

N° d'ordre :

Université de Saida- Dr. Moulay Tahar
Faculté de Technologie

Thèse

Présentée pour obtenir le diplôme de

Doctorat 3ième Cycle

Spécialité : Technologies de la Communication / Traitement du Signal et Télécommunications

Filière : Télécommunications

Par :

BEDDAD Boucif

Thème :

**Etude Comparative de nouvelles méthodes de segmentation
d'images**



Thèse soutenue le 18/11/2021 devant le jury composé de :

N°	Nom et prénom	Grade	Etablissement	Qualité
01	F.Z. DRISS KHODJA	Prof.	Université de Saida – Dr. Moulay Tahar	Président
02	B. DJELLOULI	Prof.	Université de Saida – Dr. Moulay Tahar	Rapporteur
03	A. CHERIFI	MCA	Université de Saida – Dr. Moulay Tahar	Examinateur
04	Z. CHAMA	Prof.	Université de SBA – Djillali Liabes	Examinateur
05	O. ARBOUCHE	Prof.	Université de Saida – Dr. Moulay Tahar	Examinateur
06	K. HACHEMI	MCA	Ex. Enseign. Université de Saida	Invité

Etude Comparative de Nouvelles Méthodes de Segmentation d'images

Etude Comparative des Nouvelles Méthodes de Segmentation d'images

Mots clefs

-
- | | |
|---|---|
| <ul style="list-style-type: none">- Code Composer Studio CCS- Image par Résonance Magnétique IRM- Segmentation d'images médicales- TMS320C6713DSP- Information spatiale et clustering- C-moyennes floues spatiale améliorées basé sur la distance euclidienne ISFCM- C-moyennes floues spatiale SFCM- C-moyennes floues basé sur la distance du noyau normé généralisé KGFCM | <ul style="list-style-type: none">- C-moyennes floues spatiale conditionnel CsFCM- C-moyennes floues spatiale conditionnel basé sur la distance du noyau normé CsKFCM- C-moyennes floues basé sur la distance gaussienne du noyau normé GKFCM- C-moyennes floues pondérée avec noyau normé généralisé GKWFICM- C-moyennes floues robustes avec contraintes spatiale RSCFCM- C-moyennes floues spatiale améliorées basé sur la distance du noyau normé ISKFCM |
|---|---|
-

Résumé :

L'approche traditionnelle C-moyennes floue (FCM) fait partie des méthodes les plus courantes et les plus utilisées pour la segmentation non supervisée d'image. La technique FCM n'utilise pas pleinement les informations spatiales pour résoudre le problème de la sensibilité au bruit et de l'inhomogénéité d'intensité qui affectent considérablement les performances de segmentation d'image médicale. Sur la base des différents défis rencontrés, la recherche actuelle vise l'étude comparative des nouvelles méthodes de segmentation d'image à savoir SFCM, CsFCM, CsKFCM, GKFCM, RSCFCM, KGFCM, GKWFICM.

Afin de minimiser la fonction objective de C-moyennes floues, le concept de noyau normé (kernel) et le terme d'information spatiale du voisinage de chaque pixel sont incorporé pour développer deux nouvelles techniques basée sur le processus de clustering. La première concerne la C-moyennes floues spatiale améliorées basé sur la distance euclidienne nommé ISFCM, la deuxième est C-moyennes floues spatiale améliorées basé sur la distance du noyau normé (kernel) nommé ISKFCM. Les deux algorithmes proposés sont appliqués à la fois sur des images synthétisées artificielles, des images simulées générées par BrainWeb et des images cérébrales IRM réelle pondérées en T1, T2 et PD.

Les algorithmes de segmentation par clustering ISFCM et ISKFCM ont été implémentés pratiquement en temps réel à l'aide d'un DSP à virgule flottante de type TMS320C6713DSP de Texas Instruments. L'amélioration des performances est mesurée en incluant diverses techniques d'optimisation et tous les résultats de profilage et de débogage sont affichés à l'aide de l'interface utilisateur graphique C6713. Les résultats expérimentaux de segmentation démontrent que les algorithmes présentés sont plus robustes au bruit et l'inhomogénéité d'intensité, aussi les performances ont été validées après une évaluation quantitative et qualitative à l'aide de diverses mesures telles que : l'indice de similarité (ρ), le coefficient de partition (V_{pc}) et l'entropie de partition (V_{pe}), la fonction de Fukuyama-Sugeno (V_{fs}) et la fonction de Xie-Beni (V_{xb}), la précision de segmentation optimale (SA) et le taux de classification erronée (MCR).

Comparative Study of New Images Segmentation Methods

Keywords

-
- Code Composer Studio CCS
 - Magnetic Resonance Image MRI
 - Medical images segmentation
 - TMS320C6713 DSP
 - Clustering and spatial information
 - Improved Spatial Fuzzy C-means based on Euclidean distance ISFCM
 - Spatial Fuzzy C-means SFCM
 - Conditional Spatial Fuzzy C-means based on Kernel induced distance CsKFCM
 - Gaussian Kernel based Fuzzy C-means GKFCM
 - Generalized Kernel Weighted Fuzzy C-means
 - Kernel Generalized Fuzzy C-means KGFCM
 - Robust Spatial Constrained Fuzzy C-means
 - Improved Spatial Fuzzy C-means based on Kernel distance ISKFCM
 - Conditional Spatial Fuzzy C-means CsFCM
-

Abstract:

The traditional Fuzzy C-Means (FCM) approach is one of the most common and widely used methods for unsupervised image segmentation. The FCM technique does not fully utilize spatial information to solve the problem of noise sensitivity and intensity inhomogeneity which significantly affect the performance of medical image segmentation. Based on the various challenges encountered, the current research aims at the comparative study of new image segmentation methods namely SFCM, CsFCM, CsKFCM, GKFCM, RSCFCM, KGFCM, and GKWLICM.

In order to minimize the objective function of fuzzy C-means, the concept of normalized kernel distance and the spatial information term of the neighborhood of each pixel are incorporated to develop two new techniques based on the clustering process. The first concern the enhanced spatial fuzzy C-means based on the Euclidean distance from the normalized kernel named ISFCM, the second one is the improved spatial fuzzy C-means based on the normalized kernel distance named ISKFCM. The two algorithms proposed are applied to both artificial synthesized images, simulated images generated by BrainWeb database and real MRI brain images weighted in T1, T2 and PD.

The ISFCM and ISKFCM clustering segmentation algorithms were implemented in near real time using a TMS320C6713DSP type floating point DSP from Texas Instruments. Performance improvement is measured by including various optimization techniques and all profiling and debugging results are displayed using the C6713 graphical user interface. Experimental segmentation results demonstrate that the presented algorithms are more robust noise and intensity inhomogeneity, also the performances have been validated after a quantitative and qualitative evaluation using various measures such as: the similarity index (ρ), the partition coefficient (V_{pc}) and the partition entropy (V_{pe}), the Fukuyama-Sugeno function (V_{fs}) and the Xie-Beni function (V_{xb}), the optimal segmentation accuracy (SA) and the misclassification rate (MCR).

دراسة مقارنة للطرق الجديدة لتجزئة الصورة

كلمات مفتاحية

تقنية التجزئة CsKFCM	-	تقنية التجزئة GKFCM	-	تقنية التجزئة GKWFLICM	-	تقنية التجزئة KGFCM	-	تقنية التجزئة RSCFCM	-	تقنية التجزئة ISKFCM	-	برنامجه Code Composer Studio	-
صورة بالرنين المغناطيسي	-	معالج TMS320C6713DSP	-	التجمیع Clustering	-	والمعلومات المكانیة	-	تقنیة التجزئة ISFCM	-	تقنیة التجزئة CsFCM	-	-	-
-	-	-	-	-	-	-	-	-	-	-	-	-	-
-	-	-	-	-	-	-	-	-	-	-	-	-	-

ملخص:

تعتبر تقنية Fuzzy C-Means من بين الطرق الأكثر شيوعاً والأكثر استخداماً لتجزئة الصور الغير خاضعة للرقابة. غالباً تقنية FCM لا تستخدم المعلومات المكانية بشكل كامل لحل مشكلة حساسية الضوضاء وعدم تجانس الكثافة التي تؤثر بشكل كبير على أداء تجزئة الصور الطبية. بناءً على التحديات المختلفة التي تمت مواجهتها ، يهدف البحث الحالي إلى دراسة مقارنة للطرق الجديدة لتجزئة الصورة ذكر من بينها: SFCM و CsFCM و CsKFCM و GKWFLICM و KGFCM و RSCFCM.

لخفض قيمة الدالة الموضوعية لتقنية Fuzzy C-Means، تم دمج مفهوم المسافة المستحثة من (kernel) ومصطلح المعلومات المكانية لجوار كل بکسل لتطوير تقنيتين جديدين على أساس عملية التجمیع Clustering. تتعلق الأولى بتقنية Fuzzy C-Means المكانية المحسنة القائمة على المسافة الإقلیدية المسماة ISFCM ، والثانية هي تقنية C-Means المكانية المحسنة القائمة على مسافة النواة الطبيعية kernel ISKFCM المسماة kernel. تم تطبيق الخوارزميتين المقترحتين على كل من الصور المركبة الاصطناعية، والصور المحاكاة التي تم إنشاؤها بواسطة BrainWeb وصور الدماغ الحقيقية الملقطة بالرنين المغناطيسي على شکل T1 و T2 و PD.

تم تفییذ خوارزمیات التجزئة ISFCM و ISKFCM في الوقت الحقیقی باستخدام خاصیة معالج الإشارة الرقمیة DSP من نوع TMS320C6713DSP المصنوع من طرف شركة Texas Instruments. أيضاً تم قیاس الأداء المحسن من خلال تضمین تقنيات التحسین المختلفة وتم عرض جميع نتائج التمییز وتصحیح الأخطاء باستخدام واجهة المستخدم الرسومیة C6713. أظهرت النتائج التجربیة لتجزئة أن الخوارزمیات المقدمة تعتبر أكثر قوّة في مواجهة حساسیة الضوضاء و عدم تجانس شدّة الكثافة ، بينما تم التتحقق من صحة الأداء بعد التقيیم الکمی والنوعی باستخدام مقاییس مختلفة مثل: مؤشر التشابه (ρ) ، معامل التقسیم Vpc و الإنتروربیا التقسیمیة Vfs ، دالة Vpe ، دالة $Fukuyama-Sugeno$ و دالة $Xie-Beni$ و دالة Vxb ، دقة التجزئة المثلی (SA) ومعدل سوء التصنيف (MCR).

Remerciements

Nous remercions Dieu de nous avoir accordé des connaissances de la science et de nous avoir aidé à réaliser ce travail de recherche.

Le travail présenté dans cette thèse a été effectué au sein du Laboratoire LTC (Laboratoire Technologie de la Communication) au département d'électronique de l'Université de Saida Dr. Tahar Moulay. Ce travail a été achevé grâce à l'aide de plusieurs personnes à qui j'adresse ces paragraphes de remerciements.

Mes grands remerciements en premier lieu sont adressés au Dr. HACHEMI Kaddour. Il a su m'orienter dans le monde de la recherche grâce à ses précieux conseils, sa patience, sa disponibilité, son soutien inconditionnel et sa compréhension dans les moments difficiles ainsi ses encouragements à chaque étape.

Mes remerciements vont également au Pr. DJELLOULI Bouazza, mon directeur de thèse pour son aide et sa disponibilité ainsi que ces précieux conseils.

Je suis particulièrement reconnaissant aux membres du comité de doctorat pour leurs précieuses suggestions, leur enthousiasme et leur motivation.

Tout notre respect et nos remerciements vont vers les membres du jury qui vont pleinement consacrer leur temps et leur attention afin d'évaluer notre travail, qui espérons le sera à la hauteur de leur attente.

Sans oublier de remercier Monsieur Jack-Gerard Postaire (Professeur à l'université de Lille, France) et Monsieur Sundarapandian Vaidyanathan (Professeur à l'université de Vel Tech, Inde) pour leurs soutiens pendant ces années de recherche et pour leurs aides précieuses et leurs conseils lors de la préparation de la thèse et la soutenance.

Merci à tous

Dédicace

A mes chers parents

A ma famille qui m'a aidé et soutenu.

A mes amies qui m'ont encouragé.

Table des matières

Table des matières

<i>Liste des figures</i>	XIV
<i>Liste des tableaux</i>	XVIII
<i>Notations et Abréviations</i>	XXI
<i>Introduction générale</i>	2

Chapitre I : Anatomie cérébrale et Acquisition d'images médicales de type IRM

I-1- Introduction	8
I-2- Anatomie cérébrale.....	8
I-2-1- Définitions	8
I-2-2- Les tissus cérébraux	10
I-2-3- Observation du cerveau	11
I-3- Modalités d'imagerie médicale	11
I-3-1- Échographie	11
I-3-2-Tomographie assistée par ordinateur (CT)	12
I-3-3- Imagerie par résonance magnétique (IRM).....	12
I-3-4- Tomographie calculée à émission de photons uniques	13
I-3-5- Tomographie par émission de positrons (TEP)	13
I-3-6- IRM fonctionnelle (IRMF)	14
I-4- Imagerie par résonance magnétique	14
I-4-1- Principe de base de l'IRM	15
I-4-2- Types d'IRM et ses orientations	20
I-4-3- Caractéristiques des tissus et de l'IRM	21
I-4-4- Avantages et Inconvénients de l'IRM	21
I-4-5- Processus d'acquisition et modélisation en IRM	22
I-4-5-1- Images pondérées en T1	22
I-4-5-2- Images pondérées en T2	23
I-4-5-3- Images pondérées en DP.....	23
I-4-5-4- Images Flair	23
I-5- Lésions et tumeurs cérébrales	24
I-5-1- Tumeur cérébrale humaine et sa naissance	24
I-5-2- Statistiques sur les tumeurs	24
I-5-3- Differents types des tumeurs	25
I-5-4- Catégorisation des tumeurs.....	26
I-5-5- Causes et facteurs de risque.....	27
I-5-6- Symptômes et effets secondaires.....	28
I-5-7- Diagnostic et traitement médical.....	29
I-6-Bases de données d'images IRM	29

I-6-1- Plate-forme BrainWeb et BrainVISA	30
I-6-2- Ensemble de données BRATS 2018	31
I-6-3- Ensemble de données BRATS 2019	31
I-7-Conclusion	31

Chapitre II : Principes fondamentaux des techniques de segmentation d'images

II-1-Introduction	34
II-2- Généralités sur la segmentation d'image	34
II-2-1- Définitions et caractérisations	34
II-2-2- Chaîne de traitement d'image	35
II-2-3- Objectifs et domaines d'application	36
II-2-4- Stratégies de segmentation d'image	36
II-2-5- Notions de voisinage spatial et de connexité	38
II-2-6- Mesures de distance et de similarité	39
II-2-7- Interaction, évaluation et validation	40
II-3- Les différentes approches de segmentation d'image	41
II-3-1- Approches régions	43
II-3-1-1- Segmentation par seuillage	44
II-3-1-2- Segmentation par classification des pixels	44
II-3-1-3- Segmentation par croissance de region	48
II-3-2- Approches contours	49
II-3-2-1- Méthodes dérivatives	49
II-3-2-2- Méthodes analytiques	50
II-3-2-3- Méthodes déformables	51
II-3-3- Approches hybrides régions-contours	51
II-3-3-1- Coopération séquentielle	51
II-3-3-2- Coopération des résultats	52
II-3-3-3- Coopération mutuelle	52
II-4-Application à la segmentation des images médicales	53
II-5-Influence des artefacts d'imagerie sur la segmentation	54
II-6-Erreurs liés à la segmentation et les méthodes de correction	57
II-7- Conclusion.....	58

Chapitre III : Etat de l'art des méthodes de segmentation d'image Médicale

III-1- Introduction	60
III-2- Segmentation d'image IRM cérébrale	60
III-3- Revue de la littérature en segmentation d'image médicale	61
III-4- Techniques de base de clustering	64
III-4-1- Signification du clustering vs classification	64
III-4-2- Clustering flou vs dur	65
III-4-3- Notion des sous-ensembles flous	65
III-4-4- C-moyennes floues conventionnelle FCM	66
III-4-5- C-moyennes floues spatiales SFCM	67

III-5- Etudes descriptives des nouvelles méthodes de segmentation	68
III-5-1- C-moyennes floues spatial conditionnel CsFCM	68
III-5-2- C-moyennes floues spatial conditionnel basé sur distance kernel CsKFCM ..	70
III-5-3- C-moyennes floues basé sur distance Gaussien Kernel GKFCM	72
III-5-4- C-moyennes floues Kernel Généralisé KGFCM	73
III-5-5- C-moyennes floues pondérées avec Kernel Généralisé GKWFLICM	74
III-5-6- C-moyennes floues robustes avec contraintes spatial RSCFCM	76
III-6- Analyse comparative des nouvelles méthodes de segmentation	77
III-7-Conclusion	79

Chapitre IV: Contribution à la segmentation d'images IRM cérébrales par FCM modifié considérant le contexte spatial

IV-1-Introduction	81
IV-2- Problématique	81
IV-3- Méthodologie	82
IV-3-1- Chaîne de traitement proposée.....	82
IV-3-2- Pré-traitement des images IRM	84
IV-3-2-1- Vérification ou conversion d'image en niveau de gris.....	84
IV-3-2-2- Application du Filtre de Diffusion Anisotrope modifié.....	84
IV-3-2-3- Elimination des tissus non cérébraux.....	87
IV-3-3- Détermination du nombre optimal de clusters.....	88
IV-3-4- Initialisation des centres des classes	90
IV-3-5- Contributions	91
IV-3-5-1-Choix des paramètres de l'algorithme.....	91
IV-3-5-2- Segmentation d'image basée sur IFCM_S.....	92
IV-3-5-3- Segmentation d'image basée sur ISFCM.....	94
IV-3-5-4- Segmentation d'image basée sur ISKFCM.....	98
IV-3-6- Défuzzification et extraction de la région d'intérêt	101
IV-3-7- Ségrégation et calcule de la zone tumorale	103
IV-3-8- Extraction de caractéristiques de la zone tumorale	105
IV-4- Résultats expérimentaux obtenus	107
IV-4-1- Sur des images synthétiques	107
IV-4-2- Sur des images IRM simulées	109
IV-4-3- Sur des images IRM réelles	111
IV-5-Interprétation, analyse des performances et discussions	114
IV-6-Conclusion	115

Chapitre V: Application, Optimisation et évaluation du système de segmentation sur TMS320C6713DSP

V-1- Introduction	117
V-2- Outils de mise en œuvre matériel et logiciel	117
V-2-1- TMS320C6713 DSK	117
V-2-1-1- Architecture du starter KIT TMS320C6713.....	117

V-2-1-2- Architecture du TMS320C6713 DSP	120
V-2-1-3- Avantages et inconvénients du TMS320C6713 DSP.....	121
V-2-2- Code Composer Studio	122
V-2-2-1- Description de la plate-forme d'expérimentation CCS	122
V-2-2-2- Interface et processus de programmation	123
V-2-3- MATLAB Link pour Code Composer Studio.....	123
V-3- Conception, configuration et implémentation sur C6713 DSK	124
V-3-1- Modèle simulink complet du système de segmentation.....	124
V-3-2- Étapes de mise en œuvre à l'aide duTMS320C6713 DSP	126
V-3-3- Emulation matérielle et échange de données en temps réel	128
V-3-4- Résultats issus de l'implémentation et discussion	129
V-4- Codage et optimisation de l'algorithme ISFCM et ISKFCM sur CCS	132
V-4-1- Profilage sans & avec optimisation du code C/C++	132
V-4-2- Profilage sans & avec optimisation du compilateur C	133
V-4-3- Profilage sans & avec optimisation de la mémoire cache L2	133
V-4-4- Profilage sans & avec optimisation de l'assembleur	134
V-5- Évaluation de performances et validation du système de segmentation	134
V-5-1- Outils de validation	135
V-5-2- Évaluation qualitative	135
V-5-3- Évaluation quantitative	136
V-6- Comparaison des résultats de segmentation en termes de convergence	142
V-7-Conclusion	143
Conclusion générale	145
Bibliographie	148
Annexes	156

Liste des figures

Liste des figures

Chapitre I :

Figure I.1: Une vue IRM illustrant les Différentes parties du cerveau	9
Figure I.2: Les différentes coupes du cerveau : axiale, sagittale et coronale	11
Figure I.3: Vue générale d'un Scanner IRM	15
Figure I.4: Les différents composants du système d'IRM.....	16
Figure I.5: Impact du champ magnétique sur la magnétisation du spin	17
Figure I.6: Impact de la relaxation longitudinale du signal RMN	18
Figure I.7: Processus de formation d'imagerie par résonance magnétique (IRM)	18
Figure I.8: Les Orientations de l'image IRM et ses différents types	20
Figure I.9: Images cérébrales de type IRM normales et anormales	24

Chapitre II :

Figure II.1 : Chaine de traitement d'image (Segmentation)	35
Figure II.2 : Stratégie Scalaire	37
Figure II.3 : Stratégie Marginales	37
Figure II.4 : Stratégie Vectorielles	37
Figure II.5: Représentation des deux types de connexité	38
Figure II.6: Illustration des différents types d'opérations	39
Figure II.7: Catégorisation des différentes méthodes de segmentation d'image	42
Figure II.8: Classification des différentes techniques de segmentation d'image	43
Figure II.9: Organigramme de l'algorithme K-means	47
Figure II.10: Organigramme de la segmentation par Croissance de region	48
Figure II.11: Modèles de contours	50
Figure II.12: Forme de coopération Séquentielle	52
Figure II.13: Forme de coopération des résultats	52
Figure II.14: Forme de coopération Mutuelle	53
Figure II.15: Fonction de densité de probabilité pour le modèle de bruit gaussien	54
Figure II.16: Fonction de densité de probabilité pour le modèle de bruit sel et poivre	55
Figure II.17: Brainweb image IRM simulé de 9% bruit et 20% IIH	56
Figure II.18: L'effet de volume partiel pour les lésions	56

Chapitre III :

Figure III.1: L'organigramme de la segmentation d'image IRM cérébrale	60
Figure III.2: Comparaison des deux fonctions d'appartenance	67
Figure III.3: Résultats de segmentation d'image utilisant FCM et CsFCM	70

Figure III.4: Résultats de segmentation d'image synthétique utilisant CsKFCM	71
Figure III.5: Résultats de segmentation par l'algorithme GKFCM	73
Figure III.6: Résultats de KGFCM utilisant IRM corrompue par le bruit gaussien	74
Figure III.7: Résultats de GKWFICM utilisant IRM corrompue par le bruit gaussien	75
Figure III.8: Résultats de segmentation utilisant RSCFCM	77

Chapitre IV:

Figure IV.1: Schéma général illustrant les étapes impliquées dans notre approche	83
Figure IV.2: Performances d'évaluation en termes de PSNR	85
Figure IV.3: Performances d'évaluation en termes de variance	86
Figure IV.4: Performances des différents filtres proposés	86
Figure IV.5: Résultats de l'algorithme IV.1	88
Figure IV.6: Calcul de l'histogramme de chaque bloc	89
Figure IV.7: Factorisation de la matrice de données V en utilisant PNMF	89
Figure IV.8: Les propriétés moyenne et médiane d'un pixel bruité	93
Figure IV.9: Représentation des 9 régions du filtre de Nagao	94
Figure IV.10: Les valeurs moyenne et médiane d'un pixel bruité	95
Figure IV.11: Les valeurs moyenne et médiane d'un pixel normal	96
Figure IV.12: Taux des caractéristiques extraites utilisant ISFCM	106
Figure IV.13: Taux des caractéristiques extraites utilisant ISKFCM	106
Figure IV.14 : Comparaison des résultats de segmentation sur des images synthétiques	107
Figure IV.15 : Représentation graphique de SA(%) [Cas d'un bruit gaussien]	108
Figure IV.16 : Comparaison des résultats de segmentation sur des images synthétiques	108
Figure IV.17: Représentation graphique de SA(%) [Cas d'un bruit mixe]	109
Figure VII.18: Comparaison des résultats de segmentation sur des images IRM simulées	110
Figure IV.19: Comparaison des résultats de segmentation sur des images IRM réelles	111
Figure IV.20: Représentation graphique de SA(%) des images IRM réelles (1 ^{er} cas)	112
Figure IV.21: Comparaison des résultats de segmentation sur des images IRM réelles	112
Figure IV.22: Représentation graphique de SA(%) des images IRM réelles (2 ^{eme} cas)	113
Figure IV.23: Evolution de la fonction objective	113

Chapitre V:

Figure V.1 : Le Kit de démarrage TMS320C6713 DSK.....	118
Figure V.2 : Schéma fonctionnel de la carte TMS320C6713 DSK	119
Figure V.3 : Schéma globale de l'AIC23 CODEC	119
Figure V.4 : Schéma globale de l'AIC23 CODEC	120
Figure V.5 : Architecture du processeur TMS320C6713 DSP	121
Figure V.6 : Modèle de travail du Code Composer Studio	122
Figure V.7 : L'interface de programmation CCS.....	123
Figure V.8 : Cible intégrée pour C6713 Texas Instrument	124
Figure V.9 : Modèle simulink complet du système de segmentation	125
Figure V.10 : Le dépannage de la connectivité C6713 DSK	127
Figure V.11 : Fenêtre de configuration des options de compilation	127

Figure V.12 : Projet CCS, ses fichiers et fenêtre de commande MATLAB	128
Figure V.13 : Mise en place de l'implémentation en temps réel	128
Figure V.14 : L'outil JTAG et RTDX	129
Figure V.15 : Les résultats expérimentaux de l'ISKFCM et leur implémentation sur TMS320C6713 DSP	131
Figure V.16 : L'outil de configuration du compilateur	133
Figure V.17 : Comparaison des résultats de segmentation sur des images IRM réelles	135
Figure V.18 : Comparaison des performances en termes de coefficient de partition V_{pc}	137
Figure V.19 : Comparaison des performances en termes d'entropie de partition V_{pe}	137
Figure V.20 : Comparaison des performances en termes de similarité (ρ)	138
Figure V.21 : Comparaison des performances en termes de la fonction de Xie-Beni V_{xb}	139
Figure V.22 : Comparaison des performances en termes de la fonction de Fukuyama-Sugeno V_{fs}	139
Figure V.23 : Mesures quantitatives pour la précision de segmentation (SA%)	140
Figure V.24 : Mesures quantitatives pour les taux de classification erronés (MCR%)	141
Figure V.25 : Comparaison de critères de validation pour des images IRM pondérée en T1.	142
Figure V.26 : Nombre d'itérations effectuées par ISKFCM et d'autres méthodes de clustering	143

Liste de tableaux

Liste des tableaux

Chapitre I :

Tableau I.1: Valeurs approximatives de T1 et T2 de certains tissus à 1,0 Tesla	21
Tableau I.2: Caractéristiques tissulaires du cerveau pour l'IRM.....	21
Tableau I.3: Répartition des cas cancer confirmés- Alger 2017	25
Tableau I.4: Les Grades tumoraux et ses caractéristiques	27

Chapitre II :

Tableau II.1 : Caractéristiques principales de l'association de deux cellules.....	39
Tableau II.2 : Sommaire des quatre fonctions de validité choisies	40
Tableau II.3 : Les Avantages/Inconvénients de l'algorithme k-means	47
Tableau II.4 : Méthodes d'élimination du bruit	57
Tableau II.5: Méthodes de correction d'inhomogénéité d'intensité	58
Tableau II.6: Méthodes de correction d'effet de volume partiel	58

Chapitre III :

Tableau III.1: Les Avantages/Inconvénients de l'algorithme Fuzzy C-means	67
Tableau III.2: Analyse comparative des méthodes de clustering.....	78

Chapitre IV:

Tableau IV.1: Rapport PSNR et MSE des résultats expérimentaux	87
Tableau IV.2: Selection optimale des paramètres \bar{S}_j et \tilde{S}_j cas d'un pixel bruité	95
Tableau IV.3: Selection optimale des paramètres \bar{S}_j et \tilde{S}_j cas d'un pixel normal.....	96
Tableau IV.4: Extraction de la region tumorale utilisant ISFCM et ISKFCM	104
Tableau IV.5: Caractéristiques extraites après l'exécution de l'ISFCM	106
Tableau IV.6: Caractéristiques extraites après l'exécution de l'ISKFCM.....	106
Tableau IV.7: Segmentation Accuracy (SA%) en présence du Bruit Gaussien	107
Tableau IV.8: Segmentation Accuracy (SA%) en présence du Bruit Mixe	109
Tableau IV.9: Résultats de SA(%) sur des images IRM simulées à %# de bruit et INH	110
Tableau IV.10: Résultats de SA(%) sur des images IRM réelles (1 ^{er} cas)	112
Tableau IV.11: Résultats de SA(%) sur des images IRM réelles (2eme cas)	113

Chapitre V:

Tableau V.1 : Différents Matlab Simulink Blocksets utilisés	126
Tableau V.2 : Mesure de performance sans&avec optimisation du code C	132
Tableau V.3 : Mesure de performance sans&avec optimisation du compilateur C	133

Tableau V.4 : Mesure de performance sans&avec optimisation de la mémoire cache L2	134
Tableau V.5 : Mesure de performance sans&avec optimisation de l'assembleur	134
Tableau V.6 : Performances comparatives (ρ, V_{pc}, V_{pe}) des différents algorithmes de segmentation sur images IRM cérébrales simulées avec différents IIH et niveaux de bruit ..	136
Tableau V.7 : Performances comparatives (V_{xb}, V_{fs}) des différents algorithmes de segmentation sur images IRM cérébrales simulées avec différents IIH et niveaux de bruit ..	138
Tableau V.8 : Performances comparatives (SA%, MCR%) des différents algorithmes de segmentation sur images IRM cérébrales simulées avec différents IIH et niveaux de bruit ..	140
Tableau V.9 : Les valeurs moyennes des Mesures de performances ($\rho, V_{pc}, V_{pe}, V_{xb}, V_{fs}, SA, MCR$) sur 36 images cérébrales réelles	141
Tableau V.10 : Comparaison des comportements de convergence	142

Notations et Abréviations

Notations et Abréviations

Notations:

$C (\ \nabla I \)$: Coefficient de diffusion
$G (x, y, t)$: Noyau gaussien avec différents paramètres d'échelle t
$\ y_j - v_k\ $: Mesure de similitude entre le pixel et le centre du cluster
α	: Contrôle le voisinage des pixels
\bar{y}_j	: Propriétés moyenne des pixels voisins
\tilde{y}_j	: Propriétés médiane des pixels voisins
J_{IFCM_S}	: Fonction d'objective de l'IFCM_S
\bar{S}_j	: Contrôle automatique de l'effet du terme de voisinage (cas moyenne)
\tilde{S}_j	: Contrôle automatique de l'effet du terme de voisinage (cas médiane)
d_{rj}	: Distance spatiale euclidienne entre les pixels y_j et y_r
y_r	: Pixel de la region sélectionnée
$N_j^{(s)}$: Ensemble des voisins qui existent dans chaque fenêtre autour de y_j
s	: Indice scalaire varie de 1 à 9 et indique la region sélectionnée
y_j	: Pixel de l'image d'entrée
$\ \varphi(x) - \varphi(y)\ ^2$: Distance du noyau (kernel) gaussien
V_{pe}	: Entropie de partition
V_{pc}	: Coefficient de partition
ρ	: Indice de similarité
V_{xb}	: Fonction de Xie-Beni
V_{fs}	: Fonction de Fukuyama-Sugeno
U_{ij}^m	: Degré d'appartenance de x_i au groupe j (matrice de partition)
v_j	: Centres de cluster
$NB(x_j)$: Fenêtre carrée centrée autour le pixel x_j
m	: Degré de flou
c	: Nombre de cluster
$K(x, y)$: Fonction de kernel du produit interne
σ^2	: La variance
μ	: La moyenne
γ	: Rapport gyromagnétique

M_0	:	Magnétisation nette à l'équilibre
∇I	:	Gradient de l'image
K	:	Seuil constante pour contrôler le niveau de lissage
N	:	Nombre de pixels dans l'image donnée
$L_{ISKFCM}(U, V)$:	Méthode lagrangienne de l'ISKFCM
P_k	:	Distribution de probabilité de v_k
B_0	:	Champ électromagnétique
$M_z(t)$:	Magnétisation dans la direction du champ B_0 au temps t

Abréviations :

BET	:	Brain Extraction Tool
BRATS	:	Brain Tumor Segmentation
CCS	:	Code Composer Studio
CPU	:	Central Processor Unit
CsFCM	:	Conditional Spatial Fuzzy C-means
CsKFCM	:	Conditional Spatial Fuzzy C-means based on Kernel induced distance
CT	:	Computed Tomography
DICOM	:	Digital Imaging and Communications in Medicine
DSK	:	Digital Starter Kit
DSP	:	Digital Signal Processor
EMIF	:	External Memory Interface
FCM	:	Fuzzy C-Means
FDA	:	Filtre de Diffusion Anisotrope
FDAM	:	Filtre de Diffusion Anisotrope Modifié
FID	:	Free Induction Decay
FLAIR	:	Fluid Attenuated Inversion Recovery
FMACR	:	Filtre Médian Adaptatif à Commutation Récursive
FMRGS	:	Filtre médian récursif de Gauss-Seidel
FMRI	:	Functional magnetic Resonance Imaging
GBM	:	Glioblastome multiforme
GFCM	:	Generalized Fuzzy C-Means
GKFCM	:	Gaussian Kernel based Fuzzy C-means
GKWFLICM	:	Generalized Kernel Weighted Fuzzy C-means
GLCM	:	Gray Level Co-occurrence Matrix

IDE	:	Integrated developpement environement
IFCM	:	Improved Fuzzy C-Means
IIH	:	Intensité d'inhomogénéité
IRM	:	Imagerie par Résonance Magnétique
ISFCM	:	Improved Spatial Fuzzy C-means based on Euclidean distance
ISKFCM	:	Improved Spatial Fuzzy C-means based on Kernel distance
JTAG	:	Joint Test Action Group
KFCM	:	Kernalized Fuzzy C means
KGFCM	:	Kernel Generalized Fuzzy C-means
LCR	:	Liquide céphalo-rachidien
MAC	:	Multiplier and Accumulator
MB	:	Matière Blanche
McASP	:	Multichannel Audio Serial Port
McBIC	:	Centre d'imagerie cérébrale McConnell
McBSP	:	Multichannel Buffered Serial Port
MG	:	Matière Grise
MICCAI	:	Medical Image Computing and Computer Assisted Intervention
MSE	:	Mean Square Error
PCM	:	Possibilistic C-Mean
PDF	:	Probability Density Function
PET	:	Positron Emission Tomography
PNMF	:	Factorisation matricielle non négative probabiliste
PSNR	:	Peak signal to Noise ratio
RF	:	Radio Frequency
ROI	:	Region of Interest
RSCFCM	:	Robust Spatial Constrained Fuzzy C-means
SA	:	Segmentation accuracy
SFCM	:	Spatial Fuzzy C-Means
SI	:	Similarity Index
SNR	:	Signal to Noise Ratio
SPECT	:	Single Photon Emission Computed Tomography
TE	:	Temps d'écho
TEP	:	Tomographie par émission de positrons
TR	:	Temps de répétition
VLIW	:	Very Large Instruction Word

Introduction générale

Introduction générale

En tant que discipline technologique, le domaine de la vision artificielle fait référence à un ensemble de techniques de calcul en informatique, en intelligence artificielle, en apprentissage automatique et dans certaines disciplines de l'ingénierie, qui tente d'étudier, de modéliser et d'analyser des solutions très complexes. Les systèmes de vision peuvent analyser la complexité des images avec une précision élevée. Le traitement et l'analyse d'images numériques dans des ordinateurs est appelé traitement numérique d'images. Ce dernier est entré en scène au début des années 1960 avec le développement des circuits intégrés. Les techniques de traitement d'images numériques sont maintenant utilisées dans plusieurs domaines. L'une des applications populaires est le traitement d'images médicales. L'imagerie médicale a connu une révolution au cours de la dernière décennie avec l'invention de dispositifs rapides et précis. Cela a conduit à la nécessité de développer des logiciels correspondants et de créer des nouveaux algorithmes de traitement d'images médicales. Le diagnostic et le pronostic de la maladie par ordinateur deviennent essentiels et très important pour satisfaire le besoin des clients et de disposer d'un service de meilleure qualité.

Le traitement d'images médicales consiste à utiliser des algorithmes informatiques pour effectuer l'opération du traitement numériques. En tant que sous-domaine du traitement du signal numérique, le traitement d'image numérique présente de nombreux avantages par rapport au traitement d'image analogique; cela permet d'appliquer une gamme beaucoup plus large d'algorithmes aux données et d'éviter des problèmes tels que l'accumulation de bruit et la distorsion du signal pendant le traitement. Les modalités d'imagerie médicale modernes génèrent des images de plus en plus grandes qui ne peuvent pas tout simplement être examinées manuellement et en temps réelle. Cela favorise la mise au point de méthodes d'analyse d'images plus efficaces et plus robustes, adaptées aux problèmes rencontrés dans les images médicales. La partie la plus fondamentale et la plus importante du traitement d'image médicale est la segmentation.

Actuellement, La segmentation des images attire l'attention des recherches dans le secteur médical. Les techniques de traitement d'image visent à mieux reconnaître les objets en trouvant les caractéristiques locales appropriées en séparant la zone concernée des fonds réels. Le processus de segmentation d'image numérisera chaque pixel étudié. En termes simples, le sens de la segmentation d'images utilisant des techniques de traitement d'images consiste à décomposer une image en un large éventail de domaines, en fonction des intérêts de la recherche. La segmentation manuel n'est pas efficace car les méthodes manuelles prennent énormément de temps d'exécution et que des réponses subjectives sont obtenues au sein des examinateurs. Dans la segmentation manuelle, l'état du patient doit être clairement saisi par le médecin à partir d'images telles que l'IRM et doit préparer le traitement de la maladie à partir des données médicales. En général, l'analyse et l'identification de la tumeur cérébrale sont gérées manuellement par un médecin. Les médecins devraient examiner un grand nombre

d'images IRM pour plusieurs patients. En raison de cette situation, les médecins ont plus de possibilités de faire des erreurs dans les résultats de la segmentation de la tumeur. Le développement d'une méthode de segmentation automatique de la tumeur cérébrale aide à réduire la variabilité des résultats et évolue avec un nouveau protocole standard et des mesures permettant de produire des résultats de segmentation de haute qualité. Par conséquent, la thèse actuelle propose des techniques de segmentation automatique de tumeurs cérébrales à partir d'images IRM multimodales. L'exigence de la segmentation automatique des tumeurs cérébrales devient critique pour les activités d'investigation clinique et scientifique en terme médicale.

Pour apporter une solution à la segmentation des images médicales, plusieurs méthodes ont été proposées ces dernières années. Parmi ces nouvelles méthodes, nous basons sur la segmentation par classification (clustering) qui permet d'apporter une approche de solutions aux problèmes étudiés. La segmentation par classification C-moyennes floue associée aux techniques de traitement d'images conventionnelles constitue un outil puissant pour gérer les subtilités de la segmentation d'images médicales. Le problème majeur dans le traitement des images médicales est le flou et l'incertitude. La segmentation des images médicales est la première étape vers un diagnostic automatisé mais les images médicales sont très complexes et contiennent un degré d'incertitude élevé. La flexibilité et l'adaptabilité des méthodes de classification floue facilitent les tâches pour segmenter les images médicales complexes. La segmentation des tumeurs cérébrales par IRM est la tâche de délimiter la tumeur cérébrale dans les images IRM, qui fournit la connaissance de la taille, de la forme et de l'emplacement de la tumeur et constitue une étape essentielle dans sa compréhension et son analyse.

Cette thèse a été préparée au sein du Laboratoire de Recherche LTC (Laboratoire Technologie de la Communication) de l'Université de Saida Dr Tahar Moulay. Elle a été proposée et effectuée sous la direction du Dr HACHEMI Kaddour et Pr. DJELLOULI Bouazza. Cette recherche est une continuité des travaux récemment réalisés ou les fondements des différents sujets sont explorés pour s'assurer que le domaine de recherche est couvert en profondeur. La motivation, contribution, organisation et les objectifs de cette thèse sont également exposés ci-dessous :

1. Objectifs de la thèse

L'utilisation d'un système automatisé de segmentation pour les pathologies et tissus cérébraux est très utile. La thèse proposée vise donc à faire une étude comparative des nouvelles méthodes de segmentation d'images médicale et aussi à réaliser une segmentation automatique des tissus et la tumeur cérébrale des images IRM ou la segmentation automatique est effectuée à l'aide d'une classification C-moyennes floue basée sur le terme d'information spatiale, qui offre un cadre d'optimisation global efficace pour la segmentation sans apprentissage. Les objectifs significatifs de ce travail de recherche sont:

- Etudier et analyser l'efficacité des nouvelles méthodes de segmentation en focalisant l'attention sur le cas des images IRM cérébrales.
- Utiliser les outils particuliers du traitement et les notions de base fondamentaux pour la segmentation des images médicales.

- Développer des méthodes itératives de segmentation permettant d'améliorer de façon raisonnable la qualité de l'image IRM cérébrales en réduisant les niveaux de bruit indésirable ajoutés après la numérisation.
- Introduire des contraintes d'inclusion entre les pixels voisins qui permettent d'obtenir une segmentation plus précise.
- Segmenter automatiquement la partie anormale (tumeur) des images IRM cérébrales classées par résonance magnétique en utilisant des techniques de classifications C-moyennes floues modifiées.
- Augmenter la précision du processus de segmentation des tissus (la matière blanche WM, la matière grise GM et le liquide cérébro-spinal CSF) à l'aide des techniques de classification C-moyennes flou optimisées.
- Développer une nouvelle fonction objective basée sur la fonction objective standard de Fuzzy C-Means en incorporant les informations spatiales qui permettant de regrouper des ensembles de données complexes d'images IRM et d'autres ensembles de données médicales.
- Implémenter des algorithmes de segmentation d'images sur des processeurs de traitement de signal type TMS320C6713 DSP de Texas Instrument. Cette mise en œuvre est effectuée pour faciliter l'analyse comparative des approches modifiées.
- Evaluer la performance des techniques proposées et comparer ses performances avec les nouvelles techniques existantes en termes de minimisation du temps de calcul et l'optimalité des résultats.

Pour atteindre ces objectifs, une étude comparative détaillée des différentes nouvelles techniques de segmentation existantes a été réalisé. Cette étude nous a montré tous les problèmes que l'on peut rencontrer dans le domaine du traitement des images. Et surtout lorsque l'on traite des images médicales de type IRM cérébrales. Ce travail nous a permis de réfléchir sur des algorithmes faisant intervenir des nouvelles notions que nous allons exposées en détail tout au long de cette recherche.

2. Problématique et contributions de la thèse

Cette thèse porte à la fois sur la recherche et le développement des techniques de segmentation d'images capables d'extraire la structure intéressée et significative sur les images médicales en précisant tous les problèmes confrontés et leurs solutions. Les systèmes d'imagerie utilisés dans les hôpitaux ne favorisent pas les conditions suivantes:

- La région tumorale situe entre les tissus du cerveau ne peut pas être efficacement séparée en présence d'une inhomogénéité d'intensité, effets de volume partiels, bruit d'image et autres artefacts d'imagerie.
- Les régions de tissu normales ne peuvent pas être segmentées par un outil de traitement d'image conventionnel disponible dans un centre de numérisation.
- Des volumes de données plus importants nécessitent une durée et des ressources humaines maximales pour un meilleur diagnostic.

Ces conditions s'avèrent être un défi majeur pour développer une nouvelle approche de segmentation des tumeurs cérébrales en utilisant des méthodes de classification efficaces et

intégrées pour permettre une précision de segmentation supérieure avec une vitesse de calcul élevée. Cette recherche porte principalement sur les problèmes de l'algorithme de classification C-moyennes flou et tente d'apporter une solution en introduisant des mécanismes efficaces et robustes basées sur des concepts tels que les mesures des distances, le terme d'information spatiale, la fonction objective modifiée et l'initiation des centres de classes, ... etc. La motivation de ce modeste travail est d'introduire des méthodes efficaces de classification floue considérant le contexte spatial pour une segmentation automatisée robuste basée sur les images IRM cérébrales et d'autres données médicales afin de détecter et de diagnostiquer la partie cancéreuse et d'aider ainsi les médecins à élaborer un plan de traitement efficace.

3. Organisation de la thèse

Dans cette section, l'organisation du manuscrit est expliquée ou un résumé descriptif de chaque chapitre est présenté ci-dessous. Par voie de conséquence, la thèse intitulée «Etude Comparative des Nouvelles Méthodes de Segmentation d'images» comprend cinq chapitres présentant les contributions essentielles du travail doctoral comme suite :

Chapitre I : Anatomie cérébrale et Acquisition d'images médicales de type IRM, Ce chapitre fournit entièrement l'idée de base de l'anatomie cérébrale humaine et les caractéristiques de la tumeur, la classification des tumeurs cérébrales et leurs divers outils d'analyse, les différents types de modalités d'imagerie médicale courantes disponibles, les termes fondamentaux associés à cette recherche sont aussi mentionnés et discutées en détail à travers ce chapitre. Ce dernier évoque également les principaux aspects de l'imagerie par résonnance magnétique (IRM) qui sont utiles pour la segmentation de la tumeur cérébrale, les causes et les facteurs de risque, les symptômes et les effets secondaires sont aussi présentés. Enfin une brève description des bases de données d'images IRM qui sont utilisées pour évaluer nos algorithmes de segmentation.

Chapitre II : Principes fondamentaux des techniques de segmentation d'images, ce chapitre a pour objectif d'introduire les notions de base nécessaires et faire une description des principes fondamentaux des techniques de segmentation d'images et leurs étapes du traitement. Une brève introduction aux concepts de base du domaine de traitement bas-niveau (segmentation) et une discussion détaillée sur les techniques de segmentation par classification floue sont également présentés.

Chapitre III : Etat de l'art des méthodes de segmentation d'image Médicale, Comprend entièrement «l'étude de la littérature scientifique». Ce chapitre explorera les différentes modalités d'image utilisées dans l'industrie médicale où les méthodes de segmentation sont largement appliquées. Il présentera un état de l'art et une recherche bibliographique sur les moyens, les techniques et les technologies qui permettraient une observation et une évaluation de l'évolution des différentes nouvelles méthodes de segmentation d'images médicales puis procèdera à l'observation structurée et organisée. Cette observation permettra de faire une étude comparative de ses méthodes et ses principaux problèmes. Leurs avantages et inconvénients sont présentés afin de situer la méthode proposée par rapport à celles-ci.

Chapitre IV : Contribution à la segmentation d'images IRM cérébrales par FCM modifié considérant le contexte spatial, ce chapitre décrit la méthodologie employée de notre contribution. Il est entièrement dédié à la proposition d'une nouvelle méthode non supervisée utilisée dans le but d'identifier la tumeur cérébrale et de segmenter le tissu présentent dans les images IRM en précisant tous les problèmes rencontrés et leurs solutions en présence les divers artefacts et facteurs qui dégradent l'information. Cette nouvelle méthode est basée sur l'amélioration de la segmentation par classification C-moyennes floue considérant le terme d'information spatial et la distance du voisinage utilisé. Nous détaillons les différentes étapes par lesquelles nous sommes passées et en justifiant nos choix.

