M. S., Saudi Arabia, King Fahd University of Petroleum and Minerals (Saudi Arabia), 2005.
- [Zaki-17] A. M. Zaki, C. M. Billah and M. Karim. A New Segmentation Method of Cerebral MRI Images Based on the Fuzzy C-Means Algorithm. Turkish Journal of Electrical Engineering and Computer Sciences, vol. 25, no. 4, pp. 3215–3226. 2017.
- [Zhan-15] Q. Zhang, L. T. Yang, Z. Chen and F. Xia. A HighOrder Possibilistic-Means Algorithm for Clustering Incomplete Multimedia Data. IEEE Systems Journal, vol. 11, no. 4, 2160–2169, 2015.
- [Zemm-18] N. Zemmali. Techniques d'apprentissage pour la Sélection d'attributs: Application à la Reconnaissance des Formes. Thèse de doctorat à l'université Badji Mokhtar Annaba (Algérie), 2018.
- [Zhen-08] X. Zhenping , W. Shitong and F. L. Chung. An Enhanced Possibilistic C-Means Clustering Algorithm EPCM. Soft Computing, 12(6): 593–611, 2008.
- [Zijd-94] A. Zijdenbos and B.M. Dawant. Brain Segmentation and White Matter Lesion Detection in MR Images. Critical reviews in Biomedical Engineering, vol. 22, pp. 401–465, 1994.
- [Zoua-08] H. Zouaoui. Clustering par Fusion Floue de Données Appliqué à la Segmentation d'images IRM. Mémoire de Magister à l'université de M'hamed Bouguerra, Boumerdès (Algérie), 2008.

- [Zoua-16] H. Zouaoui. A. Moussaoui. A. Taleb-Ahmed and M. Oussalah. A New Optimal Neuro-Fuzzy Inference System for MR Image Classification and Multiple Scleroses Detection. *International Conference on Bio-Inspired Computing: Theories and Applications*. Springer, pp. 487–493. 2016.
- [Zoua-19] H. Zouaoui. A. Moussaoui. A. Taleb-Ahmed and M. Oussalah. A Robust Method for MR Image Segmentation and Multiple Scleroses Detection. *Journal of Medical Imaging and Health Informatics*, vol. 9, no. 6, pp. 1119–1130. 2019.
- [Zoua-20] H. Zouaoui. A. Moussaoui. Bioinspired Inference System for MR Image Segmentation Applied to the Detection of Multiple Sclerosis. *International Journal of Swarm Intelligence R. IJSIR*, vol. 13, Issue 1, Article 1. 2020.

Productions scientifiques

- **Revues internationales**

1. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI. Bioinspired inference system for MR Image segmentation and Multiple Sclerosis detection. Journal of International Journal of Swarm Intelligence Research (IJSIR). ISSN : 1947-9263 (Print) : EISSN : 1947-9271 (Online). 2020.
2. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI, Mourad OUSSALAH, Abdelmalik TALEB-AHMED. A robust method for MR Image Segmentation and multiple sclerosis detection. Journal of Medical Imaging and Health Informatics (JMIHI). ISSN : 2156-7018 (Print) : EISSN : 2156-7026 (Online). 2019.

- **Communications internationales**

1. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI. Clustering par fusion floue de données appliqué à la segmentation d'images IRM Cérébrales. CIIA'09, Saida 03-04 mai 2009.
2. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI. Clustering par fusion floue de données appliqué à la segmentation d'images IRM. CITIC'09, Sétif 04-05 mai 2009.
3. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI. Fusion de données pour la classification automatique d'images IRM cérébrales. COSI'2009, Annaba 25-27 mai 2009.
4. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI. Fusion Floue de données pour la Segmentation d'images IRM. SNIB'2010, Biskra 02-04 Novembre 2010.
5. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI. Système multi-agent pour la Segmentation d'images IRM. JNMA'12, Bordj Bou Arréridj 27 Novembre 2012.

6. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI, Abdelmalik Taleb-Ahmed. Improved PSO algorithm for MR Image classification and multiple sclerosis detection. ICCSA'16 , Oum El Bouaghi 14 Avril 2016.
7. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI. Bioinspired inference system for medical image segmentation. MISC'16, Constantine 7- 8 Mai 2016.
8. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI. Bioinspired inference system for medical image segmentation. Chapitre Springer. Modelling and - Implementation of Complex Systems pp 31-48, 2016.
9. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI, Abdelmalik TALEB-AHMED, Mourad OUSSALAH. A New Optimal Neuro-Fuzzy Inference System for MR Image Classification and Multiple Scleroses Detection. BIC-TA 2016 , China 28-30 October 2016.
10. Hakima ZOUAOUI, Abdelouahab MOUSSAOUI, Abdelmalik TALEB-AHMED, Mourad Oussalah. A New Optimal Neuro-Fuzzy Inference System for MR Image Classification and Multiple Scleroses Detection. Chapitre Springer. Bio-inspired Computing – Theories and Applications pp 487- 493, 2016.

ملخص:

في هذه الأطروحة، نقتراح نهجًا جديدًا لتقسيم صور الرنين المغناطيسي لمرض التصلب المتعدد و هو أحد أمراض المناعة الذاتية التي تؤثر على الجهاز العصبي المركزي. بهدف تسهيل التشخيص للطبيب، نقتراح تقسيمًا تلقائيًا لآفات التصلب المتعدد. تستند خوارزمية التقسيم الخاصة بنا إلى ثلاث خطوات: في المرحلة الأولى، نجزئ مناطق الدماغ للحصول على توصيف للأنسجة الصحية السليمة (المادة البيضاء، المادة الرمادية والسائل النخاعي). في المرحلة الثانية و بعد استخراج المادة البيضاء، نقوم بإزالة البيانات الغير النمطية (القيم المتطرفة) لهذه المادة. و أخيرًا، نقوم باستخدام نموذج ضبابي من نوع ممداني لاستخراج آفات التصلب المتعدد من جميع القيم المتطرفة.

مفاتيح: التصلب المتعدد؛ التصوير بالرنين المغناطيسي؛ تقسيم؛ القيم المتطرفة؛ ممداني؛ تحكم غامض.

Résumé:

Dans cette thèse, nous proposons une nouvelle approche pour la segmentation d'images IRM de la maladie sclérose en plaques (SEP) qui est une maladie inflammatoire auto-immune affectant le système nerveux central. Ayant pour finalité d'automatiser un processus long et fastidieux pour le clinicien, nous suggérons une segmentation automatique des lésions SEP. Notre algorithme de segmentation se compose de trois étapes: la segmentation du cerveau en régions afin d'obtenir la caractérisation des différents tissus sains (substance blanche, substance grise et liquide céphalo-rachidien (LCR)). Ensuite, l'extraction de la substance blanche, l'élimination des données atypiques (valeurs aberrantes) de cette dernière. Enfin, l'utilisation d'un modèle flou de type Mamdani pour extraire les lésions de la SEP parmi toutes les données aberrantes.

Mots clés: Sclérose en Plaques; Imagerie par Résonance Magnétique; Segmentation; Données Atypiques; Mamdani; Contrôleur Flou.

Abstract:

In this thesis, we propose a new approach for the segmentation of the MR images of the Multiple Sclerosis (MS) which is an autoimmune inflammatory disease affecting the central nervous system. Aiming to automate a long and tedious process for the clinician, we propose the automatic segmentation of the MS lesions. Our algorithm of segmentation is composed of three stages: segmentation of the brain into regions in order to obtain the characterization of the different healthy tissues (White matter, grey matter and cerebrospinal fluid (CSF)) after the extraction of white matter (WM), the elimination of the atypical data (outliers) of the white matter, finally, the use of a Mamdani-type fuzzy model to extract the MS lesions among all the absurd data.

Keywords: Multiple Sclerosis; Magnetic Resonance Imaging; Segmentation; Atypical data; Mamdani; Fuzzy Controller.