Chapitre V : Application, Optimisation et évaluation du système de segmentation sur TMS320C6713 DSP, sur la base des résultats obtenus et étudiés dans les précédents chapitres, et puisque le volume des données à traiter est beaucoup plus important et la structure de ces données est nettement plus complexe, ce chapitre présente les différents outils software et hardware qui vont servir à l'implémentation de notre algorithme, ainsi que le modèle proposé pour l'implémentation. Dans ce chapitre le but est d'optimiser le temps de calcul de l'algorithme de segmentation développé puis nous évaluons les résultats obtenus afin de conclure sur la meilleure stratégie à adopter pour la segmentation d'images médicales. Les différentes méthodes développées ont été validées à la fois sur des bases d'images synthétiques, simulées et réelles.

A la fin, notre travail sera clôturé par une conclusion générale et une présentation de quelques perspectives ouvertes sur la base des travaux effectués, également mes publications relatives à cette thèse sont répertoriées dans l'annexe D. Pour une meilleure compréhension de cette thèse, des démonstrations mathématiques et quelques descriptions de l'outil de développement DSP sont figuré dans les annexes A, B et C, respectivement.

Chapitre I :

*Anatomie cérébrale et Acquisition
d'images médicales de type IRM*

I-1-Introduction :

La technologie d'imagerie médicale joue un rôle clé pour diagnostiquer facilement l'état du patient. L'art de l'imagerie médicale s'intéresse à la représentation des parties intérieures du corps humain, elles peuvent être traitées de manière efficiente par des dispositions diverses dans l'intention d'arbitrer l'évaluation objective pour un pronostic effectif. L'utilisation de traitement d'images dans la plupart des domaines sensibles tels que les hôpitaux a rendu la recherche plus intéressante et de plus en plus impératif dans des nombreuses applications médicales. Ce traitement d'images gère le processus de diagnostic et facilite le traitement biomédical en temps réel. Les modalités d'imagerie médicale modernes génèrent des images qui ne peuvent tout simplement pas être examinées manuellement. Cela conduit au développement des méthodes d'analyse plus efficaces et plus robustes adaptées aux problèmes rencontrés dans le cadre de la segmentation d'images.

Ce chapitre fournit l'idée de base de l'anatomie cérébrale humaine et les caractéristiques de la tumeur cérébrale, les différents types de modalités d'imagerie médicale courantes disponibles ces derniers temps avec leurs caractéristiques, la classification des tumeurs cérébrales et leurs divers outils d'analyse, les termes fondamentaux associés à cette recherche sont aussi mentionnés et discutées en détail à travers ce chapitre. Ce dernier évoque également les principaux aspects de l'imagerie par résonnance magnétique (IRM) qui sont utiles pour la segmentation de la tumeur cérébrale, les causes et les facteurs de risque, les symptômes et les effets secondaires. Enfin une brève description des bases de données d'images IRM sont utilisées pour évaluer nos algorithmes de segmentation.

I-2- Anatomie cérébrale:

Le corps humain est l'un des systèmes les plus complexes pose des défis qui doivent être surmontés par une utilisation efficace de la technologie. Le cerveau est une masse nerveuse située à l'intérieur de la voûte du crâne, certaines définitions sont décrites comme suit:

I-2-1- Définitions:

Le corps humain est l'un des systèmes les plus complexes du point de vue de l'ingénierie. Ce système complexe pose des défis qui doivent être surmontés par une utilisation efficace de la technologie. Le cerveau est une masse nerveuse située à l'intérieur de la voûte du crâne.

Le système nerveux humain est partagé en deux sous-systèmes, système nerveux central (CNS) et le système nerveux périphérique (PNS) qui est composé des nerfs crâniens et des nerfs spinaux provenant respectivement du tronc cérébral et de la moelle épinière. Le système nerveux central qui est composé du cerveau et de la moelle épinière loue sa plus grande partie au cerveau qui est considéré comme le plus complexe organe en sa structure anatomique dans le corps humain, responsable de la réception, traitement et interprétation des informations. Parmi les applications cruciales de l'imagerie médicale est l'analyse des captures cérébrales, en particulier l'analyse automatique des structures neuro-anatomiques en adoptant une variété de processus dans le traitement de l'imagerie médicale [MAR 12].

La partie du cerveau est protégé par le crâne osseux qui est une structure gélatineuse moelleuse responsable de toutes activités corporelles, se compose de: lobes du cerveau, cervelet et du tronc cérébral, ce sont des scissures qui divisent le cerveau en plusieurs lobes. La plus volumineuse partie du cerveau est l'hémisphère cérébral qui est composée de l'hémisphère cérébral droit et l'hémisphère cérébral gauche et situé en dessus du cervelet. L'hémisphère cérébral est impliqué dans le contrôle des mouvements musculaires, le tronc cérébral participe dans les fonctions vitales tels que : régulation des cycles du sommeil, la température corporelle, les réflexes de vomissement, le rythme cardiaque, la pression sanguine, il représente ainsi la partie qui sert à une commutation dans la transmission de l'information des hémisphères cérébraux au cervelet et de la moelle épinière vers le cervelet.

Le cerveau se compose de deux types de cellules : Un groupe de cellules appelé neurones, tandis que l'autre groupe est appelé neuroglie. Les neurones participent à l'accomplissement du traitement et la communication cérébrale. Les cellules de la néuroglie mettent le relais entre les neurones avec le sang et le Liquide Céphalo-Rachidien (LCR). La neuroglie peut être identifiée comme des cellules auxiliaires qui soutiennent et protègent les neurones. L'aspect plié de l'hémisphère cérébral appelé le cortex est composé d'environ 70% de neurones en lui apportant une couleur grise, cette substance est appelé la matière grise. Les axones des cellules nerveuses qui participent à la connexion des différentes zones de la matière grise et assistent les communications entre les cellules nerveuses. Les fibres nerveuses entourées d'une gaine de myéline protectrice forment ce qu'on appelle la matière blanche, la couleur de cette substance est due à la myéline, qui intervient comme un isolant facilitant la transmission des signaux par les cellules nerveuses [CER 13].

Le cortex cérébral est divisé en régions similaires à des dispositions géométriques des continents appelés les lobes : lobe frontal, lobe pariétal, lobe occipital et le lobe temporal. Figure I.1. Le cerveau est subdivisé en plusieurs parties, que l'on peut distinguer en se basant d'une part sur son développement et, d'autre part, sur son architecture.

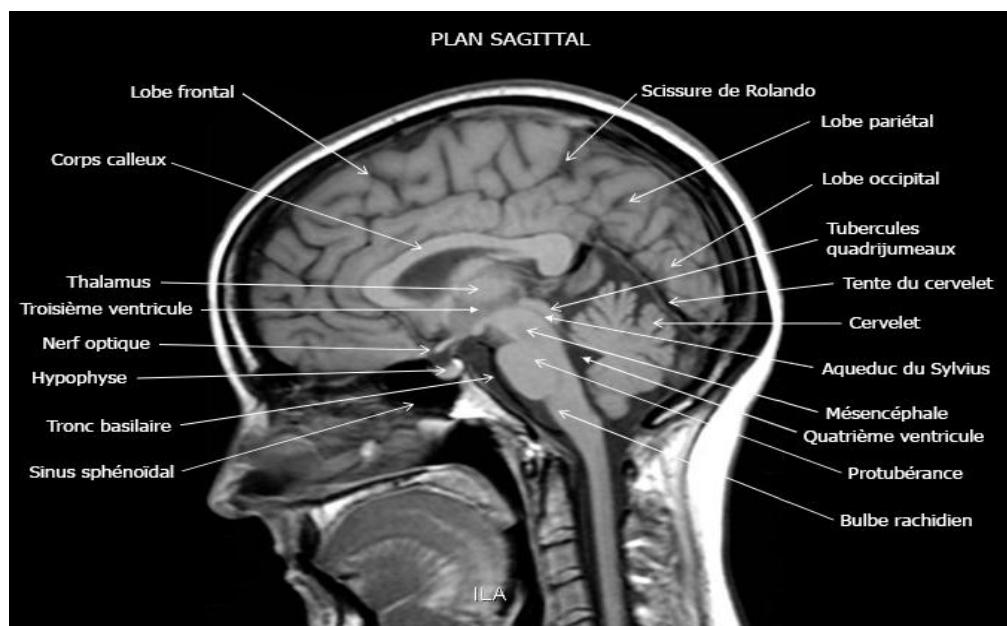


Figure I.1 : Une vue IRM illustrant les Différentes parties du cerveau.

I-2-2- Les tissus cérébraux:

Les techniques médicales offrent la possibilité de visualiser les tissus cérébraux d'une façon plus précise et plus profond. Elles permettent d'en connaître la structure anatomique et également d'en suivre leur fonctionnement. En général, le tissu cérébral peut être divisé en trois grandes classes principales. Ces différentes classes sont :

A- Le liquide céphalo-rachidien LCR:

LCR est un liquide incolore clair et aqueux produit qui agit comme un coussin, une barrière mécanique contre les chocs jouant le rôle d'amortisseur, protégeant le cerveau et la colonne vertébrale contre les blessures et remplit des fonctions importantes dans les échanges entre le sang et les tissus nerveux. Le LCR comprend du glucose, de l'oxygène et des ions qui le soutiennent pour se distribuer dans tout le tissu nerveux. Il transporte également les déchets loin des tissus nerveux. Après avoir circulé autour du cerveau et de la moelle épinière, le LCR pénètre dans une petite structure connue sous le nom de villosités arachnoïdiennes où il est réabsorbé dans la circulation sanguine. Le LCR est produit par le plexus choroïde dans les ventricules latéraux, troisième et quatrième et circule à travers l'espace sous-arachnoïdien.

B- La Matière Blanche MB:

La matière blanche (ou substance blanche) se situe dans la partie interne du cerveau. Elle est composée d'axones et de myéline. Les axones nerveux établissent les connexions entre les cellules nerveuses, la gaine de myéline a deux fonctions: substance grasse qui sert à isoler et à protéger les fibres nerveuses et recouvre les axones des neurones pour en accélérer la conduction d'impulsion. L'isolation est importante pour la prévention des court-circuits. Grâce à sa construction spéciale, la myéline accélère la propagation des impulsions le long des axones. Ces axones myélinisés s'assemblent en faisceaux (l'équivalent des nerfs) pour aller établir des connexions avec d'autres groupes de neurones. Lorsque la gaine de myéline est endommagée ou disparaît, la conduction des impulsions le long des fibres nerveuses ralentit ou échoue complètement. Par conséquent, les fonctions cérébrales sont gênées ou perdues [GER 99].

C- La Matière Grise MG:

La matière grise MG est essentiellement constituée de neurones qui ont des axones non myélinisés ou la gaine de myéline est blanche. On peut distinguer plusieurs structures dans la matière grise : d'une part, on trouve le cortex avec une épaisseur d'environ 2 à 3 millimètres, Il est le centre de la conscience et recouvre la totalité du cerveau. D'autre part, on trouve Les noyaux gris centraux qui gèrent certaines fonctions vitales, ainsi que la mémoire. Les fonctions primaires de pensée, de perception et cognitives du cerveau se produisent dans la matière grise du cerveau. Les neurones de cette partie du cerveau sont suffisamment courts pour que le signal électrique ne se dégrade pas du début du corps cellulaire à la terminaison axonale. Par conséquent, aucune isolation ou amplification du signal du canal ionique n'est requise. En revanche, les axones et donc les voies axonales qui vont du cortex cérébral aux structures cérébrales internes et à la moelle épinière, sont plus longs et ont besoin de l'isolation et de l'amplification du signal. Ainsi, là où ces neurones commencent à prédominer, la matière cérébrale devient en fait blanche. Comme la surface du cerveau est remplie totalement de

nombreuses collines et vallées, la face intérieure entre la matière grise (MG) et la matière blanche (MB) est également irrégulière [GER 99].

Ainsi, il est nécessaire de mesurer le volume ou la surface des MG, MB et LCR ainsi que leur distribution spatiale et les changements temporels pour diagnostiquer les diverses maladies cérébrales. Les images de type IRM peuvent contenir à la fois des coupes anormales, normales et défectueuses qui sont déterminées par sa symétrie aux images axiale et coronale.

I-2-3- Observation du cerveau:

Le cerveau peut être visualisé à travers des coupes bidimensionnelles selon plusieurs angles de vue. Il existe principalement trois axes anatomiques qui permettent de réaliser les coupes : axiale, sagittale et frontale. La coupe axiale (ou transverse) représente une vue de dessus du cerveau. Elle correspond à un plan perpendiculaire au champ magnétique statique. La coupe sagittale est relative à un plan parallèle au plan inter hémisphérique. L'IRM cérébrale peut être visualisée dans trois plans différents, il s'agit de vues latérales ou axial du cerveau, par contre la coupe frontale (ou coronale) est une vue de face du cerveau. Elle est acquise sur le plan perpendiculaire aux coupes axiale et sagittale. La figure I.2 suivante permet de montrer les différentes coupes du cerveau.




Figure I.2 : Les différentes coupes du cerveau : axiale, sagittale et coronale.

I-3-Modalités d'imagerie médicale:

Il existe de nombreuses modalités d'imagerie qui peuvent être utilisées pour étudier et inspecter les tumeurs cérébrales. L'imagerie médicale a évolué à partir du moment où l'image radiographique est développée. Il y a beaucoup de demandes de modalités d'image depuis 100 ans exactement depuis la découverte des rayons X. Les auteurs [XIN 16] montrent les différentes techniques d'imagerie cérébrale ou ses modalités d'imagerie importantes sont sélectionnées comme suit: la tomographie assistée par ordinateur (CT), l'échographie et l'imagerie par résonance magnétique (IRM), la tomographie calculée à émission de photons uniques, la tomographie par émission de position (TEP) et IRM fonctionnelle (IRMF).

I-3-1- Échographie:

La modalité échographique est principalement utilisée pour étudier les tissus soft. Elle mesure la réflexion des ondes ultrasonores transmettant à travers le corps. Les fréquences sonores utilisées en échographie sont supérieures à 1 MHz. Un transducteur positionné contre la surface du corps émet les ultrasons et reçoit les ondes réfléchies. Lorsque les ondes atteignent une interface entre des tissus de densités différentes, les ondes peuvent être

diffusées, absorbées, réfléchies ou transmises selon les circonstances. Les caractéristiques des ondes qui reviennent au transducteur forment les images. Une caractéristique particulière des images échographiques est le bruit de speckle. L'imagerie échographique souffre d'un niveau élevé de bruit speckle qui rend difficile une segmentation précise. Les algorithmes de segmentation ont une application limitée avec l'imagerie ultrasonore. Cependant, la tâche d'estimation de mouvement dynamique peut être correctement comprise en utilisant l'acquisition en temps réel d'images échographiques et donc cette modalité d'imagerie est également utilisée pour extraire une variété de structures, y compris la segmentation des kystes ovariens, la segmentation des échocardiogrammes et la segmentation des kystes dans les images du sein.

Il provient des réflexions avant et arrière entre les différents tissus et rend les images assez bruyantes. Il existe trois différents modes de présentation des ultrasons; Mode A, mode B et mode M. Le mode A montre les échos dans la direction du transducteur avec une amplitude sur l'axe y et une distance (en supposant une vitesse constante du son) sur l'axe x. En mode B, le faisceau sonore est balayé à travers le patient et une image bidimensionnelle est produite. Les échos de forte amplitude sont représentés par des valeurs d'intensité élevées. Le mode M montre chaque interface de production d'écho en fonction du temps, ce qui permet d'étudier le mouvement de la structure. L'échographie est utilisée en cardiologie, gynécologie, obstétrique, urologie et neurologie.

I-3-2- Tomographie assistée par ordinateur (CT):

La tomodensitométrie (TDM) est une technique d'imagerie où le tube à rayons X tourne autour du corps et les rayons sont détectés par un réseau circulaire fixe de détecteurs. Les images sont reconstruites en utilisant des mesures des rayons X transmis à travers le corps et des modèles mathématiques. Il y a une résolution de contraste plus élevée dans les images CT que dans les images radiographiques ordinaires, ce qui signifie que différents organes peuvent être séparés dans les images CT. Le scanner peut être utilisé pour détecter les tumeurs, les infarctus de la tête et les maladies abdominales.

En tomodensitométrie, l'image est reconstruite à partir d'un grand nombre de rayons X. La tomodensitométrie supprime certaines des complications associées à la radiographie de projection et génère une imagerie 3D à une résolution égale ou supérieure à l'IRM. La TDM n'est pas tellement bonne pour le contraste des tissus mous, mais c'est une modalité d'imagerie bien connue pour l'imagerie des tumeurs osseuses et osseuses. La segmentation des images CT a également été appliquée aux clichés thoraciques et aux images cérébrales, bien que l'imagerie par IRM soit actuellement largement utilisée pour la segmentation du cerveau. En outre, la modalité d'imagerie par tomodensitométrie est également utilisée pour l'imagerie du foie, de l'estomac et du cœur. [KAL 07].

I-3-3- Imagerie par résonance magnétique (IRM):

En imagerie par résonance magnétique (IRM), le corps est placé dans un champ magnétique. En introduisant un champ électromagnétique pour obtenir une résonance avec les protons (principalement dans les molécules d'eau du corps), un signal radiofréquence est émis et peut être détecté par une bobine réceptrice. Par des modèles mathématiques, ces signaux

sont transformés en images transversales du corps. Les tissus particulièrement mous sont intéressants dans ces images en raison de leur résolution de contraste élevée.

L'imagerie IRM est une méthode populaire en imagerie médicale. La majorité de la recherche médicale ces derniers temps est basée sur des images IRM car elle peut fournir une combinaison de haute résolution, un excellent contraste des tissus mous et un rapport signal / bruit élevé. De plus, l'IRM est relativement sûre et contrairement à d'autres modalités d'imagerie médicale, elle peut être utilisée aussi souvent que nécessaire. De plus, l'imagerie IRM peut être adaptée aux images du cerveau.

I-3-4- Tomographie calculée à émission de photons uniques:

C'est une technique largement utilisée pour le diagnostic. En utilisant cette méthode, les images du corps humain peuvent être créées par la distribution de traceurs radio pharmaceutiques. L'avantage de cette méthode est la capacité de transmettre les rayons gamma sur une géométrie cristalline de 2% très efficacement. Un autre avantage majeur de cette méthode est d'avoir une conception stationnaire plus conviviale pour le patient. Cette conception stationnaire améliore également la stabilité du système et élimine les artefacts des anneaux de rotation qui proviennent de la non-uniformité des cristaux. En général, la Tomographie calculée à émission de photons uniques utilise un cristal mince de 10 mm pour limiter la lumière qui se propage à partir d'images haute résolution et une triade de collimateurs à trous parallèles pour échantillonner les projections de rayon gamma [YAN 09].

Les derniers collimateurs sont incorporés avec des convergents variant qui se concentre en continu pour fournir une sensibilité et des résolutions élevées en augmentant les projections de rayons gamma. En raison de ces convergences variables, l'échantillonnage des rayons gamma est considéré comme plus efficace. Il utilise l'idée de traces pour le processus chimique de l'image. Généralement, le traceur est composé actif biologique analogue où les atomes sont remplacés par un autre atome radioactif. Après avoir introduit un tel traceur dans l'absorption spécifique du corps sera tracé au moyen d'un atome marqué. En général, cette technique utilisera TC-99m (Technetium) pour les os, le foie et le cerveau, l'iode (1-123) pour le cerveau et le Gallium (Ga-67) pour les tumeurs. Ces radio-isotopes sont des émetteurs gamma et la plupart du temps, un patient reçoit une dose allant jusqu'à 25 mCi (milliCurie) de l'activité [WEM 04].

I-3-5- Tomographie par émission de positrons (TEP):

En tomographie par émission de positrons (TEP), le rayonnement détecté est un rayonnement d'annihilation. Ce rayonnement se produit lorsque les positons et les électrons interagissent et que les photons émis sont émis dans la direction opposée. Si un détecteur circulaire détecte simultanément des photons dans des directions opposées, on suppose que l'annihilation s'est produite sur une ligne droite entre les détecteurs.

Cette méthode de numérisation d'un test d'image aidera le fonctionnement des tissus et des organes d'un corps humain. Il utilise très peu de matières radioactives pour effectuer cette activité. Comme dans le cas de tomographie calculée à émission de photons uniques, cette méthode utilise également l'idée de trace pour le processus chimique de l'image. Le type de

matière radioactive à utiliser dépendra de l'organe ou du tissu étudié par la TEP. L'utilisation de la tomographie par émission de positrons selon Vansteenkiste dans [VAN 02] est basée sur la capacité de visualiser les différences entre les métabolismes du glucose des différents tissus. Dans un corps humain, les cellules néoplasiques auront un taux de glycolyse plus élevé que les cellules non néoplasiques.

I-3-6- IRM fonctionnelle (IRMF):

L'IRM fonctionnelle est une technologie bien adaptée car elle offre une fenêtre non invasive sur la fonction cérébrale avec une couverture complète du cerveau et une résolution spatiale raisonnable. En d'autre terme, l'IRMF pourrait être un système de neuro imagerie précieux qui mesure l'action du cerveau par les changements de travail des analystes identifiés avec la circulation sanguine. Ce cadre repose sur la vérité même que le flux sanguin cérébral et l'unité de territoire d'activation des cellules physiques sont couplés. Une fois qu'un endroit du cerveau est utilisé, la circulation sanguine dans cette zone augmentera conjointement. Le type essentiel d'imagerie par réverbération attrayante utilise le raffinement Blood-Oxygen-Level Dependent (BOLD) dans leur principe de base [BEH 06].

La pensée d'imagerie par résonance magnétique se développe sur l'innovation de numérisation tomographique plus tôt et en outre la révélation des propriétés du sang riche en oxygène. La tomographie cérébrale utilise un flux statique intense et perpétuel pour ajuster les noyaux à l'intérieur de la zone mentale envisagée. Un autre flux, le champ angulaire, est alors connecté pour découvrir spatialement des noyaux entièrement différents. Enfin, un battement radiofréquence (RF) s'efforce de pousser les noyaux à des niveaux de polarisation plus élevés, avec pour résultat le châtiment actuel où qu'ils soient. Une fois le champ RF expulsé, les noyaux reviennent à leurs états uniques, et de plus l'énergie qu'ils produisent est mesurée avec une boucle pour reproduire les emplacements des noyaux. La tomographie donne ainsi une lecture de base statique de la matière cérébrale. Le point essentiel derrière l'imagerie par résonance magnétique est de construire une tomographie pour capturer les changements utiles à l'intérieur du cerveau causés par le mouvement des cellules physiques. Les variétés de propriétés magnétiques entre les conduits (sang avec riche en oxygène) et les veines (sang avec pauvre en oxygène) le sang ont donné cette connexion.

I-4-Imagerie par résonance magnétique:

L'imagerie par résonance magnétique(IRM) est une technique d'imagerie populaire qui a suscité un vif intérêt dans la science, elle est utilisée principalement en milieu médical car elle présente un contraste exceptionnel et fournit des images tridimensionnelles à haute résolution et riches en détails de l'anatomie cérébrale. Il s'agit d'une technique d'imagerie du corps entier qui n'utilise pas de rayonnement ionisant. Les propriétés non invasives et non ionisantes de cette technique et la capacité de produire des images avec un excellent contraste font de cette modalité un bon choix pour les études liées au cerveau et elle est devenue un outil complet pour les chercheurs de vastes domaines tels que les physiciens, les neurobiologistes et les sociétés pharmaceutiques.

I-4-1- Principe de base de l'IRM:

L'IRM est une technique radiologique récente, non invasive et sans effets secondaires connus, basée sur le phénomène physique de résonance magnétique nucléaire. Il s'agit simplement d'observer la résonance magnétique nucléaire des protons de l'eau contenus dans l'organisme, c'est à dire la réponse des noyaux soumis à un champ magnétique extérieur et à une excitation électromagnétique permanente. Le patient à examiner doit être placé dans un champ magnétique puissant, ce qui provoque l'alignement des protons dans les molécules d'eau du corps dans une orientation parallèle ou une position antiparallèle avec le champ magnétique. Pour mieux comprendre le fonctionnement d'un système IRM, la section transversale de la machine IRM est illustré dans la figure I.3 suivante.

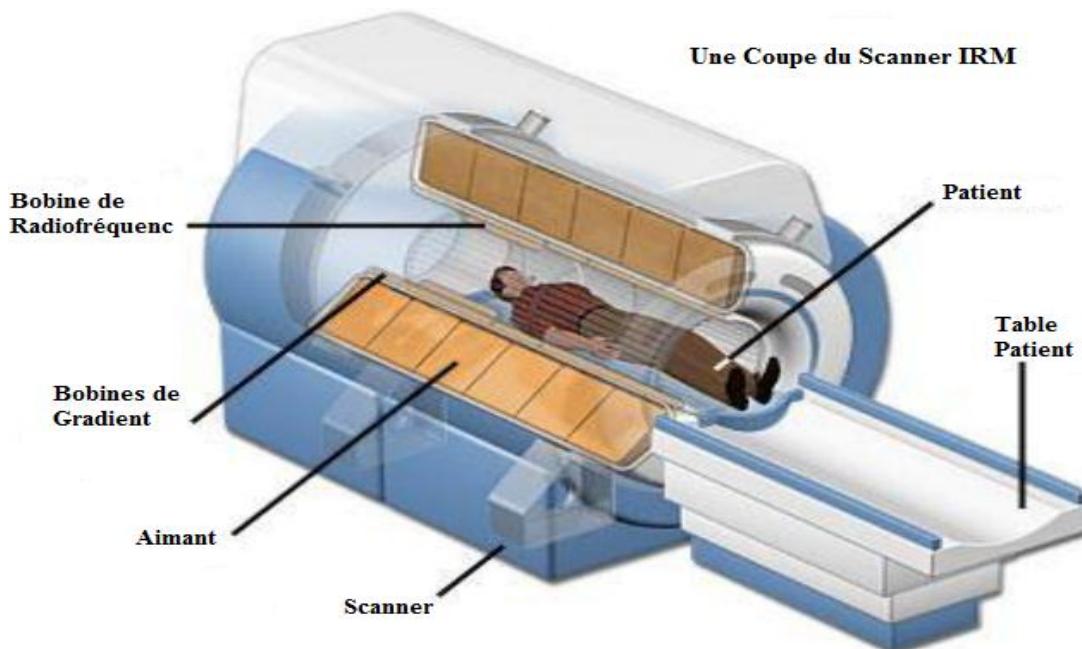


Figure I.3 : Vue générale d'un Scanner IRM.

Pour obtenir la structure détaillée du cerveau et pour identifier l'intensité de la tumeur, la technologie IRM a été conseillée pour les patients. Les étapes générales de la procédure de numérisation sont répertoriées ci-dessous :

- Le patient a été emmené à l'intérieur de l'appareil d'IRM.
- Un radiologue ajuste les champs magnétiques et la position du patient dans le scanner.
- Un ordinateur capture même les petits changements des parties internes de la région numérisée et génère les images IRM correspondantes.
- Un radiologue vérifie et interprète les images IRM et génère un rapport de diagnostic.

A- Principe physique:

Concernant le champ et moment magnétique, une impulsion Radiofréquence (RF) est introduite, provoquant le déplacement des protons en rotation hors de l'alignement. Lorsque l'impulsion est arrêtée, les protons se réalignent et émettent de l'énergie radiofréquence, un signal qui est localisé par des champs magnétiques qui sont spatialement variés et rapidement

activés et désactivés. Une antenne radio (ou bobine radio) à l'intérieur du scanner détecte le signal et crée l'image. Le composant important du système d'IRM est un grand aimant qui produit un champ magnétique puissant. Le corps du patient est placé dans le champ magnétique pendant la procédure d'imagerie. La Figure I.3 montre la représentation schématique en détaille des principaux composants de l'imagerie par résonance magnétique.




Figure I.4 : Les différents composants du système d'IRM.

-Les aimants permanents : Ils ont l'avantage de ne nécessiter aucune source d'énergie extérieur ni aucun système de refroidissement. Les inconvénients sont liés au très grand poids des aimants dans le cas d'images du corps entier et à l'impossibilité de créer des champs supérieurs à 0,3 Tesla.

-Les aimants résistifs : Ces systèmes sont constitués par une bobine ou un ensemble de bobines parcourues par un courant électrique intense. Il est possible d'obtenir des champs bien homogènes dont l'intensité est de l'ordre de 0,3 tesla, mais ces aimants nécessitent un très puissant système de refroidissement.

-Les aimants supraconducteurs : La résistance électrique de certains alliages diminue très fortement quand leur température est de l'ordre de -260° C. Si des bobines constituées de tels matériaux sont placées dans de l'hélium liquide, à la température de -269° C, il est possible d'y faire passer des courants très intenses, et d'obtenir ainsi des champs magnétiques élevés (1,5 à 3 tesla). En pratique, ces aimants nécessitent un double système de refroidissement constitué principalement d'un circuit d'hélium liquide. La consommation de liquide cryogénique doit être compensée au moyen d'un remplissage périodique.

-L'émetteur: Un synthétiseur piloté par un processeur permet la création de la série d'impulsions électriques de durée et d'amplitude bien déterminées. C'est à ce niveau qu'est

choisie la phase θ (0° , 90° ...) des impulsions. Les puissances électriques mises en jeu sont de quelques kilowatts mais quelques watts seulement sont absorbés par l'élément étudié.

-Les bobines/Antennes: L'émetteur est relié à une bobine (ou à une antenne) placée dans l'appareil IRM et permettant d'obtenir les ondes de radiofréquences. Ces ondes radio sont des impulsions de durée limitée qui n'ont pas une fréquence précise. Elles ont une certaine étendue en fréquence appelée « bande de fréquences » de l'onde radio.

Le corps humain est composé d'une grande quantité d'eau et la plupart des noyaux d'hydrogène du corps sont présents dans l'eau. La propriété fondamentale du spin nucléaire de la matière et son interaction avec un champ magnétique externe pour induire un signal électrique constituent la base de l'IRM. Le signal IRM est généralement dérivé des noyaux atomiques dans l'atome d'hydrogène qui est abondant dans le corps humain. La variation de la densité de l'hydrogène, en particulier sa liaison moléculaire dans divers tissus, génère un meilleur contraste des tissus soft que la TDM. Dans la nature, les noyaux d'hydrogène tournent autour de son axe conduisant à la génération d'un champ électromagnétique comme sur la figure II.5 (a). Les spins précèdent autour de l'axe du champ magnétique avec une fréquence de précession appelée fréquence ω_0 proportionnelle au champ magnétique externe comme indiqué dans l'équation (I.1):

$$\omega_0 = \gamma B_0 \quad (I.1)$$

Dans l'équation (I.1), le terme γ indique la propriété du noyau aussi appelé rapport gyromagnétique. En règle générale, l'orientation des spins est aléatoire et le champ magnétique total est donc nul. Lorsqu'ils sont placés dans un grand champ magnétique, les spins de tous les noyaux du corps sont alignés parallèlement ou antiparallèlement au champ magnétique comme sur la figure I.5 (b). Lorsqu'une impulsion RF est introduite à la fréquence ω_0 , il y a un échange d'énergie entre les noyaux et l'impulsion RF, ce qui affecte l'équilibre de spin communément appelé résonance. Cela est illustré dans la figure I.5 (c).

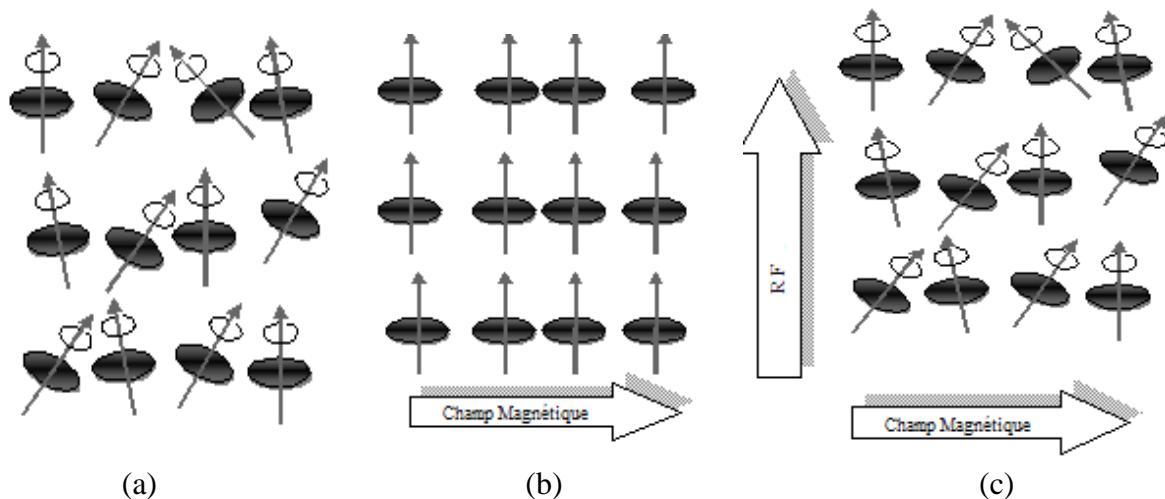


Figure I.5 : Impact du champ magnétique sur la magnétisation du spin (a) Orientation aléatoire des spins (b) Alignement des spins avec le champ magnétique externe (c) Application de l'impulsion RF.

Lorsque le signal RF est désactivé, les spins retournent progressivement à leur état de repos connu sous le nom de relaxation. Le signal décroissant détecté est connu sous le nom de

Free Induction Decay (FID). Pendant ce processus de relaxation, l'énergie électromagnétique absorbée est retransmise et forme le signal RMN. Les processus de relaxation examinés peuvent être longitudinaux ou transversaux. La relaxation longitudinale correspond à l'interaction du réseau de spin. Les spins retournent à leur état d'équilibre en délivrant un signal d'amplitude décroissante. La récupération de la direction de spin d'origine est connue sous le nom de relaxation longitudinale qui suit une courbe exponentielle et se caractérise par une constante de temps spécifique au tissu T_1 après laquelle 63% de la valeur finale est restaurée comme le montre la figure I.5 ci-dessus. La magnétisation dans la direction du champ B_0 au temps t est donnée par l'équation (I.2) suivante:

$$M_z(t) = M_0(1 - \exp(-\frac{t}{T_1})) \quad (I.2)$$

Avec M_0 étant la magnétisation nette à l'équilibre. La constante de temps de la relaxation exponentielle est appelée temps de relaxation spin-réseau ou temps de relaxation T_1 longitudinal. La figure suivante représente la relaxation longitudinale du signal RMN.

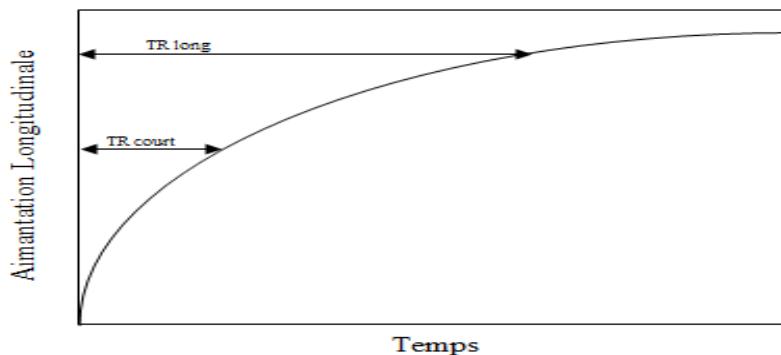


Figure I.6 : Impact de la relaxation longitudinale du signal RMN.

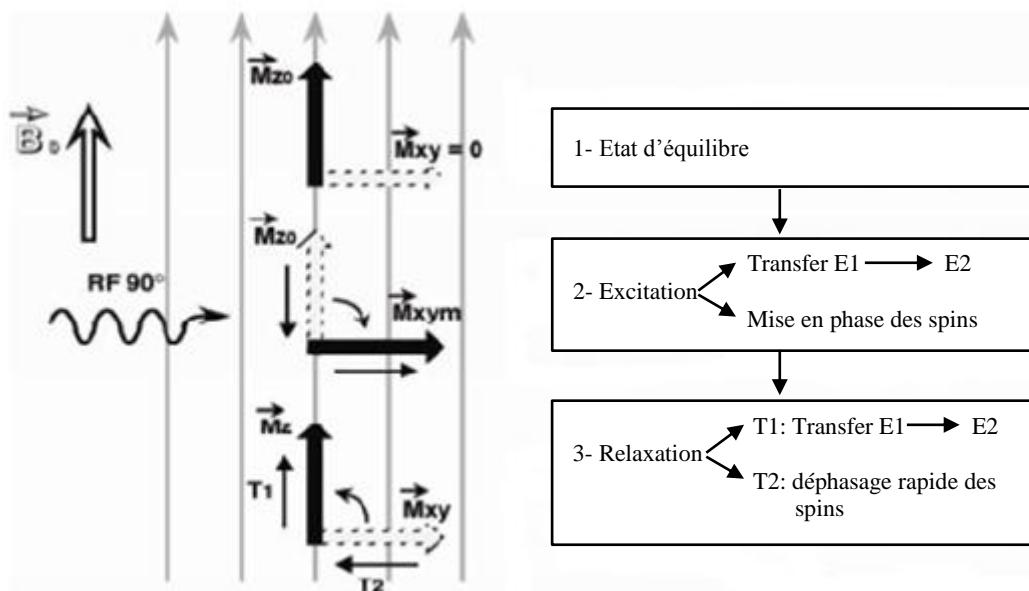


Figure I.7 : Processus de formation d'imagerie par résonance magnétique (IRM).

La figure I.7 montre le processus de formation d'IRM en terme général. La relaxation transversale correspond à la déphase du spin et représente l'interaction spin-spin. Cela donne une décroissance exponentielle du signal décrite par une constante appelée temps T2. L'aimantation transversale en fonction du temps t est :

$$M_T(t) = M_T(0) \exp\left(\frac{-t}{T_2}\right) \quad (I.3)$$

C'est ce qui fait dire que en fonction de la liaison moléculaire des protons donnés, les constantes T1 et T2 sont différentes pour le même proton pendant le retour à l'état d'équilibre.

B- Séquences d'acquisition de l'IRM:

Les informations spatiales sont obtenues à partir de gradients de champ magnétique (gradient x, gradient y ou gradient z) dans lesquels l'emplacement de divers voxels est codé par des intensités de champ légèrement différentes. Le temps d'écho (TE) et le temps de répétition (TR) sont utilisés pour caractériser une séquence d'IRM. Le temps entre l'impulsion RF et la mesure du signal est connu comme le temps d'écho, tandis que le temps entre deux impulsions RF (temps autorisé pour la récupération longitudinale) est connu comme le temps de répétition. Pour les TR courts, la magnétisation longitudinale des tissus avec un T1 long n'aura pas le temps de se restaurer complètement, et leur signal initial sera plus faible, tandis que les tissus avec un T1 petit seront plus élevés (grande magnétisation).

Cela constitue les bases de la modalité pondérée en T1 (T1w ou T1), où le contraste de l'image entre les tissus est défini par leur valeur constante T1. Lorsque TR est réglé assez longtemps, le contraste de l'image ne dépend plus de lui de sorte qu'une récupération longitudinale complète est atteinte pour tous les tissus. Le TE long rend l'image dépendante du temps de relaxation transverse T2. Le signal sera plus faible pour les tissus qui possèdent des désintégrations transversales plus rapides (petite valeur T2).

Cela constitue la base des images pondérées en T2 (T2w ou T1). Si TR est long et TE est court, alors T1 et T2 ne sont plus des paramètres distincts qui produisent l'image pondérée en densité de protons. Dans l'image pondérée en densité de protons, la force du signal dépend de la force de la magnétisation atteinte M0 (en fonction de la densité de protons). Dans toutes les images T1, T2, les tissus à haute intensité sont représentés comme des zones lumineuses et appelés hyperintenses, tandis que les tissus à faible intensité sont représentés comme des zones sombres et appelés hypointenses. Cependant, le contraste est obtenu à partir des différences de temps de récupération T1, décroissance T2 et d'images pondérées par protons.

Les algorithmes de segmentation des images médicales utilisent les différentes modalités pour fournir des résultats efficaces. Dans le cas de la tumeur cérébrale, la visualisation des images T1 ou T2 seule est différente de l'idéal. Les tumeurs apparaissent hypo-intenses ou normales sur les images T1, et il est donc difficile à détecter et à délimiter. En injectant des agents de contraste tels que le gadolinium aux images T1 (contraste T1 amélioré), une meilleure détection peut être obtenue. Une autre séquence populaire pour l'observation des tumeurs cérébrales est le FLAIR (T2 Fluid Attenuated Inversion Recovery). Ceci est construit en renversant initialement le champ magnétique longitudinal Mz dans la direction opposée à l'aide d'une impulsion électromagnétique orientée à 180 ° du champ d'origine B0. Classiquement, tous les protocoles cliniques d'IRM comprennent une séquence

T1w, T2w, T1 à contraste amélioré (T1C) ainsi que pour les coupes FLAIR. La figure II.8 ci-dessous montre les différentes modalités d'IRM.

I-4-2- Types d'IRM et ses orientations:

Les images cliniques n'utilisent pas le système de coordonnées de résonance magnétique XYZ pour la collecte et la présentation d'images. Au lieu de cela, le système de coordonnées anatomiques est utilisé. Un examen IRM du cerveau commence par des scanners localisateurs rapides et obtient idéalement des coupes dans trois plans d'imagerie orthogonaux. Les trois axes sont appelés: Axial, Coronal et Sagittal selon les plans. La figure I.8 suivante montre les différentes modalités de l'imagerie par résonance magnétique.




Figure I.8 : Les Orientations de l'image IRM et ses différents types.

L'intensité du signal IRM produit par un tissu particulier dépend de la densité de protons qui détermine les temps de relaxation. Il existe trois types de pondération du contraste de l'image IRM. Ils sont appelés: image pondérés en T1, pondérés en T2 et pondérés en densité de protons DP et leurs valeurs approximatives sont présentées dans le tableau II.1. La Fig. II.8 montre les types et l'orientation de l'IRM. Les différences de T1, T2 et de densité de protons dans divers tissus créent des différences de contraste tissulaire sur les images. Deux paramètres clés qui contrôlent le contraste de l'image sont le temps de répétition (TR) et le temps d'écho (TE). TR est le temps (mesuré en millisecondes) entre les applications d'une impulsion d'excitation RF et le début de l'impulsion RF suivante. TE est le temps (mesuré en millisecondes) entre les applications de l'impulsion RF et le pic de l'écho détecté. Pour un type de noyau donné dans un environnement donné, TR détermine la quantité de relaxation T1. Lorsque TR est plus long, une plus grande aimantation longitudinale est récupérée. Les tissus avec T1 court ont une grande intensité de signal par rapport aux tissus avec un T1 plus long. Le tableau I.1 suivant montre les valeurs approximatives de T1 et T2 de certains tissus (MB, MG, LCR) à 1,0 Tesla.

Tableau I.1 : Valeurs approximatives de T1 et T2 de certains tissus à 1,0 Tesla.

Tissue	T1 (ms)	T2 (ms)
Muscle	600	40
Matière grise	520	100
Matière blanche	390	90
Liquide cérébrospinal	2000	300

I-4-3- Caractéristiques des tissus et de l'IRM:

Les images IRM représentent les caractéristiques des tissus présents dans le corps humain. Le tableau I.2 montre les tissus et leur apparence correspondante des tissus cérébraux dans les images IRM. Les temps de relaxation mentionnés comme longs, intermédiaires et courts dans le tableau II.2 sont approximativement équivalents à 2200-2400 ms, 900 ms et 780 ms respectivement pour les images T1 et 500-1400 ms, 100 ms et 90 ms respectivement pour les images T2 dans un champ magnétique constant domaine de 1,5 Tesla.

Tableau I.2 : Caractéristiques tissulaires du cerveau pour l'IRM.

Tissus Cérébraux	Temps de relaxation		Contraste d'image		
	T1	T2	PD	T1	T2
MB	Court	Court	Brillant	Brillant	Gris
MG	Intermédiaire	Intermédiaire	Isointense	Gris	Gris
LCR	Longue	Longue	Gris	Sombre	Brillant

La force du signal IRM et le contraste entre les tissus cérébraux dépendent principalement de trois paramètres: PD, T1 et T2. Plus la densité des protons sont élevée, plus les signaux seront grands. T1 et T2 peuvent être radicalement différents pour différents tissus mous, et ces paramètres sont responsables du contraste majeur entre les tissus mous. Les paramètres temporels T1 et T2 sont fortement influencés par la viscosité ou la rigidité d'un tissu. Plus la viscosité et la rigidité sont élevées, plus les valeurs pour T1 et T2 sont faibles. La matière blanche apparaît gris clair dans T1 et gris foncé dans les images T2. La matière grise apparaît grise sur les deux images. Le liquide céphalo-rachidien apparaît noir en T1 et blanc en images T2. Les images T1 sont utilisées pour les informations anatomiques et les images T2 pour les informations pathologiques.

I-4-4- Avantages et Inconvénients de l'IRM:

L'imagerie IRM est la technique la plus populaire qui joue un rôle vital dans l'imagerie cérébrale pour détecter la maladie de la substance blanche et grise qui ne peut pas être identifiée par tomodensitométrie. L'IRM fournit des informations riches sur la structure anatomique, permettant des études quantitatives pathologiques ou cliniques. L'intensité et le contraste des images IRM sont principalement basés sur le temps de relaxation T1 et T2 ce qui la rend utile en particulier en imagerie neurologique (cerveau), musculaire squelettique et oncologique (cancer). Les avantages de cette technique sont énumérés comme suit :

- L'IRM a une résolution anatomique des tissus soft supérieure à la TDM.

- La distinction entre la matière grise et la substance blanche est beaucoup plus grande avec T1 et T2 MR qu'avec CT.
- La couleur de la matière blanche sur T1 MR est plus claire que la matière grise.
- Ils n'impliquent pas d'exposition aux radiations, de sorte qu'ils sont souvent utilisés en toute sécurité chez des personnes qui pourraient également être exposées aux conséquences des radiations, comme les femmes enceintes et les bébés.
- Ils sont particulièrement utiles pour montrer les structures des tissus mous, comme les ligaments et les poils, et les organes comme le cerveau, le cœur et les yeux.
- Ils peuvent fournir des données sur la façon dont le sang circule dans les organes et les vaisseaux sanguins liés, permettant de connaître les problèmes de circulation sanguine, comme les blocages.

Malgré ses nombreux avantages, l'imagerie par résonance magnétique (IRM) présente certains inconvénients qui sont reliés à la disponibilité d'utilisation, on notera comme suit:

- Les scanners IRM sont très précieux. Cela signifie que le nombre de scanners qu'une fiducie de soins primaires pourra financer est proscrit. Par conséquent, si la condition n'est pas urgente, il est nécessaire d'attendre plusieurs mois pour posséder l'IRM.
- Les appareils d'IRM sont souvent pleins de mouvement, ce qui les rend inadaptés aux problèmes d'investigation comme les tumeurs buccales à la suite d'une toux ou d'une déglutition, ce qui rendra les images moins claires.
- La combinaison du fait d'être placé dans une maison intérieure et donc les bruits forts qui sont créés par les aimants feront en sorte que certaines personnes se sentiront claustrophobes alors qu'elles subissent une IRM.

I-4-5- Processus d'acquisition et modélisation en IRM:

Après avoir vu les notions de base concernant l'imagerie par résonance magnétique, cette dernière applique un champ magnétique puissant de 0,2 à 3 tesla qui aligne le proton présent dans la molécule d'eau du corps. Le scanner produit un courant radiofréquence qui fait varier le champ magnétique. Lorsque le champ est désactivé, le proton revient progressivement à son état d'origine. Le processus de retour produit un signal radio qui peut être mesuré dans le scanner et créé sous forme d'une image MR. Les protons dans les différents tissus reviennent à leur état d'origine à des vitesses différentes, il est donc possible de faire des comparaisons entre les différents tissus ou chaque modalité contient des informations spécifiques ne se retrouvant pas dans les autres. Dans l'IRM, on peut pondérer l'image en T1, T2 ou en densité de protons, suivant certains paramètres d'acquisition :

I-4-5-1- Images pondérées en T1:

Une image pondérée en T1 est une image dont le contraste est principalement dû aux différences de temps de récupération T1 des tissus. Les examens d'IRM peuvent être acquis avec différents types de contraste. Les images pondérées en T1 sont formées en fonction du temps de relaxation du réseau de spin (T1) des protons qui donnent naissance aux signaux IRM. Ces images offrent un bon contraste entre la matière grise et la matière blanche. Les images pondérées en T1 sont généralement utilisées pour les informations anatomiques,

offrant également une sensibilité élevée aux produits de contraste paramagnétiques qui peuvent montrer la pathologie, la graisse, les fluides à haute teneur en protéines et l'hémorragie subaiguë.

I-4-5-2- Images pondérées en T2:

Dans les images pondérées en T2, les tissus gris et blancs sont généralement faibles et ont des intensités comparatives. Une image IRM pondérée T2 est une image dont le contraste est principalement dû aux différences de temps de décroissance T2 des tissus. Les balayages pondérés T2 utilisent une séquence d'écho de spin, avec un TE long et un TR long. Ils ont longtemps été le cheval de bataille clinique car la séquence d'écho de spin est moins sensible aux homogénéités du champ magnétique. Ils sont particulièrement bien adaptés à l'œdème car ils sont sensibles à la teneur en eau (l'œdème se caractérise par une teneur en eau accrue). Les images IRM pondérées en T2 offrent une sensibilité élevée à la plupart des processus pathologiques, car la plupart des différentes pathologies ont une teneur en eau accrue et sont donc lumineuses.

I-4-5-3- Images pondérées en DP:

Lorsqu'une séquence IRM est définie pour produire une image pondérée en DP, ce sont les tissus ayant la concentration ou la densité de protons (atomes d'hydrogène) les plus élevées qui produisent les signaux les plus forts et produisent aussi l'image la plus lumineuse. La séquence pondérée par la densité de protons produit un contraste principalement en minimisant l'impact des différences T1 et T2 avec les TR longs et les TE courts.

I-4-5-4- Images FLAIR:

La récupération par inversion atténuée par fluide (FLAIR) concerne la disposition des impulsions de récupération par inversion acclimatée qui invalide le signal des liquides. La disposition des fluides a remplacé l'image DP. Comme dans le cas des dispositions de récupération par inversion inverse, la succession d'imagerie du type à réverbération à virage rapide est intéressante pour rembourser le temps d'obtention long connecté au long TR. Ces unités de région de regroupement sont couramment utilisées en imagerie cérébrale pour l'imagerie de l'œdème. En choisissant de manière critique le temps d'inversion TI (le temps entre les battements d'inversion et d'excitation), le signal de tout tissu express sera supprimé. L'imagerie FLAIR du cerveau a constitué un outil répétitif pour mesurer les lésions chez les patients souffrant de troubles neurologiques examinés.

Toutes les images issues du système IRM ont été stockées dans l'extension (.DCM) d'un format spécial appelé DICOM (Digital Imaging And Communications In Medicine). Le fichier DICOM contient toutes les informations du patient en détails. Il contient des métadonnées sur l'image et ces données sont sous une forme invisible. Dans cette norme, les informations sur l'image ont été stockées dans un fichier d'en-tête où les informations du patient telles que la date d'une image prise, l'âge, le sexe, la description de l'étude, la modalité, le type d'image, la taille, etc. peuvent avoir une utilité différente dans l'utilisation clinique et la recherche. La conversion du fichier DICOM en d'autres formats d'image tels que JPEG ou TIFF garantit la confidentialité du patient car ces formats de fichier ne contiennent aucune

information d'en-tête. Mais en raison de l'indisponibilité du fichier d'en-tête, ces formats d'image manquent de nombreuses informations importantes. L'environnement MATLAB avec la boîte à outils de traitement d'image prend en charge les manipulations de fichiers DICOM.

I-5-Lésions et tumeurs cérébrales:

Le cerveau est la pièce maîtresse qui est chargée de contrôler et de planifier tous les autres organes du corps. Les images IRM sont très sensibles et détectent tous les types d'anomalies de la matière blanche et grise. La tumeur cérébrale est une croissance massive anormale des cellules qui perturbe le fonctionnement normal du cerveau. Donc, si une tumeur est située à l'intérieur cerveau, les exercices contrôlés par ce système sensoriel sont également influencés. Il est entendu que la détection et le diagnostic précoce des tumeurs contribuent à sauver la vie ; il est essentiel de déposer un système de diagnostic assisté par ordinateur pour identifier les différentes classes de tumeurs et la gravité d'une tumeur particulière. Cette phase présente une brève description de la tumeur cérébrale en générale. La figure I.9 montre une comparaison entre une image IRM normale et une autre anormale.




Figure I.9 : Images cérébrales de type IRM normales et anormales.

I-5-1- Tumeur cérébrale humaine et sa naissance:

La naissance d'une tumeur cérébrale est basée sur le gliome et prolifère sur la base de divers facteurs. Un gliome est une sorte de tumeur qui se déclenche dans le cerveau ou la moelle épinière des êtres humains et qui résulte des cellules de la neuroglie. Ces cellules de la neuroglie sont des cellules utiles du système nerveux central (SNC) qui entourent les neurones et agissent comme un mécanisme de soutien en isolant entre elles. Selon Andrew Koob, un neuroscientifique américain, près de 90% du cerveau est composé de cellules gliales. Principalement, les astrocytes, les oligodendrocytes et les cellules épendymaires sont les trois types de cellules gliales. Elle a la capacité de se multiplier et de se déchirer. Et si ce processus de multiplication et de division se produit rapidement et sans aucun contrôle, il est dit que c'est la naissance d'un gliome [WES 11].

I-5-2- Statistiques sur les tumeurs :

À l'échelle mondiale, le cancer est devenu une immense menace pour les êtres humains parmi diverses autres maladies. Indépendamment des excellentes avancées pour le diagnostic

et le traitement, le cancer est toujours une énorme menace pour notre humanité comme une maladie du siècle. En Algérie chaque année, les personnes reçoivent un diagnostic des tumeurs primaire : plus de 50.000 nouveaux cas de cancer et pas moins de 20.000 décès ont été enregistrés en 2019. Ces chiffres de propagation du cancer, révélés par le professeur et le chef de service d'oncologie à l'hôpital Mustapha Pacha et sauvegardé dans le registre national du cancer, ses statistiques sont prises en compte pour la projection de cette épidémie. Une projection du nombre de cas de cancer qui se produiront en Algérie d'ici 2025, 60.000 nouveaux cas seront comptabilisés chaque année, estimant que le chiffre sera revu à la hausse d'ici 2030, pouvant atteindre les 70.000 cas/an. Les données sur les incidents de cancer générées par le registre national du cancer de 2017 inclus les différents endroits du pays, plus de 19.000 nouveaux cas à l'est du pays, contre plus de 17.000 dans le centre, et près de 8.000 à l'ouest de l'Algérie. Les statistiques du cancer de la ville d'Alger pour l'année 2017 sont représenté dans le tableau I.3 suivant :

Tableau I.3 : Répartition des cas cancer confirmés- Alger 2017 (Source:<http://www.insp.dz>)

Tranches d'âges	Effectifs Homme	% Homme	Effectifs Femme	% Femme
0-4	44	1.2	26	0.6
5-9	30	0.8	18	0.4
10-14	27	0.8	7	0.2
15-19	36	1	27	0.6
20-24	33	0.9	71	1.7
25-29	53	1.5	101	2.4
30-34	65	1.8	187	4.5
35-39	104	2.9	299	7.1
40-44	154	4.3	429	10.3
45-49	202	5.7	505	12.1
50-54	255	7.2	490	11.7
55-59	334	9.4	447	10.7
60-64	477	13.4	442	10.6
65-69	475	13.4	381	9.1
70-74	416	11.7	276	6.6
75+	783	22	440	10.5
Inconnu	66	1.9	38	0.9
Total	3554	100	4184	100

I-5-3- Différents types des tumeurs:

Selon l'organisation mondiale de la santé OMS ; il existe plus de 120 types différents de tumeurs cérébrales. Parmi ces différents types de tumeurs, les tumeurs cérébrales courantes comprennent l'astrocytome : l'astrocytome pilocytaire (grade I), l'astrocytome diffus (grade II), l'astrocytome anaplasique (grade III), le glioblastome multiforme (GBM) (grade IV). L'astrocytome pilocytaire est l'un des types de neuroglie largement répandus chez les enfants. Ce type de tumeur survient pour environ 2% de toutes les tumeurs. L'astrocytome de bas grade qui est l'astrocytome diffus signale environ 11% de toutes les tumeurs humaines chez les hommes et les femmes de 20 à 60 ans. L'astrocytome anaplasique est une tumeur maligne de type grade III commune qui survient pour environ 3% de toutes les tumeurs cérébrales chez les adultes âgés de 30 à 60 ans. Le GBM, également connu sous le nom de glioblastome, est l'un des types de tumeurs cérébrales les plus mortels.

Le glioblastome rapporte environ 50% des astrocytomes entiers et 20% des tumeurs cérébrales humaines totales. Ces GBM sont de nature très maligne et agressive qui survient

chez les personnes âgées entre 50 et 70 ans. Environ 10% des enfants sont atteints de ce glioblastome de grade IV le plus meurtrier et il est à noter que ce type de tumeur est plus résistant aux procédures de traitement standard actuelles. Les auteurs [MAD 15] illustre les types de tumeurs les plus courants.

A- Tumeur cérébrale primaire :

Une tumeur cérébrale maligne primaire est une tumeur qui prend naissance dans le cerveau lui-même. Bien que les tumeurs cérébrales primaires libèrent souvent des cellules cancéreuses vers d'autres sites du système nerveux central (le cerveau ou la colonne vertébrale), elles se propagent rarement à d'autres parties du corps. Les tumeurs cérébrales primaires représentent 2,7% de tous les cancers qui surviennent chaque année en Inde. Ces types de tumeurs sont rares et difficiles à éliminer. Ils ont une réponse très hétérogène à la thérapie. Les tumeurs cérébrales primaires sont généralement localisées dans la fosse crânienne postérieure chez l'enfant et dans les deux tiers antérieurs des hémisphères cérébraux chez l'adulte, bien qu'elles puissent toucher n'importe quelle partie du cerveau. La classification des tumeurs cérébrales primaires est généralement basée sur le tissu d'origine et parfois sur l'emplacement de la tumeur.

B- Tumeur cérébrale secondaire:

Une tumeur cérébrale secondaire (métastase) survient lorsque les cellules cancéreuses se propagent au cerveau à partir d'un cancer primaire dans une autre partie du corps. Les tumeurs secondaires ou métastatiques sont environ trois fois plus fréquentes que les tumeurs primaires du cerveau. Ils prennent leur origine dans des cellules tumorales qui se propagent au cerveau à partir d'un autre endroit du corps. La tumeur secondaire contient des cellules similaires à la tumeur primaire.

C- Tumeur cérébrale bénigne:

Il représente la moitié de toutes les tumeurs cérébrales primaires. Leurs cellules semblent relativement normales, se développent lentement et ne se propagent pas (métastases) à d'autres sites du corps ou envahissent les tissus cérébraux. Les tumeurs bénignes peuvent toujours être graves et même mortelles si elles se trouvent dans des zones vitales du cerveau où elles exercent une pression sur les tissus nerveux sensibles ou si elles augmentent la pression dans le cerveau. Bien que certaines tumeurs cérébrales bénignes puissent présenter un risque pour la santé, y compris le risque d'invalidité et de décès, la plupart sont généralement traitées avec succès avec des techniques telles que la chirurgie.

D- Tumeur cérébrale malignes:

Une tumeur cérébrale maligne primaire est une tumeur qui prend naissance dans le cerveau lui-même. Il est classé en trois catégories: faible, intermédiaire ou élevé. Plus d'informations peuvent être trouvées dans Staging / Grading. La diversité biologique de ces tumeurs, cependant, rend la classification difficile.

I-5-4- Catégorisation des tumeurs:

Un système de classification et de notation pour faciliter et systématiser le pronostic, la planification du traitement et la communication est développé par l'Organisation mondiale de la santé (OMS). En utilisant la biopsie, les tumeurs cérébrales sont classées en fonction de leur type cellulaire et de leur grade, ce qui permet au médecin de prendre la décision

appropriée pour un traitement ultérieur. Sur la base des caractéristiques morphologiques et moléculaires du gliome, les tumeurs humaines sont classées en histologiques et structurales et immunohistochimies. Selon les caractéristiques histopathologiques, les gliomes dans le cerveau humain sont classés. L'OMS a classé les tumeurs en grade I, grade II, grade III et grade IV en fonction de leur gravité.

Les tumeurs de bas grade sont classées en grade I et grade II qui se développent lentement et sont considérées comme les moins malignes. Les autres grades tumoraux classés grade III et grade IV sont considérés comme de grade élevé qui croît très rapidement. En règle générale, les tumeurs de grade II sont cogitées comme la ligne mince marginale parmi les tumeurs bénignes et malveillantes. Les tumeurs de grade III sont malveillantes et se développent à un rythme modeste. Le glioblastome multiforme (GBM) est une tumeur primitive maligne de grade IV qui se développe très rapidement. Les gliomes classés dans la catégorie extrême sont extrêmement sujets à la vascularisation ayant la propension à pénétrer. Même après l'élimination chirurgicale, le gliome de haut grade repousse et s'infiltra tout le temps dans le corps humain. Contrairement à la tumeur de haut grade, le gliome de bas grade se développe très lentement pendant plusieurs années à l'intérieur du corps et peut être surveillé. Ces tumeurs de bas grade peuvent être contrôlées sauf si elles se développent et provoquent des symptômes. Les différents grades de gliomes et leurs caractéristiques sont présentés ci-dessous dans le tableau I.4.

Tableau I.4: Les Grades tumoraux et ses caractéristiques

N°	Grades	Caractéristiques des tumeurs
1	Grade I	<ul style="list-style-type: none"> - Moins malin. - Survie à relativement long terme. - Les cellules tumorales se développent lentement. - L'apparence est de nature presque normale.
2	Grade II	<ul style="list-style-type: none"> - L'apparence est légèrement anormale. - La croissance des cellules tumorales est lente. - Peut refaire surface en tant que tumeur de grade supérieur - Les tissus du voisinage peuvent être envahis.
3	Grade III	<ul style="list-style-type: none"> - Réplique activement les cellules anormales. - Anomalie totale d'apparence. - Infiltrer à travers le tissu normal - Probabilité d'occurrence plus élevée
4	Grade IV	<ul style="list-style-type: none"> - Apparence extrêmement aberrante - Des vaisseaux sanguins frais se forment pour soutenir son évolution. - Présence de cellules décédées dans la zone affectée.

I-5-5- Causes et facteurs de risque:

Les causes exactes de la tumeur cérébrale ne sont pas connues, mais certains facteurs de risque ont été identifiés comme des facteurs qui peuvent être préoccupants pour la croissance de la tumeur. Les causes et les facteurs de risque peuvent être environnementaux ou génétiques. Certains des facteurs de risque sont décrits ci-dessous :

Une tumeur ou un néoplasme peut être causé par une prolifération anormale des tissus, qui peut être due à des mutations génétiques. Tous les types de néoplasmes ne provoquent pas une prolifération tumorale des tissus. Les cellules souches cancéreuses peuvent jouer un rôle majeur dans la croissance tumorale. Les scientifiques pensent que le cancer pourrait avoir ses propres cellules souches qui ont un impact sur la repousse des tumeurs.

La croissance et la division des cellules chez une personne en bonne santé sont strictement bien contrôlées. De nouvelles cellules sont créées pour remplacer les anciennes et les cellules qui sont endommagées ou qui ne sont plus nécessaires disparaissent à mesure que les cellules nouvellement développées prennent en charge leurs place. De cette manière, il existe un équilibre entre la croissance et la mort des cellules du cerveau. Lorsque cet équilibre est perturbé, une tumeur peut se former et développer d'une façon progressive.

Un large éventail de facteurs environnementaux peut être considéré comme la cause de la tumeur cérébrale par de nombreuses études dans ce domaine. Ces facteurs comprennent le travail dans les unités de raffinage du pétrole ou de fabrication de caoutchouc synthétique, le tabagisme, la consommation prolongée de médicaments, les virus ou les infections courantes, la prise d'aliments durcis (nitrites) et l'exposition aux rayonnements ionisants, la pollution de l'air, les lignes électriques résidentielles, le formaldéhyde industriel et les produits chimiques agricoles. Avec cette longue liste de facteurs environnementaux étudiés comme facteurs de risque, seule la divulgation aux rayonnements ionisants est constamment liée à un risque accru de maturation d'une tumeur cérébrale.

Outre les facteurs environnementaux, les facteurs génétiques sont également concentrés comme facteur de risque de développement de tumeurs cérébrales. Le terme «génétique» fait référence aux gènes du corps humain. Les facteurs génétiques se réfèrent généralement aux maladies héréditaires qui expliquent le développement des tumeurs cérébrales. On dit que seulement 5 à 10% de tous les types de cancer chez l'homme sont hérités d'une génération à l'autre au sein d'une famille. Quelques rares syndromes génétiques héréditaires sont impliqués dans le développement d'une tumeur cérébrale. Pour cette raison, très peu de familles comptent plusieurs personnes atteintes de tumeurs cérébrales.

I-5-6- Symptômes et effets secondaires:

Les symptômes de la tumeur cérébrale varient selon la personne et dépendent du type, de la taille et de l'emplacement de la tumeur. Cette dernière ne peut être évitée car les causes ne sont détectées que récemment. Il est impossible d'attendre les symboles exacts qui indiquent une tumeur cérébrale. Problèmes de mémoire, changements de personnalité ou d'élocution, les crises sont quelques symptômes de tumeur cérébrale. Lorsque la tumeur obstrue le liquide circulant dans et autour du cerveau, un gonflement se produit qui peut être un signe indicatif de tumeur cérébrale. Lorsque le cerveau est placé dans le crâne, toute croissance indésirable dans ces régions peut altérer le fonctionnement normal du cerveau.

Les tumeurs peuvent endommager directement le tissu cérébral et provoquer des tensions ou des déplacements dans le cerveau. Les différents types de tumeurs cérébrales ont des différents effets secondaires. Certaines tumeurs peuvent également produire des effets

secondaires émotionnels et physiques tels que la perte de cheveux, les nausées, la fatigue, les maux de tête et autres effets particulières selon l'état du patient.

I-5-7- Diagnostic et traitement médical:

À l'aide de l'imagerie médicale, les médecins peuvent identifier si la tumeur est présente dans le cerveau ou non. Ensuite, les patients seront invités à subir une biopsie pour confirmer la présence et déterminer le type de cancer. La biopsie est essentiellement un mode opératoire chirurgical pour détacher les tissus de la tumeur cérébrale et rechercher les cellules cancéreuses dans la tumeur. Le pathologiste observe et examine les cellules du cerveau pour détecter leur anomalie au microscope. Un examen par biopsie peut indiquer un cancer ou une altération des tissus tumoraux qui mène au cancer et à d'autres maladies. Et les médecins estiment que la biopsie est le moyen solitaire de diagnostiquer et de confirmer une tumeur cérébrale humaine. Malheureusement, parfois, le test de biopsie ne peut pas être examiné en raison de la présence d'une tumeur dans un endroit complexe comme le tronc cérébral, car il n'est pas possible de détacher le tissu de cette zone particulière.

Les tumeurs cérébrales sont diagnostiquées par un médecin sur la base des résultats des antécédents médicaux et de l'examen physique et des résultats d'une variété de tests spécialisés du cerveau et du système nerveux. Le traitement d'une tumeur cérébrale dépend du type, de l'emplacement et de la taille de la tumeur ainsi que de l'âge et de la santé du patient. La tumeur cérébrale ne peut pas encore être évitée, car la détection des causes n'est que récente. Les symptômes des tumeurs cérébrales varient d'un patient à l'autre.

Le médecin commence le diagnostic en tenant compte des antécédents médicaux, des symptômes et en effectuant un examen neurologique complet. L'examen neurologique comprend des tests tels que le test de mémoire et d'état mental, le test de vision comprenant le nerf optique, le test d'équilibre et de coordination, le test de mouvement de la langue, le test de l'odorat, le test d'audition et le test du sens du toucher. Si les résultats de l'examen neurologique conduisent le médecin à suspecter le patient d'avoir une tumeur cérébrale, le patient pourrait être conseillé pour des tests supplémentaires en utilisant des modalités d'imagerie telles que l'IRM et la tomodensitométrie (TDM). Ces deux modalités utilisent l'infographie pour former une image du cerveau.

Parfois, une chirurgie et d'autres tests radiologiques peuvent être nécessaires pour un diagnostic exact. La chirurgie est normalement effectuée sur une tumeur primaire pour diagnostiquer et retirer autant de la région tumorale que possible. La biopsie est une intervention chirurgicale qui enlève une petite quantité de tissu tumoral qui à son tour est soumise à un pathologiste pour retirer autant de la région tumorale. La chirurgie des tumeurs cérébrales métastatiques aide à diagnostiquer la maladie et à prolonger la vie du patient. La radiothérapie et la chimiothérapie sont d'autres traitements supplémentaires pour éliminer ou contrôler la tumeur cérébrale.

I-6-Bases de données d'images IRM:

Pour accéder aux images médicales réelles et simulées comme l'IRM, la TEP ou la tomodensitométrie et pour entreprendre une recherche est très complexe en raison de

problèmes de confidentialité et d'obstacles techniques lourds. Les bases de données qui sont utilisées dans cette recherche sont des séries d'ensembles de données d'imagerie par résonance magnétique (IRM) en accès libre, elles sont aussi disponibles pour analyser et évaluer les algorithmes développées dans cette thèse. Cet ensemble de données consiste en une collection transversale de 683 sujets âgés de 16 à 96 ans. Les sujets sont tous droitiers et comprennent des hommes et des femmes. Pour chaque sujet, trois ou quatre scanners individuels IRM pondérée en T1 & T2 et FLAIR obtenus en sessions d'imagerie sont inclus. Les descriptions de l'ensemble de données Brain Tumor Segmentation (BRATS 2018 et BRATS 2019), BrainWeb et BrainVISA sont présentée dans cette section.

I-6-1- Plate-forme BrainWeb et BrainVISA:

Les images médicales qui sont utilisées dans cette thèse se composent d'images simulées téléchargées à partir du site web (<http://www.bic.mnII.mcgill.ca/brainweb>) de l'Institut neurologique de Montréal, Université McGill, Centre d'imagerie cérébrale McConnell (McBIC) ou le fantôme du cerveau et les images IRM simulées ont été rendus publics et peuvent être utilisés pour tester les algorithmes. Le simulateur Brai web est basé sur un ensemble de fantômes tissulaires générés à partir de 27 acquisitions hautes résolution (1 mm³ de voxels isotropes), à faible bruit et à écho de gradient pondéré en T1, T2 ou DP du même individu, qui ont été enregistrées dans un espace stéréotaxique commun où elles étaient sous-échantillonné avec intensité moyenne [KWA 99]. La non-uniformité d'intensité a été réduite par déconvolution en utilisant le noyau de floue non-uniformité qui est dérivé de l'histogramme d'intensité de l'image. L'image a ensuite été segmentée: un neuroanatomiste formé a identifié des points dans les tissus purs et un classificateur de distance minimale floue a été appliqué pour identifier le contenu tissulaire de chaque voxel.

Le processus de simulation de BrainWeb comprend jusqu'à quatre étapes. Les paramètres RMN de chaque tissu et les équations de Bloch sont utilisés pour générer une simulation à zéro dimension décrivant l'intensité de chaque tissu pur. Les intensités tissulaires sont pondérées par les proportions tissulaires dans chaque voxel des fantômes pour produire des images synthétiques. Les effets de l'échantillonnage dans le domaine de Fourier sont abordés, suivis de l'ajout de champs de bruit gaussiens aux composantes réelles et imaginaires des images et de la reconstruction d'images de magnitude. Enfin, des champs d'inhomogénéité d'intensité sont appliqués pour générer les volumes d'image simulés finaux.

Les images issues de la plateforme BrainVISA sont aussi utilisées dans cette recherche. BrainVISA est une plate-forme logicielle modulaire conçue pour héberger des outils hétérogènes dédiés à la recherche en neuroimagerie. Elle vise à aider les chercheurs à développer de nouveaux outils de neuroimagerie et à partager les données médicales. Cette plate-forme est dédié particulièrement aux méthodologistes ainsi qu'aux cliniciens (par exemple, les neurologues, les neurochirurgiens) qui ont besoin de partager leurs données et les processus avec d'autres laboratoires de recherche ou sites cliniques. Le logiciel est multiplateforme (Unix et Windows) et peut être utilisé sur un ordinateur personnel, ce qui facilite l'utilisation quotidienne des modules branchés et la gestion des données, en particulier dans les environnements cliniques. Particulièrement l'environnement convivial de BrainVISA

permet aux utilisateurs de gérer efficacement divers outils de traitement des données cérébrales à jour.

I-6-2- Ensemble de données BRATS 2018:

BRATS est un défi de segmentation d'image de tumeur cérébrale. Il est organisé conjointement avec la conférence internationale sur Medical Image Computing and Computer Assisted Intervention (MICCAI). BRATS Challenge a commencé en 2012 et depuis lors est toujours concentré sur l'évaluation des méthodes de segmentation des tumeurs cérébrales dans les images d'imagerie par résonance magnétique (IRM) ou la plupart de ces méthodes sont améliorées. BRATS 2018 a fourni des ensembles de données de type IRM de tumeur cérébrale et des données de survie globale (SG) des patients. Ces images provenaient de 19 institutions et ont différents scanners et protocoles cliniques pour assurer la variété des données. L'ensemble de données se compose de 285 ensembles de fichiers image avec 210 cas de gliome de haut grade (HGG) et 75 cas de gliome de bas grade (LGG) tandis que l'ensemble de validation comprend 66 cas. Pour chaque cas, il existe quatre séquences d'IRM, dont la pondération T1 (T1), aussi la pondération T1 avec contraste améliorant le gadolinium (T1c), la pondération T2 (T2) et FLAIR. Pour la tâche de prédiction de survie, l'ensemble de données comprenait l'âge, les jours de survie et le statut de résection de 163 patients atteints de gliome de haut grade.

I-6-3- Ensemble de données BRATS 2019:

Toutes les images IRM ont été téléchargées du BRATS Brain Tumor Segmentation Challenge. L'ensemble de données de formation BRATS 2019 comprend 259 cas de gliomes de haut grade (HGG) et 76 cas de gliomes de bas grade (LGG), est annoté manuellement par les cliniciens et les radiologues agréés par le conseil d'administration. Pour chaque patient, un précontraste natif (T1), un post-contraste pondéré en T1 (T1Gd), un T2 (T2) et une pondération T2 Fluid Attenuated Inversion Recovery (T2-FLAIR) sont fournis. Cette base de données est concentrée sur les algorithmes de segmentation des tumeurs cérébrales et a établi un cadre de référence et d'évaluation des différents algorithmes de segmentation.

I-7-Conclusion:

Ce chapitre a résumé les informations de base requises pour notre travail de recherche et il a fourni une brève description du cerveau humain et de la tumeur cérébrale. En outre, on a donné un aperçu sur le contexte biomédical de base impliquée. Les différentes modalités d'imagerie associées sont discutées avec une référence particulière à l'IRM. La raison du choix de l'imagerie IRM pour cette étude et les principes de base de l'IRM sont bien expliqués. L'anatomie de la tumeur cérébrale, la classification de diverses tumeurs cérébrales et le diagnostic sont expliqués dans une large mesure. Les connaissances mathématiques et conceptuelles sur le système d'imagerie IRM et ses terminologies, la nécessité de traiter les coupes IRM fait également partie de ce chapitre. L'ensemble de données Brainweb, BRATS2018 et BRATS2019 sont exposé comme des aspects importants pour évaluer notre système de segmentation.

En ce fait, les différents défis liés à ce domaine d'étude sont mis en évidence. Dans le chapitre suivant, nous présenterons nos contributions de segmentation basée sur la méthode de clustering des données c-moyennes floues ou notre étude est entièrement vise à trouver des solutions aux problèmes caractérisés par l'effet de l'inhomogénéité d'intensité et le bruit dans les images médicales de type IRM.

Chapitre II :

*Principes fondamentaux des techniques de
segmentation d'images*

II-1-Introduction :

La segmentation d'images constitue une étape essentielle en traitement d'images car c'est l'une des étapes critiques de l'analyse d'images. Elle a pour but de rassembler les pixels suivant des critères prédéfinis. Ce chapitre explore le rôle de la segmentation ainsi que ses applications dans les différents domaines d'étude, aussi il traite également les techniques standard de segmentation et leurs limitations. Nous aborderons cette recherche d'abord par une brève introduction aux concepts de base du domaine de traitement bas-niveau (segmentation). Ensuite, nous décrivons brièvement les différentes techniques et approches de segmentation d'image figurant en littérature. Puis, nous focalisons particulièrement sur la segmentation des images médicales enfin nous mettons en relief les points forts et les points faibles des approches. Nous terminons ce chapitre par une présentation des erreurs liées à la segmentation et les méthodes de correction.

II-2- Généralités sur la segmentation d'image :

Quel que soit son origine une image constitue une représentation d'un univers composé d'entités : objets dans une scène intérieure, cellules, surfaces sismiques, organes du corps humain...etc. Le but de toute méthode de segmentation est l'extraction d'attributs caractérisant ces entités. Les attributs étudiés correspondent à des points d'intérêt ou à des zones caractéristiques de l'image. On peut regrouper les opérations sur l'image sous un ensemble, qui se compose de trois couches, traitement d'image (couche basse), analyse d'image (couche intermédiaire) et compréhension d'image (couche haute) [TEH 17]. Dans ce qui suit, on va présenter les notions de base du traitement et segmentation d'image :

II-2-1- Définitions et caractérisations:

Dans un système de traitement d'images, l'opération la plus importante est la segmentation d'image. Nous pouvons adopter la définition suivante pour cette opération : « La segmentation est un traitement de bas niveau qui consiste à créer une partition de l'image A en sous-ensembles R_i , appelés régions tels qu'aucune région n'est vide, l'intersection entre deux régions est vide et l'ensemble des régions recouvre toute l'image. Une région est un ensemble de pixels connexes ayant des propriétés communes qui les différencient des pixels des régions voisines » [COC 95]. Quelques règles à suivre pour obtenir une segmentation sont [MEL 12]:

- Les régions doivent être uniformes et homogènes par rapport à certaines caractéristiques (niveau de gris, écart type, gradient).
- Les régions adjacentes doivent avoir des valeurs très différentes par rapport à la caractéristique prise en compte dans la segmentation.
- Leurs intérieurs doivent être simple et sans beaucoup de petits trous (des parties de région non segmentés).
- Les limites de chaque région doivent être simples et spatialement précises.

De façon plus précise et d'un point de vue mathématique, on peut définir la segmentation comme étant la partition d'une image A en n ensembles R_i appelés régions. Les régions doivent respecter les conditions suivantes:

$$\bigcup_{i=1}^n R_i = A \quad \text{Avec} \quad R_i \cap R_j = \emptyset \quad i \neq j \quad (\text{II.1})$$

$$\text{Et } \begin{cases} P(R_i) = \text{vrai} & \forall i = 1, \dots, n \\ P(R_i \cup R_j) = \text{faux} & \forall i \neq j \text{ } R_i \text{ adjacente à } R_j \end{cases} \quad (\text{II.2})$$

Cette définition ne conduit pas à une méthode de segmentation unique et il peut exister plusieurs méthodes de segmentation. Un exemple pour $P(R_i)$ nous avons la proposition suivante "R_i est homogène" qui peut être vraie ou fausse [ROS 08].

La segmentation est un domaine vaste qui sert à fournir des régions homogènes où l'on retrouve de très nombreuses approches. Toutes ces approches visent à l'extraction des indices visuels. Après de nombreuses années passées à rechercher la méthode optimale, les chercheurs ont compris que la segmentation idéale n'existe pas. On peut même montrer et justifier que le problème de la segmentation est le plus souvent un problème mal posé. Etant donnée une image, il existe toujours plusieurs segmentations possibles. Une bonne méthode de segmentation sera donc celle qui permettra d'arriver à une meilleure interprétation.

II-2-2- Chaîne de traitement d'image:

Le traitement d'image est une technique de transformation pour obtenir une image améliorée en effectuant certaines opérations afin de percevoir des informations utiles. C'est l'analyse et la manipulation d'une image numérisée en particulier pour l'amélioration de sa qualité. Le but principal de la technique de traitement d'image est d'identifier l'image considérée pour faciliter la visualisation, ainsi que pour la netteté, la restauration, et la récupération. Le traitement de l'image constitue le noyau du domaine de recherche en ingénierie et dans les disciplines de l'informatique [COH 91].

Le système de traitement d'image consiste à traiter les images en tant que signaux bidimensionnels tout en leur appliquant les méthodes de traitement de signal déjà définies. Dans le traitement d'image, l'entrée est une image (peut être une image vidéo ou une image numérique dans n'importe quel format) et la sortie peut être une image ou les caractéristiques de l'image d'entrée. La représentation et le traitement des images numériques font l'objet de recherches très actives à l'heure actuelle. Les traitements sont nombreux, et parmi eux on compte la segmentation d'image. Les étapes principales du traitement d'image sont les suivantes:

- Capturer l'image avec un système numérique.
- Analyser et manipuler l'image, ce qui comprend la compression des données et l'amélioration de l'image.
- La sortie est la dernière étape dans laquelle le résultat peut être une image altérée ou un rapport basé sur une analyse d'image.

Les techniques de traitement d'images sont subdivisées en sous-classes plus larges telles que la restauration, la segmentation et l'amélioration des images numériques. Les différents algorithmes sont disponibles pour exécuter ces sous-classes de traitement d'image et certaines des techniques impliquées sont développées en termes de traitement bidimensionnel. La figure II.1 représente le cas du traitement bas niveau : la segmentation.



Figure II.1 : Chaine de traitement d'image (Segmentation).

II-2-3- Objectifs et domaines d'application:

La segmentation est le processus par lequel on va déterminer les régions les plus importantes d'une image et ses résultats sont utilisés dans des nombreuses applications. L'objectif principal est de permettre l'exploitation du contenu de l'image pour l'interprétation et l'analyse soit :

- L'extraction d'éléments et d'informations qualitatives de l'image
- Fournir des régions homogènes et réduire le bruit
- Localiser les contours de région
- Fournir une description de haut niveau : représentation par un graphe dont les nœuds sont des régions, chaque région est connectée à ses voisines et chaque région porte une étiquette qui donne des informations comme la taille, la couleur, la forme,...

La segmentation d'images à un large éventail d'applications pratiques et certains des domaines qui l'exigent sont mentionnés ci-dessous:

- Imagerie médicale pour :
 - Localiser les tumeurs.
 - Mesurer les volumes de tissus.
 - Chirurgie assistée par ordinateur.
 - Planification du traitement diagnostique.
 - Étude de la structure anatomique.
- Localiser les objets dans les images satellites.
- Reconnaissance faciale.
- Systèmes de contrôle automatique de la circulation.
- Vision de la machine.
- Détection d'objets.
- Surveillance vidéo.
- Récupération d'images basée sur le contenu.

II-2-4- Stratégies de segmentation:

La segmentation d'image fait partie d'une chaîne de traitement, c'est un domaine vaste où l'on retrouve de très nombreuses approches mais la nature vectorielle des images ou multi-spectrales implique la mise en œuvre de stratégies de segmentation spécifiques basées sur ces approches, vu qu'il n'existe pas de méthode de segmentation universelle et valables pour tous les types d'images.

La détection des caractéristiques et la segmentation sont deux domaines étroitement liés. Pour déterminer la présence de certaines propriétés d'image, on parle de détection de caractéristiques, alors que la segmentation suppose généralement que la propriété est déjà présente et tente de localiser avec précision les zones qui possèdent cette propriété. Le processus de segmentation des images multi-composantes peut être divisé en trois stratégies de la manière suivante; il s'agit des stratégies scalaires, marginales et vectorielles.

II-2-4-1- Les stratégies scalaires:

L'approche scalaire commence par une fusion des n composantes de l'image multi-composante. L'image sous forme mono-composante ainsi obtenue est traitée par la suite. Par

exemple une image vectorielle couleur codé dans l'espace RVB peut être transformée avant traitement en une image scalaire. Cela peut être réalisé au moyen d'une analyse en composantes principales dont on ne retient que la première composante.

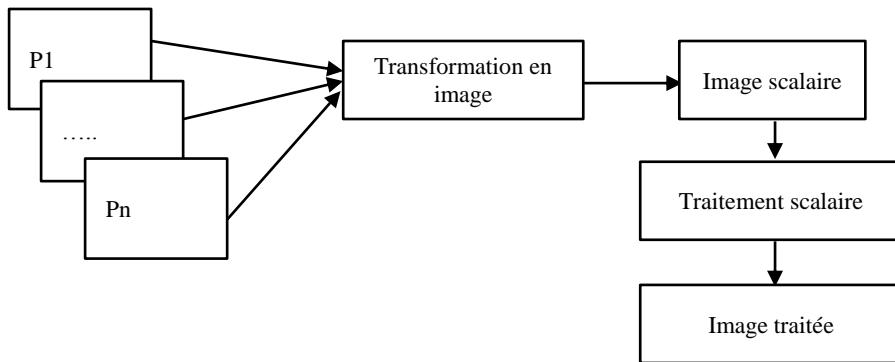


Figure II.2 : Stratégie Scalaire.

II-2-4-2- Les stratégies marginales:

L'approche marginale opère un traitement scalaire sur chaque composante de l'image. Les résultats obtenus sont ensuite fusionnés en une seule image mono-composante. Cette stratégie demande autant de traitements qu'il y a de composantes.

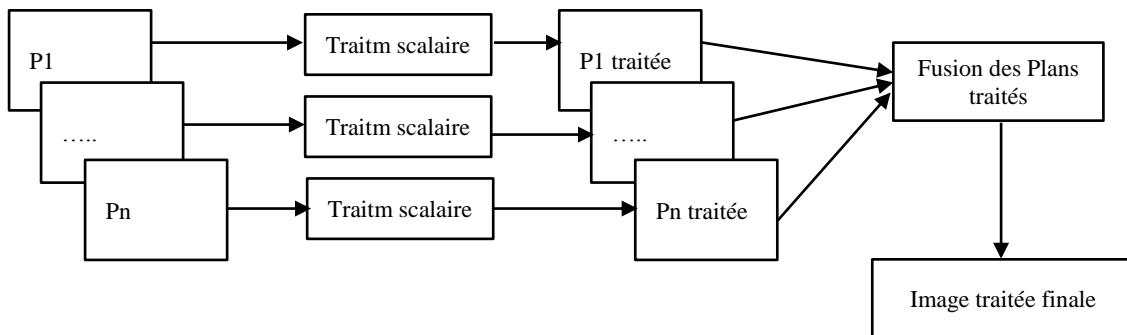


Figure II.3 : Stratégie Marginales.

II-2-4-3- Les stratégies vectorielles:

L'approche vectorielle utilise directement et de façon globale, l'information vectorielle présente dans l'image. La corrélation entre composantes est ainsi prise en compte.

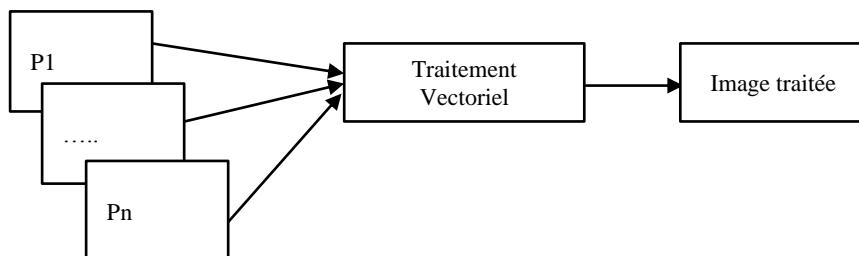


Figure II.4 : Stratégie Vectorielles.

En analyse d'image médicale, la segmentation au premier plan est plus fréquente que les autres tâches d'analyse d'image. Certaines approches basées sur les modèles, telles que les contours et surfaces actifs ou les modèles de formes actives, sont généralement utilisées pour distinguer la structure requise de l'arrière-plan [BIT 13].

II-2-5- Notions de voisinage spatial et de connexité:

La section qui nous intéresse ici concerne les relations entre pixels dans les images numériques; et ceci pour préparer l'étude des divers algorithmes de traitement d'images impliquant des opérations entre pixels voisins. Notamment la notion de connexité entre pixels qui est une notion particulièrement importante pour la détection des frontières d'objets dans une image, et des pixels composant un objet. Deux pixels seront considérés comme connexes (appartenant au même objet donc) s'ils satisfont à deux critères : le premier, c'est le Critère de similarité (par exemple même niveau de gris) et le deuxième c'est le Critère de voisinage s'ils sont adjacents.

La notion de connexité représente ici la notion de voisinage (adjacent) par contact direct ou chaque pixel a deux types de voisins. En général, on utilise deux règles de connexité [SAL 12]. Soit dans un maillage carré, deux pixels (i,j) et (i',j') sont dit de:

- Connexité 4 où sont considérés connexes les 4 voisins latéraux (droite, gauche, dessus, dessous), c'est-à-dire :

$$|i-i'| + |j-j'| = 1 \quad (\text{II.3})$$

- Connexité 8 où sont considérés connexes les 4 voisins latéraux (droite, gauche, dessus, dessous) et les 4 voisins diagonaux :

$$\text{Max}(|i-i'|, |j-j'|) = 1 \quad (\text{II.4})$$

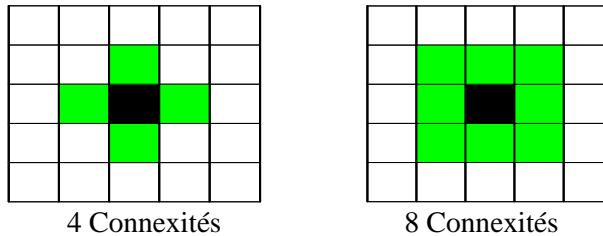


Figure II.5 : Représentation des deux types de connexité.

Le type d'opérations que l'on peut appliquer à des images numériques pour transformer une image d'entrée $a[m,n]$ en une image de sortie $b[m,n]$ peut être classé en trois catégories illustré graphiquement sur la figure II.6:

- Point** : La valeur de sortie ne dépend que de la valeur d'entrée au même point.
- Local** : La valeur de sortie ne dépend que des valeurs dans un voisinage du même point dans l'image d'entrée.
- Global** : La valeur de sortie dépend potentiellement de toutes les valeurs d'entrée.

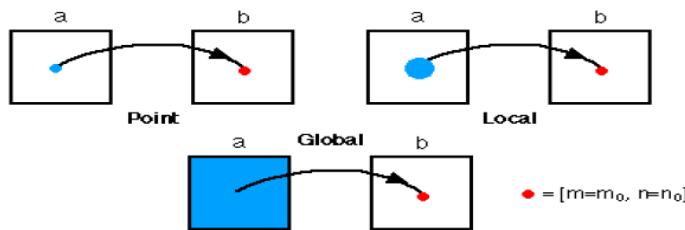


Figure II.6 : Illustration des différents types d'opérations.

II-2-6- Mesures de distance et de similarité:

Pour calculer la similarité ou la dissimilarité, nous avons besoin des formules mathématiques. Un objet de données est décrit par un ensemble de caractéristiques, généralement représenté dans un vecteur multi - dimensionnel. Les caractéristiques peuvent être continues ou binaires, quantitatives ou qualitatives, nominales ou ordinaires, qui déterminent les mécanismes de mesure correspondants.

On désigne la distance entre deux instances x_i et x_j par $d(x_i, x_j)$. Une mesure de distance valide doit être symétrique et sa valeur est minimale (généralement zéro) dans le cas de vecteurs identiques. Une mesure de distance est appelée une métrique. Sur un jeu de données X , elle est définie en respectant les conditions suivantes:

- i) Symétrie, $d(x_i, x_j) = d(x_j, x_i)$
- ii) Positivité, $d(x_i, x_j) \geq 0$ pour tout x_i, x_j
- iii) Inégalité de triangle, $d(x_i, x_j) \leq d(x_i, x_k) + d(x_k, x_j)$ pour tous les x_i, x_j et x_k
- iv) Réflexivité, $d(x_i, x_j) = 0$ ssi $x_i = x_j$

Les mesures de distance sont généralement utilisées pour mesurer les entités continues. Il existe plusieurs types de mesures de distance et le choix de la mesure de distance dépend du problème posé. Pour les caractéristiques binaires, nominales ou ordinaires, les mesures de distance varient considérablement. Certaines mesures de distance couramment utilisées pour les caractéristiques quantitatives sont résumées dans le tableau II.1 suivant :

Tableau II.1 : Caractéristiques principales de l'association de deux cellules.

Mesures de distance	Fonction	Commentaire
Euclidienne	$d_{ij} = \sqrt{\sum_k (x_{ik} - x_{jk})^2}$	La mesure en ligne droite dans un espace multi varié entre les points de données.
Euclidienne à l'échelle	$d_{ij} = \sqrt{\sum_k \frac{(x_{ik} - x_{jk})^2}{s_k^2}}$	Similaire à la distance euclidienne, sauf que chaque variable est mise à l'échelle par sa variance, s^2
Manhattan/City	$d_{ij} = \sum_k x_{ik} - x_{jk} $	La somme de la différence absolue entre les points de chaque dimension individuelle
Minkowski	$d_{ij} = (\sum_k x_{ik} - x_{jk} ^\gamma)^{\frac{1}{\gamma}}$	Une mesure de distance générale, qui inclut un paramètre supplémentaire γ
Mahalanobis	$d_{ij} = \sqrt{(x_i - x_j) S^{-1} (x_i - x_j)}$	la mesure de distance multi variée où x_i et x_j sont les colonnes de vecteurs des points i et j et S la matrice de variance-covariance de l'échantillon.
Hamming	$d_{ij} = \frac{\#(x_{ik} - x_{jk})}{m}$	La proportion de valeurs qui diffèrent entre les deux points. Utile pour les données catégoriques

De façon générale, l'un des problèmes les plus essentiels dans les techniques de segmentation est l'évaluation et la validation des résultats pour trouver le meilleur partitionnement qui correspond aux données sous-jacentes. Les critères d'évaluation et de validation des résultats seront étudiés en détail dans la section suivante.

II-2-7- Interaction, évaluation et validation:

Dans tout processus de segmentation, le compromis entre l'interaction manuelle et la performance est d'une importance considérable. L'interaction manuelle peut grandement améliorer la précision en intégrant les connaissances préalables de l'expert. Notons cependant, même les méthodes automatiques de segmentation nécessitent généralement la spécification des paramètres initiaux qui peuvent affecter les performances de la segmentation [WAR 06].

L'évaluation des méthodes de segmentation est fondamentale dans le traitement des images, elle permet de mieux comprendre la différence entre les méthodes de segmentation. De nombreux critères de validité ont été proposés pour la segmentation d'images, mais la plupart des études ont uniquement pris en compte la structure géométrique de l'échantillon. Dans cette thèse nous nous sommes basés sur la segmentation par classification et clustering ou les résultats dépendent des fonctions de validité du cluster.

Ces derniers sont souvent utilisés pour évaluer les performances de la classification dans différents indices et même pour comparer deux méthodes de classification différentes. Les fonctions représentatives de la fonction de validité basée sur les partitions floues sont le coefficient de partition V_{pc} et l'entropie de partition V_{pe} où le maximum V_{pc} et le minimum V_{pe} mènent à la meilleure interprétation des échantillons considérés.

Les inconvénients de V_{pc} et V_{pe} sont leur manque de connexion directe à une propriété géométrique et leur tendance à diminuer de façon monotone avec le nombre de classe c . Il est clair que la meilleure partition est celle dans laquelle les échantillons entre les différents clusters sont séparés. Ceci est quantifié, par exemple, par la fonction V_{fs} de Fukuyama-Sugeno V_{fs} et la fonction V_{xb} de Xie-Beni [PAL 95].

Dans cette section nous décrivons la métrique de performance utilisée pour évaluer la qualité des résultats du clustering et de la classification telle que, l'indice de validité de la classification, l'indice de qualité d'image et la matrice de confusion. Le tableau II.2 présente les quatre fonctions de validité pour évaluer les performances de nos algorithmes [KAN 15].

Tableau II.2 : Sommaire des quatre fonctions de validité choisies.

Fonction de validité	Description	Partition optimale
Coefficient de partition	$V_{pc}(U) = \frac{\sum_{j=1}^n \sum_{i=1}^c u_{ij}^2}{n}$	Max(V_{pc})
Entropie de partition	$V_{pe}(U) = -\frac{1}{n} \left\{ \sum_{j=1}^n \sum_{i=1}^c [u_{ij} \log u_{ij}] \right\}$	Min(V_{pe})
Xie-Beni	$V_{xb}(U) = \frac{\sum_{j=1}^n \sum_{i=1}^c u_{ij}^2 \ x_j - v_i\ ^2}{n \times (\min\{\ v_i - v_k\ ^2\})}$	Min(V_{xb})
Fukuyama-Sugeno	$V_{fs}(U, V, X) = \sum_{j=1}^n \sum_{i=1}^c u_{ij}^m (\ x_j - v_i\ ^2 - \ v_i - \bar{v}\ ^2)$	Min(V_{fs})

On définit l'indice de similarité (ρ) comme suit:

$$\rho = \frac{1}{C} \sum_{i=1}^C \frac{2|A_i \cap B_i|}{|A_i| + |B_i|} \quad (\text{II.5})$$

L'indice de similarité (ρ) est une mesure de validité très efficace car il compare les résultats de la segmentation à la réalité. L'image libre de bruit et d'inhomogénéité est considérée ici comme une image de vérité.

A_i et B_i représentent les ensembles de pixels appartenant au groupe i dans le résultat de la segmentation et dans la «Vérité sur le terrain». L'indice de similarité ρ se situe dans l'intervalle $[0,1]$ et le résultat de clustering optimal est obtenu lorsque $\rho = 1$, c'est la valeur la plus élevée correspondant à un meilleur résultat.

Les indices de qualité d'image utilisés pour vérifier les performances des résultats des algorithmes de segmentation sont présentés dans cette section. La précision de segmentation optimale (SA) et le taux de classification erronée (MCR) sont utilisés pour évaluer les performances de réduction de bruit, l'indice SA étant défini comme la somme des pixels correctement classés divisé par la somme du nombre total de pixels :

$$SA = \frac{\text{nombre de pixels correctement classés}}{\text{nombre total de pixels de la classe } i} \times 100 \quad (\text{II.6})$$

$$MCR = \frac{\text{nombre de pixels mal classé}}{\text{nombre total de pixels de la classe } i} \times 100 \quad (\text{II.7})$$

II-3- Les différentes approches de segmentation d'image :

Généralement, le processus de segmentation se fait de trois manières simples: il s'agit de méthodes manuelles, automatiques et semi-automatiques.

Dans la segmentation manuelle, les pixels seront indiqués manuellement et cela prend beaucoup de temps si l'image est très grande. Ces techniques exigent plus de temps pour suivre les objets, des ressources humaines et aussi sont plus coûteuses.

Cependant elles sont toujours utilisées dans les méthodes traditionnelles à des fins médicales et beaucoup ne permettent pas d'obtenir des résultats appropriés avec une bonne précision. Par contre la segmentation automatique est difficile en raison de la nature complexe des images et de leurs variations.

Les algorithmes utilisés dans le processus de segmentation doivent disposer d'information permettant de définir au préalable quelques paramètres à l'aide d'un ordinateur. Cette information contiendra les niveaux de bruit et la probabilité de divers objets ayant différents niveaux de distribution. Cette méthode nécessite de nombreuses recherches supplémentaires avant la segmentation pour juger de l'information correcte définissant les paramètres nécessaires.

La segmentation semi-automatique combine les avantages des deux méthodes décrites ci-dessus. On peut procéder à la segmentation automatique en disposant des informations de base ou initiales sur les structures à étudier. Cette méthode comprend de nombreux types de techniques de segmentation [RIT 13].

Lorsqu'on parcourt la littérature consacrée à la segmentation d'image, nous nous en inspirons pour dire que les méthodes de segmentation peuvent être classées en deux grandes catégories comme l'illustre la figure II.7.

L'approche directe de bas niveau extrait à partir de l'image seulement une information pertinente, mais l'approche indirecte de haut niveau fait intervenir une modélisation de l'image ou de la donnée recherchée.

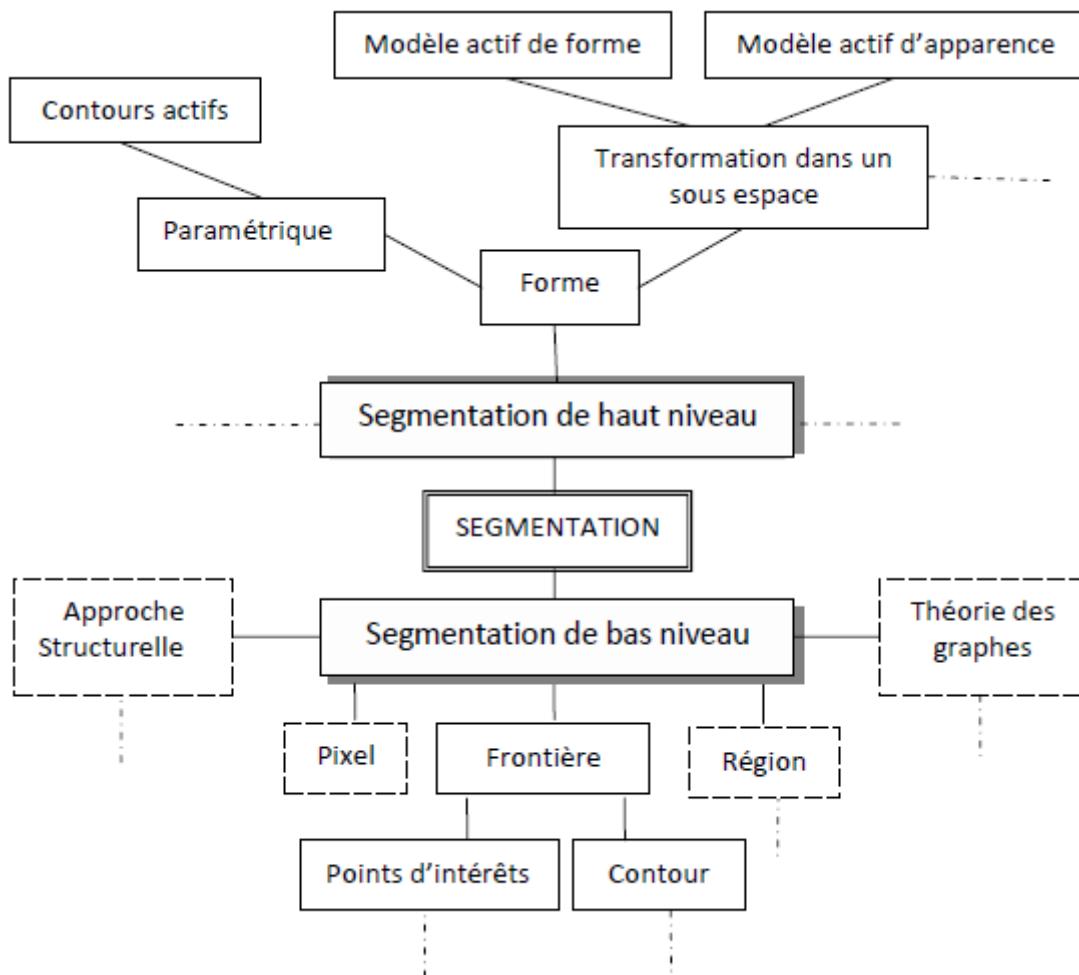


Figure II.7 : Catégorisation des différentes méthodes de segmentation d'image.

D'une manière générale, la segmentation d'images est un problème ancien et important, et il en existe de nombreuses méthodes. La plupart de ces méthodes ont été développées pour être utilisées sur une certaine classe d'images et ne sont donc pas des méthodes générales de segmentation d'images [BHA 99].

Dans cette partie, nous présenterons les différentes approches de la segmentation de bas niveau, ensuite, nous nous intéresserons aux méthodes de classification supervisée en général et la classification non supervisée en particulier. Bhanu et Lee [BHA 94] divisent les algorithmes de segmentation d'images en trois catégories principales:

- **Approches basées sur les contours** : C'est la recherche de discontinuités locales ou «déttection de contours».
- **Approches basées sur les régions** : Cette approche cherche à détecter des zones de l'image présentant des caractéristiques d'homogénéité « extraction de régions ». On y trouve par exemple : la croissance de région, décomposition/fusion et classification.
- **Approches basées sur les deux cas (coopérative)** : elles sont duales en ce sens qu'une région définit une ligne par son contour et qu'un contour fermé définit une région.

Le schéma de la figure II.8 suivante donne une planification de ces différentes techniques de segmentation d'image dont certaines sont décrites dans la section suivante.

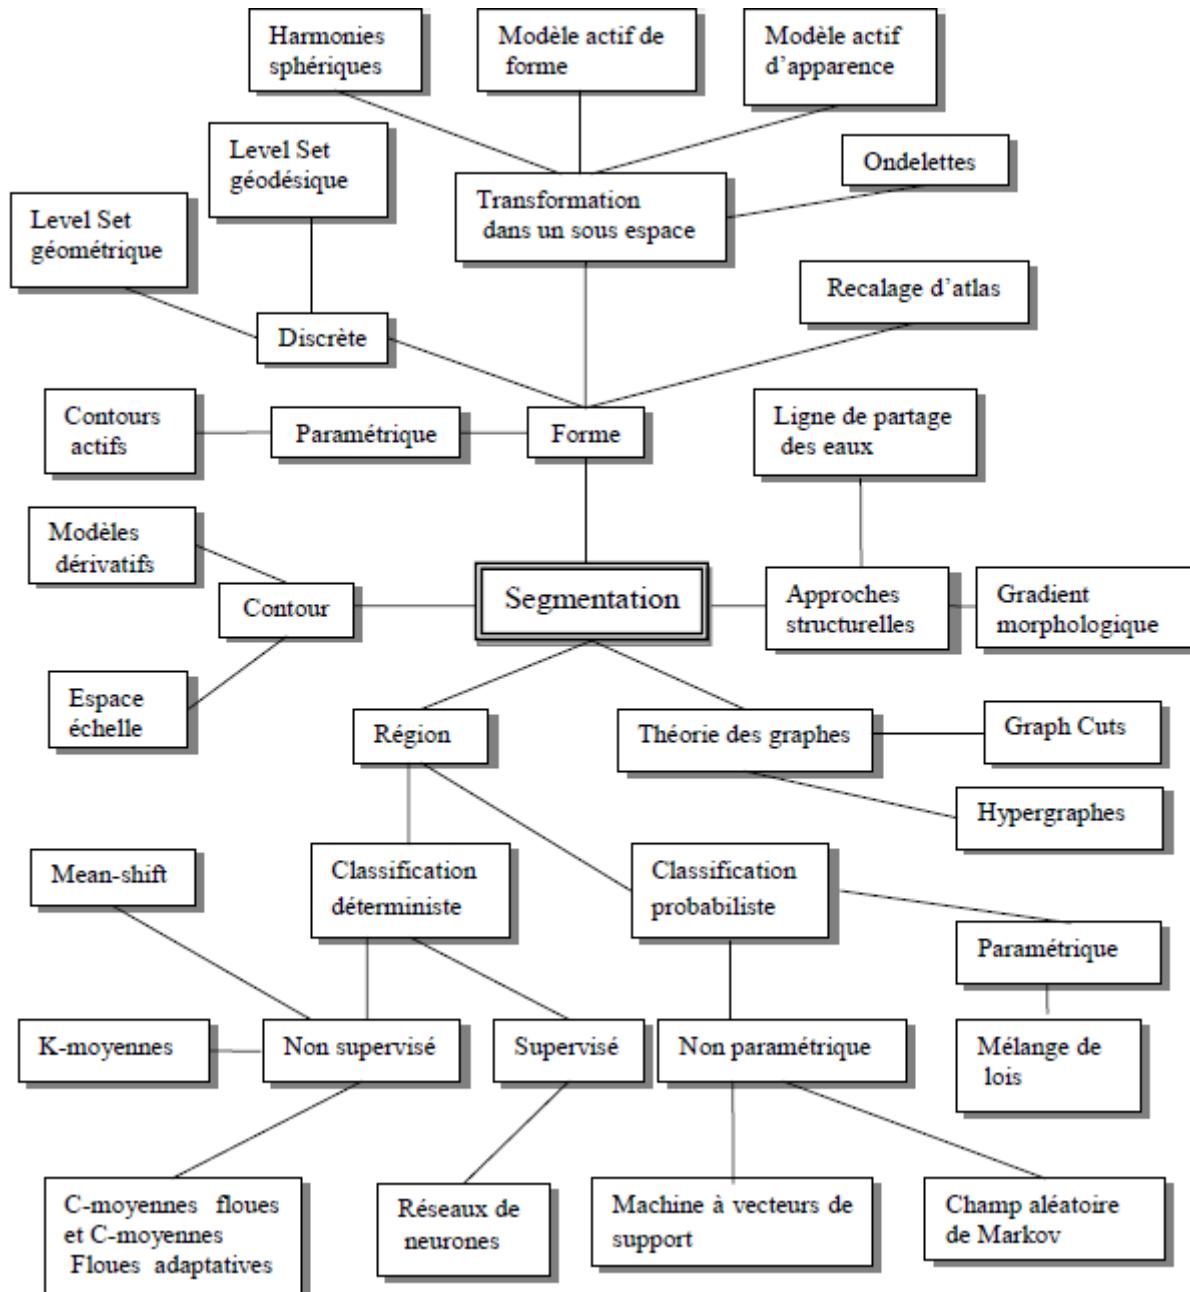


Figure II.8 : Classification des différentes techniques de segmentation d'image.

II-3-1- Approche région:

L'approche région cherche à regrouper les pixels en régions homogènes. Cette méthode est axée sur l'aspect important du processus de segmentation qui n'est pas couvert par la technique par points ou un ensemble de pixels sera divisé en objets de pixels en fonction de leurs valeurs de gris indépendamment. Les points isolés ou les petites zones seront différenciés en tant que pixels d'objet en ne considérant pas la connectivité comme une caractéristique importante. Ces régions sont construites en évaluant la similarité entre les pixels ou entre un pixel et ceux d'une même région [MEL 12].

Généralement, le but de cette approche est de satisfaire les critères homogènes prédéfinis d'un domaine de recherche [HAR 98]. La plupart des segmentations des images médicales assistées par ordinateur sont basées sur une analyse des valeurs de gris.

II-3-1-1- Segmentation par seuillage:

La méthode la plus simple de segmentation d'image s'appelle la méthode de seuillage. Cette méthode est basée sur un niveau de gris (ou une valeur de seuil) pour transformer une image en niveaux de gris en une image binaire. Le but de cette méthode consiste à sélectionner la valeur de seuil (ou les valeurs lorsque plusieurs niveaux sont sélectionnés). La classification consiste à retrouver ces nuages de points qui correspondent aux classes des pixels présentes dans l'image. Donc le seuillage consiste à classer, suivant le nombre de classes, les différents pixels d'une image, en se basant sur l'histogramme de niveaux de gris de l'image. En d'autres termes, la segmentation d'une image en N classes consiste à chercher N-1 seuils.

Le principe de base du seuillage est de définir un seuil T d'intensité ou de couleur, et de comparer chaque pixel (x, y) d'une image $f(x, y)$ au seuil T . Si au point (x, y) , $f(x, y) > T$, le point s'appelle un point d'objet; autrement appelé un point de fond [GON 01].

L'image segmentée $g(x, y)$ est définie par:

$$g(x, y) = \begin{cases} 1 & \text{si } f(x, y) > T \\ 0 & \text{si } f(x, y) \leq T \end{cases} \quad (\text{II.8})$$

Lorsque T est constant sur toute l'image, le processus s'appelle le seuillage global. Lorsque T bascule sur une image, cela s'appelle un seuil variable. Il existe également un troisième type appelé seuillage local ou régional où la valeur de T en un point quelconque (x, y) dépend des propriétés de son voisinage. Si T dépend des coordonnées spatiales (x, y) elles-mêmes, le seuillage variable est appelé seuillage adaptatif.

Une segmentation optimale par seuillage nécessite donc une localisation optimale des seuils de segmentation dans l'histogramme. En partant de l'hypothèse du seuillage, si l'histogramme possède plusieurs modes (pics), les seuils optimaux sont situés entre ces derniers. Cependant, dans la pratique, ce cas de figure ne se présente pas fréquemment, ce qui rend l'opération de segmentation plus complexe (par exemple, dans le cas où l'histogramme possède un seul mode). Afin de résoudre ce problème de seuils optimaux, une multitude de méthodes ont été développées.

Les méthodes de segmentation par seuillage d'histogrammes permettent d'obtenir des régions homogènes. Cependant, les régions obtenues ne sont pas compactes. En plus, l'extension de l'histogramme vers l'espace multi spectral est difficile à réaliser.

II-3-1-2- Segmentation par classification des pixels (Clustering):

La classification est une des solutions fréquemment employées pour réaliser la segmentation d'une image en régions, qui permet de passer d'une représentation sous forme de pixels à des objets pouvant par la suite être analysés afin d'interpréter le contenu des images. Clustering est le processus de regroupement d'objets ayant des caractéristiques similaires, à savoir l'intensité. Dans la segmentation d'images médicales, les niveaux d'intensité de différents objets d'une image sont différents. Par exemple, l'intensité de la tumeur dans une image médicale est différente de celle d'autres images. Les méthodes basées sur les clusters identifient cette partie dans un cluster.

Dans le cas où le nombre de classes est connu a priori, nous parlons alors de classification supervisée ; dans le cas contraire il s'agit de la classification non supervisée.

Ce type de méthode considère une région comme un ensemble de pixels connexes appartenant à une même classe. Elles supposent donc que les pixels qui appartiennent à une même région possèdent des caractéristiques similaires et forment un nuage de points dans

l'espace des attributs. La classification consiste à retrouver ces nuages de points qui correspondent aux classes des pixels présentes dans l'image.

Comme mentionné précédemment, l'objectif principal de la segmentation d'image est de partitionner une image en régions épuisées et mutuellement exclusives, homogènes par rapport à un critère prédéfini. Dans le cas des tumeurs cérébrales, la segmentation consiste à séparer les différents tissus tumoraux, tels que les tumeurs solides ou actives, les œdèmes et les nécroses, des tissus cérébraux normaux tels que les GM, MW et LCR. La segmentation des tumeurs cérébrales nécessite une mesure objective pouvant être utilisée pour définir l'homogénéité de chaque tissu.

Il existe deux manières d'obtenir la mesure objective, à savoir les méthodes de segmentation non supervisée et supervisée. La différence entre eux réside dans le fait que les méthodes non supervisées n'utilisent pas les données d'apprentissage qui ont été étiquetées manuellement, comme c'est le cas des méthodes supervisées. Dans la segmentation non supervisée, le nombre de classes est automatiquement spécifié par un algorithme qui regroupe des pixels similaires. Donc la classification est définie comme une procédure dans laquelle les pixels similaires d'une image sont identifiés et regroupés dans une même classe. Il existe deux grandes tendances:

II-3-1-2-1- Classification non supervisée(Automatiques):

Elle vise à séparer automatiquement l'image en clusters sans aucune connaissance a priori sur les classes. Elle se base sur une mesure de distance entre les vecteurs d'attributs. Les algorithmes les plus fréquemment cités dans la littérature pour cette catégorie sont K-means, Isodata, et Fuzzy c-means....

II-3-1-2-2- Classification supervisée:

Elle s'opère à partir de la connaissance de chacune des classes définies par une approche probabiliste. Elle se base sur l'apprentissage de propriétés discriminantes sur un échantillon de données déjà classées. Les algorithmes de cette catégorie sont "Minimum-Distance-to-Means", "Likelihood" et "Parallelopiped" .L'inconvénient des méthodes de classification est qu'elles sont très sensibles au bruit.

La plupart des algorithmes de classification peuvent être rangés en deux catégories :

II-3-1-2-3- Classification hiérarchique:

La classification hiérarchique fournit une hiérarchie de partitions. Ce type de classification regroupe les méthodes ascendantes et descendantes. Ces algorithmes essaient de créer une hiérarchie de classes. Les objets les plus similaires sont rassemblés dans des groupes aux plus bas niveaux, tandis que les objets moins similaires se retrouvent dans des groupes aux plus hauts niveaux [LAG 10].

II-3-1-2-4- Classification non hiérarchique (partitionnelle):

Il n'y a pas de hiérarchie. Dans la plupart de ces méthodes, le choix a priori du nombre de classes est nécessaire. Les points d'initialisation peuvent être des points d'un nuage pris au hasard ou les centroides d'une partition préalable.

Les classes obtenues n'ont pas plus d'importance les unes que les autres. Nous distinguons deux types de classification partitionnelle : classification dure, classification floue... [LAG 10].

En générale, les méthodes de classifications par partition sont efficaces pour partitionner un ensemble de points par apprentissage ou non. Ces méthodes donnent de bons résultats

quand les régions sont uniformes. Cependant, elles donnent de mauvais résultats quand les images à traiter sont bruitées. En effet, les méthodes de classification par partition travaillent dans certain espace d'attributs et négligent le rapport spatial entre les pixels de l'image. Les méthodes de classification floue présentent des caractéristiques plus robustes. En effet, ces méthodes peuvent retenir plus d'informations que les autres méthodes de classification.

Dans la suite de ce paragraphe, nous présentons un type de classification non hiérarchique (partitionnelle) : la méthode des k- moyennes (k-Means) construit k classes à partir d'un ensemble de n individus, tout en minimisant la quantité de la fonction objective.

II-3-1-2-4-1- K- moyenne (K-Means Clustering):

K-Moyennes clustering est une méthode de classification / regroupement d'éléments en k groupes (où k est le nombre de groupes présélectionnés). Le regroupement est effectué en minimisant la somme des distances au carré (distances euclidiennes) entre les éléments et le centroïde correspondant. Parmi les divers algorithmes de classification, K-Means est l'une des méthodes les plus utilisées dans l'analyse de données en raison de ses bonnes performances de calcul.

Soit $X = \{x_k / k = 1, \dots, n\}$ un sous-ensemble d'un espace n-dimensionnel. Une partition de X en "c" classes peut être représentée par des sous-groupes mutuellement disjoint $C_1 \dots C_c$, tel que $\cup C_1 \dots \cup C_c = X$ chaque vecteur x_k est assigné à seulement une classe qui lui est la plus proche. La fonction objective correspondante s'exprime sous la forme :

$$J = \sum_{i=1}^c \sum_{k=1}^n U_{ik} d^2(x_k, v_i) \quad (\text{II.9})$$

Où l'optimisation se fait de manière itérative et les paramètres sont:

- v_i : désigne le prototype (centroïde) de cette classe.
- d : mesure la similarité entre le prototype et le vecteur de données.
- U_{ik} : est un indicateur binaire désignant l'appartenance ou non du vecteur x_k à la classe C_i ($U_{ik} = 1$ si $x_k \in C_i$ et $U_{ik} = 0$ sinon, $\forall i = 1 \dots c$ et $\forall x_k \in X$). L'indicateur d'appartenance U_{ik} s'exprime comme suit :

$$U(x_k, v_i) = \{1 \text{ si } d(x_k, v_i) = \min c(x_k, v_c) \text{ ou } 0 \text{ sinon}\} \quad (\text{II.10})$$

Les démarches de l'algorithme k-means clustering qui est représenté sur la figure II.9 sont données sous formes des étapes l'une est exécutée après l'autre comme suit :

Étape 1: Choisissez les K clusters.

Étape 2: Choisissez 'k' points de données au hasard dans l'ensemble de données. Ces données agissent comme centres initiaux du cluster.

Étape 3: Attribuez chaque point de données de l'observation «n» dans un groupe avec la distance minimale entre le point de données et le centre du classe.

Étape 4: Recalculez le centre de la grappe en faisant la moyenne de tous les points de données de la classe.

Étape 5: Répétez les étapes 3 et 4 jusqu'à ce qu'il n'y ait plus de changement dans les centres de classe.

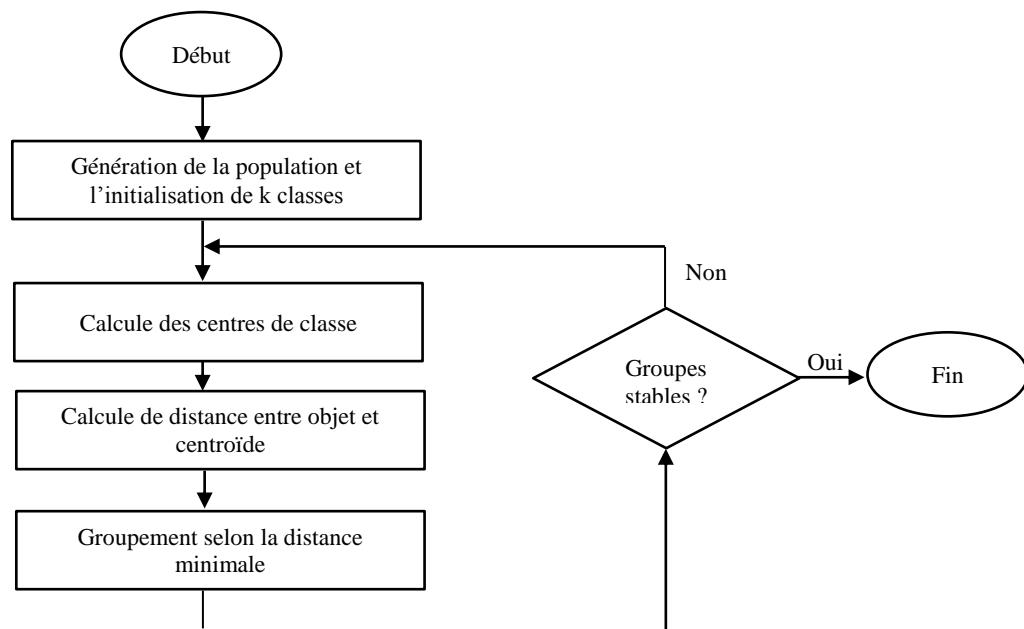


Figure II.9 : Organigramme de l'algorithme K-means.

L'algorithme K-means peut être compris comme une procédure de descente de gradient, mettant à jour les centroïdes de cluster pour minimiser la fonction objectif de l'équation (II.9). Les K-moyennes convergent toujours vers un minimum local. Velmurugan & Santhanam [VEL 10] ont mis au jour le minimum local particulier trouvé sur les centroïdes des groupes de départ. Les Avantages/Inconvénients de cette méthode sont présentés dans le tableau II.3.

Tableau II.3 : Les Avantages/Inconvénients de l'algorithme k-means.

Avantages	Inconvénients
- Elle est très populaire du fait qu'il est très facile à comprendre et à mettre en œuvre	- La partition finale dépend de la partition initiale, dépend de l'ordre d'affectation
- Non supervisée, elle ne nécessite aucune information sur les données	- Le calcul des centroïdes, après chaque affectation d'un individu, influence le résultat de la partition finale
- Sa simplicité conceptuelle, sa rapidité et ses faibles exigences en taille mémoire	- Un mauvais choix du nombre k produit de mauvais résultats

En général, l'analyse des clusters non hiérarchique a tendance à être utilisée lorsque de grands ensembles de données sont impliqués. Cela présente deux inconvénients:

- 1) il est souvent difficile de savoir le nombre de cluster dont on dispose. Par conséquent, il peut être nécessaire de répéter l'analyse plusieurs fois.
- 2) cette analyse peut être très sensible au choix des centres de cluster initiaux.

De plus, il peut être intéressant d'essayer différentes méthodes pour voir son impact.

Une stratégie possible consiste à utiliser une approche hiérarchique initiale pour déterminer le nombre de clusters dans les données, puis utiliser les centres de clusters ainsi obtenus en tant que cluster centres initiaux dans la méthode non hiérarchique.

II-3-1-3- Segmentation par croissance de région:

Les méthodes par croissance de région, de par leur relative simplicité de mise en œuvre ont été l'une des premières familles d'outils utilisés pour la segmentation d'image. Zucker introduit les premiers travaux relatifs à la croissance de région.

A partir d'un ensemble de points initiaux, cette méthode agrège les pixels suivant un double critère : l'homogénéité et l'adjacence. Cette agrégation de pixels est contrôlée par un prédictat (expression booléenne). Le processus s'applique sur une ou plusieurs régions. Pour chaque région, il comprend une phase d'initialisation et une phase itérative. Ce type de segmentation permet de sélectionner un pixel ou un ensemble de pixels de l'image, appelé germe, autour duquel on fait croître une région. Les régions sont construites en ajoutant successivement à chaque germe les pixels qui lui sont connexes et qui vérifient un critère de similarité. La croissance s'arrête lorsque tous les pixels ont été traités. Le processus de croissance de région étant itératif, le contenu d'une région à l'itération "n" est notée $R^{[n]}$.




Figure II.10 : Organigramme de la segmentation par Croissance de région.

II-3-1-3-1- Sélection des germes:

L'initialisation de la croissance de région nécessite le positionnement de germes désignant la ou les premières régions. Bien entendu, le point ou la zone germe doit faire partie de la région recherchée, au risque d'obtenir une segmentation partiellement voire totalement erronée. Ces germes constituent donc la région initiale $R^{[0]}$.

II-3-1-3-2- Processus itératif:

Suite à la phase d'initialisation, un processus itératif de déformation ajoute progressivement des points situés à la périphérie de la région qui va croître, s'ils respectent le prédictat. Ces nouveaux points sont regroupés dans l'ensemble que l'on note $C^{[n]}$. Considérons une croissance de région ne faisant croître qu'une seule région. Étant donné une région initiale $R^{[0]}$, la région suivante $R^{[n+1]}$ est obtenue à partir de la région courante $R^{[n]}$ et de la couronne $C^{[n]}$ par la réunion suivante :

$$R^{[n+1]} = R^{[n]} \cup C^{[n]} \quad (\text{II.11})$$

Dans la croissance de région, la condition d'agglomération implique la définition d'un terme de similarité entre un point candidat et la région segmentée. Ce terme de ressemblance, appelé critère, est utilisé par le prédictat pour décider de l'ajout ou non d'un pixel. En pratique, le critère implique presque toujours une mesure d'homogénéité sur les intensités des points de la région segmentée. Le processus a été initialisé à partir de deux germes. Le résultat est donné à différentes itérations de l'évolution.

II-3-1-3-3- Convergence, critère d'arrêt:

Comme l'itération porte sur une région croissante et bornée, la convergence est assurée au bout d'un nombre fini d'itérations. Le processus de croissance peut s'arrêter selon deux scénarios :

- Toutes les régions satisfont le prédictat et la segmentation comprend n régions
- Il existe n-1 région qui vérifie le prédictat, la n ième région comprend les points ne vérifiant pas le prédictat.

Des travaux récents ont montré que l'avantage des méthodes de croissance de régions est de préserver la forme de chaque région de l'image. Cependant une mauvaise sélection des pixels de départ, un choix de critère de similarité, ainsi qu'un ordre mal adapté selon lequel les pixels voisins sont examinés, peuvent entraîner des phénomènes de sous segmentation ou de sur segmentation. Les méthodes de segmentation par croissance de région sont nombreuses. Nous avons décrit son principe général d'agrégation comme un processus itératif piloté par un critère évalué sur la région en train de croître.

II-3-2- Approches Contours:

Un contour peut approximativement être défini comme une frontière entre deux régions ou l'intensité des pixels change brusquement. Généralement l'utilisation d'un tel opérateur de contour se combine avec un seuillage et comme étant ce dernier est généralement imparfait, on obtient, d'une part, des contours qui ne limitent pas les régions fermées. Donc on doit faire recours à des algorithmes de fermetures des contours. D'autre part, les zones de fortes variations ne correspondent pas forcément à un contour d'objet. Alors un post-traitement est nécessaire pour analyser les différents contours obtenus.

Dans l'approche "contour" (ou "frontière"), on considère que les primitives à extraire sont les lignes de contrastes séparant des régions de niveaux de gris différents et relativement homogènes, ou bien des régions de texture différentes. En pratique, il s'agit de reconnaître les zones de transition et de localiser au mieux la frontière entre les régions. On distingue notamment les modèles dérivatifs et les modèles variationnelles.

II-3-2-1- Méthodes dérivatives:

Les modèles dérivatifs consistent à modéliser les contours ou des zones d'images et supposent que l'image numérique provient de l'échantillonnage d'une fonction scalaire à support borné et dérivable en tout point. Ces variations d'intensité de l'image peuvent correspondre à des variations d'illuminations (ombres), des changements d'orientation ou de distance à l'observateur, des changements de réflexion de surface, des variations d'absorption des rayons, etc. Or, dans le traitement d'une image numérique, toutes ces grandeurs sont condensées en une seule variable bi ou tridimensionnelle ; dans le cas monochrome, c'est l'intensité lumineuse. On distingue trois types de contours simples : Marche d'escalier ou le contour est net (contour idéal), Rampe ou le contour est plus flou, Toit ou il s'agit d'une ligne sur un fond uniforme.




Figure II.11 : Modèles de contours ; (a) Marche, (b) Rampe, (c) Toit.

Ce sont des contours idéaux qui ont permis une approche de détection par les opérateurs gradient et laplacien. Les variations locales d'intensité constituent la source de ces opérateurs.

II-3-2-1-1- Opérateurs dérivatifs du premier ordre:

Le gradient se base sur la première dérivée de l'image I en chacun de ces points dans les deux directions horizontale et verticale. Un point de contours aura une amplitude $A(i,j)$ et une direction $D(i,j)$:

$$\frac{\partial I(i,j)}{\partial x} = I_x(i,j); \quad \frac{\partial I(i,j)}{\partial y} = I_y(i,j); \quad (\text{II.12})$$

$$A(i,j) = \sqrt{(I_x(i,j) * I_x(i,j)) + (I_y(i,j) * I_y(i,j))} \quad (\text{II.13})$$

$$D(i,j) = \arctg\left(\frac{I_y(i,j)}{I_x(i,j)}\right) \quad (\text{II.14})$$

La détermination des points contours est ramenée dans un premier temps à la recherche de filtre linéaire permettant d'estimer le gradient en chaque point. De nombreux opérateurs sont ainsi apparus dans la littérature parmi lesquels nous pouvons citer les masques de Sobel, Prewit, Robertetc [MER 12].

II-3-2-1-2- Opérateurs dérivatifs de deuxième ordre:

Le Laplacien se base sur la dérivée seconde de l'image. Il est défini par :

$$\Delta^2 = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2} \quad (\text{II.15})$$

Contrairement au gradient, le Laplacien permet d'obtenir des contours fermés et d'un pixel d'épaisseur, par contre il a l'inconvénient d'être plus sensible au bruit que le gradient. Le Laplacien est déterminé en chaque point de l'image par filtrage linéaire. Les points contours sont alors assimilés au passage par zéro du Laplacien. Aussi il augmente le bruit présent dans l'image car il s'agit d'une méthode dérivative [MER 12].

II-3-2-2- Méthodes analytiques:

Dans le groupe des méthodes analytiques, on peut inclure les filtres de Canny, Deriche, Bourennane, Laggoune et Sarifuddin. Chacun de ces détecteurs possède ses propres caractéristiques et particularités. Les filtres de Canny et Deriche sont développés en se basant sur un modèle de contour de type marche (échelon), alors que les filtres de Bourennane et ceux de Laggoune utilisent le contour de type rampe et le contour de type pic respectivement. Chacun de ces chercheurs propose une paire de filtres : passe bas et passe bande. Le filtre passe bas permet de lisser l'image (et donc d'atténuer le bruit) alors que le filtre passe bande permet de détecter les contours. Les détecteurs de Canny, Deriche, Bourennane et Laggoune

sont bien adaptés aux images nettes et aux images bruitées par un réglage d'un ou plusieurs paramètres [SAR 08].

II-3-2-3- Méthodes déformables:

Contrairement Les modèles déformables, introduits par Kass [KAS 87] sont aussi connus sous les noms de « snakes » ou « contours actifs ». L'intérêt principal des contours actifs est de détecter des objets dans une image en utilisant les techniques d'évolution de courbes. L'idée est de partir d'une courbe initiale, généralement un carré ou un cercle, et de la déformer jusqu'à obtenir le contour de l'objet. En effet, celui-ci présente quelques inconvénients tels que la sensibilité à l'initialisation, au bruit, et le réglage difficile de ses différents paramètres. [MER 12].

Les principales limites des méthodes de détection de contour sont les suivantes [MER 12]:

- Les contours extraits selon les méthodes classiques souvent ne correspondent pas nécessairement à la limite des objets. Dans de nombreuses images de basse qualité, quelques-unes des méthodes produisent des faux contours.
- Les techniques de détection de contour dépendent de l'information contenue dans le voisinage local de l'image. Il n'y a pas d'information globale.
- Dans la plupart des cas, les stratégies de détection des contours ignorent l'organisation d'ordre supérieur qui peut être utilement présent dans l'image.
- Après l'extraction des points de contours, ces derniers sont reliés afin de déterminer les frontières. Le processus de fermeture des contours peut parfois conduire à des discontinuités et des lacunes dans l'image.
- Il est souvent difficile d'identifier et de classer les contours parasites.

II-3-3- Approches hybrides régions-contours :

Certaines recherches s'accordent pour dire que la coopération entre les techniques de segmentations par régions et par contours contribue à une meilleure prise en compte des caractéristiques de toutes les composantes de l'image et, par conséquent, à une meilleure segmentation. En effet, les algorithmes combinant les techniques de segmentation basées sur les régions et celles basées sur les contours prennent avantage de la nature complémentaire de l'information sur la région et sur le contour [ZHA 06]. Ainsi, une segmentation par coopération régions-contours peut être exprimée comme une entraide entre ces deux concepts afin d'améliorer le résultat final de segmentation. Il existe trois formes de coopération région-contour [SEB 07]:

II-3-2-1- Coopération Séquentielle:

L'une des techniques de segmentation (région ou contour) est réalisée en premier lieu; son résultat va être exploité par l'autre technique pour renforcer la définition des critères ou des paramètres de la segmentation ; L'intégration de l'information provenant de la segmentation par contours dans une segmentation par régions est l'une des formes de coopération les plus courantes (Figure II.12).

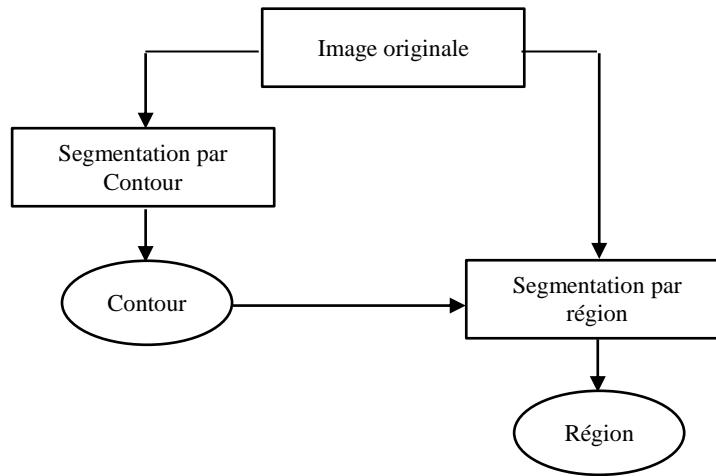


Figure II.12 : Forme de coopération Séquentielle.

II-3-2-1- Coopération des résultats:

Les deux types de segmentation seront réalisés indépendamment ; la coopération concerne leurs résultats qui seront intégrés afin d'atteindre une meilleure segmentation (Figure II.13), cette intégration peut être faite sous forme de complémentarité ou de recherche de consensus.

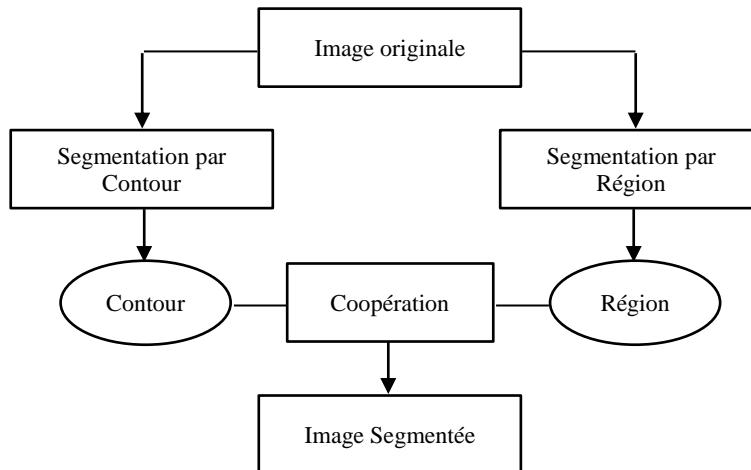


Figure II.13 : Forme de coopération des résultats.

II-3-2-1- Coopération Mutuelle:

Dans l'approche de coopération mutuelle, les deux techniques de segmentation sont exécutées en parallèle, elles coopèrent mutuellement au cours de leur processus d'exécution et la Figure II.14 montre cette forme. La coopération permet de prendre des décisions plus sûres et plus fiable.

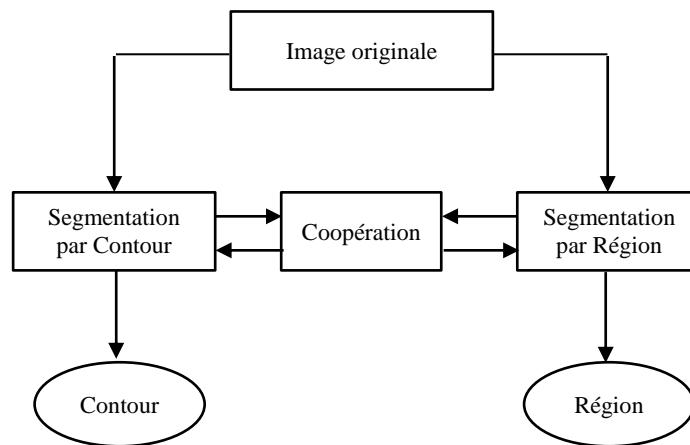


Figure II.14 : Forme de coopération Mutuelle.

II-4- Application à la segmentation des images médicales:

En règle générale, la segmentation des images médicales est l'une des études les plus critiques dans le domaine de la médecine, c'est une tâche essentielle dans de nombreuses applications d'images médicales, telles que la planification chirurgicale, l'évaluation post-chirurgicale et la détection d'anomalies car les résultats obtenus orientent les analyses vers la vérification du traitement administré. Le but de la segmentation est de diviser une image en un ensemble de régions disjointes ayant des caractéristiques similaires telles que l'intensité, la couleur et la texture [BAL 10]. Plus spécifiquement, la segmentation d'image est le processus d'attribution d'une étiquette à chaque pixel d'une image, de sorte que les pixels ayant la même étiquette partagent des caractéristiques et propriétés visuelles similaires. Dans la segmentation d'images médicales, des composants d'images dissemblables sont utilisés pour l'analyse de différentes structures, tissus et régions pathologiques [CLA 95]. L'objectif principal des méthodes de segmentation d'images médicales est d'aider au processus de diagnostic. En d'autres termes, ces méthodes sont utilisées pour aider les praticiens médicaux à évaluer l'imagerie médicale ou à reconnaître les résultats anormaux d'une image médicale.

Nous nous concentrons sur quelques questions importantes liées à la segmentation des images médicales, y compris une terminologie commune qui sera utilisée tout au long de cette thèse. Aussi une revue de littérature complète est réalisée et une étude d'algorithmes de segmentation d'images médicales comprenant des modules de l'automatisation de processus séparés et de plusieurs types de segments tels que la tumeur réelle et la zone de lésion réelle est mise en œuvre des algorithmes développés. Les performances du module de segmentation entièrement automatisé sont évaluées.

Les systèmes d'imagerie médicale actuels sont capables de fournir de grandes quantités d'images, ce qui nécessite une analyse en profondeur. Normalement, les experts effectuent certaines procédures d'évaluation sur les images médicales, ce qui peut entraîner des erreurs d'opération nécessitant beaucoup de temps. Ici, le contexte biomédical: anatomie cérébrale, les tissus du cerveau, les différentes lésions et les tumeurs cérébrales, le principe de base du système d'acquisition IRM sont présenté dans l'annexe A. L'imagerie par résonance magnétique (IRM) génère une énorme quantité d'informations sur l'image. Non seulement la taille et la résolution des images augmentent avec l'amélioration de la technologie, mais également le nombre de dimensions. Le développement d'algorithmes d'analyse d'images médicales nécessite des études de validation approfondies pour rendre les résultats utilisables dans la pratique. Cela ajoute une autre dimension au processus de recherche qui implique la

communication entre deux mondes différents : le monde médical centré sur le patient et le monde technique centré sur l'ordinateur et le développent des algorithmes pour résoudre ses problèmes.

II-4- Influence des artefacts d'imagerie sur la segmentation :

Il existe plusieurs types d'artefacts qui dégradent la qualité de l'image. Les premières sont des imperfections réelles ajoutées à l'image. D'autres artefacts sont introduits par la nature physique ou le principe de fonctionnement du capteur d'image, par exemple les intégrations temporelles et spatiales du signal d'image et par leurs distributions spectrales. Les artefacts les plus importants sont d'abord décrits.

II-4-1- Bruit:

La segmentation d'un environnement bruyant est plus difficile dans une procédure de segmentation basée sur un ordinateur, car un système visuel humain peut effectivement réduire le bruit afin d'identifier un objet d'intérêt particulier. Le bruit aléatoire dans les images provoque une classification erronée et des bords fragmentés. Il peut être généré par l'acquisition de l'image à partir du capteur ou par la compression de l'image. Le bruit est généralement réduit pendant le prétraitement. Toutefois, une réduction du bruit peut également être incluse dans la segmentation, car elle peut supprimer certains petits détails des images.

II-4-1-1- Bruit Gaussien :

Une image à très haute résolution risque de contenir du bruit. Pour cette image, un simple fondu flou peut suffire, car même de petites caractéristiques telles que les cils ou la texture du tissu seront représentées par un grand groupe de pixels. Malheureusement, ce n'est pas le cas de la vidéo où la réduction du bruit en temps réel fait encore l'objet de nombreuses recherches.

La distribution normale (ou gaussienne) est une distribution de probabilité continue qui est souvent utilisée en première approximation pour décrire les variables aléatoires à valeurs réelles qui tendent à se regrouper autour d'une valeur moyenne unique. Le graphe de la Fonction de densité de probabilité de la distribution gaussienne est représenté dans la figure II.15 suivante :

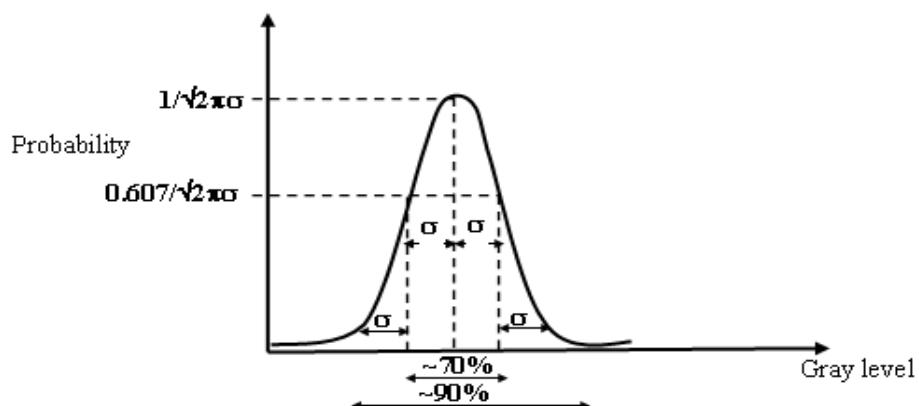


Figure II.15 : Fonction de densité de probabilité pour le modèle de bruit gaussien.

La fonction de densité de probabilité est :

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{\frac{(x-\mu)^2}{2\sigma^2}} \quad (\text{II.16})$$

Où, le paramètre μ est la moyenne, σ^2 est la variance (la mesure de la largeur de la distribution gaussienne). La distribution avec $\mu = 0$ et $\sigma^2 = 1$ s'appelle la normale standard. Le bruit gaussien est utile pour modéliser des processus naturels qui introduisent du bruit (par exemple, le bruit causé par la nature discrète du rayonnement et la conversion du signal optique en électrique, le bruit électrique lors de l'acquisition, etc.).

II-4-1-2- Bruit Sel et Poivre:

Ce type (Salt & Pepper) est une forme de bruit que l'on voit habituellement sur les images. Il se représente de manière unique en tant que pixels blancs et noirs apparaissant de manière aléatoire. Une approche efficace de réduction du bruit pour ce type implique l'utilisation d'un filtre médian ou d'un filtre moyenne harmonique de contraste. Les bruits de sel et de poivre affectent les images lorsque celles-ci sont transférées rapidement.

Dans le modèle de bruit Salt & Pepper illustré à la figure II.16, seules deux valeurs sont possibles, a et b , et la probabilité d'obtenir chacune d'elles est inférieure à 0,1 (sinon, le bruit dominerait énormément l'image). Pour une image de 8 bits / pixel, la valeur d'intensité typique pour le bruit de poivre est proche de 0 et pour le bruit de sel est proche de 255.

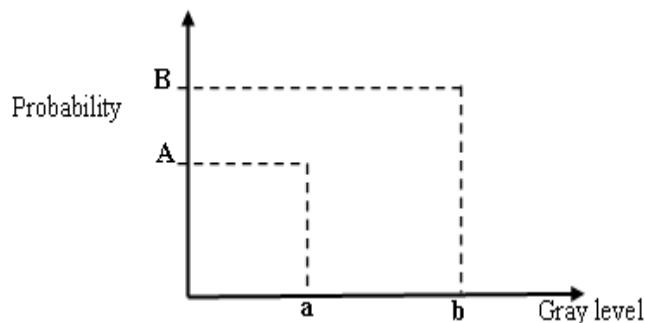


Figure II.16 : Fonction de densité de probabilité pour le modèle de bruit sel et poivre.

La fonction de densité de probabilité est :

$$PDF_{Salt\&pepper} = \frac{A \text{ for } g(a) = "Pepper"}{B \text{ for } g(b) = "Salt"} \quad (\text{II.17})$$

Le bruit Salt & Pepper est généralement causé par le mauvais fonctionnement des cellules du capteur ou par une défaillance de la cellule mémoire ou par des erreurs de synchronisation lors de la numérisation ou de la transmission des images.

II-4-1-3- Bruit Mixte:

La combinaison du bruit gaussien et impulsif est appelée bruit mixte.

II-4-1-4- Bruit Ricien:

Il est bien connu que les images de magnitude MR sont corrompues par le bruit Ricien, qui provient d'un bruit gaussien complexe dans les mesures du domaine de fréquence d'origine (espace k). Les images de résonance magnétique (IRM) contaminées par le bruit Ricien peuvent affecter la précision de l'analyse quantitative.

II-4-2- Inhomogénéité d'intensité (IIH):

Un autre artefact important qui influence grandement la segmentation basée sur l'intensité est l'inhomogénéité du champ ou de l'inclinaison (IIH) ou la non-uniformité de l'intensité (INU) [VOV 07] et [MAD 05], qui est généralement généré par le processus d'acquisition d'image. En IRM, l'inhomogénéité de l'intensité est due à l'inhomogénéité du champ magnétique ou à la mauvaise position du patient lors de la procédure de soulignement, tandis que dans les images ultrasonores, l'ombrage est dû aux ombres acoustiques. Les figures II.18 (a) et II.18 (b) montrent les images IRM simulées par Brainweb présentant une inhomogénéité de 20% et 9% de bruit d'une image pondérée en T1 et une autre image pondérée en T2, respectivement. La segmentation basée sur la classification est généralement préférable pour la correction d'inhomogénéité d'intensité, car des classes d'intensités élevées indiquent les limites entre les segments.




Figure II.18 : Brainweb image IRM simulé de 9% bruit et 20% IIH, (a) : pondérée en T1, (b) : pondérée en T2.

II-4-3- Effets de volume partiels:

Les images médicales souffrent grandement d'effets de volume partiels, ce dernier est un artefact selon lequel un voxel dans le volume cérébral MR contient plus d'un tissu et provient de la résolution insuffisante de l'image. Il augmente le taux de classification erronée et entraînent un flou d'intensité entre les tissus au-delà des limites. Nous pouvons voir l'effet de la fraction tissulaire sur la figure II.19 (b). De toute évidence, l'effet de volume partiel peut entraver la détection de la limite absolue des tissus en raison de l'absence de concordance entre les limites de pixel et de tissu. Par conséquent, certaines méthodes sont nécessaires pour estimer l'effet de volume partiel.




Figure II.19 : L'effet de volume partiel pour les lésions. (a) : image IRM avec MS lésions, (b) : vérité terrain des MS lésions.

II-4-4- Artéfact de mouvement:

L'artéfact de mouvement est un des artefacts les plus fréquemment rencontré. Il se constitue lorsqu'il y a translation dans l'espace du segment pendant l'acquisition. Ils ont pour conséquence la dispersion du signal : image floue de la structure en mouvement. Il y a deux types de mouvements rencontrés:

- Les mouvements périodiques: Ce sont les mouvements de la respiration, les battements cardiaques et les flux sanguins.
- Les mouvements apériodiques: Ce sont les mouvements du patient, les mouvements oculaires, la déglutition, le péristaltisme digestif et le flux du liquide cérébro-spinal.

II-4- Erreurs liés à la segmentation et les méthodes de correction:

Les erreurs générales identifiées lors de la segmentation avaient plus de 20% d'erreurs en raison de résultats insuffisants. Les résultats ont également montré qu'une grande quantité d'interaction et de contrôle de tous les résultats par l'utilisateur était nécessaire, car une large gamme d'images nécessitait plus qu'une approche automatisée. Toutefois, si les erreurs doivent être corrigées par la suite, un outil de correction est nécessaire pour obtenir l'effort utilisateur supplémentaire requis [SCH 12].

Ces dernières années, diverses approches de segmentation des images médicales ont été proposées et certaines améliorations significatives ont été obtenues. Cependant, en raison des lacunes des systèmes d'imagerie médicale, les images médicales peuvent contenir différents types d'artefacts. Ces artefacts peuvent affecter la qualité des données et perturber la pathologie. Certains artefacts peuvent être atténués par la technologie d'imagerie magnétique, tandis que d'autres nécessitent un post-traitement. Ces problèmes limitent la précision et la robustesse des résultats de la segmentation pour les techniques de segmentation d'images médicales. Certaines méthodes de correction d'homogénéité de densité, bruit, effets de volume partiels existantes sont listées dans les tableaux II.4, II.5 et II.6 suivants :

Tableau II.4 : Méthodes d'élimination du bruit.

Méthodes	Description
Filtre de lissage gaussien	L'image bruitée est convolutionnée par un noyau gaussien, puis met à jour la valeur d'un pixel en fonction d'un voisinage spatial pondéré [MAN 14]
Modèle de variation totale	Un modèle de variation totale est défini. Il comporte deux termes qui désignent la constante dans de petites zones et un ensemble connectés pour le lissage de voisinage. Le bruit est réduit en minimisant la fonction d'objection [OSH 04]
Filtre médian	Le filtre réduit le bruit en mettant à jour la valeur d'un pixel sur la base d'une notion du milieu des valeurs de niveau de gris dans un voisinage spatial [ARA 13]
Filtre adaptatif local dans le domaine de transformation	Le bruit est estimé dans une fenêtre en mouvement en informatisant et en modifiant le spectre dans une fenêtre locale [DAB 07]
Filtre moyen	Le filtre réduit le bruit en mettant à jour la valeur d'un pixel sur la base d'une notion de moyenne des valeurs de niveau de gris dans un voisinage spatial [LI 12]
Algorithme de moyens non locaux	La valeur des pixels est mise à jour en fonction de la moyenne pondérée des échantillons dont le voisinage est similaire au voisinage du pixel actuel [SHA 04]

Tableau II.5 : Méthodes de correction d'inhomogénéité d'intensité.

Méthodes	Description
Segmentation basée clustering	L'inhomogénéité de la densité est estimée en utilisant un algorithme modifié de c-moyennes floues [LI 14]
Basé sur l'histogramme	Elle fonctionne sur des histogrammes d'intensité d'image [SLE 98]
Filtration	Il utilise filtre passe-bas pour séparer artefact de basse fréquence supposant qu'il s'agit une inhomogénéité de densité) de l'image d'origine [JOH 96]
Séquence spéciale	Il est obtenu en utilisant une certaine séquence d'impulsions pour obtenir le champ d'inhomogénéité
Fantôme basé	Le champ d'inhomogénéité est estimé par un fantôme uniforme, puis par la mise à l'échelle et le lissage des images fantômes acquises

Tableau II.6 : Méthodes de correction d'effet de volume partiel.

Méthodes	Description
Modélisation statistique	Une modélisation alpha-mating a été utilisée pour distinguer le tissu de premier plan (tumeurs) et le tissu de fond (tissu normal) [ZEN 12]
Amélioration de la résolution	Elle modélise la réponse du détecteur dans la matrice système utilisée dans la reconstruction itérative pour améliorer la résolution spatiale [ALE 06]
Déconvolution	Elle a été utilisée pour estimer l'effet de débordement provoqué par la fonction de diffusion ponctuelle

Certaines méthodes de segmentation d'image peuvent encore être améliorées. En outre, l'analyse des images médicales est une tâche complexe car elles impliquent généralement une grande quantité de données. Par conséquent, il est nécessaire de proposer des méthodes de segmentation plus flexibles, précises, robustes et non supervisées que les techniques existantes.

II-3- Conclusion :

A travers ce chapitre introductif, nous avons proposé une description générale des principes fondamentaux des techniques de segmentation d'images qui représente le concept de base nécessaire pour développer une méthode de segmentation. Cette dernière est une étape cruciale dans tout processus d'analyse d'images. Elle consiste à préparer l'image afin de la rendre plus exploitable par un processus automatique. Nous avons présenté un ensemble succinct des méthodes de segmentation. Par ailleurs, dans les approches par seuillage et par classification, et par contours, nous avons montré que la segmentation peut être considérée comme un problème d'optimisation. L'accent a été mis sur les méthodes auxquelles nos algorithmes vont être comparés. Le chapitre suivant présente un état de l'art et une étude des algorithmes de clustering avec une application aux données médicales.

Chapitre III :

*Etat de l'art des méthodes de
segmentation d'image Médicale*

III-1-Introduction :

La thèse discute des différentes méthodes de segmentation du cerveau qui existent actuellement et le problème inhérent à chaque approche a été discuté au plus haut niveau. Les méthodes de segmentation du cerveau peuvent être classées comme des méthodes manuelles et des méthodes semi-automatisées ou automatisées assistées par ordinateur. Ce chapitre propose une revue de la littérature sur les techniques de segmentation C- moyenne flou avec une application aux images médicales, en particulier des images par résonance magnétique. Les concepts de base de la méthode de clustering c moyenne flou pour le diagnostic médical et la pertinence de la théorie du flou sont également abordés. Comme cette thèse se concentre sur les nouvelles techniques de segmentation avec une application aux données médicales, la taxonomie des ensembles de données médicales est également introduite.

III-2- Segmentation d'image IRM cérébrale:

En imagerie médicale, la segmentation devient extrêmement gênante en raison de la complexité des images et de l'absence de modèles d'anatomie qui capturent pleinement les déformations possibles dans chaque structure. Les images médicales sont souvent sujettes à des bruits importants. L'imagerie par résonance magnétique étant la procédure d'imagerie la plus largement utilisée, elle est une technologie dynamique et flexible. La segmentation des images médicales reste un défi pour le domaine du traitement du signal.

La segmentation précise et robuste du tissu cérébral étudié par IRM est une question très importante dans beaucoup d'applications et en particulier dans l'étude de certains désordres du cerveau. Une segmentation du tissu cérébral consiste à séparer les différents tissus tumoraux, tels que la tumeur, l'œdème et la nécrose, ainsi que les tissus normaux tels que la matière grise, la matière blanche et le liquide céphalorachidien. La segmentation est facilitée par l'utilisation de plusieurs types d'IRM. Les images pondérées en T1, T2 et en densité de protons sont notamment couramment employées en clinique. Ces trois types de séquences peuvent être complétées par d'autres types d'IRM, telles que les séquences utilisant un produit de contraste tel que le Gadolinium, FLAIR, et les de perfusion, de diffusion et spectroscopiques [LAM 13].

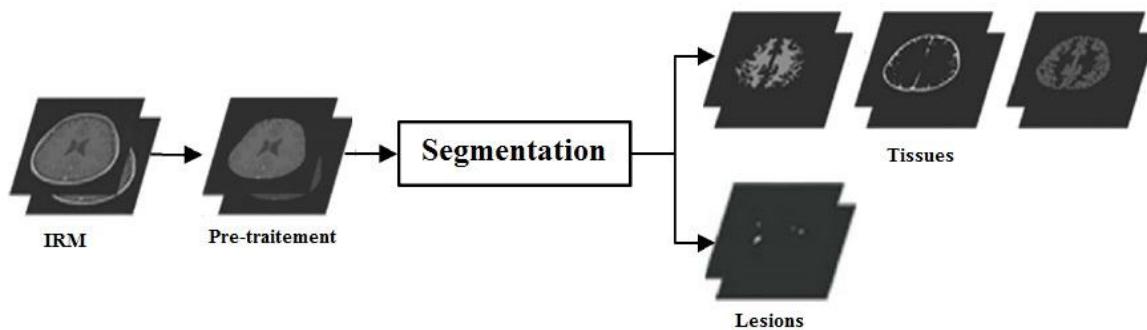


Figure III.1 : L'organigramme de la segmentation d'image IRM cérébrale.

La segmentation d'images a pour objectif d'identifier, dans les images, les pixels ou voxels appartenant à une région particulière. Cette région peut correspondre à une structure anatomique, pathologique ou fonctionnelle. La segmentation du cerveau étudié par IRM peut comprendre :

- La segmentation de structures.

- La classification des tissus.
- La segmentation du volume d'objet (par exemple tumeur).
- La classification ou segmentation des tissus, peut, par exemple concerner la segmentation des tumeurs comprennent des méningiomes et des gliomes.

Elle inclut aussi la segmentation du cerveau en liquide cérébrospinal (LCS), matière blanche (MB) et matière grise (MG) et la quantification de lésions. Les méthodes utilisées se basent sur les propriétés iconiques des structures à identifier, c'est à dire liées aux intensités des pixels ou sur les propriétés géométriques de ces structures. Ces propriétés correspondent à des connaissances à priori sur les structures à segmenter et peuvent être implicites. En raison des avantages de l'imagerie par résonance magnétique (IRM) par rapport à d'autres méthodes d'imagerie diagnostique, la majorité des recherches sur la segmentation d'images médicales portent sur son utilisation pour les images IRM et de nombreuses méthodes sont disponibles. Parmi celles-ci, les méthodes de segmentation floue présentent des avantages considérables, car elles permettent de conserver beaucoup plus l'information de l'image d'origine que les méthodes de segmentation dures. En particulier, l'algorithme C-Moyennes floues (FCM) attribue des pixels à des groupes flous sans étiquettes. Contrairement aux méthodes de clustering dures qui forcent les pixels à appartenir exclusivement à une classe. L'algorithme de clustering Fuzzy C-Means (FCM) est une méthode de segmentation souple qui a été largement utilisée récemment pour la segmentation d'applications d'images MR.

III-3- Revue de la littérature en segmentation d'image médicale:

Des nombreux chercheurs ont mis au point des différents modèles de FCM modifiés. Il existe une énorme quantité de travaux liés à l'amélioration de la FCM conventionnelle et d'autres formes de segmentation d'images sont trouvées dans la littérature. Cette section présente certaines approches C-moyennes floue qui ont été développées et appliquées aux images médicales pour réduire le bruit et d'autres distorsions d'imagerie. Parmi les méthodes non supervisées associées pour la segmentation des images médicales, on peut citer quelques travaux relatifs :

Verma et al. [VER 16] ont proposé un algorithme de classification FCM intuitionniste amélioré, qui intègre les informations spatiales locales et les informations de niveau de gris locales dans la Fuzzy C-Means intuitionniste. La technique de division de l'évolution par courbe discrète est utilisée pour trouver un cluster pour la segmentation d'images cérébrales de type T1, T2 et PD MR.

Adhikari et al. ont présenté une méthode de segmentation d'images cérébrales par IRM intégrant l'intensité de l'homogénéité (IIH) et des informations spatiales à l'aide de l'algorithme probabiliste FCM. Cette méthode fonctionne en deux étapes : tout d'abord, il estime l'inhomogénéité de l'intensité en fusionnant des surfaces gaussiennes et génère ensuite l'image corrigée par IIH. Dans la deuxième étape, il classe les pixels de l'image corrigée IIH par un algorithme FCM probabiliste [ADH 12].

Dubey et al. [DUB 16] ont proposé une FCM intuitionniste basée sur un ensemble approximatif. L'initialisation du centre de cluster est effectuée à l'aide d'une mesure intuitive basée sur un ensemble approximatif. La composition du centre de regroupement est réorganisée par une mesure de similarité intuitive. Méthode utilisée pour segmenter une image dans la WM, le GM et le LCR, ce qui est très utile pour le diagnostic des maladies du cerveau.

Chuang et al. ont également suggéré une autre contribution majeure de l'information spatiale à la fonction de membre de la FCM, connu sous le nom d'algorithme sFCM. La

fonction spatiale est la somme de la fonction d'appartenance dans le voisinage de chaque pixel considéré. Il représente la probabilité pour qu'un pixel appartienne à un groupe particulier. Cette fonction spatiale est incorporée à une fonction d'appartenance pondérée. Les avantages de cette méthode sont: il donne des régions plus homogènes que celles des autres méthodes et supprime les taches bruyantes et réduit partiellement les taches parasites [CHU 06].

Krinidis et al. [KRI 10] a proposé un nouvel algorithme de clustering C-moyennes flou (FLICM) robuste, sans paramètre, qui définissait un nouveau facteur fuzzy incorporant la fonction objectif de l'algorithme standard (FCM) afin de réaliser la segmentation d'image pour le bruit de limitation et améliore en même temps les performances du clustering. La principale caractéristique de FLICM est l'utilisation d'une mesure de similarité locale floue (à la fois spatiale et au niveau de gris), visant à garantir l'insensibilité au bruit et la préservation des détails de l'image.

Zhao et al. a également proposé plusieurs algorithmes de classification floue avec des informations spatiales, dans lesquels une sorte d'information spatiale appelée information spatiale non locale est introduite dans la classification floue. De plus ils ont utilisé les valeurs de degré d'appartenance floue de pixels pour définir une nouvelle mesure de similarité pour la classification spectrale, appelée mesure de similarité floue. Par la suite, les informations spatiales dérivées de l'image ont ensuite été introduites dans la mesure de similarité floue pour améliorer les performances de segmentation du regroupement spectral sur des images corrompues par du bruit.

L'approche FCM trouve ses applications dans une variété de problèmes allant de l'analyse des données à la segmentation des images. K. Xiao et al. [XIA 10] ont effectué un lissage gaussien sur l'image d'entrée et ils ont proposé une méthode permettant de déterminer le poids de chaque caractéristique à l'aide de la technique d'amorçage lorsqu'il s'agissait de traiter plusieurs caractéristiques pour faire face à l'intensité des homogénéités.

En 2016, Muhammad Sharif et al expliquent les défis que pose l'élimination du bruit dans les images IRM, qui aident à diagnostiquer une anomalie dans les tissus cérébraux. Le travail propose un filtre de bruit hybride basé sur une logique floue qui construit une fonction d'appartenance floue robuste utilisant la variance de bruit estimée ainsi que des statistiques locales et globales. La méthode vise à attribuer des poids appropriés en fonction de leur capacité à éliminer le bruit et à préserver les détails. Les auteurs ont procédé à une simulation détaillée et présenté les résultats de la restauration sur des paramètres de performance bien connus. Ils concluent que la méthode proposée permet une meilleure restauration par rapport aux méthodes existantes [MUH 16].

Kannan et al. [KAN 10] ont développé un KFCM robuste en incorporant une distance induite par le noyau ainsi qu'une méthode d'initialisation efficace pour remédier aux limites de l'algorithme FCM standard. Cependant l'utilisation de KFCM pour la segmentation d'images médicales, telle que l'inhomogénéité de l'intensité et la sensibilité au bruit présente des contraintes importantes qui rendent inadéquat cet algorithme. Par conséquent, l'ajout de certaines informations spatiales à la fonction d'objectif précédente constituerait une stratégie efficace pour les chercheurs afin de résoudre les problèmes de KFCM et d'améliorer la précision du processus de segmentation.

Guo et al. [GUO 16] ont proposé un algorithme FCM adaptatif basé sur la détection de bruit (NDFCM), dans lequel le paramètre de compromis est réglé automatiquement en mesurant la variance locale des niveaux de gris. Bien que l'algorithme de détection de bruit NDFCM utilise plus de paramètres, il est rapide car le filtrage des images est exécuté avant le début des itérations de cette méthode.

Gong et al. [GON 13] ont proposé une méthode de segmentation c-moyennes flous dans lesquelles les informations spatiales non locales sont introduites dans une fonction objectif en utilisant un paramètre variant, qui est adaptatif en fonction du niveau de bruit pour chaque pixel d'images afin d'améliorer la robustesse de FLICM face au bruit et aux valeurs aberrantes. Semblable à FLICM, KWFLICM est également libre de toute sélection de paramètre. Cependant, KWFLICM a une complexité de calcul supérieure à celle de FLICM. En fait, la sélection des paramètres dépend des patchs d'image et des statistiques locales.

Haung et al. [HAU 11] ont proposé une méthode efficace d'estimation de la vallée basée sur un histogramme pour déterminer le nombre de groupes d'une image. Ainsi, GSKFCM présente les caractéristiques intéressantes suivantes: il est relativement indépendant des types de bruit et constitue par conséquent un meilleur choix pour la mise en cluster en l'absence d'une connaissance préalable du bruit. Les contraintes locales floues intègrent de manière floue simultanément la fonction noyau, la relation spatiale et le niveau de gris local. Ce système peut fournir une robustesse significative aux images bruitées et améliorer partiellement les performances de la segmentation.

L'algorithme FGFCM proposé par [CAI 07], qui introduit une mesure de similarité locale combinant des informations de niveau spatial et de niveau de gris pour former une image somme non pondérée linéairement. Le regroupement est effectué sur la base de l'histogramme de niveau de gris de l'image sommée. Ainsi, son temps de calcul est également très petit. Cependant, ces algorithmes ont besoin de certains paramètres a (ou λ) pour contrôler le compromis entre robustesse au bruit et efficacité de la préservation des détails.

Wang et al. [WAN 13] ont présenté un nouvel algorithme adaptatif de clustering spatial flou, appelé algorithme adaptatif de clustering flou (ASIFC), qui permet de résoudre le problème de bruit et le manque d'informations spatiales pour les algorithmes FCM classiques avec des améliorations de la robustesse à deux niveaux. Ceci est réalisé grâce à l'incorporation du cadre théorique de l'information dans les algorithmes de type FCM. Ils ont élargi l'idée pour améliorer spécifiquement la robustesse des algorithmes FCM. Le problème du manque d'informations spatiales est pris en compte à l'aide d'une nouvelle mesure de similarité adaptative, tandis que le bruit et les valeurs aberrantes doivent être identifiés via la maximisation de l'information mutuelle.

Kamarujjaman et al. ont proposé une fonction d'appartenance spatiale locale inhérente à la méthode non supervisée UMSFCM (c-moyennes flou spatiale modifiée). La méthode proposée segmente l'IRM cérébrale en présence d'une inhomogénéité d'intensité et de bruit. Les informations locales et la corrélation entre les éléments du masque créé dynamiquement ont été utilisées par la fonction d'appartenance spatiale locale. La fonction d'appartenance pondérée a été utilisée pour optimiser la fonction objective. Les informations globales et locales sont combinées pour générer les centres de cluster optimaux avec un nombre minimal d'itérations de l'algorithme [KAM 16].

Elazab et al. ont proposé un cadre de clustering C-moyennes flous régularisé de manière adaptative pour la segmentation d'images de résonance magnétique cérébrale. La structure peut être sous la forme de trois algorithmes pour le niveau de gris moyen local remplacé par le niveau de gris du filtre moyen, du filtre médian et des images pondérées conçues, respectivement. Elle utilise aussi l'hétérogénéité des niveaux de gris dans le voisinage (informations contextuelles locales) et remplace la distance euclidienne standard par des fonctions de Kernel à base radiale gaussienne [ELA 15].

Song et al. ont présenté un algorithme modifié de c-moyennes floues robustes (MRFCM) pour la segmentation d'images cérébrales par résonance magnétique IRM. Selon les informations de niveau de gris des pixels du voisinage local, les valeurs de déviation de

chaque pixel adjacent sont calculées dans l'espace noyau en fonction de leur valeur médiane, et la mesure pondérée adaptative normalisée de chaque pixel est obtenue. Le bruit impulsif et le bruit gaussien dans l'image peuvent être efficacement supprimés et les informations de détail et de contour de l'image IRM du cerveau peuvent être mieux préservées. En même temps, l'histogramme gris est utilisé pour remplacer un pixel lors du processus de regroupement [SON 19].

Despotovic et al. ont développé une nouvelle méthode basée sur FCM clustering pour la segmentation d'images médicales spatialement cohérente et résistante au bruit. La contribution est double: d'abord les informations spatiales et les caractéristiques d'image locales sont intégrées à la fois dans la mesure de similarité et dans la fonction d'appartenance pour compenser l'effet du bruit et en suite un voisinage anisotrope basé sur des caractéristiques de congruence de phase est introduit pour permettre une segmentation plus précise sans lissage d'image [DES 13].

III-4- Techniques de base de clustering:

Dans la littérature, les différentes techniques de clustering sont disponibles. Les techniques classiques du clustering (théorie de base) seront discutées dans cette section:

III-4-1- Signification du Clustering vs Classification:

Le concept de clustering existe depuis longtemps. Clustering aussi connu sous nom (Segmentation), il est une technique où un grand jeu de données est partitionné en groupes plus petits appelés clusters, Il s'agit d'un processus dans lequel certaines zones d'ensembles de données sont remplacées par des clusters en utilisant des mesures de similarité telles que la similarité entre deux objets quelconques du même groupe est supérieure à celle entre deux objets appartenant à deux groupes différents. En simple, la segmentation entière dans le traitement de l'image peut être considérée comme une mise en cluster. Le clustering est utilisé pour obtenir une vue d'un ensemble de données. Un ensemble de clusters suffit souvent pour obtenir un aperçu de la distribution des données au sein d'un ensemble de données. Les méthodes de clustering ont tendance à être divisées en deux types: méthodes hiérarchiques et non hiérarchiques qui sont discutées dans le premier chapitre.

La classification est le processus d'apprentissage d'une fonction qui mappe des objets de données à un sous-ensemble d'un ensemble de classes particulier. En conséquence, un classifieur est formé avec un ensemble étiqueté d'objets d'apprentissage et identifiant chaque classe. Un meilleur classifieur est supposé gérer les deux fonctions. Pour la plupart des applications pratiques, trouver un mappage précis est plus important que de développer des modèles de classe compréhensibles. Par conséquent, plusieurs approches sont utilisées pour catégoriser les objets qui n'offrent pas de modèle de classe compréhensible.

La classification et le clustering sont fortement associés pour la segmentation d'image. La classification tente d'apprendre le caractère distinctif d'un ensemble de classes donné, tandis que la mise en cluster découvre un ensemble de classes à l'intérieur d'un ensemble de données. Une caractéristique importante du clustering est qu'il n'est pas essentiel de déterminer un ensemble d'objets spécimens. Aussi les algorithmes de clustering sont très populaires dans la segmentation d'images car ils sont intuitifs et faciles à implémenter et elles sont appliquées avec succès dans divers domaines et applications. Cependant, ces algorithmes de classification ne sont applicables que pour des images spécifiques telles que des images médicales, des images microscopiques, etc.

III-4-2- Clustering flou vs dur:

Les techniques de clustering flous reposent sur la théorie des ensembles flous (FST), dans la mesure où, du fait de l'existence du concept de degré d'appartenance, un objet d'un ensemble de données peut appartenir à plusieurs clusters.

Les techniques de clustering dures sont basées sur la théorie des ensembles croustillants (CST) dans laquelle il n'existe aucune possibilité d'appartenance partielle des objets à plusieurs clusters. En d'autres termes, les clusters révélés par une technique de clustering dure sont disjoints, c'est-à-dire un objet d'un ensemble de données, après l'application d'une technique de clustering dur, soit appartient totalement à un cluster particulier, soit n'appartient pas du tout à ce cluster.

III-4-3- Notion des sous-ensembles flous:

Ils manipulent et représentent également les informations de données ou l'image qui possèdent des incertitudes non statistiques. Les incertitudes et les imprécisions sont représentées mathématiquement de manière à fournir un outil formalisé pour traiter les imprécisions intrinsèques à de nombreux problèmes dans les applications en temps réel. La logique floue fournit une inférence de morphologie qui permet aux capacités de raisonnement approximatives d'un être humain de pouvoir être utilisées comme système basé sur la connaissance. Ces concepts de la logique floue fournissent une approche mathématique forte pour les incertitudes associées à la plupart des processus humains. Les caractéristiques principales de la logique floue sont présentées ci-dessous:

- Le raisonnement exact peut être considéré comme un cas limité pour un raisonnement approximatif.
- Il considère chaque possibilité comme une question de degré.
- Dans cette méthode, les informations sont interprétées avec une nature élastique sous forme équivalente et le flou contient la collection d'un large éventail de variables.
- L'inférence est considérée comme un processus de propagation ou de diverses contraintes élastiques.
- Tous les types de systèmes logiques peuvent être flous à l'aide de méthodes simples de logique floue.

Cependant, deux caractéristiques importantes de la logique floue offrent de meilleures performances pour des applications spécifiques, comme expliqué ci-dessous. Dans le premier cas, ces systèmes conviennent mieux à un raisonnement incertain et approximatif. Ce cas est plus flexible pour résoudre les modèles avec des bases mathématiques très complexes. Dans le second cas, la prise de décision de ce système avec des valeurs estimées pour la plupart des informations incomplètes et incertaines est facilement possible.

En théorie des ensembles classique, un sous-ensemble U d'un ensemble S peut être considéré comme une application des éléments de S vers les éléments de l'ensemble 0, 1, constitué des deux éléments 0 et 1, Ce mappage peut être représenté sous la forme d'un ensemble de paires ordonnées, avec exactement une paire ordonnée présente pour chaque élément de S . Le premier élément de la paire ordonnée est un élément de l'ensemble S , et le deuxième élément est un élément de l'ensemble 0, 1. La valeur zéro est utilisée pour représenter la non-appartenance et la valeur un pour représenter l'appartenance.

III-4-4- C-moyennes floues conventionnelle FCM:

FCM est un regroupement multi-estimé où la participation d'un ensemble flou diffère d'un autre ensemble flou. L'algorithme FCM (fuzzy c-means) est l'un des algorithmes de segmentation d'images les plus traditionnels et classiques. FCM peut être minimisé par la fonction objective donnée par l'équation III.1. Considérons un ensemble de motifs non étiquetés X , soit $X = \{x_1, x_2, \dots, x_N\}$, $x \in R_f$, où N est le nombre de motifs et f la dimension des vecteurs de motif (caractéristiques). L'algorithme FCM se concentre sur la minimisation de la valeur d'une fonction objective. Cette dernière mesure la qualité du partitionnement qui divise un jeu de données en c groupes. L'algorithme est une méthode de classification itérative qui produit une partition c optimale en minimisant la somme pondérée au sein du groupe de la fonction objective d'erreur au carré. Fuzzy c-means (FCM) est une méthode de regroupement qui permet à un élément de données d'appartenir à deux ou plusieurs clusters. Elle est basée sur la minimisation de la fonction objective suivante :

$$J_m(U, V) = \sum_{i=1}^N \sum_{j=1}^c U_{ij}^m d^2(x_i, v_j), \quad 1 \leq m < \infty \quad (\text{III.1})$$

Où m est un nombre réel supérieur à 1, U_{ij} est le degré d'appartenance de x_i au groupe j , x_i est le nombre de données mesurées en dimension d , v_j est le centre de dimension d du groupe et $\|\cdot\|$ est une norme exprimant la similitude entre les données mesurées et le centre. Le partitionnement flou est réalisé par une optimisation itérative de la fonction objective indiquée ci-dessus, avec la mise à jour des centres de cluster v_j par :

$$v_j = \frac{\sum_{i=1}^N U_{ij}^m x_i}{\sum_{i=1}^N U_{ij}^m} \quad (\text{III.2})$$

La fonction d'appartenance est définie comme suit:

$$U_{ij} = \frac{1}{\sum_{k=1}^c \left[\frac{\|x_i - c_k\|}{\|x_i - c_j\|} \right]^{\frac{2}{m-1}}} \quad (\text{III.3})$$

Cette itération s'arrêtera quand :

$$\max_{ij} = \{ |U_{ij}^{(k+1)} - U_{ij}^{(k)}| \} < \varepsilon \quad (\text{III.4})$$

Où ε est un critère de terminaison compris entre 0 et 1, alors que k sont les étapes d'itérations. Cette procédure converge vers un minimum local ou comme un point idéal de J_m . L'algorithme de la méthode FCM est résumé ci-dessous :

1. Fixer ($m > 1$ et $2 < c < N-1$) et donner: l'erreur ε , centres de cluster v_j
Répéter
 2. Calculer la matrice de partition U_{ij} avec v_j par eq. (III.3)
 3. Calculer la fonction objective J_m par eq. (III.1)
 4. Mise à jour les centres de clusters v_j avec U_{ij} par eq. (III.2)
- Jusqu'à stabilisation des centres de cluster par eq. (III.4)

Ce type d'algorithme est fort utilisé en traitement d'images médicales. On peut résumer la différence entre fuzzy C-means et k-means dans la fonction d'appartenance d'un nuage de points dans deux clusters dans l'exemple présenté dans la figure III.2. Les avantages et inconvénients de la méthode FCM standard (classique) sont présentés dans la table III.1.

Tableau III.1 : Les Avantages/Inconvénients de l'algorithme Fuzzy C-means.

Avantages	Inconvénients
- FCM donne des meilleurs résultats pour les ensembles de données qui se chevauchent	- FCM exige une spécification a priori du nombre de cluster
- Elle est comparativement meilleure que l'algorithme k-means	- Les mesures de distance euclidienne peuvent pondérer de manière inégale les facteurs sous-jacents
- L'appartenance à chaque point de données est attribuée à chaque centre de groupe	- Nous obtenons le meilleur résultat avec une valeur inférieure de β mais au détriment d'un plus grand nombre d'itérations

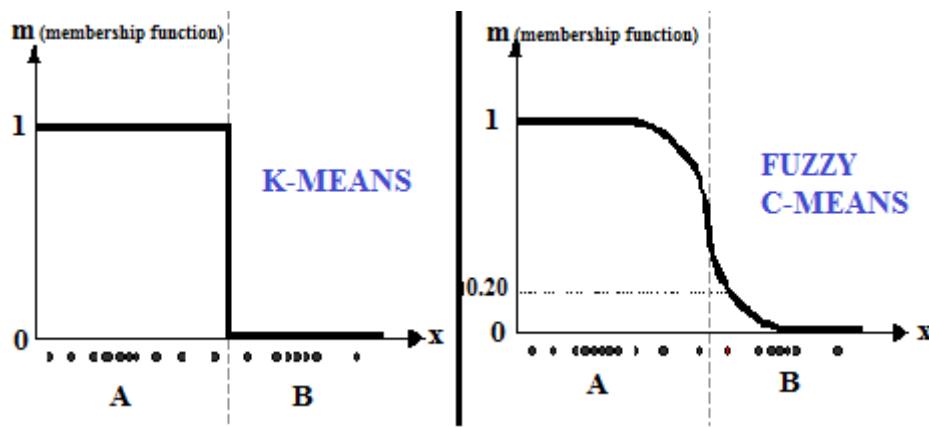


Figure III.2 : Comparaison des deux fonctions d'appartenance.

III-4-5- C-moyennes floues spatiales SFCM:

Les informations spatiales des images ne sont pas pleinement utilisées dans un algorithme FCM conventionnel. C'est pour cette raison l'algorithme FCM spatial est introduit pour permettre au cluster d'incorporer les informations spatiales dans la fonction d'appartenance. Cette fonction est la résultante de la somme de toutes les fonctions d'appartenance au voisinage dans chaque pixel considéré [44] [79] [82]. Les principaux avantages de cette méthode sont les suivants:

- Réduit les zones bruitées des images.
- Moins sensible au bruit que d'autres techniques.
- Il identifie les régions de manière plus homogène que d'autres méthodes.

Cette méthode est plus appropriée pour la segmentation d'image bruyante et fonctionne efficacement dans les données simples et multiples qui contiennent des informations spatiales. Dans cette méthode, les pixels voisins sont hautement corrélés et c'est une autre caractéristique clé de cette méthode SFCM. Par conséquent, la valeur du pixel voisin ressemble à la même valeur et la probabilité d'entrer dans les mêmes groupes est élevée. Dans le clustering, la relation spatiale est plus importante mais dans l'algorithme SFCM, elle n'est pas utilisée et elle est définie comme suit :

$$h_{ij} = \sum_{k \in NB(x_j)} u_{ik} \quad (\text{III.5})$$

Où le paramètre NB (x_j) représente une fenêtre carrée centrée autour le pixel x_j .

III-5- Etudes descriptives des nouvelles méthodes de segmentation:

La segmentation précise et fiable du tissu cérébral fournie par l'IRM est un problème très critique dans plusieurs applications telles que la chirurgie et la radiothérapie. Elle est une étape essentielle de l'analyse quantitative d'images cérébrales et a donc fait l'objet de nombreuses recherches. Dans cette phase, nous présentons une étude des nouvelles méthodes de segmentation d'IRM cérébrales basé sur l'algorithme c-moyennes floues spatiales et en présence d'une inhomogénéité d'intensité, d'un bruit important et des valeurs aberrantes. Les chercheurs ont modifiée et améliorées la méthode FCM standard en utilisent le concept d'estimation de champ de biais, d'informations spatiale, de nouveau terme de voisinage et des termes supplémentaire afin de traiter les artifacts d'imagerie médicale. Parmi les nouvelles méthodes présentées dans la littérature, on a étudiés et discutés les algorithmes suivant:

III-5-1- C-moyennes floues spatial conditionnel CsFCM:

Adhikari et al. [ADH 15] ont développé un algorithme de clustering de type C-means flou conditionnel et spatial intitulé : **Conditional spatial fuzzy C-means clustering algorithm (CsFCM 2015)**. Cette méthode capable de segmenter efficacement les images cérébrales de type IRM avec la présence d'une inhomogénéité de bruit et d'intensité. En conséquence, les auteurs ont incorporé une interaction locale spatiale entre les pixels adjacents dans la fonction d'appartenance floue, de sorte que, si les pixels voisins partagent des caractéristiques similaires, les pixels centraux devraient avoir une probabilité plus grande de se regrouper dans le même groupe que les pixels voisins. Ils ont également introduit le conditionnement dans le mécanisme de regroupement. L'algorithme prend en compte la variable de conditionnement associée à chaque pixel qui décrit le niveau d'implication dans la construction de la fonction d'appartenance et des différents clusters. Ceci est réalisé en introduisant une fonction d'adhésion pondérée.

Dans la présente étude, le processus de segmentation est modélisé comme un problème de classification des intensités de pixels dans différentes régions homogènes. Contrairement à l'algorithme sFCM, ils ont également introduit l'aspect de conditionnement du mécanisme de clustering. L'algorithme prend en compte les variables de conditionnement prenant les valeurs f_1, f_2, \dots, f_N pour tous les pixels x_1, x_2, \dots, x_N , respectivement. Le f_k ($k = 1, 2, \dots, N$) décrit un niveau d'implication du pixel x_k dans les valeurs d'appartenance finales et les clusters construits. De plus, contrairement à l'algorithme sFCM, un autre paramètre spatial conditionnel u_{ik} est introduit, incorporant la variable conditionnelle à la fonction d'appartenance, qui définit l'appartenance comme suit :

$$u_{ik} = \frac{f_{ik}}{\|x_k - v_i\|^{m-1} / \sum_{c=1}^C \|x_k - v_c\|^{m-1}} \quad (\text{III.6})$$

Où f_{ik} est la variable de conditionnement qui définit le niveau d'implication du pixel x_k dans le deuxième groupe en considérant son voisinage dans un domaine spatial et est définie comme suit:

$$f_{ik} = \frac{\sum_{j \in N(x_k)} \mu_{ij}}{M} \quad (\text{III.7})$$

Où $N(x_k)$ est le voisinage carré ayant le pixel x_k comme centre et M le nombre total de pixels du voisinage. Un quartier plus grand atténuerait les contours; conduisant à un taux plus élevé d'erreur de classification des pixels. Par conséquent, sa taille est déterminée

empiriquement, ce qui donne de meilleurs résultats. Dans la présente étude, on utilise $N (x_k) = 3 \times 3$. On peut noter que f_{ik} est dans la plage $0 \leq f_{ik} \leq 1$. Les valeurs d'appartenance globale et locale, respectivement u_{ik} et μ_{ik} , sont supposées être indépendantes l'une de l'autre et, en combinant ces deux paramètres d'appartenance, nous avons introduit une autre variable d'appartenance pondérée Z_{ik} et le cluster center w_i , qui incorporent les informations spatiales locale et globale et sont définies comme suit:

$$Z_{ik} = \frac{(\mu_{ik})^p (u_{ik})^q}{\sum_{c=1}^C (\mu_{ck})^p (u_{ck})^q} \quad (\text{III.8})$$

Où p et q sont les paramètres permettant de contrôler l'importance relative des deux fonctions d'appartenance. En particulier, ces paramètres contrôlent le compromis entre les valeurs de membres locales et globales pour la construction des valeurs de membres finales et des centres de clusters [ADH 15].

$$w_i = \frac{\sum_{k=1}^N Z_{ik}^m x_k}{\sum_{k=1}^N Z_{ik}^m} \quad (\text{III.9})$$

L'algorithme de la méthode CsFCM est résumé ci-dessous :

Entrée: valeurs définies pour le nombre de clusters C , le degré de flou $m = 2$, $p = 2$, $q = 2$ et l'erreur ε .

1. Initialiser au hasard les centres des clusters $v_i^{(0)}$
2. Initialiser au hasard les centres des groupes de joints $w_i^{(0)}$
3. $j = 1$
4. Répéter
 - a. $j = j + 1$
 - b. Calculer la valeur d'appartenance $U^{(j)}$ en utilisant les centres de cluster $v_i^{(j-1)}$
 - c. Calculer la valeur d'appartenance spatiale conditionnelle $u_{ik}^{(j)}$ en utilisant les centres $v_i^{(j-1)}$
 - d. Calculer la valeur d'appartenance pondérée $Z_{ik}^{(j)}$
 - e. Mettre à jour la valeur de cluster commun $w_i^{(j)}$
 - f. Mettre à jour les centres $v_i^{(j)}$
5. Jusqu'à $\|w_i^{(j)} - w_i^{(j-1)}\| < \varepsilon$
6. Renvoie le centre de cluster w_i et la valeur de Z_{ik}

Les résultats expérimentaux montrent que l'algorithme CsFCM présente des performances supérieures en termes d'études qualitatives et quantitatives telles que les fonctions de validité des clusters, la précision de la segmentation, la précision de la segmentation tissulaire. La figure III.3 présente les résultats qualitatifs de la segmentation d'une image utilisant l'algorithme FCM et CsFCM: (a) image originale pondérée en T1 avec 9% de bruit et 40% d'inhomogénéité, (b) image segmenté avec FCM, (c) image segmenté avec CsFCM, (d)-(f) CSF, GM, WM extraites après l'utilisation du FCM, (g)-(i) CSF, GM, WM extraites après l'utilisation du CsFCM.




Figure III.3 : Résultats de segmentation d'image utilisant FCM et CsFCM.

III-5-2- C-moyenne floue spatial conditionnel basé sur distance kernel CsKFCM:

B. Gharnali et S. Alipour ont présenté une nouvelle approche de segmentation d'image IRM intitulé : **Conditional Spatial FCM Based on Kernel-Induced Distance Measure (CsKFCM 2018)** pour résoudre les problèmes de l'algorithme standard FCM. L'approche comprend deux étapes successives. La première étape est réalisée par l'incorporation d'une interaction spatiale locale entre les pixels adjacents dans la fonction d'appartenance floue imposée par un variable auxiliaire associée à chaque pixel. ce variable décrit le niveau d'implication de chaque pixel pour la construction de la fonction d'appartenance et les différents clusters. Ils ont ensuite adapté une distance induite par kernel pour remplacer la distance euclidienne d'origine qui s'avère plus robuste que le FCM traditionnel. Le problème de sensibilité au bruit et d'inhomogénéité d'intensité dans les données IRM est efficacement réduit en incorporant une métrique de distance induite par la distance kernel et des informations spatiales locales dans une fonction d'appartenance pondérée [GHA 18].

La philosophie de la «méthode de kernel» est que chaque algorithme (linéaire) qui utilise uniquement des produits scalaires peut être étendu à la version (non linéaire) correspondante de cet algorithme qui est implicitement exécutée dans un espace de fonctions supérieur via des kernels [GHA 18]. Un kernel dans l'espace des fonctions peut être représenté par la fonction K ci-dessous:

$$K(x, y) = \langle \varphi(x), \varphi(y) \rangle \quad (\text{III.10})$$

Où φ représente une carte non linéaire implicite, et $\langle \varphi(x), \varphi(y) \rangle$ désigne l'opération de produit interne. $K(x, y) = \varphi(x)^T \varphi(y)$ est une fonction kernel gaussienne de produit interne et $K(x, y) = \exp[-(\|x - y\|^2) / 2\sigma^2]$. L'algorithme de segmentation CsKFCM proposé par [GHA 18] est résumé comme suit :

Fixer le nombre de clusters C, le degré de flou m = 2, p = 2, q = 2 et l'erreur ϵ .

1. Initialiser au hasard les centres des clusters $v_i^{(0)}$
2. Initialiser au hasard les centres des groupes de joints $w_i^{(0)}$
3. $j = 1$
4. Répéter
 - a. $j = j + 1$
 - b. Calculer la valeur d'appartenance $U^{(j)}$ en utilisant les centres de cluster $v_i^{(j-1)}$ comme suit :

$$\mu_{ik} = \frac{1}{(1 - k(x_k, v_i))^{m-1} / \sum_{c=1}^C (1 - k(x_k, v_c))^{m-1}} \quad (\text{III.11})$$

- c. Calculer la valeur d'appartenance spatiale conditionnelle $u_{ik}^{(j)}$ en utilisant les centres $v_i^{(j-1)}$ comme suit :

$$U_{ik} = \frac{f_{ik}}{(1 - k(x_k, v_i))^{m-1} / \sum_{c=1}^C (1 - k(x_k, v_i))^{m-1}} \quad (\text{III.12})$$

- d. Calculer la valeur d'appartenance pondérée $Z_{ik}^{(j)}$

- e. Mettre à jour la valeur de cluster commun $w_i^{(j)}$

- f. Mettre à jour les centres $v_i^{(j)}$ comme suit :

$$v_i = \frac{\sum_{k=1}^N \mu_{ik}^m k(x_k, v_i) x_k}{\sum_{k=1}^N \mu_{ik}^m k(x_k, v_i)} \quad (\text{III.13})$$

5. Jusqu'à $\|w_i^{(j)} - w_i^{(j-1)}\| < \epsilon$
6. Renvoie le centre de cluster w_i et la valeur de Z_{ik}

L'algorithme développé a été comparé et appliqué sur (a) une image synthétique voir la figure III.3, (b) il contient un modèle à deux classes corrompu par le bruit gaussien avec mean = 0, variance = 0,02. Les figures 3 (c) à (f) montrent les résultats de la segmentation de FCM, SFM, CsFCM et CsKFCM respectivement. (c) sans contraintes spatiales et FCM ne peut pas séparer les deux classes. SFM et le CsFCM utilisent la corrélation entre les pixels voisins, ils ne parviennent pas à générer des clusters précises.

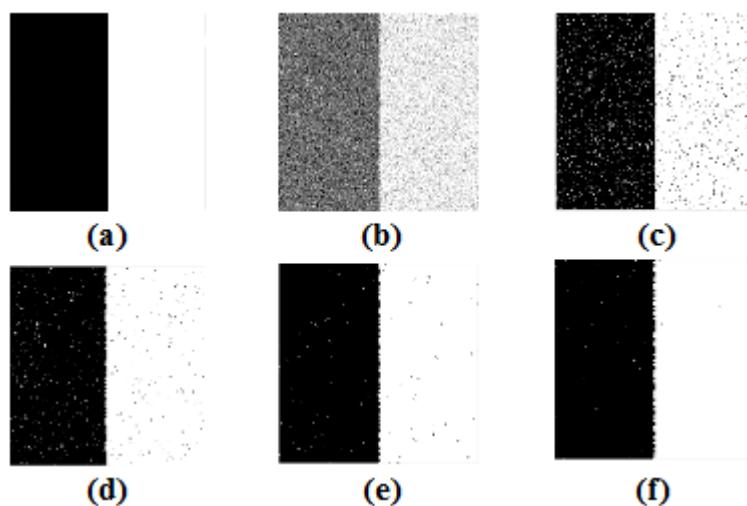


Figure III.4 : Résultats de segmentation d'image synthétique utilisant CsKFCM.

III-5-3- C-moyennes floues basé sur distance Gaussien Kernel GKFCM:

K. Rehna et al. ont créé une nouvelle méthode de segmentation d'image médicale intitulé : **Gaussian Kernel Based Fuzzy C-Means Clustering Algorithm (GKFCM 2016)**. Le système développé présente une variante de l'algorithme de type c-moyennes floues qui fournissent un regroupement d'images. L'algorithme de regroupement de c-moyennes floues du kernel est dérivé de l'algorithme de regroupement de c-moyennes floues. L'algorithme KFCM fournit un regroupement d'images et améliore la précision de manière significative par rapport à l'algorithme classique de c-moyennes floues. La nouvelle méthode est appelé algorithme de clustering FCM basé sur le kernel gaussien. La principale caractéristique de GKFCM est l'utilisation d'une approche de clustering flou visant à garantir l'insensibilité au bruit et la préservation des détails de l'image. L'objectif du travail est de regrouper la faible intensité dans la zone d'homogénéité à partir d'images bruitées, en utilisant la méthode de regroupement, en segmentant cette partie séparément à l'aide de l'approche d'ensemble de niveaux de contenu. La conception de ce système vise à produire de meilleurs résultats de segmentation pour les images corrompues par le bruit, de sorte qu'il puisse être utile dans divers domaines tels que l'analyse d'images médicales, telles que la détection des tumeurs, l'étude de la structure anatomique et la planification du traitement [REH 16].

Nous décrivons maintenant l'algorithme de c-moyennes floues basé sur kernel gaussien (GKFCM) proposé par K. Rehna et al. [REH 16]. On a une carte non linéaire comme : $\varphi: x \rightarrow \varphi(x) \in F$ où $x \in X$, X désigne l'espace de données et F l'espace de transformation avec une dimension supérieure, même infinie. GKFCM minimise la fonction objective suivante :

$$J_m(U, V) = \sum_{i=1}^C \sum_{k=1}^N U_{ik}^m \|\varphi(x_k) - \varphi(v_i)\|^2 \quad (\text{III.14})$$

Avec :

$$\|\varphi(x_k) - \varphi(v_i)\|^2 = K(x_k, x_k) + K(v_i, v_i) - 2K(x_k, v_i) \quad (\text{III.15})$$

Ou $K(x, y) = \varphi(x)^T \varphi(y)$ est une fonction de kernel du produit interne. Si nous adoptons la fonction gaussienne en tant que fonction de kernel, c'est-à-dire:

$K(x, y) = \exp [-\|x - y\|^2 / \sigma^2]$ puis $K(x, x) = 1$, selon l'équation (III.14), l'équation (III.15) peut être écrit comme suit :

$$J_{GKFCM}(U, V) = 2 \sum_{i=1}^C \sum_{k=1}^N U_{ik}^m (1 - K(x_k, v_i)) \quad (\text{III.16})$$

Minimisons l'équation (III.16) sous la contrainte de u_{ik} , nous avons :

$$u_{ik} = \frac{(1/(1-K(x_k, v_i)))^{\frac{1}{m-1}}}{\sum_{j=1}^C (1/(1-K(x_k, v_j)))^{\frac{1}{m-1}}} \quad (\text{III.17})$$


Et les centres de cluster :

$$v_i = \frac{\sum_{k=1}^N u_{ik}^m k(x_k, v_i) x_k}{\sum_{k=1}^N u_{ik}^m k(x_k, v_i)} \quad (\text{III.18})$$

Ici, nous utilisons simplement la fonction de kernel gaussien pour plus de simplicité. Si nous utilisons d'autres fonctions de kernel, il y aura des modifications correspondantes dans les équations. (III.17) et (III.18). En fait, l'équation (III.15) peut être considérée comme une nouvelle métrique induite par le noyau dans l'espace de données, définie comme suit:

$$d(x, y) = \|\varphi(x_k) - \varphi(v_i)\| = \sqrt{2(1 - K(x, y))} \quad (\text{III.19})$$

Afin de démontrer les performances de la méthode proposée par [REH 16], l'algorithme GKFCM a été appliqué sur des images médicales, y compris une image CT de l'image IRM du cerveau. La figure III.5 montre les résultats de la segmentation.



III-5-4- C-moyennes floues Kernel Généralisé KGFCM:

F. Zhao et al. ont proposé une nouvelle version modifiée de l'algorithme de clustering C-moyennes flou (FCM) intitulé : **Kernel generalized fuzzy c-means clustering with spatial information (KGFCM 2013)**. L'approche KGFCM utilise une image filtrée en moyenne et une image filtrée en médiane pour définir le terme de contrainte spatiale, qui est désigné respectivement par KGFCM_S1 et KGFCM_S2. Elles introduisent le terme de contrainte spatiale, ces deux méthodes peuvent utiliser les informations de voisinage d'un pixel pour guider la mise en cluster des pixels de sorte qu'elles se comportent mieux que GFCM dans la segmentation d'image grise bruyante. De plus, KGFCM_S1 (KGFCM_S2) peut obtenir des performances de segmentation équivalentes à KFCM_S1 (KFCM_S2) tout en consommant moins de temps d'exécution. Kernel gaussien est adopté comme fonction du noyau. Il est connu que le paramètre σ de la fonction de kernel gaussien peut affecter les résultats finaux des méthodes du noyau dans une certaine mesure. Dans KGFCM_S1 et KGFCM_S2, la variance échantillon est adoptée pour estimer σ^2 , qui a été utilisée et qui a été vérifiée pour pouvoir déterminer le paramètre σ^2 de la fonction de kernel gaussien [ZHA 13].

Pour rendre FCM robuste au bruit, GFCM a été intégrée avec un terme de contrainte spatiale ou la fonction objective de la mise en cluster de c-moyennes floue généralisée de kernel avec des informations spatiales (KGFCM) est donnée comme suit :

$$J_{KGFCM} = 2 \sum_{i=1}^c \sum_{j=1}^N U_{ij}^m (1 - K(x_j, v_i)) + \sum_{j=1}^N a_j \sum_{i=1}^c u_{ij} (1 - u_{ij}^{m-1}) + B \quad (\text{III.20})$$

Avec :

$$B = 2\beta \sum_{i=1}^c \sum_{j=1}^N U_{ij}^m (1 - K(x_j, v_i)) \quad (\text{III.21})$$

Ou $a_j = \alpha \cdot \min \{ \|x_k - v_s\|^2 \text{ avec } s \in \{1, \dots, c\} \}$ et le paramètre α ($0 < \alpha < 1$) contrôle la vitesse de convergence du GFCM. Avec un paramètre approprié α , le KGFCM peut réaliser à la fois une convergence rapide et de bonnes performances de clustering. Le troisième terme B est le terme de contrainte spatiale, dans lequel le paramètre β contrôle l'effet de pénalité de la contrainte spatiale. La condition nécessaire pour la minimisation de la fonction objective dans l'équation (12) avec les contraintes donne les équations suivantes de mise à jour des centres de cluster et la fonction d'appartenance:

$$u_{ij} = \frac{1}{\sum_{l=1}^c \left(\frac{2(1-K(x_j, v_l)) - a_j + 2\beta(1-K(\bar{x}_j, v_l))}{2(1-K(x_j, v_l)) - a_j + 2\beta(1-K(\bar{x}_j, v_l))} \right)^{\frac{1}{m-1}}} \quad (\text{III.22})$$

$$v_i = \frac{\sum_{k=1}^N u_{ij}^m (K(x_j, v_i)x_j + \beta K(\bar{x}_j, v_i)\bar{x}_j)}{\sum_{j=1}^N u_{ij}^m (K(x_j, v_i) + \beta K(\bar{x}_j, v_i))} \quad (\text{III.23})$$

Les détails relatifs de l'approche clustering c-moyennes flou kernel généralisées avec des informations spatiales (KGFCM) pour la segmentation d'image médicale sont décrits dans l'algorithme suivant :

Entrée: Image $X = \{x_1, x_2, \dots, x_n\}$, le nombre de clusters c ($2 \leq c \leq n$), le seuil ε , le nombre maximal d'itérations T , l'indice de flou m , le paramètre α et β , la taille de la fenêtre w .

Sortie: c clusters de X .

Étape 1: Calculez l'image filtrée moyenne ou médiane \bar{X} .

Étape 2: initialisation les centres de cluster $V^{(1)} = [V_1^{(1)}, V_2^{(1)}, \dots, V_c^{(1)}]$ et définissez l'indice itératif $k = 1$.

Étape 3: Mettez à jour les fonctions d'appartenance $u_{ij}^{(k)}$ en utilisant Eq. (III.22).

Étape 4: Calculez les centres de cluster $V_i^{(k+1)}$ en utilisant Eq. (III.23)

Étape 5: Si $\|V^{k+1} - V^k\| < \varepsilon$ ou le nombre d'itérations $k > T$, puis indiquez les résultats de segmentation, sinon $k = k + 1$, passez à l'étape 3.

Afin de démontrer les performances des méthodes proposées par [ZHA 13] (KGFCM_S1 et KGFCM_S2), des expériences de segmentation sont effectuées sur des images médicales réelles en particulier sur l'IRM cérébrales. La figure III.6 montre les résultats obtenus.




Figure III.6 : Résultats de segmentation KGFCM utilisant IRM corrompue par le bruit gaussien.

III-5-5- C-moyennes floues pondérées avec Kernel Généralisé GKWFLICM:

K. H. Memon et D. Lee. ont développé une nouvelle variante de clustering FCM intitulé : **Generalised kernel weighted fuzzy C-means clustering algorithm with local information (GKWFLICM 2018)**. L'algorithme GKWFLICM donne des résultats robustes de segmentation d'image utilisant des informations de voisinage d'image spatiale et locales, elle est limitée aux données d'entrée unidimensionnelles, c'est-à-dire l'intensité de l'image. [MEM 18] propose une généralisation de KWFLICM (GKWFLICM) applicable aux ensembles de données d'entrée de multidimensionnelle. L'algorithme proposé incorpore des informations de voisinage parmi les données M -dimensionnelles, ce qui atténue les inconvénients de l'algorithme de classification FCM standard (sensible au bruit et aux valeurs aberrantes, performances médiocres pour des classes de tailles différentes et aussi des densités différentes) et améliore considérablement les performances de clustering [MEM 18].

K. H. Memon et D. Lee continue de développer le travail généré par Maoguo Gong et al. [GON 13] qui propose d'améliorer la robustesse au bruit et aux valeurs aberrantes de FLICM en présentant un facteur flou pondéré et une méthode de kernel. KWFLICM est basé sur la minimisation de la fonction objective suivante:

$$J_m = \sum_{i=1}^N \sum_{k=1}^c U_{ki}^m (1 - K(x_i, v_k)) + G_{ki} \quad (\text{III.24})$$

Le facteur de mesure de similarité locale floue G_{ki} amélioré peut être obtenu comme:

$$G_{ki} = \sum_{i=1}^N \sum_{k=1}^c U_{ki}^m \sum_{\substack{i \neq j \\ j \in N_i}} w_{ij} (1 - u_{kj})^m (1 - K(x_j, v_k)) \quad (\text{III.25})$$

Où w_{ij} représente le facteur flou pondéré de compromis du i ème pixel. La distance non-euclidienne entre les pixels est calculée par $(1 - K(x_j, v_k))$, en fonction de la méthode du noyau. Pour que la convergence itérative devienne un terme de pénalité plus rapide, utilisez $(1 - u_{kj})^m$. Les membres mis à jour u_{kj} et les centres de cluster v_k nécessaires pour minimiser sont obtenus comme suit:

$$u_{ij} = \frac{1}{\sum_{l=1}^c \left(\frac{(1 - K(x_i, v_l)) + \sum_{i \neq j, j \in N_i} w_{ij} (1 - u_{kj})^m (1 - K(x_j, v_l))}{(1 - K(x_i, v_l)) + \sum_{i \neq j, j \in N_i} w_{ij} (1 - u_{lj})^m (1 - K(x_j, v_l))} \right)^{\frac{1}{m-1}}} \quad (\text{III.26})$$

$$v_k = \frac{\sum_{i=1}^N u_{ki}^m K(x_i, v_k) x_i}{\sum_{i=1}^N u_{ki}^m K(x_i, v_k)} \quad (\text{III.27})$$

Où w_{ij} s'appuie sur les deux contraintes locales spatiales w_{sc} et le niveau de gris comme $w_{ij} = w_{gc} \cdot w_{sc}$ avec distance spatiale du i ème pixel voisin du i ème pixel central est obtenu par :

$$J_{\text{KWFLICM}} \text{ est basé sur } w_{sc} = \frac{1}{(d_{ij}+1)} ; \quad (\text{III.28})$$

$$J_{\text{GKWFLICM}} \text{ est basé sur } w_{sc} = \frac{1}{(\|y_i - y_j\|^2 + 1)} ; \quad (\text{III.29})$$

L'algorithme GKWFLICM peut être résumé comme suit :

- 1: Définissez une valeur pour c , m , la valeur initiale $itr = 1$, le nombre maximal d'itérations $itrmax$, dif et le seuil d'arrêt de l'algorithme ϵ .
- 2: Calculez Li pour tous les i ème vecteurs donnés utilisant algorithmes 1 et 2 de [MEM 18].
- 3: Initialiser les centres de cluster $V^{(0)}$.
- 4: Calculez w_{ij} en basant sur l'équation (III.29).
- 5: Calculez l' u_{kj} matrix à l'aide de l'équation (III.26).
- 6: Mettez à jour les centres de cluster V (itr) à l'aide de l'équation (III.27).
- 7: Arrêtez si $\max \|V^{(itr)} - V^{(itr+1)}\| < \epsilon$ ou $itr > itrmax$, sinon $itr = itr + 1$ et passez à l'étape 4.

En outre, les performances de réduction de bruit ont été comparées par rapport à la précision de segmentation optimale. La figure III.7 ci-dessus montre les résultats de la segmentation GKWFLICM avec d'autres méthodes appliquées sur une image synthétique corrompue par un bruit gaussien (30%).




Figure III.7 : Résultats de segmentation GKWFLICM utilisant IRM corrompue par le bruit gaussien.

III-5-6- C-moyennes floues robustes avec contraintes spatial RSCFCM:

Z. Ji et al. ont utilisé le log-postérieur négatif comme fonction de dissimilarité, aussi ils ont introduit un nouveau facteur afin d'intégrer le modèle d'estimation de champ de polarisation dans la fonction objective FCM floue. Ces paramètres sont proposés pour développer une approche de clustering intitulé : **Robust spatially constrained fuzzy c-means algorithm for brain MR image segmentation (RSCFCM 2014)**. Dans cette méthode, un facteur spatial est proposé pour surmonter l'impact du bruit sur les images. En incorporant les informations spatiales parmi les pixels de voisinage, le facteur spatial proposé est construit sur la base des probabilités postérieures et antérieures et prend en compte la direction spatiale. Il joue le rôle de filtres linéaires pour lisser et restaurer les images corrompues par le bruit. Par conséquent, le facteur spatial proposé est rapide et facile à mettre en œuvre et permet de conserver plus de détails. Le log-postérieur négatif est utilisé comme fonction de dissimilarité en prenant en compte les probabilités antérieures, ce qui peut améliorer encore la capacité d'identifier la classe pour chaque pixel. Pour surmonter l'impact de l'inhomogénéité de l'intensité, ils ont approximé le champ de polarisation au niveau pixel par pixel en utilisant une combinaison linéaire de polynômes orthogonaux. La fonction objective floue est alors intégrée au modèle d'estimation de champ de polarisation pour surmonter l'inhomogénéité d'intensité dans l'image et segmenter les images IRM du cerveau simultanément [Ji 14].

Z. Ji et al. introduit une variante utilisant des paramètres proposés pour modifier la fonction objective de FCM. Sous cet aspect, la fonction objective correspondante devient :

$$J_{\text{RSCFCM}} = \sum_{i=1}^N \sum_{k=1}^K U_{ik}^m d_{ik} - \sum_{i=1}^N \sum_{k=1}^K U_{ik}^m \log(\pi_{ik}) - \sum_{i=1}^N \sum_{k=1}^K F_{ik} \log(\pi_{ik}) \quad (\text{III.30})$$

$$U_{ik} = \left\{ \sum_{j=1}^K \left[\left(\frac{d_{ik} - \log(\pi_{ik})}{d_{ij} - \log(\pi_{ij})} \right)^{\frac{1}{m-1}} \right] \right\}^{-1} \quad (\text{III.31})$$

Où $d_{ik} = -\log(p(X_i|\theta_k, b_i))$ et $p(X_i|\theta_k, b_i)$ est la fonction de vraisemblance suivant la distribution gaussienne avec le paramètre θ_k et le champ de polarisation b_i qui peut être écrite ainsi:

$$p(X_i|\theta_k, b_i) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\Sigma_k|^{1/2}} \exp\left\{-\frac{1}{2}(x_i - b_i \mu_k)^T \Sigma_k^{-1} (x_i - b_i \mu_k)\right\} \quad (\text{III.32})$$

$$b_i = \sum_{k=1}^M w_k g_k(i) = w^T G(i) \quad (\text{III.33})$$

Pour obtenir les estimations des matrices de moyenne et de covariance, nous devons minimiser la fonction objective.

$$\mu_k = \frac{\sum_{i=1}^N U_{ik}^m x_i b_i}{\sum_{i=1}^N U_{ik}^m b_i} \quad (\text{III.34})$$

$$\Sigma_k = \frac{\sum_{i=1}^N U_{ik}^m (x_i - b_i \mu_k) (x_i - b_i \mu_k)^T}{\sum_{i=1}^N U_{ik}^m} \quad (\text{III.35})$$

Où $M = (P+1)(P+2)/2$ est le nombre de polynômes $g_k(i)$, $w^T G(i)$ donne une combinaison linéaire d'un ensemble de fonctions de base $G(i)$ qui sont des polynômes orthogonaux dans cette étude, et P est le degré de ces polynômes. En introduisant un nouveau facteur F_{ik} tenant compte de la direction spatiale sur la base des probabilités postérieures et des probabilités antérieures, défini comme :

$$F_{ik} = \exp \left[\frac{\beta}{2N_i} \sum_{m \in S_k^*} (Z_{mk} + \pi_{mk}) \right] \quad (\text{III.36})$$

Où β est la valeur qui contrôle le lissage avant. S_k^* est le voisinage du pixel i dans la direction S_k^* pour le cluster k , et S_k^* est donné par :

$$S_k^* = \arg \min_{S=1} \sum_{m \in \vartheta_i^S} \text{dist}(x_i, v_k) \quad (\text{III.37})$$

Où $\text{dist}(x_i, v_k)$ est la distance euclidienne entre le point i et le centre de cluster v_k à l'étape d'itération t et ϑ_i^S est le voisinage du pixel i dans la direction s pour le cluster k . Dans cette méthode, ils ont défini $S = 4$, c'est-à-dire que quatre directions horizontales, verticale et deux diagonales sont considérées. Les valeurs d'espérance conditionnelle Z_{ik} des variables cachées peuvent être calculées comme suit :

$$Z_{ik} = \frac{\pi_{ik} p(X_i | \theta_k, b_i)}{\sum_{j=1}^N \pi_{ik} p(X_i | \theta_k, b_i)} \quad (\text{III.38})$$

$$\pi_{ik} = \frac{U_{ik}^m + F_{ik}}{\sum_{l=1}^K (U_{il}^m + F_{il})} \quad (\text{III.39})$$

Par conséquent, l'algorithme RSCFCM développé par [Ji 14] pour la segmentation d'images cérébrales par résonance magnétique peut être résumé comme suit :

- 1 : Initialiser le nombre de cluster, la taille du quartier, le paramètre β pour contrôler la régularité du facteur proposé, le champ de polarisation à chaque pixel et le centre de cluster. Sur la base des centroïdes initialisés, initialiser les matrices de covariance, les valeurs des fonctions d'appartenance et les probabilités antérieures.
- 2 : Mettez à jour de la fonction d'appartenance avec Eq. (III.31)
- 3 : Mettez à jour des valeurs d'espérance conditionnelle avec Eq. (III.38)
- 4 : Mettez à jour des probabilités antérieures avec Eq. (III.39)
- 5 : Mettez à jour le nouveau facteur avec Eq. (III.36)
- 6 : Mettez à jour le champ de biais avec Eq. (III.33)
- 7 : Mettez à jour les centroïdes et la matrice de covariance avec Eqs. (III.34 et III.35)
- 8 : Si la distance entre les nouveaux centres de cluster obtenus et les anciens est inférieure au seuil minimal spécifié par l'utilisateur $\epsilon = 0,001$, arrêtez l'itération; sinon, passez à l'étape 2.

Z. Ji et al. ont appliqué l'algorithme RSCFCM sur des images IRM cérébrale pondérée en T1 et simulée avec 9% de bruit pour la segmenter en GM, WM, CSF et arrière-plan. La figure III.8 montre les résultats obtenus après une comparaison avec d'autres méthodes.

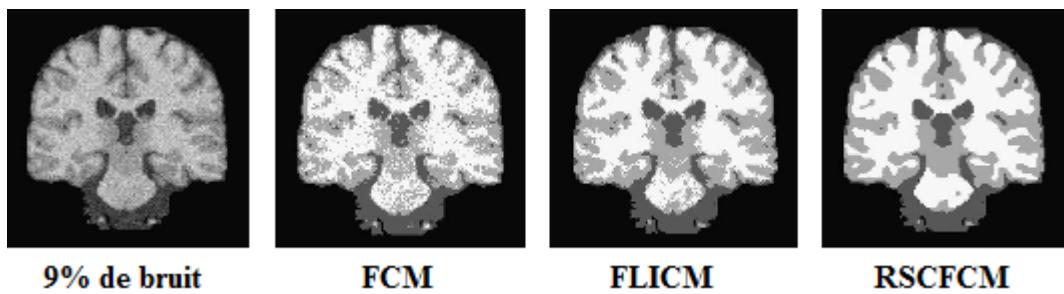


Figure III.8 : Résultats de segmentation utilisant RSCFCM.

III-6- Analyse comparative des nouvelles méthodes de segmentation:

La contribution majeure de cette thèse est le développement d'une nouvelle technique d'analyse de clustering. Il est donc très important d'analyser et de discuter les point forts et les

points faibles des nouvelles méthodes de segmentation d'image médicale en basant sur les méthodes c-moyennes floues considérant le contexte spatial. Une comparaison de certains nouveaux algorithmes de segmentation est résumée dans le tableau III.2. Ce dernier met en évidence les avantages et les limitations remarqué pendant l'étude expérimentale de ces différentes approches. Le Tableau III.2 montre que toutes les méthodes développées sont appliquées avec succès à un type particulier de problèmes et contribuent au diagnostic médical précoce. Mais, ces méthodes ont des limites et nécessitent des recherches approfondies sur les différents types de problèmes pour les résoudre.

Tableau III.2 : Analyse comparative des méthodes de clustering.

Méthodes	Avantages	Limitations
CsFCM [ADH 15]	-Produire une solution optimale locale. -Elle peut produire des résultats de segmentation supérieurs même en présence d'un taux de bruit (<9%) et d'inhomogénéité d'intensité (40%).	-Fonctionne mal sur les tumeurs avec le motif complexe. -La présence d'un pourcentage élevé d'IHH et de bruit peut dégrader les performances de l'algorithme.
CsKFCM [GHA 18]	-Réduire l'inhomogénéité de l'intensité et le bruit dans l'image pour obtenir une précision de segmentation élevée. -La méthode fonctionne bien sur la classe conditionnelle	-La sortie (résultats) dépend de la valeur initiale du cluster. -L'algorithme CsKFCM prend un peu plus de temps de calcul que l'algorithme CsFCM
GKFCM [REH 16]	-Plus efficace et plus résistant au bruit que l'approche de clustering KFCM. - Elle est plus efficace et robuste avec un bon schéma d'apprentissage des paramètres par rapport au FCM et ses variantes.	- Elle échoue pour l'ensemble de données non linéaire. - Le choix aléatoire des centres de clusters ne peut pas conduire aux bons résultats de segmentation.
KGFCM [ZHA 13]	- La distribution non linéaire des données d'image peut être apprise sans connaissance préalable. -Résoudre le problème de sensibilité au bruit gaussien et aussi le problème des coïncidentes (centres de clusters).	- Difficile à réduire la complexité de calcul. - La détermination de β dépend du niveau de bruit des images (β est une valeur constante).
GKWFLICM [MEM 18]	-Amélioration des performances de clustering pour les données d'espace caractéristiques M-dimensionnelles. - Relativement efficace dans le sens où elle fonctionne pour améliorer la précision du clustering.	-Aucun prétraitement n'est effectué pour améliorer l'image avant l'opération de segmentation. -GKWFLICM a été testé uniquement avec les jeux de données d'apprentissage et des tests supplémentaires sont nécessaires avec des jeux de données réels.
RSCFCM [Ji 14]	-Utilisant le log-postérieur négatif comme fonction de dissimilarité, introduisant un nouveau facteur tenant compte de la direction spatiale afin d'intégrer le modèle d'estimation de champ de polarisation.	-RSCFCM ne produit pas une reproductibilité élevée. -Le paramètre β est choisi suffisamment petit pour empêcher l'image de perdre une grande partie de sa netteté et de ses détails

III-3- Conclusion :

Dans ce chapitre, une étude de la littérature montre que des nombreux algorithmes de classification c moyenne floue ont pour objectif de modéliser efficacement des modèles non supervisés. Dans le but d'améliorer les résultats de l'approche de clustering et de la segmentation, de nombreuses techniques ont été présentées en utilisant divers algorithmes. Les avantages et inconvénients sous-jacents de chacune des techniques existantes ont également été examinés. Dans la mesure où une analyse détaillée des techniques disponibles a été effectuée de manière systématique, elle sera très utile pour les travaux de recherche actuels visant à améliorer les performances des techniques de clustering et à améliorer les résultats de la segmentation de FCM et ses variantes à partir d'images IRM cérébrales.

Chapitre IV :

*Contribution à la segmentation d'images
IRM cérébrales par FCM modifié
considérant le contexte spatial*

IV-1-Introduction :

C-moyennes floue FCM standard est un algorithme de classification distinctif. Il a été exploité dans de nombreuses disciplines scientifiques et techniques. Notre motivation est de développer des algorithmes de segmentation robustes efficaces basés sur les nouvelles techniques de C-Moyennes floue considérant le contexte spatial pour la segmentation des images médicales de type IRM et aussi pour différencier les tissus et trouver les parties touchées. Cette recherche vise principalement à fournir la meilleure technique de segmentation par clustering qui est principalement conçus pour traiter les problèmes suivants: la vulnérabilité à la sensibilité d'initialisation, le faible taux de convergence, les limites floue qui rend la dissimilarité entre les tissus dans les limites est plus difficile, les problèmes de bruits lourds qui entraînent une faible précision de segmentation d'image et optimise le classement des performances des approches proposées.

Pour améliorer l'approche de C-moyennes floue spatiale, ISFCM et ISKFCM sont développés en intégrant les informations spatiales. Cette nouvelle technique vise à donner de bons résultats par rapport aux d'autres méthodes discutées dans le deuxième chapitre en modifiant et minimisant la fonction objective utilisée. Pour obtenir des résultats de clustering avec plus de précision, une meilleure fonction objective est requise. Cette fonction est basée sur l'ajout d'un nouveau terme de données spatiale par rapport à chaque cluster en introduisant une variable conditionnelle basée sur les régions de filtre de Nagao modifié, aussi définie comme les valeurs médiane et moyenne de la fonction d'appartenance des pixels du voisinage sélectionné afin de modifie l'exposant de la distance entre un pixel et une classe itérativement. Le problème de nombre de cluster et l'initialisation des centres de classes sont bien démontrés pour accélérer le taux de convergence et réduire la consommation de mémoire et le nombre d'itérations pendant l'exécution de l'algorithme.

Le reste de ce chapitre illustre les résultats expérimentaux des algorithmes développés sur des données d'imagerie cérébrale IRM synthétiques, simulées et réelles, ainsi qu'une série de comparaisons entre les méthodes développées et proposés sont présentés. En outre les tissus cérébraux, la ségrégation, l'extraction et le calcul de la zone tumorale sont également introduites a fin de déduire les caractéristique de cette dernière.

IV-2- Problématique:

Ce chapitre analyse les problèmes de la segmentation des images médicales IRM et tente de fournir une solution efficace pour éliminer le défaut de sensibilité au bruit et de l'intensité non uniforme. Plusieurs d'autres problèmes liés aux méthodes de FCM spatiale qui sont abordés dans la littérature ou la majorité de ces méthodes présentent plusieurs inconvénients. Parmi ces inconvenants on a :

- L'algorithme FCM spatiale dépend du nombre de clusters.
- Le clustering FCM interactif dépendant de l'utilisateur peut donner un très bon résultat à condition que l'utilisateur soit suffisamment possède des informations préalables.
- La distance euclidienne présente certaines limitations.
- La mise en cluster non supervisée produit un cluster de bruit.
- La FCM n'intègre pas d'informations sur le contexte spatial, ce qui la rend sensible au bruit et aux autres artefacts d'imagerie. Les pixels d'une image sont fortement corrélés, c'est-à-dire que les pixels du voisinage immédiat possèdent presque les mêmes données de caractéristiques.

- Différents chercheurs n'ont pas réussi à prouver que la FCM spatiale était optimal totalement, c'est-à-dire qu'il minimisait tout type de distinction objective.
- L'étape supplémentaire sur FCM spatiale était insensible au paramètre fuzzification m , à partir de quelques expériences. Cependant, étant donné que la compétitivité du FCM est contrôlée à l'aide de m , cela ne peut pas être facilement établi.
- L'initialisation de FCM spatiale nécessite la définition de certains paramètres (les centres de cluster) et des paramètres inefficaces peuvent conduire à un problème de minima local. Cela nécessite l'initialisation des centres de cluster de façon automatique et précise.
- Certains SFCM n'ont fourni aucune stratégie pour choisir le taux de suppression. Ils ont formulé un critère basé sur des considérations relatives à la validité d'un cluster.
- La FCM spatiale cherche des clusters du même type.
- La fonction objective n'est pas bonne pour des classes de taille inégale très proches.
- La nature itérative consomme beaucoup de temps de calcul.

Pour résoudre tous ces problèmes, nous introduit une nouvelle méthode de segmentation FCM clustering modifié en incorporant des informations spatiales et le principe de voisinage des pixels par l'intégration des différentes régions de filtre de Nagao et en modifiant la pondération d'appartenance de chaque cluster à l'aide de l'exposant de pondération de Fuzziness et aussi sans initialisation aléatoire des centres de clusters car elle fournit des résultats erronés. Cette nouvelle méthode développée permis non seulement de fournir une meilleure solution en cas de mauvaise qualité d'image et de non-linéarité des données en présence de bruit et intensité inhomogénéité, mais il essaie de fournir une solution plus fine pour réduire le temps de calcul et la consommation de mémoire.

IV-3- Méthodologie:

La segmentation automatique des images médicales est une tâche difficile et complexe et les résultats de segmentation sont affectés par les artefacts et la proximité du niveau de gris des différents tissus cérébraux. Il n'y a pas d'algorithme de segmentation universel adapté à toutes les images médicales. Le choix de l'algorithme est influencé par le type d'image, la raison de l'analyse et son utilisation possible. Différentes approches de segmentation des images IRM couramment utilisées ont déjà été discutées dans le chapitre II. La présente section explique la mise en œuvre de la méthode proposée pour la segmentation des images de résonance magnétique. La représentation schématique par blocs des différentes étapes de notre méthode est illustrée dans la Figure IV.1.

IV-3-1- Chaîne de traitement proposée:

La méthode de segmentation proposée permet de détecter les tumeurs cérébrales des images IRM et de segmenter les tissus cérébraux à l'aide de techniques de clustering FCM modifiées. Le flux procédural et les différentes étapes impliquées dans l'approche de segmentation développée sont les suivantes:

1. Lire l'image IRM cérébrale d'entrée pondérée en T1, T2 ou DP.
2. Convertir l'image d'entrée en niveau de gris puis en données scalaire.
3. Prétraitement: Application du Filtre de Diffusion Anisotrope modifié (FDAM) puis procéder à l'élimination des tissus non cérébraux.
4. Détermination du nombre de classes en utilisant PNMF

5. Exécuter l'algorithme k-means modifié (k-means#) pour avoir les centres de classes comme des centroïdes initiaux pour ISFCM et ISKFCM.
6. Exécuter les deux algorithmes ISFCM et ISKFCM en parallèle.
7. Post-traitement: Défuzzification et extraction de la région d'intérêt.
8. Ségrégation et Calcul de la zone tumorale.
9. Extraction des caractéristiques de la zone tumorale.
10. Sauvegarder l'image segmentée et les données.

Dans cette section, les améliorations de notre approche seront divisées en plusieurs parties pour une discussion plus approfondie ou le système de segmentation proposé comprend différentes phases qui permettent de classifier, segmenter et détecter les tumeurs cérébrales à partir des images IRM pondérées en T1, T2 et DP. Une représentation graphique des différentes principales étapes de notre approche proposée est illustrée dans la figure IV.1:

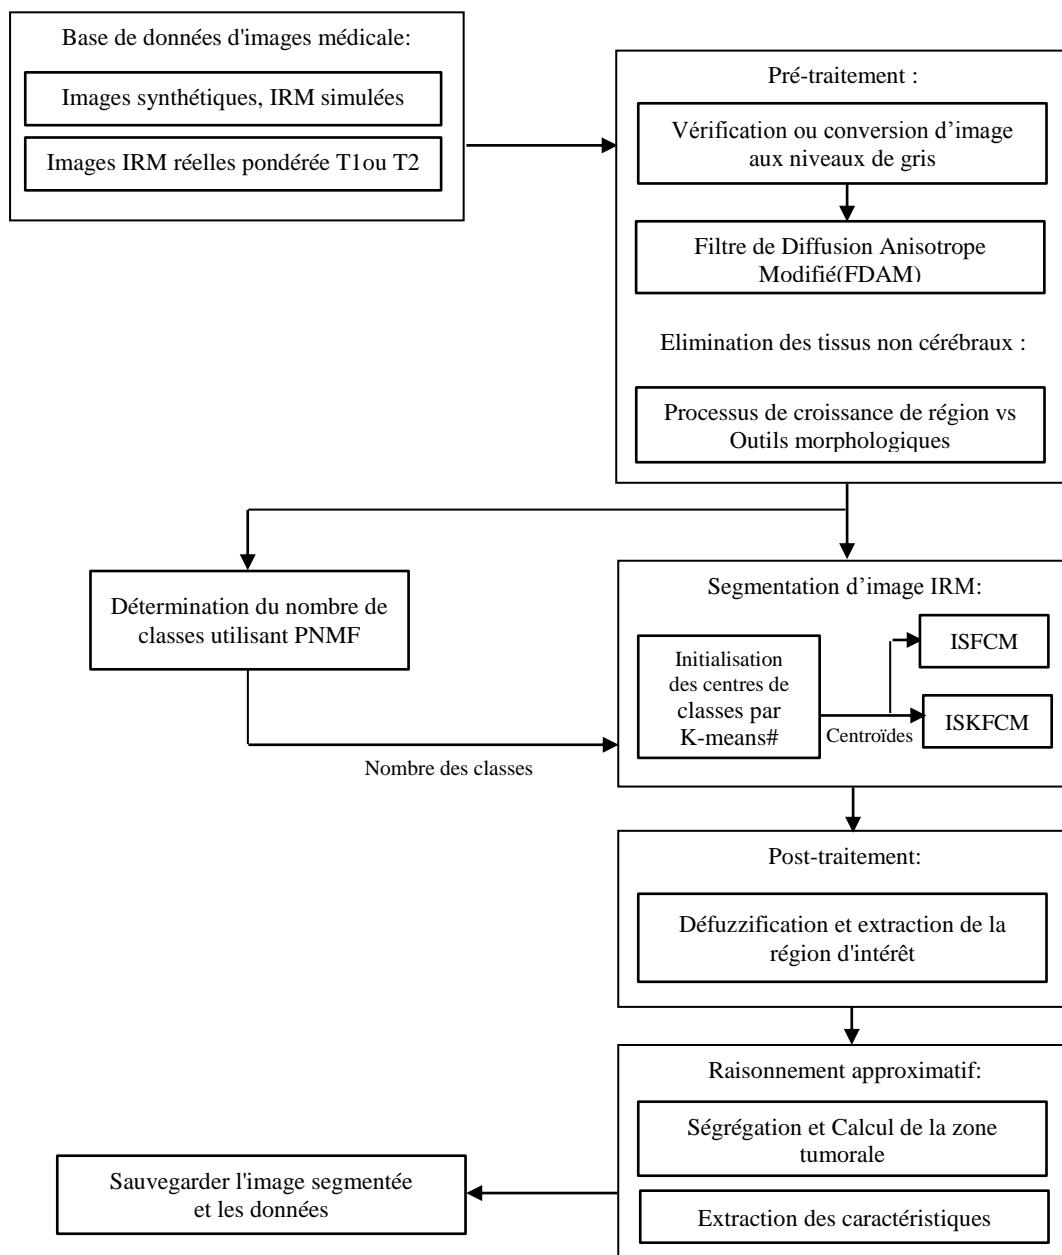


Figure IV.1 : Schéma général illustrant les étapes séquentielles impliquées dans notre approche.

IV-3-2- Prétraitement des images IRM:

Le prétraitement constitue une étape importante dans toutes les applications de traitement d'image médicale. Ici, l'objectif fondamental de l'amélioration de la qualité des images IRM est de traiter l'image d'entrée donnée afin que l'image résultante soit plus pertinente que l'image d'origine. Donc, les informations indésirables qui peuvent être qualifiées de bruit et qui doivent être supprimées au stade du prétraitement avant de poursuivre le traitement de l'image. L'étape de prétraitement convertira l'image IRM du cerveau humain en niveaux de gris. Puis il effectue un filtrage du bruit et d'autres artefacts à l'aide d'un filtre de diffusion anisotrope modifié, aussi il est utilisé pour réduire le contraste entre les pixels consécutifs. Après l'étape du pré-traitement, nous pouvons appliquer l'algorithme de segmentation pour segmenter la tumeur cérébrale.

IV-3-2-1- Vérification & conversion d'image en niveau de gris:

Ici, nous utilisons des images cérébrales de type IRM, certaines sont collectées à partir des images DICOM et d'autres proviennent d'une base de données en temps réel, qui contient généralement les détails du patient et contient également des informations de laboratoire. Les images sont présentées dans une matrice 2D où les pixels sont considérés comme les éléments. Ces matrices 2D sont stockées dans MATLAB et affichées sous la forme d'une image en niveaux de gris de taille 256×256 dont l'intensité de ces niveaux de gris varie de 0 à 255 où 0 ressemble à une couleur purement noire et 255 ressemble à une couleur purement blanche. Toute valeur intermédiaire entre ce rang varie en intensité du noir au blanc.

IV-3-2-2- Application du Filtre de Diffusion Anisotrope modifié:

Les images IRM peuvent être provoquées par des artefacts inhérents au processus d'acquisition ce qui rend le diagnostic difficile. L'objectif est donc de connaître la nature de ce bruit et on cherche à connaître aussi sa distribution statistique afin de le supprimer ou minimiser. Les études scientifiques ont démontré que ce bruit est dû au processus thermique de l'objet numérisé à l'acquisition (k-space) et ce dernier suit une distribution ricienne. Par conséquent dans la partie suivante, on propose une technique (filtre de diffusion anisotrope modifié (FDAM)) permettant d'évaluer et de supprimer la quantité de bruit dans les images IRM ou les détails les plus fins sont améliorés.

La technique appliquée est basée sur la fonction de conduction thermique traditionnelle pour restaurer les bords flous et éliminer les bruits. Le filtre de diffusion anisotrope modifié (FDAM) est basé sur l'équation suivante:

$$\begin{cases} \frac{\partial I}{\partial t} = \operatorname{div}[c(\|\nabla I\|) \cdot \nabla I] \\ I_{t=0} = I_0 \end{cases} \quad (\text{IV.1})$$

Où I_0 est l'image d'origine au temps t, div est l'opérateur divergence, ∇I est le gradient de l'image et C ($\|\nabla I\|$) est le coefficient de diffusion. Deux fonctions de coefficient de diffusion largement utilisées sont données par les équations (IV.2) et (IV.3):

$$c(\|\nabla I\|) = \exp \left[-\left(\frac{\|\nabla I\| * (1 + (\|\nabla I\| / 255))}{K} \right)^2 \right] \quad (\text{IV.2})$$

$$(\|\nabla I\|) = \frac{1}{1 + \left(\frac{\|\nabla I\|}{K} \right)^2} \quad (\text{IV.3})$$

Où K est une valeur de seuil constante pour contrôler le niveau de lissage. Eq. (IV.2) exprime des valeurs de contraste élevés Eq. (IV.3) et concerne de vastes régions.

Dans le système proposé, le filtre de diffusion anisotrope avec 8 voisins connectés est appliqué sur l'image pour éliminer le bruit et réduire le contraste entre les pixels consécutifs. L'idée essentielle de ce filtre proposé est assez simple :

$$I(x, y, t) = I_0(x, y) * G(x, y, t) \quad (IV.4)$$

Où $I(x, y, t)$ est l'image filtrée, $I_0(x, y)$ est l'image originale et $G(x, y, t)$ est le noyau gaussien avec différents paramètres d'échelle t .

Dans cette méthode, le filtrage peut être atteint comme une voie itérative de l'égalisation de la diffusion où $I(x, y, 0) = I_0(x, y)$ est la condition principale, et est équivalente au temps t . On a introduit une solution pour le problème qui permet un flou de variante spatiale (anisotrope) afin de localiser les bords avec plus de précision. On a utilisé le voisinage 8-connecté dans les calculs. L'avantage de l'Eq. (IV.1) est que le coefficient de diffusion c ($\|\nabla I\|$) peut être réglé de manière adaptative à chaque itération, ce qui permet de distinguer la frontière de l'image et de diminuer la diffusion le long de la direction du bord. Le filtre résultant est basé sur l'équation suivante :

$$I_{i,j}^{t+1} = I_{i,j}^t + \lambda(c_U^t \nabla_U I_{i,j}^t + c_D^t \nabla_D I_{i,j}^t + c_L^t \nabla_L I_{i,j}^t + c_R^t \nabla_R I_{i,j}^t + c_{UL}^t \nabla_{UL} I_{i-1,j-1}^t + c_{UR}^t \nabla_{UR} I_{i-1,j+1}^t + c_{DL}^t \nabla_{DL} I_{i+1,j-1}^t + c_{DR}^t \nabla_{DR} I_{i+1,j+1}^t) \quad (IV.5)$$

Où $I_{i,j}^{t+1}$ est la valeur du pixel à la position (i, j) au moment t , le coefficient λ appartient $[0-0.25]$ et les termes ∇ sont déterminés sur la base de la fonction de diffusion dont les arguments finis différences calculées sur un voisinage connecté à 8.

$$\begin{aligned} \nabla_U I_{i,j}^t &= I_{i-1,j}^t - I_{i,j}^t; \quad \nabla_D I_{i,j}^t = I_{i+1,j}^t - I_{i,j}^t; \\ \nabla_L I_{i,j}^t &= I_{i,j-1}^t - I_{i,j}^t; \quad \nabla_R I_{i,j}^t = I_{i,j+1}^t - I_{i,j}^t; \\ \nabla_{UR} I_{i,j}^t &= I_{i-1,j+1}^t - I_{i,j}^t; \quad \nabla_{UL} I_{i,j}^t = I_{i-1,j-1}^t - I_{i,j}^t; \\ \nabla_{DL} I_{i,j}^t &= I_{i+1,j-1}^t - I_{i,j}^t; \quad \nabla_{DR} I_{i,j}^t = I_{i+1,j+1}^t - I_{i,j}^t \end{aligned} \quad (IV.6)$$

Pour évaluer et comparer le filtre FDAM proposé en vue d'estimer et supprimer le bruit et aussi réduire le contraste entre les pixels, plusieurs algorithmes de débruitage ont été étudié, on peut citer: [AIN 19] a développé un Filtre Médian Adaptatif à Commutation Récursive (FMACR) et [EKA 17] a optimisé le Filtre médian récursif de Gauss-Seidel (FMRGS). Pour valider le choix de FDAM, plusieurs simulations sont effectuées sur des images ou l'image IRM pondérée en T2 est corrompue par le bruit Rician à des différentes densités de bruit et les performances sont mesurées à l'aide des paramètres tels que le rapport signal / bruit de crête (PSNR) et la variance. Les performances sont présenté dans les figures IV.2 et IV.3.

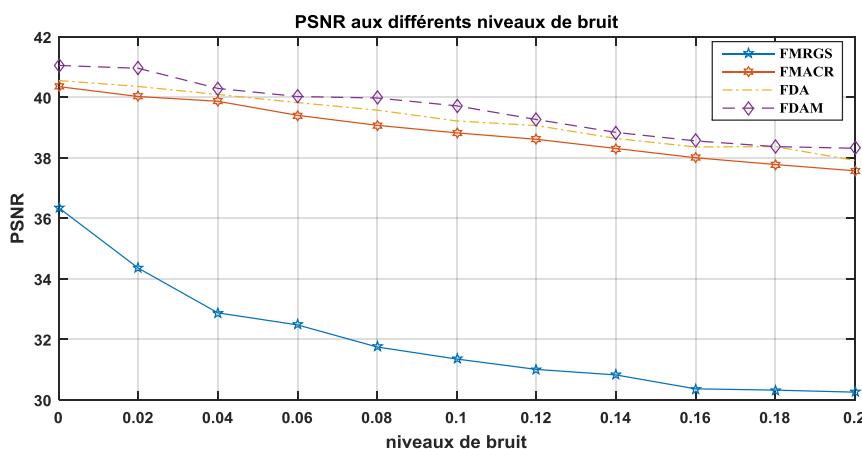


Figure IV.2 : Performances d'évaluation en termes de PSNR.

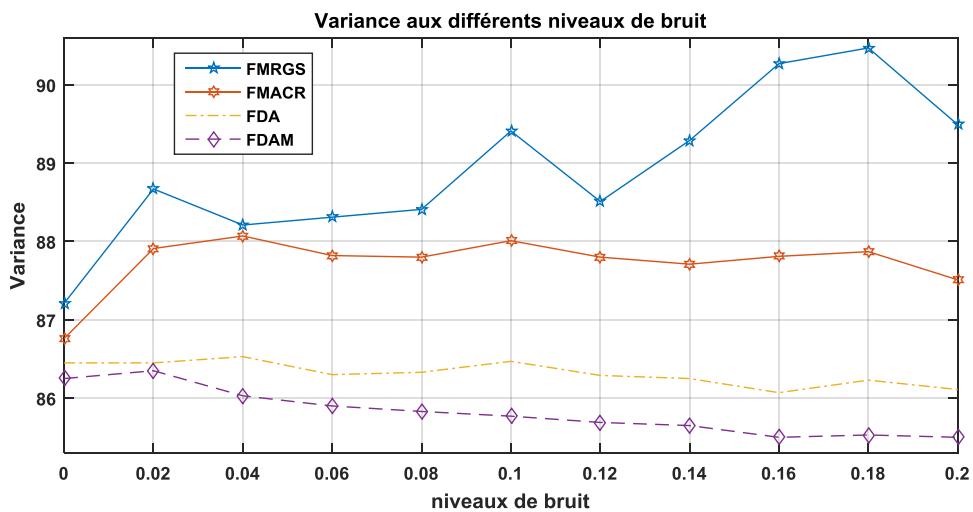


Figure IV.3 : Performances d'évaluation en termes de variance.

Les résultats expérimentaux obtenus à partir des différents filtres utilisés sont évalués et comparés à l'aide d'une inspection visuelle qualitative présentée dans la figure IV.4.




Figure IV.4 : Performances des différents filtres proposés : (a) image originale; (b) image corrompu avec 20% du bruit Rician; (c) résultats du filtre médiane ; (d) résultats du filtre gaussienne ; (e) résultats de FMRGS ; (f) résultats de FMACR ; (g) résultats de FDA ; (e) résultats de FDAM.

De plus, le rapport d'erreur quadratique moyenne (MSE) est calculé pour la comparaison entre les diverses techniques de filtrage et présenté dans le tableau IV.1. Il est très intéressant aussi de noter que le Filtre de Diffusion Anisotrope Modifié (FDAM) a pu atteindre des meilleurs résultats par rapport aux autres filtres proposés de suppression du bruit existants.

Le FDAM affiche également des performances fiables et stables sur une gamme différente de densités de bruit variant de 10% à 25% et conserver les détails de l'image dans le taux de bruit élevé ce qui indiquent également que le filtre développé pour cette approche peut améliorer les performances de préservation des bords et d'élimination efficace du bruit dans le domaine du filtrage de diffusion anisotrope.

Tableau IV.1 : Rapport PSNR et MSE des résultats expérimentaux.

Bruit Ricien	PSNR				MSE			
	$\sigma = 10$	$\sigma = 15$	$\sigma = 20$	$\sigma = 25$	$\sigma = 10$	$\sigma = 15$	$\sigma = 20$	$\sigma = 25$
FMRGS	32.10	30.39	29.09	27.95	40.08	59.4	80.15	104.23
FMACR	26.25	23.13	21.98	20.34	154.27	316.04	412.37	600.96
FDA	33.61	30.71	28.72	28.19	28.29	55.19	87.23	98.54
FDAM	33.67	32.11	30.40	29.10	27.94	39.98	59.25	79.96

IV-3-2-3- Elimination des tissus non cérébraux:

L'image IRM constitue principalement du crâne et les tissus cérébraux. Pour segmenter le cerveau, les tissus cérébraux d'intérêt doivent être extraits de l'image d'origine. Cette procédure est très essentielle pour faciliter une mesure précise des structures cérébrales. L'inclusion des tissus non cérébraux peut entraîner une interprétation erronée qui conduisant à la réduction des performances et l'analyse très difficiles. A cet effet, nous avons appliqué le processus de croissance de région contre les outils morphologiques développés par [ROS 11]. En bref, les étapes de la méthode proposée sont résumées dans l'algorithme suivant:

Algorithme IV.1 Processus de croissance de région semi-automatisé

Entrée: Image I convertie en niveau de gris

7. Lire l'image d'entrée et fixer les paramètres
8. Sélectionner le pixel de départ en utilisant:
 - a. Placer une fenêtre au centre de l'image de forme rectangulaire de taille quinze lignes et dix colonnes.
 - b. Trouver la somme de toutes les lignes et stocker les résultats dans un tableau
 - c. Trouver la somme de toutes les colonnes et stocker les résultats dans un autre tableau
 - d. Trouver l'intersection de la ligne et de la colonne ayant la somme maximale. Ceci est pris comme point de départ.
9. Fixer la valeur de seuil $T=0.1854$
10. Commencer avec un seul pixel (points de départ) et ajouter lentement de nouveaux pixels
11. Vérifier les pixels voisins et ajouter-les à la région s'ils sont similaires au point de départ comme suit : $|\text{pixel voisin} - \text{points de départ}| < T$
12. Arrêter si aucun pixel supplémentaire ne peut être ajouté
13. Répéter les étapes 5 et 6 pour chacun des pixels nouvellement ajoutés

Sortie: L'image obtenue après l'enlèvement du crâne est prise en entrée dans cette thèse

Cet algorithme semi-automatisé a été proposé pour supprimer les structures crâniennes et osseuses des images IRM qui est généralisable à plusieurs scanners IRM et protocoles d'acquisition en utilisant le processus de croissance de la région. Des expériences sur des exemples d'images cérébraux IRM dés identifiés montrent également que l'algorithme proposé est indépendant de la modalité du scanner et il suggère une application clinique prometteuse qui pourrait être utilisée et aussi il est plus rapide sur le plan des calculs.

La figure IV.5 montre les résultats obtenus après l'exécution de l'algorithme IV.1 sur un ensemble des images médicales de type IRM.

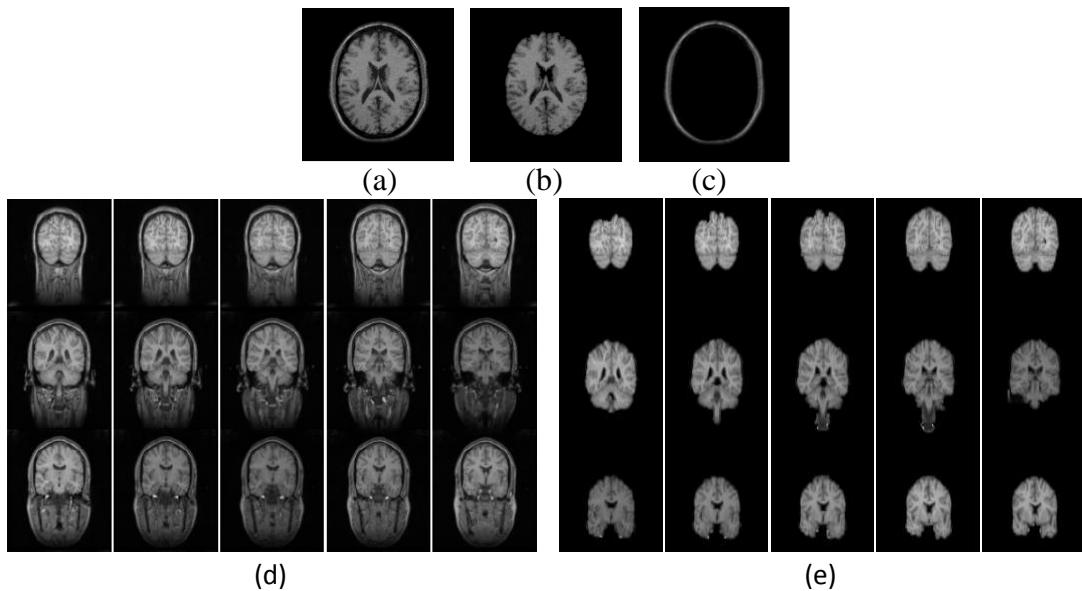


Figure IV.5 : Résultats expérimentaux de l'algorithme IV.1 (a) image IRM originale en coupe axiale ; (b) partie du cerveau ; (c) partie non cerveau ; (d) ensemble des images IRM originales en coupe Coronal ; (e) partie du cerveau des images IRM.

IV-3-3- Détermination du nombre optimal de clusters:

Le nombre de clusters est le paramètre le plus important dans l'initialisation de la méthode C-moyennes floue. La détermination de ce nombre est nécessaire pour exécuter l'algorithme. Lorsqu'on regroupe des données réelles sans informations a priori sur les structures des données, généralement on doit faire des hypothèses sur le nombre de classes sous-jacentes. Notre algorithme proposé recherche ensuite ce nombre particulier et optimal de clusters d'une façon automatique.

La méthode FCM spatial présent l'inconvénient d'être trop sensible aux choix de nombres de cluster dans une image, pour résoudre ce problème on intègre la factorisation matricielle non négative probabiliste PNMF en tant que technique de clustering dans notre procédé et nous justifions comment elles peuvent être utilisées pour construire une énergie fonctionnelle robuste. La méthode proposée explique comment utiliser le NMF pour détecter d'une façon automatique les régions d'image et estimer le nombre optimal de cluster. Les formules théoriques et mathématiques de NMF et PNMF sont présentées dans l'annexe IV.

Premièrement, nous créons une matrice de donnée qui comporte les valeurs d'intensités de l'image. Puis on partitionne l'image en m blocs (b_1, b_2, \dots, b_m) et en calculant l'histogramme de chaque bloc voir la figure IV.6 ce dessus. Les histogrammes des blocs sont ensuite générés pour former les colonnes de la matrice de données V . Notre but est de chercher les histogrammes de base de telle sorte que l'histogramme de chaque bloc puisse être exprimé sous la forme d'une combinaison linéaire positive. Ceci est développé en utilisant la factorisation matricielle non négative probabiliste PNMF qui fournit un moyen naturel de regrouper la matrice de données de l'histogramme et prend en compte le bruit dans la matrice de données V afin d'effectuer une factorisation maximale. Plus de détails sont mis à disposition en annexe A.

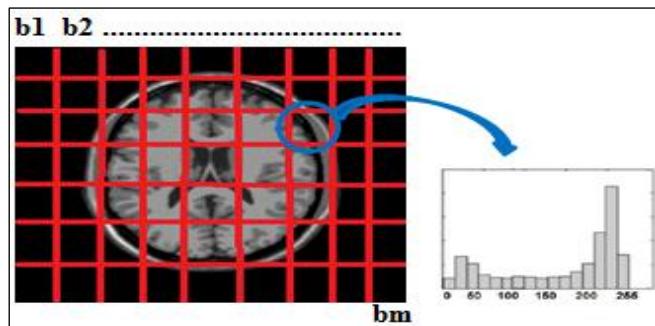
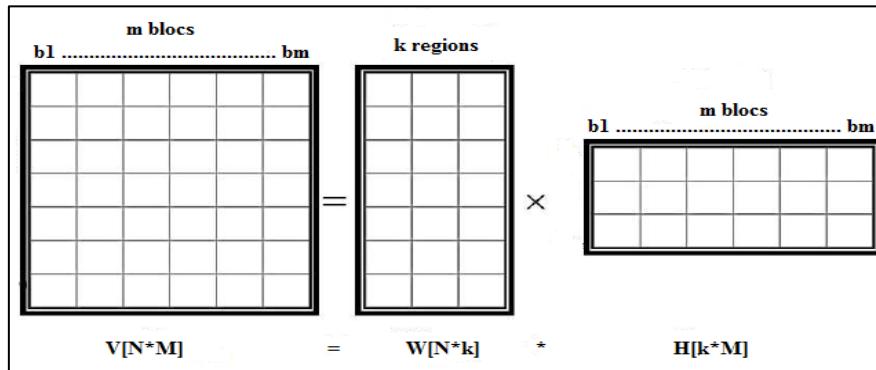


Figure IV.6 : Calcul de l'histogramme de chaque bloc.

La façon la plus simple pour trouver l'histogramme de base est de décomposer la matrice de données V en deux matrices avec des entrées positive $V = W H$, où W étant donné comme $N \times k$ et la matrice H est $k \times M$. les k colonnes du matrice W définissent les histogrammes de base et les K lignes du matrice H regroupe la matrice de données et représente la distribution des régions dans les m blocs voir la figure IV.7

Figure IV.7 : Factorisation de la matrice de données V en utilisant PNMF.

L'algorithme IV.2 proposé pour détecter le nombre des clusters C d'une image donnée peut être résumé dans les différentes étapes suivantes :

Algorithme IV.2 Détermination du nombre de classes en utilisant PNMF

Entrée: image IRM convertie en niveaux de gris, m est le nombre des blocs

1. Lire l'image d'entrée et fixer les paramètres
2. Initialiser la taille des blocs et diviser l'image en blocs
3. Calculer l'histogramme de chaque bloc
4. Construire la matrice de donnée V .
5. Fixer la valeur du seuil $S=0.90$ manuellement
6. Appliquer le processus de PNMF pour obtenir des matrices de facteur W et H .
7. Calculer la norme Frobenius pour les deux matrices W et H .
8. Augmenter le nombre de régions C de manière itérative
9. Répéter les étapes de 5 à 7 jusqu'à la différence entre les normes Frobenius (nouveau -ancien) est inférieur au seuil « S ».

Sortie: le nombre des clusters C .

IV-3-4- Initialisation des centres des classes:

L'initialisation des centres des classes de FCM nécessite la définition précise de certains paramètres et lors des inefficaces centres des classes peuvent conduire à un problème de segmentation. L'approche de clustering FCM spatial est relativement sensible aux positions initiales des centres de cluster. Les centroïdes du cluster final ne sont peut-être pas les meilleurs, car cette initialisation se fait d'une façon aléatoire ou l'algorithme peut converger vers des solutions locales. En conséquence, il est essentiel pour les deux algorithmes ISFCM et ISKFCM proposée d'avoir des meilleurs centres de cluster initial.

L'algorithme d'initialisation IV.3 mentionné ci-dessus peut aider à trouver des meilleurs centres initiaux pour notre système de segmentation dans une certaine mesure, ils sont relativement compliqués, ce qui nécessite toujours une meilleure méthode pour l'initialisation du centre de cluster. L'approche proposée pour trouver le centre de gravité du cluster initial est présentée, ou le choix des centroïdes initiaux appropriés est l'étape clé de la procédure de base de K Means. Il est facile et efficace de choisir aléatoirement les centroïdes initiaux, mais les résultats sont souvent médiocres [CHE 05]. Une autre mesure de distance Mahalanobis mesure de distance est utilisée. L'utilisation de cette distance permet à l'algorithme k-means de détecter des hyper-ellipsoïdaux avec orientation arbitraire.

L'incorporation d'informations spatiales dans le processus de segmentation FCM rend l'algorithme robuste au bruit et aux bords flous. Mais lorsque l'utilisation d'informations spatiales dans l'approche de la segmentation peut converger vers des minima locaux, l'algorithme de c-moyennes spatiaux flous est donc nécessite une initialisé optimisée. En utilisant MATLAB pour réaliser l'algorithme d'initialisation des centres de cluster : k-means modifiée, k signifie que l'algorithme accepte l'entrée k; et n objets de données en k clusters pour que l'accès au cluster se rencontre: similitude des objets plus élevée dans le même cluster et moindre similitude entre les différents objets du cluster. Le meilleur centre de clustering V_i est calculé automatiquement en fonction de la densité des pixels pour regrouper les données. Les différentes principales étapes de la technique de clustering K-moyennes modifiée (K-means#) sont résumées dans l'algorithme IV.3 comme suit :

Algorithme IV.3 Initialisation des centroïdes par K-moyennes modifiée (K-means#)

Entrée : Image I convertie en niveau de gris avec l'ensemble des données $I = \{x_1, x_2, \dots, x_n\}$, nombre des clusters C,

1. Lire l'image I et fixer les paramètres d'entrée.
 2. Choisir les centroïdes V_i comme des centres de classes initiaux :
 - a. Placer une fenêtre au centre de l'image de forme rectangulaire de taille quinze lignes et dix colonnes.
 - b. Trouver la somme de toutes les lignes et stocker les résultats dans un tableau
 - c. Trouver la somme de toutes les colonnes et stocker les résultats dans un autre tableau
 - d. Trouver l'intersection de la ligne et de la colonne ayant la somme maximale. Ceci est pris comme point de départ.
 3. Répéter
 4. Affecter chaque objet à leur centre de cluster le plus proche à l'aide de la mesure de distance Manhattan
 5. Calculer le nouveau centre du cluster en calculant les points moyens.
-

6. Jusqu'à Pas de changement dans le centre du cluster.

7. Enregistrer les centres de classes finales.

Sortie : L'ensemble des centres de classes V_i

IV-3-5- Contributions:

Le clustering flou est toujours défini comme le processus de regroupement, avec incertitude des données non étiquetées dans les groupes ou les clusters les plus homogènes autant que possible. Cependant, ce travail s'intéresse principalement aux méthodes de clustering flou et plus spécifiquement à l'algorithme c-moyennes floue. Il s'agit d'une classification non supervisée, car elle n'a aucune connaissance préalable de la structure des données. Elle génère des clusters flous en minimisant de manière itérative une fonction objective. L'inconvénient majeur de cet algorithme réside dans l'absence d'informations ou de contraintes spatiales, ce qui le rend sensible au bruit. Afin de surmonter ce problème et d'accélérer le processus de segmentation et d'améliorer la qualité du résultat du clustering, notamment en présence de niveaux de bruit élevés, nous proposons des nouvelles méthodes : ISFCM et ISKFCM qui consiste à introduire des informations spatiales locales à faible complexité de calcul et l'autre à modifier l'appartenance des pixels qui dépendre du calcul de la distance entre les pixels au sein des voisins spatiaux locaux et des centres de cluster. De nombreuses variantes ont été ainsi proposées, celles-ci consistent soit à changer la fonctionnelle à minimiser, soit à définir une autre distance ou soit encore à modifier l'influence du facteur flou.

IV-3-5-1- Choix des paramètres de l'algorithme:

Avant d'entamer la segmentation, il faut définir et expliquer les différents paramètres gouvernant les algorithmes proposés et nécessaires à cette dernière, à savoir les valeurs de m , la distance et les vecteurs forme représentant les pixels des images:

A- Choix de paramètre m :

Il n'existe pas de méthode pour optimiser de manière générale ce paramètre, chaque problème appelle un choix dépendant de la nature de données utilisées. Le paramètre m contrôle le degré de flou de la partition floue U . Si m est proche de 1, la partition résultante est quasiment non floue, chaque vecteur x_j est assigné à une classe i et une seule avec un degré d'appartenance $u_{ij} = 1$. Les valeurs comprises dans l'intervalle [1.5 - 3] pour m sont généralement acceptées afin d'assurer la convergence de l'algorithme de segmentation. De ce fait et après certains expérimentations sur les valeurs de m , nous avons choisi $m=2$ dans le cadre de notre étude.

B- Choix de la distance:

Pour notre cas, nous avons opté de développer l'algorithme ISFCM avec la distance la plus usuelle et la plus rapide à calculer, qui est la distance euclidienne. Cependant cette distance donne de bons résultats que lorsque les classes sont de forme sphérique et ayant la même taille, ou lorsqu'elles sont bien séparées. Or en réalité les classes peuvent avoir des formes géométriques quelconques et des tailles différentes, pour cela on a remplacé cette dernière par la distance de fonction noyau gaussien (kernel distance) pour avoir ISKFCM.

C- Choix des vecteurs forme:

Le choix des vecteurs forme est fondamental puisque leur pertinence va permettre de discriminer les pixels entre eux. Le vecteur forme x_j d'un pixel j est alors formé des niveaux de gris de ce pixel. Ce choix particulier est défini suivant le type de modalité. L'image anatomique que nous utilisons est l'IRM. L'imagerie par résonance magnétique est une modalité d'imagerie multi-spectrale donnant accès à un grand nombre de paramètres et donc de vecteurs forme. La première caractéristique qui peut être exploitée est le signal lui-même, principalement par l'intermédiaire d'images pondérées en T1, T2 et DP en densité de protons. Le vecteur forme x_j d'un pixel j est alors formé des niveaux de gris de ce pixel dans toutes les images. Cette information est très largement utilisée en segmentation d'images, en particulier dans un cadre flou.

IV-3-5-2- Segmentation d'image basée sur IFCM_S:

Motivés par les forces individuelles de FCM_S et ses variantes : FCM_S1, FCM_S2 et la combinaison de ses deux propriétés spatiales (moyenne et médiane) et la méthode IFCM_S développé par [NAS 12] qui agissent directement sur la fonction objectif afin d'améliorer les résultats de la classification notamment en présence du bruit. Celles-ci introduisent généralement un autre terme dans la fonction objectif qui permet de la modifier afin de minimiser l'effet de l'inhomogénéité d'intensité. La fonction objective de méthode FCM_S est définie comme suit:

$$J_{FCM_S} = \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| y_j - v_k \right\|^2 + S \quad (IV.7)$$

Où S peut prendre soit $S1$ (moyenne des pixels voisins de la zone sélectionnée) ou $S2$ (médiane des pixels voisins de la zone sélectionnée) comme première et seconde variantes de l'approche de segmentation FCM_S:

$$S1 = \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| \bar{y}_j - v_k \right\|^2 \quad (IV.8)$$

$$S2 = \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| \tilde{y}_j - v_k \right\|^2 \quad (IV.9)$$

La fonction d'appartenance est donnée par:

$$U_{kj} = \frac{\left(\left\| y_j - v_k \right\|^2 + \alpha \left\| \bar{y}_j - v_k \right\|^2 \right)^{\frac{-1}{m-1}}}{\sum_{i=1}^C \left(\left\| y_j - v_i \right\|^2 + \alpha \left\| \bar{y}_j - v_i \right\|^2 \right)^{\frac{-1}{m-1}}} \quad (IV.10)$$

Et les centres des clusters prototype sont calculés par:

$$v_k = \frac{\sum_{j=1}^N U_{kj}^m (y_j - \alpha \bar{y}_j)}{\left(1 + \alpha \right) \sum_{j=1}^N U_{kj}^m} \quad (IV.11)$$

Où le paramètre α contrôle le voisinage des pixels ($0 \leq \alpha \leq 1$: si $\alpha = 0$ on obtient le FCM standard), C désigne le nombre des classes et N étant donné que le nombre de pixels dans l'image donnée. De plus, le terme $\| y_j - v_k \|$ indique la mesure de similitude entre le pixel et le centre du cluster. La fonction objective est minimisée lorsque des valeurs d'appartenance élevées sont affectées à des points de données proches du centre de leurs clusters et de faibles valeurs d'appartenance à des points de données éloignés.

Pour des meilleures performances, l'idée de rassembler les deux propriétés de FCM_S1 et FCM_S2 permettre d'intégrer des informations spatiales plus détaillées et précisées. Ces informations spatiales incorporées prend en compte à la fois le niveau de gris et la relation

spatiale du pixel et garantit la robustesse au bruit et l'intensité d'homogénéité. L'approche IFCM_S introduit respectivement les propriétés moyenne et médiane en même temps, qui peuvent être utilisées pour remplacer le terme de voisinage par \bar{y}_j et \tilde{y}_j de la zone de filtrage sélectionnée. Dans la fonction objectives de la méthode IFCM_S : il existe des paramètres cruciaux α_1 et α_2 utilisés pour équilibrer entre robustesse au bruit et l'efficacité de conservation des détails de l'image, ils sont généralement choisis par une analyse expérimentale sur des images avec différentes types ou $0 \leq (\alpha_1 \text{ et } \alpha_2) \leq 1$: si $(\alpha_1 \text{ et } \alpha_2) = 0$ on obtient le FCM standard, si $\alpha_1 = 0$ et $\alpha_2 \neq 0$ on obtient le FCM_S2, si $\alpha_1 \neq 0$ et $\alpha_2 = 0$ on obtient le FCM_S1). La fonction d'objective est donnée par :

$$J_{IFCM_S} = \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| y_j - v_k \right\|^2 + \alpha_1 \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| \bar{y}_j - v_k \right\|^2 + \alpha_2 \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| \tilde{y}_j - v_k \right\|^2 \quad (IV.12)$$

La fonction d'appartenance est donnée par :

$$U_{kj} = \frac{\left(\|y_j - v_k\|^2 + \alpha_1 \|\bar{y}_j - v_k\|^2 + \alpha_2 \|\tilde{y}_j - v_k\|^2 \right)^{-1}}{\sum_{i=1}^C \left(\|y_j - v_i\|^2 + \alpha_1 \|\bar{y}_j - v_i\|^2 + \alpha_2 \|\tilde{y}_j - v_i\|^2 \right)^{-1}} \quad (IV.13)$$

Et les centres de classes sont donnés par :

$$v_k = \frac{\sum_{j=1}^N U_{kj}^m (y_j + \alpha_1 \bar{y}_j + \alpha_2 \tilde{y}_j)}{(1 + \alpha_1 + \alpha_2) \sum_{j=1}^N U_{kj}^m} \quad (IV.14)$$

Cette méthode en quelque sorte, elle souffre dans le cas de plusieurs pixels de haut bruit dans l'image et particulièrement dans la même fenêtre 3×3 . Donc, une technique améliorée est nécessaire pour résoudre les problèmes de cette dernière. La figure IV.8 montre les valeurs de \bar{y}_j et \tilde{y}_j calculées à partir d'une fenêtre 3×3 autour du pixel bruyant y_j .




Figure IV.8 : les propriétés moyenne et médiane d'un pixel bruyé.

1er Cas: le pixel central d'une fenêtre locale, représenté par la région A sur la figure (IV.8), est corrompu par le bruit, tandis que les autres pixels de la fenêtre sont homogènes. En analysant cet exemple par le calcul des deux valeurs moyenne et médiane. Ici, le terme spatial équilibre les valeurs d'appartenance du pixel bruyant central en tenant compte des informations provenant de ses pixels voisins sans bruit. Ainsi, l'influence du bruit sur le pixel central peut être réduite en incorporant des contraintes spatiales.

2eme Cas: le pixel central d'une fenêtre locale n'est pas un pixel bruyant et certains pixels dans sa fenêtre locale peuvent être corrompus par le bruit, comme illustré la figure (IV.11).

Par conséquent, les contraintes spatiales incorporées dans les fonctions objectives de (IV.7) et (IV.12) suppriment l'influence des pixels bruyants légèrement. Par contre l'algorithme proposé devient être plus robuste au bruit lourd et l'intensité d'inhomogénéité.

IV-3-5-3- Segmentation d'image basée sur ISFCM:

Les idées présentées dans IFCM_S [NAS 12] sont motivées pour proposer un nouvel algorithme ISFCM. L'inconvénient major de la méthode IFCM_S est relié au calcul du terme de voisinage à chaque étape d'itération, ce qui prend beaucoup de temps d'exécution. La taille et la position du masque (3×3) choisi par [NAS 12] et la manière d'utilisation de la distance euclidienne restent leur principale limitation. Les auteurs n'ont pas fourni aucune stratégie pour la sélection et le réglage des deux paramètres α_1 et α_2 d'une façon automatique et plus précise. Afin d'éviter ces inconvénients, plusieurs modifications ont été apportées à l'algorithme standard et qui sont présentées comme des variantes du FCM spatial. Donc une sélection appropriée du paramètre d'attraction de voisinage est nécessaire pour améliorer les performances de segmentation. De l'analyse comparative appliquée pour les deux paramètres α_1 et α_2 , nous pouvons conclure que la détermination de ces paramètres est en fait dépendante du bruit et de l'intensité d'inhomogénéité dans une certaine mesure. Il est très important de noter que α_1 et α_2 doivent être choisi suffisamment grand pour éliminer les pixels bruyants et assez petit pour conserver des détails plus fins de l'image.

A- Intégration des régions du filtre de Nagao:

Nous proposons dans cette thèse, un nouveau cadre FCM spatial et robuste qui incorpore l'information spatiale locale et l'information de niveau de gris pour segmenter les images cérébrales IRM. La méthode proposée intègre l'image extra filtrée moyenne et l'image filtrée médiane suivant des conditions et qui peuvent être calculées pour remplacer le terme de voisinage en utilisant un masque (5×5) qui possède un ensemble des 9 sous-fenêtres (régions) contenues dans un voisinage de (3×3) à chaque pixel. La figure IV.9 montre les neuf régions du filtre de Nagao utilisé dans cette recherche.

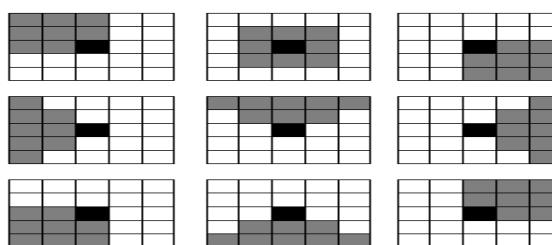


Figure IV.9 : Représentation des 9 régions du filtre de Nagao.

B- L'effet du terme de voisinage:

Pour les deux paramètres α_1 et α_2 seront remplacé d'une façon plus précise et doivent être contrôlé automatiquement l'effet du terme de voisinage par \bar{S}_j et \tilde{S}_j respectivement qui fait intervenir l'influence des pixels voisins et utilise les informations spatiales locales et les niveaux de gris pour équilibrer l'élimination du bruit et la préservation des détails. Les deux nouveaux paramètres \bar{S}_j et \tilde{S}_j sont définies comme suit :

$$\bar{S}_j = \min \{S_j^{(s)}\} \quad (\text{IV.15})$$

$$S_j^{(s)} = \frac{1}{N_R} \sum_{r \in N_j^{(s)}} \frac{\|y_j - y_r\|}{d_{rj} + 1} \quad (\text{IV.16})$$

$$\tilde{S}_j = \tilde{S}_j^{(s)} = \text{med} \left\{ \frac{\|y_j - y_r\|}{d_{rj+1}} \right\}_{r \in N_j^{(s)}} \quad (\text{IV.17})$$

Où $N_j^{(s)}$ représente l'ensemble des voisins qui existent dans chaque fenêtre autour de y_j et N_R est sa cardinalité, l'indice (s) varie de 1 à 9 et indique la région sélectionnée. d_{rj} représente la distance spatiale euclidienne entre les pixels y_j et y_r . Le terme d'information spatiale dépend principalement de deux problèmes de voisinage: la similitude d'intensité et la position spéciale relative entre l'élément observé et ses éléments voisins (voir la figure IV.10).

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(1)} = 69.31 ; \tilde{S}_j^{(1)} = 66.69$$

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(4)} = 69.64 ; \tilde{S}_j^{(4)} = 66.69$$

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(7)} = 72.59 ; \tilde{S}_j^{(7)} = 67.93$$

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(2)} = 70.42 ; \tilde{S}_j^{(2)} = 66.28$$

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(5)} = 74.18 ; \tilde{S}_j^{(5)} = 70.01$$

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(8)} = 72.92 ; \tilde{S}_j^{(8)} = 67.10$$

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(3)} = 69.62 ; \tilde{S}_j^{(3)} = 66.28$$

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(6)} = 73.22 ; \tilde{S}_j^{(6)} = 66.69$$

204	198	205	204	200
200	190	197	200	209
201	195	40	198	206
200	202	199	201	200
201	199	200	198	199

$$S_j^{(9)} = 72.08 ; \tilde{S}_j^{(9)} = 67.10$$

Figure IV.10 : Les valeurs moyenne et médiane d'un pixel bruité.

Dans le cas de présence d'un pixel bruité, la sélection optimale des valeurs médiane et moyenne et les deux paramètres \bar{S}_j et \tilde{S}_j sont représenté dans le tableau IV.2 suivant :

Tableau IV.2 : Sélection optimale des paramètres \bar{S}_j et \tilde{S}_j cas d'un pixel bruité.

(s)	$S_j^{(s)}$	$\tilde{S}_j^{(s)}$	y_j	\bar{y}_j	\tilde{y}_j
1	69.31	66.69	40	199	200
2	70.42	66.28	40	200	200
3	69.62	66.28	40	202	200
4	69.64	66.69	40	200	199
5	74.18	70.01	40	202	200
6	73.22	66.69	40	200	199
7	72.59	67.93	40	199	198
8	72.92	67.10	40	199	200
9	72.08	67.10	40	198	198

$$\bar{S}_j = \min \{ S_j^{(s)} \}$$

$$\bar{S}_j = 69.31$$

$$\tilde{S}_j = 66.69$$

$$\bar{y}_j = 199 \quad \tilde{y}_j = 200$$

Les principales améliorations que nous avons adoptées avec les contraintes d'inclusion spatiale entre les pixels voisins et le pixel central voisins qui permettent d'obtenir une segmentation plus précise dans le cas d'un pixel normal (voir figure IV.11).

<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(1)} = 1.67 ; \tilde{S}_j^{(1)} = 1.50$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199	<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(2)} = 1.58 ; \tilde{S}_j^{(2)} = 0.82$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199	<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(3)} = 1.74 ; \tilde{S}_j^{(3)} = 0.82$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									
<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(4)} = 0.81 ; \tilde{S}_j^{(4)} = 0.50$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199	<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(5)} = 2.08 ; \tilde{S}_j^{(5)} = 0.82$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199	<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(6)} = 1.00 ; \tilde{S}_j^{(6)} = 0.50$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									
<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(7)} = 1.70 ; \tilde{S}_j^{(7)} = 1.50$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199	<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(8)} = 1.08 ; \tilde{S}_j^{(8)} = 1.00$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199	<table border="1"> <tr><td>204</td><td>198</td><td>205</td><td>204</td><td>200</td></tr> <tr><td>200</td><td>190</td><td>197</td><td>200</td><td>209</td></tr> <tr><td>201</td><td>195</td><td>198</td><td>198</td><td>206</td></tr> <tr><td>200</td><td>202</td><td>199</td><td>201</td><td>200</td></tr> <tr><td>201</td><td>199</td><td>200</td><td>198</td><td>199</td></tr> </table> $S_j^{(9)} = 1.19 ; \tilde{S}_j^{(9)} = 0.82$	204	198	205	204	200	200	190	197	200	209	201	195	198	198	206	200	202	199	201	200	201	199	200	198	199
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									
204	198	205	204	200																																																																									
200	190	197	200	209																																																																									
201	195	198	198	206																																																																									
200	202	199	201	200																																																																									
201	199	200	198	199																																																																									

Figure IV.11 : Les valeurs moyenne et médiane d'un pixel normal.

Dans le cas de présence d'un pixel non bruité, la sélection optimale des valeurs médiane et moyenne et les deux paramètres de control \bar{S}_j et \tilde{S}_j sont représentés dans le tableau IV.3:

Tableau IV.3 : Sélection optimale des paramètres \bar{S}_j et \tilde{S}_j cas d'un pixel normal.

(s)	$S_j^{(s)}$	$\tilde{S}_j^{(s)}$	y_j	\bar{y}_j	\tilde{y}_j
1	1.67	1.50	40	199	200
2	1.58	0.82	40	200	200
3	1.74	0.82	40	202	200
4	0.81	0.50	40	200	199
5	2.08	0.82	40	202	200
6	1.00	0.50	40	200	199
7	1.70	1.50	40	199	198
8	1.08	1.00	40	199	200
9	1.19	0.82	40	198	198

En d'autres termes, si le pixel considéré est bruité, le poids du terme voisin doit être suffisamment grand pour biaiser l'appartenance du pixel par son voisinage immédiat; dans le cas contraire, ce poids doit être suffisamment petit pour ne pas altérer de manière significative l'appartenance du pixel et le conserver en tant que détail. Pour exploiter cette information spatiale locale, on a travaillé sur les pixels voisins qui possèdent des caractéristiques similaires ou la probabilité d'appartenir au même cluster est grande.

C- L'algorithme ISFCM:

L'objectif principal est d'optimiser la segmentation par classification considèrent le contexte spatial en minimisant la fonction objective par l'intégration de ses deux paramètres de contrôles \bar{S}_j et \tilde{S}_j . La fonction objective de l'algorithme ISFCM utilisant l'information spatiale locale et la distance euclidienne peut être résumée et formulée comme suit:

$$J'_{ISFCM} = \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| y_j - v_k \right\|^2 + \frac{1}{N_R} \sum_{k=1}^C \sum_{j=1}^N \bar{S}_j U_{kj}^m \sum_{r \in N_j} \left\| y_r - v_k \right\|^2 + \frac{1}{N_R} \sum_{k=1}^C \sum_{j=1}^N \tilde{S}_j U_{kj}^m \sum_{r \in N_j} \left\| y_r - v_k \right\|^2 \quad (IV.18)$$

$$\bar{S}_j = \min \{ S_j^{(s)} \}$$

$$\bar{S}_j = 0.81$$

$$\tilde{S}_j = 0.50$$

$$\bar{y}_j = 200 \quad \tilde{y}_j = 199$$

Le problème de minimisation dans l'équation (IV.18) peut être résolu en utilisant la méthode du multiplicateur de Lagrange. La minimisation de J_{ISFCM} peut être transformée en un problème de minimisation non contraint suivant:

$$J'_{ISFCM} = \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| y_j - v'_k \right\|^2 + \frac{1}{N_R} \sum_{k=1}^C \sum_{j=1}^N \bar{S}_j U_{kj}^m \sum_{r \in N_j} \|y_r - v'_k\|^2 + \frac{1}{N_R} \sum_{k=1}^C \sum_{j=1}^N \tilde{S}_j U_{kj}^m \sum_{r \in N_j} \|y_r - v'_k\|^2 + \sum_{j=1}^N \lambda_j (1 - \sum_{k=1}^C U_{kj}) \quad (IV.19)$$

En utilisant la dérivée première de J_{ISFCM} en fonction de U_{kj} et on reset le résultat au zéro, on obtient:

$$\left[m \cdot U_{kj}^{m-1} \cdot \left\| y_j - v'_k \right\|^2 + \frac{1}{N_R} \cdot m \cdot \bar{S}_j U_{kj}^{m-1} \sum_{r \in N_j} \|y_r - v'_k\|^2 + \frac{1}{N_R} \cdot m \cdot \tilde{S}_j U_{kj}^{m-1} \sum_{r \in N_j} \|y_r - v'_k\|^2 - \lambda_j \right]_{U_{kj}=U_{kj}^*} = 0 \quad (IV.20)$$

Puis, on résoudre l'équation (IV.20) pour trouver U_{kj}

$$U_{kj}^* = \left[\frac{\lambda_j}{m \cdot \left(\left\| y_j - v'_k \right\|^2 + \frac{1}{N_R} \bar{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 + \frac{1}{N_R} \tilde{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 \right)} \right]^{1/(m-1)} \quad (IV.21)$$

Sachant que $\sum_{k=1}^C U_{kj} = 1$ pour $\forall j \in (1 \dots N)$, on obtient :

$$\sum_{k=1}^C \left[\frac{\lambda_j}{m \cdot \left(\left\| y_j - v'_k \right\|^2 + \frac{1}{N_R} \bar{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 + \frac{1}{N_R} \tilde{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 \right)} \right]^{1/(m-1)} = 1 \quad (IV.22)$$

$$\lambda_j = \frac{m}{\left[\sum_{k=1}^C \left(\left\| y_j - v'_k \right\|^2 + \frac{1}{N_R} \bar{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 + \frac{1}{N_R} \tilde{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 \right) \right]^{1/(m-1)}} \quad (IV.23)$$

On remplace λ_j dans l'équation (IV.22), on aura :

$$U'_{kj} = \frac{\left(\left\| y_j - v'_k \right\|^2 + \frac{1}{N_R} \bar{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 + \frac{1}{N_R} \tilde{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 \right)^{-1/(m-1)}}{\sum_{k=1}^C \left(\left\| y_j - v'_k \right\|^2 + \frac{1}{N_R} \bar{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 + \frac{1}{N_R} \tilde{S}_j \sum_{r \in N_j} \|y_r - v'_k\|^2 \right)^{-1/(m-1)}} \quad (IV.24)$$

Avec le même procédé et après résolution pour v'_k , on a trouvé :

$$v'_k = \frac{\sum_{j=1}^N U_{kj}^m (y_j + \frac{1}{N_R} \bar{S}_j y_r + \frac{1}{N_R} \tilde{S}_j y_r)}{\sum_{j=1}^N (1 + \bar{S}_j + \tilde{S}_j) U_{kj}^m} \quad (IV.25)$$

Il est à noter que y_r pourrait être remplacé par la valeur moyenne \bar{y}_j ou la valeur médiane \tilde{y}_j des pixels voisins dans une fenêtre spécifiée autour de y_j qui dépendant des deux paramètres de control \bar{S}_j et \tilde{S}_j . Le calcul du terme de voisinage se fait une fois au début du processus de clustering, ce qui ne nécessite pas beaucoup de temps de traitement. En effet, nous aboutissons à une version étendu qui mettent à jour la matrice de partition et les centres de cluster en utilisant (IV.27) et (IV.28) respectivement. La fonction objective J_{ISFCM} est donnée par l'équation (IV.26) comme suit:

$$J_{ISFCM} = \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \left\| y_j - v_k \right\|^2 + \sum_{k=1}^C \sum_{j=1}^N \bar{S}_j U_{kj}^m \left\| \bar{y}_j - v_k \right\|^2 + \sum_{k=1}^C \sum_{j=1}^N \tilde{S}_j U_{kj}^m \left\| \tilde{y}_j - v_k \right\|^2 \quad (IV.26)$$

La fonction de mise à jour des degrés d'appartenance est :

$$U_{kj} = \frac{\left(\left\| y_j - v_k \right\|^2 + \bar{S}_j \left\| \bar{y}_j - v_k \right\|^2 + \tilde{S}_j \left\| \tilde{y}_j - v_k \right\|^2 \right)^{-1/(m-1)}}{\sum_{k=1}^C \left(\left\| y_j - v_k \right\|^2 + \bar{S}_j \left\| \bar{y}_j - v_k \right\|^2 + \tilde{S}_j \left\| \tilde{y}_j - v_k \right\|^2 \right)^{-1/(m-1)}} \quad (IV.27)$$

Et la fonction de mise à jour des centres de classes est :

$$v_k = \frac{\sum_{j=1}^N U_{kj}^m (y_j + \bar{S}_j \bar{y}_j + \tilde{S}_j \tilde{y}_j)}{\sum_{j=1}^N (1 + \bar{S}_j + \tilde{S}_j) U_{kj}^m} \quad (\text{IV.28})$$

Cette nouvelle approche est basée sur l'incorporation d'informations spatiales dans le processus de clustering qui permet d'élaborer d'une manière générale une mesure de variance et reflète les informations sur les objets voisins des données dans lesquelles la variance est plus élevée aux frontières entre les différentes structures. Ainsi, elle fournit une nouvelle source de preuves pour prendre la meilleure décision sur les résultats de la segmentation. Le principe général et les étapes de la mise en œuvre de cette approche ISFCM est illustré dans l'algorithme IV.4 qui consiste de huit étapes suivantes:

Algorithme IV.4 ISFCM

Entrée: le nombre de clusters C, l'image à segmenté converti en niveau de gris, degré de flou $m = 2$ et l'erreur convergente ϵ .

1. Lire l'image d'entrée et fixer les paramètres
2. Choisir la mesure de similarité d_{rj} comme distance spatiale euclidienne
3. Déterminer les nouveaux paramètres \bar{S}_j et \tilde{S}_j
4. Calculer les images filtrées moyenne \bar{y}_j et médiane \tilde{y}_j respectant eq (IV.27) et (IV.28)
5. Initialiser les centres des clusters $v_k^{(0)}$
6. $j = 1$
7. Répéter
 - a. $j = j + 1$
 - b. Calculer la matrice des degrés d'appartenance $U^{(j)}$ par l'intermédiaire des centres de cluster $v_k^{(j-1)}$ en utilisant l'équation (IV.27)
 - c. Attribuez chaque pixel à un cluster spécifique pour lequel l'appartenance est maximale
 - f. Mettre à jour les centres $v_k^{(j)}$ utilisant l'équation (IV.28)
8. Jusqu'à $\|v_k^{(j)} - v_k^{(j-1)}\| < \epsilon$

Sortie: Image segmentée à l'aide d'ISFCM

IV-3-5-4- Segmentation d'image basée sur ISKFCM:

La mesure de distance euclidienne est utilisée comme mesure de similarité, qui n'est pas efficace que pour les clusters sphériques à diamètres égaux et qui ne produit pas de meilleurs résultats pour les clusters généralisées. Cette hypothèse induit en erreur la classification des pixels situés au niveau des frontières entre les régions. Afin d'obtenir une mesure de similarité efficace entre les objets, la fonction de noyau est utilisée comme facteur de distance induite par le noyau (kernel) gaussien : a pour but de réduire les distorsions dans les pixels des images et de trouver la structure appropriée dans un ensemble de données de pixels non linéaires. Le terme d'information spatiale et les paramètres régularisés aussi sont ajoutés à la fonction objective. Pour cette raison on doit replacer la distance euclidienne par la distance de la fonction de noyau kernel dans la phase suivante pour obtenir des meilleurs résultats de

segmentation. Cette approche essaie de fournir la meilleure solution aux problèmes rencontrés et donc d'aider à prendre la bonne décision sur les images médicales IRM.

L'idée de base de cette méthode développée ISKFCM (Improved Spatial Kernel Fuzzy C-Means) est d'abord de mapper les données d'entrée dans un espace d'entités avec une dimension plus élevée via une transformation non linéaire, puis d'effectuer ISFCM dans cet espace d'entités. Ainsi, la structure de données complexe et séparable de façon non linéaire d'origine dans l'espace d'entrée peut devenir simple et séparable linéairement dans l'espace de caractéristique après la transformation non linéaire. La distance euclidienne $\|x - y\|^2$ est remplacée par la distance du noyau gaussien (kernel) $\|\varphi(x) - \varphi(y)\|^2$, qui est défini comme :

$$\|\varphi(x) - \varphi(y)\|^2 = K(x, x) + K(y, y) - 2K(x, y) \quad (\text{IV.29})$$

Où le noyau gaussien est adopté comme une fonction de kernel :

$$K(x, y) = \exp(-\|x - y\|^2/\sigma^2) \quad (\text{IV.30})$$

En remplaçant l'équation (IV.30) dans l'Eq (IV.29), on obtient :

$$\|\varphi(x) - \varphi(y)\|^2 = 2(1 - K(x, y)) \quad (\text{IV.31})$$

Où le terme σ^2 est la variance et x' est la valeur moyenne de la région sélectionnée, qui est donné comme suit :

$$\sigma^2 = \sum_{j=1}^n \|y_j - x'\|^2/n \quad \text{et} \quad x' = \sum_{j=1}^n y_j/n \quad (\text{IV.32})$$

Les deux termes de control \bar{S}_j^* et \tilde{S}_j^* dépendent de l'information spatiale des pixels voisins y_r et la distance du noyau (kernel) gaussien $\|\varphi(y_j) - \varphi(y_r)\|^2$ et ils devient :

$$\bar{S}_j^* = \min \{S_j^{*(s)}\} \quad (\text{IV.33})$$

$$S_j^{*(s)} = \frac{1}{N_R} \sum_{r \in N_j^{(s)}} \frac{\|y_j - y_r\|}{\|\varphi(y_j) - \varphi(y_r)\|^2 + 1} \quad (\text{IV.34})$$

$$\tilde{S}_j^* = \bar{S}_j^* = \text{med} \left\{ \frac{\|y_j - y_r\|}{\|\varphi(y_j) - \varphi(y_r)\|^2 + 1} \right\}_{r \in N_j^{(s)}} \quad (\text{IV.35})$$

Grâce à la substitution du kernel et d'après l'équation (IV.31), la fonction objective de l'approche proposée ISKFCM est donnée par :

$$J_{\text{ISKFCM}} = \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m \|\varphi(y_j) - \varphi(v_k)\|^2 + \sum_{k=1}^C \sum_{j=1}^N \bar{S}_j^* U_{kj}^m \|\varphi(\bar{y}_j) - \varphi(v_k)\|^2 + \sum_{k=1}^C \sum_{j=1}^N \tilde{S}_j^* U_{kj}^m \|\varphi(\tilde{y}_j) - \varphi(v_k)\|^2 \quad (\text{IV.36})$$

En utilisant l'équation (IV.31) dans l'Eq (IV.36), on obtient :

$$J_{\text{ISKFCM}} = 2 \sum_{k=1}^C \sum_{j=1}^N U_{kj}^m (1 - K(y_j, v_k)) + 2 \sum_{k=1}^C \sum_{j=1}^N \bar{S}_j^* U_{kj}^m (1 - K(\bar{y}_j, v_k)) + 2 \sum_{k=1}^C \sum_{j=1}^N \tilde{S}_j^* U_{kj}^m (1 - K(\tilde{y}_j, v_k)) \quad (\text{IV.37})$$

La fonction objective J_{ISKFCM} est minimisée en utilisant la méthode lagrangienne L_{ISKFCM} comme ci-dessous :

$$L_{\text{ISKFCM}}(U, V) = J_{\text{ISKFCM}}(U, V) + \sum_{j=1}^n \lambda_j (1 - \sum_{k=1}^C U_{kj}) \quad (\text{IV.38})$$

Pour obtenir le degré d'appartenance pour chaque pixel, nous considérons d'abord le terme $\frac{\partial L_{ISKFCM}(U,V)}{\partial U_{kj}} = 0$, puis nous obtenons :

$$2 \cdot m \cdot U_{kj}^{m-1} \cdot (1 - K(y_j, v_k)) + 2 \cdot m \cdot \bar{S}_j^* U_{kj}^{m-1} \cdot (1 - K(\bar{y}_j, v_k)) + 2 \cdot m \cdot \tilde{S}_j^* U_{kj}^{m-1} \cdot (1 - K(\tilde{y}_j, v_k)) - \lambda_j = 0 \quad (IV.39)$$

Avec le même procédé pour $\frac{\partial L_{ISKFCM}(U,V)}{\partial \lambda_j} = 0$, on obtient :

$$1 - \sum_{k=1}^C U_{kj} = 0 \quad (IV.40)$$

Depuis l'équation (IV.40), on a :

$$U_{kj} = \left[\frac{\lambda_j}{m \cdot 2 \cdot ((1 - K(y_j, v_k)) + \bar{S}_j^* (1 - K(\bar{y}_j, v_k)) + \tilde{S}_j^* (1 - K(\tilde{y}_j, v_k)))} \right]^{1/(m-1)} \quad (IV.41)$$

On remplace l'équation (IV.41) dans Eq (IV.39), on trouve:

$$\left(\frac{\lambda_j}{m} \right)^{1/(m-1)} = \frac{1}{2 \sum_{k=1}^C ((1 - K(y_j, v_k)) + \bar{S}_j^* (1 - K(\bar{y}_j, v_k)) + \tilde{S}_j^* (1 - K(\tilde{y}_j, v_k)))^{-1/(m-1)}} \quad (IV.42)$$

Substitue l'équation (IV.42) dans Eq (IV.41), on obtient alors l'équation générale de la fonction d'appartenance comme:

$$U_{kj} = \frac{((1 - K(y_j, v_k)) + \bar{S}_j^* (1 - K(\bar{y}_j, v_k)) + \tilde{S}_j^* (1 - K(\tilde{y}_j, v_k)))^{-1/(m-1)}}{\sum_{k=1}^C ((1 - K(y_j, v_k)) + \bar{S}_j^* (1 - K(\bar{y}_j, v_k)) + \tilde{S}_j^* (1 - K(\tilde{y}_j, v_k)))^{-1/(m-1)}} \quad (IV.43)$$

En minimisant la fonction objective par la dérivée partielle de L_{ISKFCM} par rapport à v_k et en la mettant $\frac{\partial L_{ISKFCM}(U,V)}{\partial v_k} = 0$, nous avons :

$$\sum_{j=1}^N U_{kj}^m K(y_j, v_k) (y_j - v_k) + \sum_{j=1}^N U_{kj}^m \bar{S}_j^* K(\bar{y}_j, v_k) (\bar{y}_j - v_k) + \sum_{j=1}^N U_{kj}^m \tilde{S}_j^* K(\tilde{y}_j, v_k) (\tilde{y}_j - v_k) = 0 \quad (IV.44)$$

À partir de l'équation (IV.44), en résolvant le problème de minimisation pour v_k , nous obtenons les centres de cluster comme:

$$v_k = \frac{\sum_{j=1}^N U_{kj}^m (K(y_j, v_k) y_j + \bar{S}_j^* K(\bar{y}_j, v_k) \bar{y}_j + \tilde{S}_j^* K(\tilde{y}_j, v_k) \tilde{y}_j)}{\sum_{j=1}^N U_{kj}^m (K(y_j, v_k) + \bar{S}_j^* K(\bar{y}_j, v_k) + \tilde{S}_j^* K(\tilde{y}_j, v_k))} \quad (IV.45)$$

Cette sous-section présente le principe de la méthode développée ; un nouveau procédé de C-Moyennes floue spatiale basée sur la distance modifiée induite par la fonction du noyau Kernel pour traiter les problèmes de segmentation des images cérébrales IRM qui sont gravement affectés par la mauvaise qualité et le bruit lourd et l'intensité d'inhomogénéité. La nouvelle approche de voisinage, les deux nouveaux paramètres de contrôle et la distance de kernel sont ajoutés au FCM modifié pour améliorer le processus de segmentation d'image.

Une fonction d'appartenance floue modifiée a été formulée qui inclut la notion du kernel gaussien avec les informations locales spatiales. Par conséquent, trois termes d'appartenance sont introduites ici; l'un peut être traité comme local moyenne et l'autre comme local médiane et un autre comme global qui sont générés par l'algorithme de clustering FCM. Ces termes génèrent finalement une fonction d'appartenance combinée pondérée pour évaluer les valeurs d'appartenance finales et les centres de cluster de l'algorithme ISKFCM.

Le principe général et les étapes de mise en œuvre de cet approche est illustré dans l'algorithme IV.5 qui consiste de huit étapes :

Algorithme IV.5 ISKFCM

Entrée: le nombre de clusters C, image en niveau de gris, degré de flou $m = 2$ et l'erreur convergente ε .

1. Lire l'image d'entrée et fixer les paramètres
2. Choisir la mesure de similarité $\|\varphi(\mathbf{y}_j) - \varphi(\mathbf{y}_r)\|^2$ comme distance du fonction de noyau (kernel) gaussien
3. Déterminer les nouveaux paramètres $\bar{\mathbf{S}}_j^*$ et $\tilde{\mathbf{S}}_j^*$
4. Calculer les images filtrées moyenne $\bar{\mathbf{y}}_j$ et médiane $\tilde{\mathbf{y}}_j$ respectant eq (IV.43) et (IV.45)
5. Initialiser les centres des clusters $\mathbf{v}_k^{(0)}$
6. $j = 1$
7. Répéter
 - a. $j = j + 1$
 - b. Calculer la matrice des degrés d'appartenance $\mathbf{U}^{(j)}$ par l'intermédiaire des centres de cluster $\mathbf{v}_k^{(j-1)}$ en utilisant l'équation (IV.43)
 - c. Attribuez chaque pixel à un cluster spécifique pour lequel l'appartenance est maximale
 - f. Mettre à jour les centres $\mathbf{v}_k^{(j)}$ en utilisant l'équation (IV.45)
8. Jusqu'à $\|\mathbf{v}_k^{(j)} - \mathbf{v}_k^{(j-1)}\| < \varepsilon$

Sortie: Image segmentée à l'aide d'ISFCM

IV-3-6- Défuzzification et extraction de la région d'intérêt:

Une étape très importante est nécessaire dans cette phase, on parle alors de « Défuzzification ». La Défuzzification dans l'analyse de cluster flou, est une procédure pour convertir la matrice de partition floue U en une partition nette qui est ensuite utilisée pour déterminer les informations de classification des objets de données. Lorsque l'on ne souhaite pas mettre en évidence les pixels où les degrés d'appartenance sont approximativement les mêmes pour chaque classe, une façon naturelle de procéder est de considérer que la classe finale d'un pixel est celle pour laquelle le degré d'appartenance est maximal :

$$\forall k \in [1, n] x_k \in C_j \Leftrightarrow (U_{jk} > U_{ik} \forall i \neq j \in [1, c]) \quad (IV.46)$$

Le processus de la défuzzification se fait après la dernière itération des deux l'algorithme ISFCM et ISKFCM proposées. Une approche populaire pour la défuzzification de la partition floue est l'application du principe du degré d'appartenance maximale (DAM). L'objet de données x_i est affecté à la classe de v_k si et seulement si son degré d'appartenance au cluster v_k est le plus grand, c'est-à-dire :

$$U_{ik} = \max \{ U_{jk} \} \quad (IV.47)$$

Si l'ensemble de données n'est pas uniforme, cette technique peut effectuer des affectations de cluster incorrectes, en particulier des objets de données marginaux de grands clusters dans l'image. Pour résoudre ce problème, nous proposons une méthode basée sur les probabilités pour la défuzzification de la partition de cluster floue, utilisant la partition floue et la probabilité bayésienne pour générer un modèle probabiliste des distributions de données, et applique le modèle pour produire les informations de classification. Pour créer notre propre modèle probabiliste des distributions de données à l'aide d'une partition floue, nous avons basé la méthode de [LE 11].

Étant donné une matrice de partition floue U , le vecteur $U_k = \{u_{ki}\}$ $i = 1..n$, $k = 1..c$, est un modèle de possibilité de la distribution des données de v_k sur X . Supposons que P_k soit la distribution de probabilité de v_k sur X , où $P_{k1} \geq P_{k2} \geq P_{k3} \geq \dots \geq P_{kn}$. On associe à P_k une distribution de possibilité U_k de v_k sur X telle que u_{ki} est la possibilité de x_i , où

$$u_{kn} = n \times P_{kn} \quad (\text{IV.48})$$

$$u_{ki} = i(P_{ki} - P_{k,i+1}) + u_{k,i+1}, i=n-1, \dots, 1 \quad (\text{IV.49})$$

En inversant les deux équations (IV.48) et (IV.49), nous obtenons la transformation d'une distribution de possibilité en une distribution de probabilité [LE 12]. Supposons que U_k est ordonné de la même manière avec P_k sur X : $u_{k1} \geq u_{k2} \geq u_{k3} \geq \dots \geq u_{kn}$

$$P_{kn} = u_{kn}/n \quad (\text{IV.50})$$

$$P_{ki} = P_{k,i+1} + (u_{ki} - u_{k,i+1})/i \quad (\text{IV.51})$$

P_k est une distribution de probabilité approximative de v_k sur X , et $P_{ki} = P(x_i|v_k)$. Dans les ensembles de données réels, pour un cluster v_k , les points de données proviennent généralement de différentes distributions aléatoires. Parce qu'ils se regroupent en v_k , ils ont tendance à suivre la distribution normale de v_k estimée comme suit :

$$\sigma_k = \sqrt{\sum_{i=1}^n P_{ki} \|x_i - v_k\|^2} \quad (\text{IV.52})$$

$$P_n(x_i|v_k) = \left(\frac{1}{(2\pi)^{1/2} \times \sigma_k} \times e^{-\frac{\|x_i - v_k\|^2}{2\sigma_k^2}} \right)^{-1} \quad (\text{IV.53})$$

Nous utilisons le modèle probabiliste comme dans les équations (IV.52) et (IV.53) pour la défuzzification de la partition floue. L'objet de données x_i est affecté à la classe de centroïde de v_k , où :

$$P(v_k|x_i) = \max\{P(v_l|x_i)\} \text{ avec } l=1 \dots c \quad (\text{IV.54})$$

$$P(v_k|x_i) = P(x_i, v_k) / P(x_i) = P(x_i|v_k) \times P(v_k) / P(x_i) \quad (\text{IV.55})$$

$$P(v_k|x_i) = \max\{P(x_i|v_l) \times P(v_l)\} \text{ avec } l=1 \dots c \quad (\text{IV.56})$$

Toutes les images d'entrée pondérées en T1, T2 et PD subissent les étapes algorithmiques de défuzzification et extraction de la région d'intérêt pour obtenir une image de sortie résultante efficace. La conception de cet outil et les résultats de segmentation sont utilisés pour l'extraction exacte de la zone d'intérêt. L'algorithme de défuzzification proposé (Algorithme IV.6) est mentionné comme suit:

Algorithme IV.6 Défuzzification de la partition de cluster floue

Entrée: le nombre optimal de cluster c , les centres de cluster $V = \{v_i\}$, $i = 1..c$, la matrice de partition $U = \{u_{ki}\}$, $i = 1..n$, $k = 1..c$.

1. Lire les centres de cluster V et la matrice de partition U
2. Convertir les distributions de possibilité dans U en distributions de probabilité en utilisant l'équation (IV.49) et (IV.51)
3. Construire un modèle probabiliste des distributions de données en utilisant les deux équations (IV.52) et (IV.53)
4. Appliquer le modèle pour produire les informations de classification pour chaque point de données à l'aide de l'équation (IV.56).

Sortie: La classification de $x_i \in X$, $i = 1..n$.

IV-3-7- Ségrégation et calcule de la zone tumorale:

Une fois la région tumorale extraite soit identifiée, La zone est calculée en utilisant l'algorithme IV.3 qui aide à estimer la région tumorale de la manière la plus efficace avec peu de temps d'exécution. La méthode de binarisation est utilisée pour calculer la zone tumorale. Elle permet de détecter la taille de la tumeur en calculant le nombre de pixels blancs (digit 0) dans l'image binaire. C'est l'image ayant seulement deux valeurs soit noir (0) ou blanc (1). Ici, [256x256] est une taille d'image maximale. La résolution horizontale de l'image de sortie est de 96 dpi. La résolution verticale de l'image de sortie est de 96 dpi. Depuis cette résolution horizontale et verticale, on peut trouver la zone d'un seul pixel [KOW 12].

Algorithme IV.7 Raisonnement Approximative

Entrée: Image I convertie en niveau de gris

1. Lire l'image I et fixer les paramètres d'entrée
2. Si la taille de l'image I est 256X256 alors passez à l'étape 2 sinon redimensionner l'image I Pixels = Largeur (L) x Hauteur (H) = 256X256;
3. Convertir l'image I en image binaire sous la forme suivante:

$$I = \sum_{L=0}^{255} \sum_{H=0}^{255} [f(0) + f(1)]$$
 avec $f(0)$ = pixel noir (digit 0), $f(1)$ = pixel blanc (digit 1)
4. Calculer le nombre P des pixels blanc : $P = \sum \sum [f(1)]$
5. Sachant que : 1 Pixel = 0.264 mm
6. Calculer la taille de la tumeur S en utilisant l'équation suivante :

$$S = [(\sqrt{P}) * 0.264] \text{ mm}^2$$

Sortie: La surface calculée de la tumeur S

Des séquences d'images cérébrales IRM axiales pondérée en T1 et T2 avec présence de tumeur ont été utilisées pour diagnostiquer le patient. Les méthodes proposées ISFCM et ISKFCM ont réussi à identifier la région tumorale avec des variations de niveaux d'intensité. L'identification exacte de la région tumorale et les résultats expérimentaux sont visualisée et illustrée sous forme tableau IV.4. Il est visiblement évident que l'algorithme de segmentation ISKFCM fonctionne avec compétence très élevée pour atteindre la partie tumorale.

Tableau IV.4 : Extraction de la région tumorale utilisant ISFCM et ISKFCM.

N° Images	Ensemble de données IRM	Résultat de l'ISFCM			Résultat de l'ISKFCM		
		Zone tumorale	Nombre de pixels	Taille de la tumeur [mm ²]	Zone tumorale	Nombre de pixels	Taille de la tumeur [mm ²]
IRM_001			738	7.17		549	6.82
IRM_002			1339	9.66		1529	10.33
IRM_003			4624	17.95		4617	17.94
IRM_004			1393	9.85		1406	9.89
IRM_005			267	4.31		269	4.32
IRM_006			1812	11.24		1817	11.25
IRM_007			1359	9.73		1319	9.58
IRM_008			1283	9.45		1277	9.43
IRM_009			4134	16.97		3981	16.65
IRM_010			1201	9.14		1129	8.87

IV-3-8- Extraction de caractéristiques de la zone tumorale:

Une fois que les tumeurs candidats ont été détectées à partir des images IRM, l'étape suivante consiste à mettre en place un vecteur de fonctionnalité complet pour chacun des candidats afin de les différencier. Les caractéristiques sont extraites de l'image segmentée à l'aide de la technique GLCM (Gray Level Co-occurrente Matrix) qui permet de représenter ces caractéristiques des objets d'intérêt d'une manière en mesurant certaines propriétés ou entités. Les caractéristiques d'image de premier ordre telles que la moyenne, la variance, l'écart type et l'asymétrie sont prises en compte et extraites. De plus, les caractéristiques d'image du second ordre telles que le contraste, la corrélation, l'énergie, l'homogénéité et l'entropie sont extraites pour cette recherche empirique. Les résultats (vecteurs de caractéristiques) sont transmis à la phase suivante pour le processus de classification (classificateurs). Les cinq caractéristiques texturales du second ordre sont estimées à partir des formules suivantes :

A- Contraste:

Le contraste local d'une image est défini comme la séparation entre la zone la plus sombre et la zone la plus lumineuse. Il est mesuré par la fonction suivante qui devrait être faible si les valeurs d'intensité du pixel sont similaires.

$$\text{Contraste} = \sum_{i,j=0}^{n-1} p(i,j)(i-j)^2 \quad (\text{IV.57})$$

Où n est le nombre de niveaux de gris et $p(i, j)$ représente la matrice de probabilité de l'image d'origine.

B- Corrélation:

La relation statistique entre les deux pixels voisins est indiquée par cette caractéristique ou la corrélation est calculée en ce que l'on appelle le coefficient de corrélation, qui varie entre -1 et +1.

$$\text{Corrélation} = \frac{\sum_i \sum_j (i-j)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (\text{IV.58})$$

Où $\mu_x, \mu_y, \sigma_x, \sigma_y$ sont les deux moyennes et les écarts-types de l'image d'entrée dans l'ordre ligne et colonne.

C- Homogénéité:

L'homogénéité est définie comme la qualité ou l'état d'homogénéité.

$$\text{Homogénéité} = \sum_{i,j=0}^{n-1} \frac{p(i,j)}{1+(i-j)^2} \quad (\text{IV.59})$$

D- Entropie:

L'entropie est une mesure de l'incertitude dans une variable aléatoire. Elle devrait être élevée si les niveaux de gris sont répartis de façon aléatoire dans toute l'image.

$$\text{Entropie} = - \sum_i \sum_j p(i,j) \log(p(i,j)) \quad (\text{IV.60})$$

E- Energie:

Elle est connue comme l'uniformité ou le deuxième moment angulaire et elle fournit la somme des éléments carrés comme suit :

$$\text{Energie} = \sum_{i,j=0}^{n-1} p(i,j)^2 \quad (\text{IV.61})$$

Les valeurs des caractéristiques pour différentes la région tumorale réelles utilisées pour l'application de segmentation sont également analysées dans ce travail. En utilisant dix images IRM en entrée de notre système proposé, certain caractéristiques de ces images sont extraites et présentées dans les deux tableaux IV.5 et IV.6 suivants :

Table IV.5 : Caractéristiques extraites après l'exécution de l'ISFCM

N°	Images cérébrales IRM	Corrélation	Contraste	Entropie	Energie	Homogénéité
1	IRM_001	0.0076	0.9433	0.8761	0.9974	0.3394
2	IRM_002	0.0096	0.9288	0.8505	0.9948	0.3848
3	IRM_003	0.0161	0.9135	0.8011	0.9922	0.4755
4	IRM_004	0.0119	0.9398	0.8021	0.9948	0.4839
5	IRM_005	0.0147	0.9574	0.6477	0.993	0.7514
6	IRM_006	0.0128	0.9396	0.7775	0.9937	0.5267
7	IRM_007	0.0227	0.9346	0.6512	0.9901	0.736
8	IRM_008	0.0131	0.9106	0.8463	0.9939	0.3899
9	IRM_009	0.0072	0.9245	0.9041	0.997	0.2735
10	IRM_010	0.0143	0.9118	0.8475	0.9953	0.3913

Table IV.6 : Caractéristiques extraites après l'exécution de l'ISKFCM

N°	Images cérébrales IRM	Corrélation	Contraste	Entropie	Energie	Homogénéité
1	IRM_001	0.0079	0.9439	0.8783	0.9949	0.3390
2	IRM_002	0.0103	0.9284	0.8515	0.9947	0.3846
3	IRM_003	0.0165	0.9138	0.8022	0.9932	0.4754
4	IRM_004	0.0117	0.9407	0.8036	0.9949	0.4840
5	IRM_005	0.0154	0.9581	0.6470	0.9937	0.7510
6	IRM_006	0.0121	0.9413	0.7783	0.9941	0.5262
7	IRM_007	0.0223	0.9340	0.6519	0.9912	0.7361
8	IRM_008	0.0145	0.9114	0.8465	0.9940	0.3893
9	IRM_009	0.0084	0.9242	0.9048	0.9976	0.2729
10	IRM_010	0.0157	0.9123	0.8480	0.9957	0.3911

Les caractéristiques sont représentées sur les figures IV.12 ,13 et ils sont suffisamment diversifiés, ce qui contribue à une segmentation réussie des images médicales IRM.

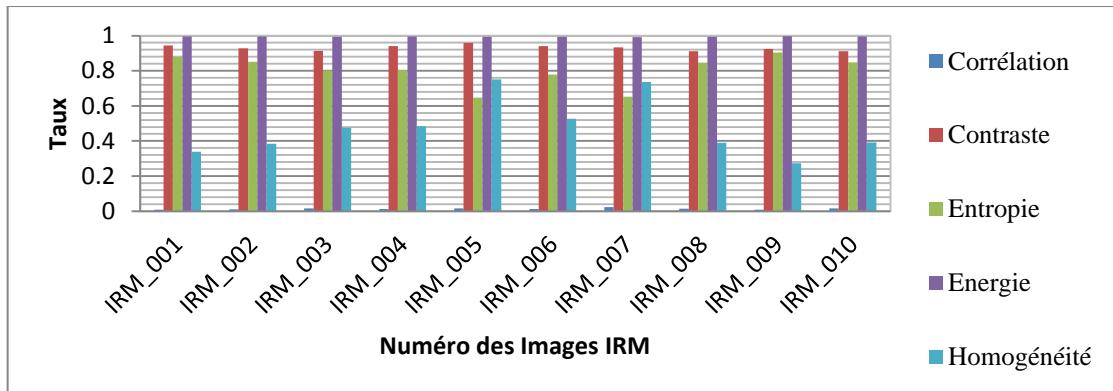


Figure IV.12 : Taux des caractéristiques extraites utilisant ISFCM.

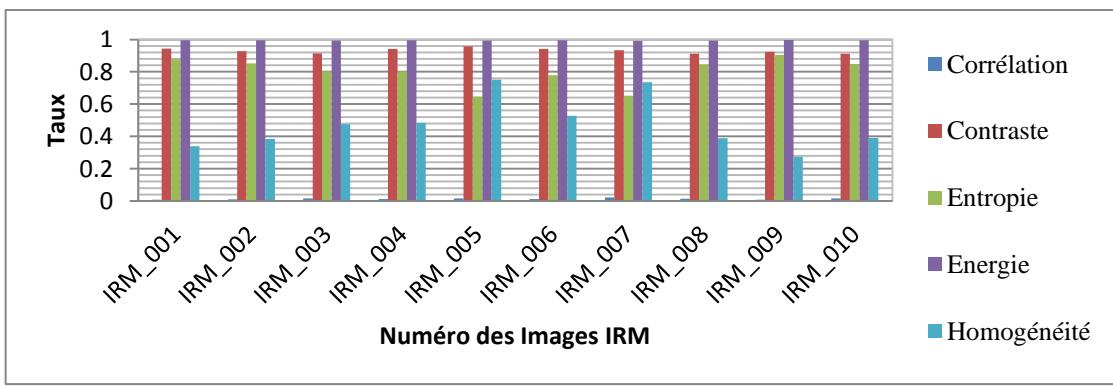


Figure IV.13 : Taux des caractéristiques extraites utilisant ISKFCM.

IV-4- Résultats expérimentaux obtenus:

Dans cette section, le travail expérimental est démontré pour prouver et estimer l'efficacité et l'efficience des méthodes développées. De nombreuses expériences ont été essayées, seuls les très bons résultats sont sélectionnés pour être présentées ici. Pour l'analyse comparative, les méthodes existantes telles que FCM, GFCM, IFCM_S1, IFCM_S2, RSCFCM, KGFCM, GKFCM, CsKFCM et les méthodes proposées ISFCM, ISKFCM sont considérées et appliquées sur trois types d'images: des images synthétiques, des images IRM simulées et des images IRM réelles. Les expériences sont effectuées sur un processeur Intel(R) Core™ i3 CPU avec une vitesse de 2,4 GHz et 4 Go de RAM. Le logiciel utilisé pour l'implémentation de ces algorithmes est MATLAB (version 8.5) Math Works Laboratory.

IV-4-1- Sur des images synthétiques:

Des images synthétiques de taille 256×256 sont utilisées pour tester l'efficacité et la robustesse des algorithmes proposés en termes de segmentation. La première image comprend quatre classes (les quatre valeurs d'intensité sont respectivement 0, 117, 185 et 255) et la deuxième image comprend trois classes (les trois valeurs d'intensité sont respectivement 0, 117 et 255). Les deux images synthétiques sont représentées sur la figure IV.14 (a) et IV.16 (a). Ces images sont corrompues respectivement par le bruit mixte (Gaussian 0.04 et sel et poivre 0.04) et un bruit gaussien avec une densité du bruit 0.05. Les Figues IV.14 (c-h) et IV.16 (c-h) montrent les résultats de segmentation obtenus pour différents algorithmes.

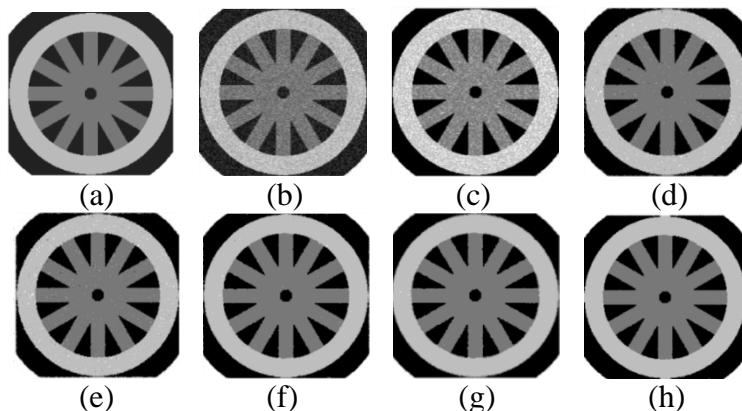


Figure IV.14 : Comparaison des résultats de segmentation sur des images synthétiques : (a) image original, (b) image corrompu par un bruit Gaussien de densité 0.05, (c) FCM, (d) KGFCM, (e) GKFCM, (f) CsKFCM, (g) ISFCM, (h) ISKFCM.

Table IV.7 : Segmentation Accuracy (SA%) en présence du Bruit Gaussien

N°	Méthodes	Densité du Bruit Gaussien					
		0.00	0.02	0.04	0.06	0.08	0.10
1	FCM	100	92.89	84.22	78.19	74.06	70.52
2	GFCM	99.77	96.76	89.95	84.02	79.55	75.81
3	IFCM_S1	99.99	98.79	94.36	89.80	85.76	82.39
4	IFCM_S2	99.99	99.07	95.41	90.98	87.37	84.07
5	RSCFCM	100	99.8	99.29	98.09	96.47	96.15
6	KGFCM	99.99	99.71	99.46	98.28	97.42	94.14
7	GKFCM	100	99.84	99.42	98.51	98.47	96.17
8	CsKFCM	100	100	99.84	99.76	98.92	98.40
9	ISFCM	100	99.55	99.55	99.46	99.42	99.08
10	ISKFCM	100	99.61	99.57	99.54	99.46	99.29

Les résultats sont analysés en termes d'efficacité de segmentation et le rapport Segmentation Accuracy (SA%) est utilisée pour prouver la précision de la segmentation proposé par rapport aux autres méthodes existantes. Plus la valeur de l'indice de SA est élevé, plus les résultats de segmentation sont meilleurs. Une brève analyse des taux de segmentation des techniques proposées sont également rapportée dans le tableau IV.7 ci-dessus.

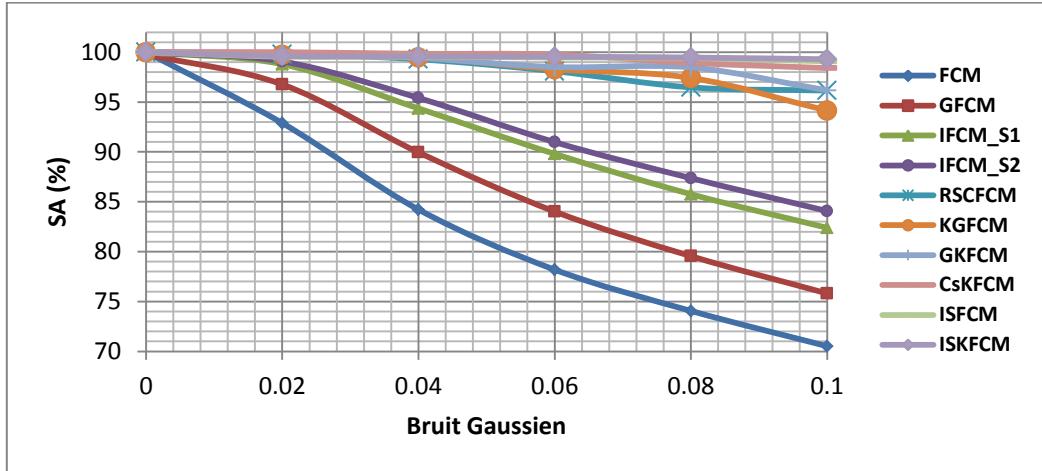


Figure IV.15 : Représentation graphique de SA(%) [Cas d'un bruit gaussien].

Pour valider les performances de l'algorithme proposé en présence de bruit, le bruit de type mixte est ajouté à l'image synthétique pour émuler la distribution réelle du bruit. La figure IV.16 (b) montre l'image corrompue avec le bruit mixte (Gaussian 0.04 et sel et poivre 0.04). Les figures IV.16 (c à h) montre clairement les résultats expérimentaux obtenus par les algorithmes FCM, KGFCM, GKFCM, CsKFCM, ISFCM et ISKFCM respectivement.

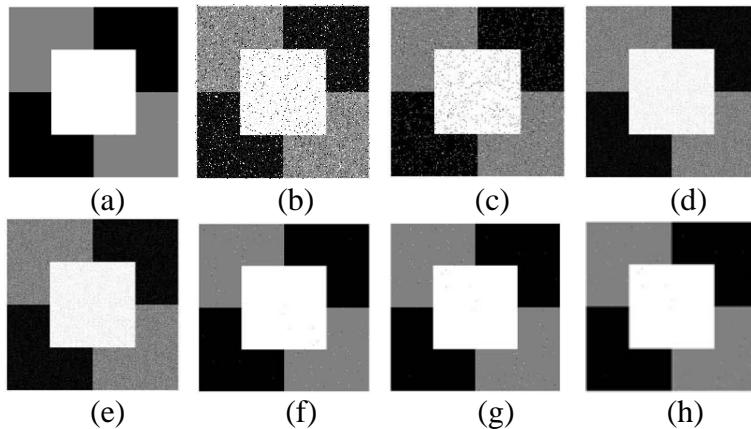


Figure IV.16 : Comparaison des résultats de segmentation sur des images synthétiques : (a) image originale, (b) image corrompue par un bruit mixte, (c) FCM, (d) KGFCM, (e) GKFCM, (f) CsKFCM, (g) ISFCM, (h) ISKFCM.

D'après le tableau IV.8 ci-dessous, on constate clairement que les performances de nos méthodes proposées sont appréciables en termes d'efficacité de segmentation SA % et de rapport de correspondance. Les performances de l'algorithme FCM, GFCM, IFCM_S1 et IFCM_S2 se dégrade. Les algorithmes de clustering KGFCM et GKFCM limitent leurs performances à mesure que le niveau de variance du bruit augmente. Par contre les algorithmes ISFCM et ISKFCM produisent des résultats supérieurs par rapport à CsKFCM en raison de l'impact des informations spatiales de voisinage et le type de la distance introduite.

Table IV.8 : Segmentation Accuracy (SA%) en présence du Bruit Mixe

N°	Méthodes	Densité de Bruit Mixe					
		0.00	0.02	0.04	0.06	0.08	0.10
1	FCM	100	92.77	84.01	77.85	73.67	70.09
2	GFCM	99.77	96.64	89.74	83.68	79.16	75.38
3	IFCM_S1	99.99	98.67	94.15	89.46	85.37	81.96
4	IFCM_S2	99.99	98.95	95.26	90.64	86.98	83.64
5	RSCFCM	100	99.08	97.23	95.33	93.87	91.22
6	KGFCM	99.99	99.40	99.06	97.75	96.84	93.52
7	GKFCM	100	99.21	98.51	97.05	95.13	94.93
8	CsKFCM	100	98.67	97.91	96.45	94.73	92.01
9	ISFCM	100	99.37	99.24	98.85	98.69	98.45
10	ISKFCM	100	99.49	99.36	98.90	98.82	98.67

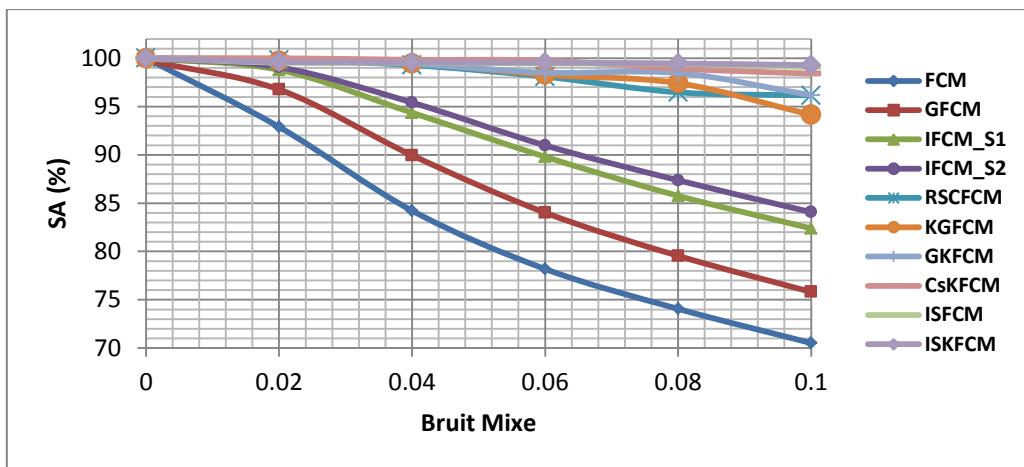


Figure IV.17 : Représentation graphique de SA(%) [Cas d'un bruit mixe].

IV-4-2- Sur des images IRM simulées:

Pour cette expérience, nous avons également utilisé la base de données des images IRM simulées de Brain web qui est produites par un simulateur IRM basé sur les équations des modèles de magnétisation nucléaire. Ces images sont utilisées pour être segmenté en quatre classes: matière grise (MG), matière blanche (MB), liquide céphalo-rachidien (LCR) et le fond. Les images simulées présentent différents niveaux de bruit (5%, 7% et 9%) et champs de polarisation (20%, 40% et 60%). Nous avons utilisé plusieurs combinaisons de données d'images cérébrales simulées pondérées en T1 pour cette expérience. Le premier ensemble contient des images de 5% de bruit, 20% d'inhomogénéité alors que le second ensemble est de 7% de bruit et 40% d'inhomogénéité. Le troisième ensemble contient des images de 9% de bruit, 60% d'inhomogénéité.

Une observation visuelle des résultats a clairement révélé la nature supérieure de l'approche proposée en termes d'efficacité de segmentation. Dans toutes les images testées, l'ISKFCM est capable de segmenté l'image avec des qualités importantes. L'une des raisons est que la méthode développée introduit des paramètres de contrôle spatial du voisinage optimal, ce qui a permis d'améliorer les performances. Les résultats ci-dessous révèlent qu'il existe une variation significative dans les performances des approches étudiées et l'ISFCM et ISKFCM. Les résultats de segmentation de différentes régions tissulaires et le total des résultats segmentés sont présentés dans la figure IV.18 et les rapports de segmentation des différents cas de % bruit et INU sont illustrés dans le tableau IV.9 ci-dessous.




Figure IV.18 : Comparaison des résultats de segmentation sur des images IRM simulées : (a) image IRM simulée pondérée en T1 avec INU = 60% et 9% de bruit, (b) crâne dépouillant, (c) partie non cerveau, (d) FCM, (e) GFCM, (f) KGFCM, (g) GKFCM (h) CsKFCM, (i) ISFCM, (j) ISKFCM.

Table IV.9 : Résultats de SA(%) sur des images IRM simulées à différents % de bruit et INU

N°	Méthodes	T1 avec 5% Bruit et 20% INH			T1 avec 7% Bruit et 40% INH			T1 avec 9% Bruit et 60% INH			
		MB	MG	LCR	MB	MG	LCR	MB	MG	LCR	
1	FCM	MB	86.16	13.85	00.00	84.65	15.37	00.00	78.76	21.25	00.00
		MG	22.31	77.61	00.09	23.54	76.27	00.21	29.15	70.36	00.51
		LCR	02.07	42.93	55.05	04.61	42.44	52.96	04.35	49.86	45.80
2	GFCM	MB	96.94	03.05	00.00	94.59	05.40	00.00	91.51	08.51	00.00
		MG	09.11	90.68	00.22	13.73	86.08	00.19	14.73	84.77	00.53
		LCR	01.58	28.15	70.29	03.31	30.44	66.28	04.56	29.77	65.68
3	GKFCM	MB	97.39	02.61	00.00	97.41	03.69	00.00	91.25	08.75	00.00
		MG	10.36	89.53	00.12	11.63	88.24	00.14	15.55	84.29	00.15
		LCR	01.96	25.46	72.59	03.01	27.49	69.53	04.66	26.58	68.77
4	KGFCM	MB	97.82	02.28	00.00	96.62	03.39	00.00	90.83	09.19	00.00
		MG	09.98	89.96	00.08	12.44	87.45	00.13	16.02	83.87	00.12
		LCR	01.85	25.13	73.02	2.89	28.38	68.74	4.31	27.36	68.35
5	CsKFCM	MB	98.49	01.53	00.00	96.87	03.14	00.00	93.29	06.73	00.00
		MG	07.88	91.94	00.21	10.08	89.70	00.25	14.35	85.01	00.65
		LCR	00.00	10.47	89.54	00.00	12.22	87.81	00.00	16.19	83.85
6	ISFCM	MB	98.83	01.18	00.00	97.71	02.31	00.00	93.97	06.04	00.00
		MG	06.31	93.59	00.13	08.42	91.47	00.16	10.72	88.80	00.51
		LCR	00.00	07.29	92.73	00.00	09.43	90.59	00.00	13.84	86.17
7	ISKFCM	MB	98.96	01.05	00.00	97.86	02.15	00.00	94.31	05.71	00.00
		MG	06.18	93.72	00.12	08.25	91.64	00.13	10.39	89.16	00.48
		LCR	00.00	07.16	92.86	00.00	09.28	90.74	00.00	13.51	86.51

IV-4-3- Sur des images IRM réelles:

Une expérimentation approfondie est effectuée où les performances de l'algorithme ISFCM et ISKFCM sont également testées sur 75 images IRM cérébrales réelles de 29 patients à différents stades. Ces images sont collectées à partir de la base de données BRATS 2018&2019 qui font partie du centre de calcul et d'analyse d'images biomédicales - CBICA, ce dernier est consacrée au développement des méthodes d'analyse d'images informatisées et à leur application à une grande variété d'études de recherche clinique. Les images IRM à traiter présentent sous la forme des coupes axiale, coronal, sagittal du cerveau et pondérée en T1, T2 et PD. La figure IV.19 montre les résultats de la segmentation qualitative d'une image IRM réelle sans aucun pré-traitement appliqué pour l'état normal du patient. Dans cette sous-section, la plupart des méthodes de segmentation proposées ont des résultats très satisfaisants et efficaces en termes de performance.




Figure IV.19 : Comparaison des résultats de segmentation sur des images IRM réelles : (a) image IRM original, (b) crâne dépouillant, (c) partie non cerveau, (d) FCM, (e) GFCM, (f) KGFCM, (g) GKFCM (h) CsKFCM, (i) ISFCM, (j) ISKFCM.

D'après la comparaison des résultats obtenus dans la figure IV.19 et d'un point de vue plus claire, on notera que la méthode développée ISKFCM, bien que s'appuyant encore sur un modèle spatiale enrichie et amélioré, permet toutefois d'aboutir à des résultats qui présentent des qualités structurelles très largement supérieures à celles des résultats obtenus par les autres méthodes proposée dans cette thèse, ceci s'expliquant par le fait que cette dernière ne s'appuie sur aucune information préalable notamment en ce qui concerne le respect des propriétés anatomiques des tissus. Dans ce qui suit, nous présentons les résultats des taux de segmentation SA% par les différents algorithmes implémentés.

Table IV.10 : Résultats de SA(%) sur des images IRM réelles

N°	Tissus Cérébraux	Différentes Méthodes de Segmentation						
		FCM	GFCM	GKFCM	KGFCM	CsKFCM	ISFCM	ISKFCM
1	MB	86.22	93.49	93.66	94.78	94.62	95.36	97.13
2	MG	83.16	86.87	87.64	85.33	91.88	92.19	92.01
3	LCR	82.44	85.25	86.90	88.79	90.14	90.97	92.31
4	Moyenne	83.94	88.53	89.40	89.63	92.21	92.84	93.82




Figure IV.20 : Représentation graphique de SA(%) des images IRM réelles.

Pour mieux tester les performances, les algorithmes ont été appliqués à l'ensemble des données collectées auprès de la base BRATS 2019. Les résultats expérimentaux obtenus après chaque processus de traitement est illustré sur la figure IV.21 (d à j) ci-dessous :




Figure IV.21 : Comparaison des résultats de segmentation sur des images IRM réelles : (a) image IRM originale, (b) crâne dépouillant, (c) partie non cerveau, (d) FCM, (e) GFCM, (f) GKFCM, (g) KGFCM, (h) CsKFCM, (i) ISFCM, (j) ISKFCM.

Table IV.11 : Résultats de SA(%) sur des images IRM réelles

N°	Tissus Cérébraux	Différentes Méthodes de Segmentation						
		FCM	GFCM	GKFCM	KGFCM	CsKFCM	ISFCM	ISKFCM
1	MB	85.13	93.17	92.11	94.06	94.30	94.73	96.72
2	MG	84.26	86.30	87.14	84.89	90.97	91.19	91.96
3	LCR	83.04	85.35	86.48	86.22	89.51	89.74	90.81
4	Moyenne	84.14	88.27	88.57	88.39	91.59	91.87	93.16

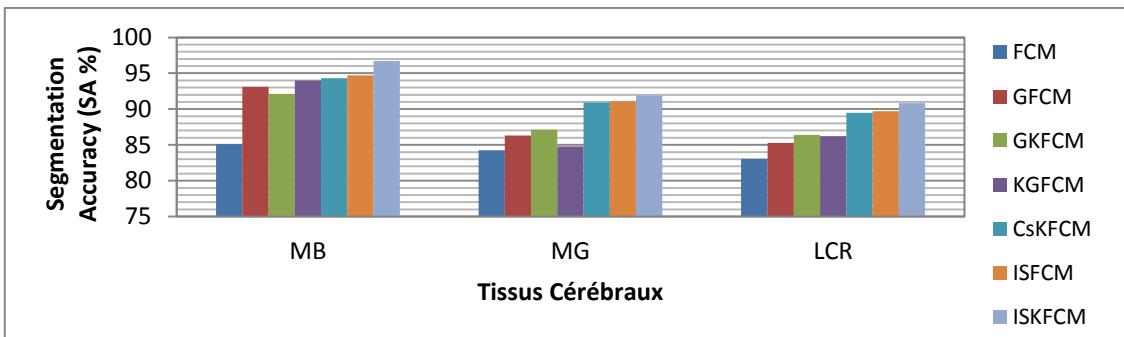


Figure IV.22 : Représentation graphique de SA(%) des images IRM réelles.

La figure IV.23 (a) et (b) ci-dessous montrent clairement les deux courbes d'évolution de la fonction objective pendant l'exécution de nos algorithmes ISFCM et ISKFCM sur une image simulée avec 9% de bruit et 40% d'intensité d'inhomogénéité.

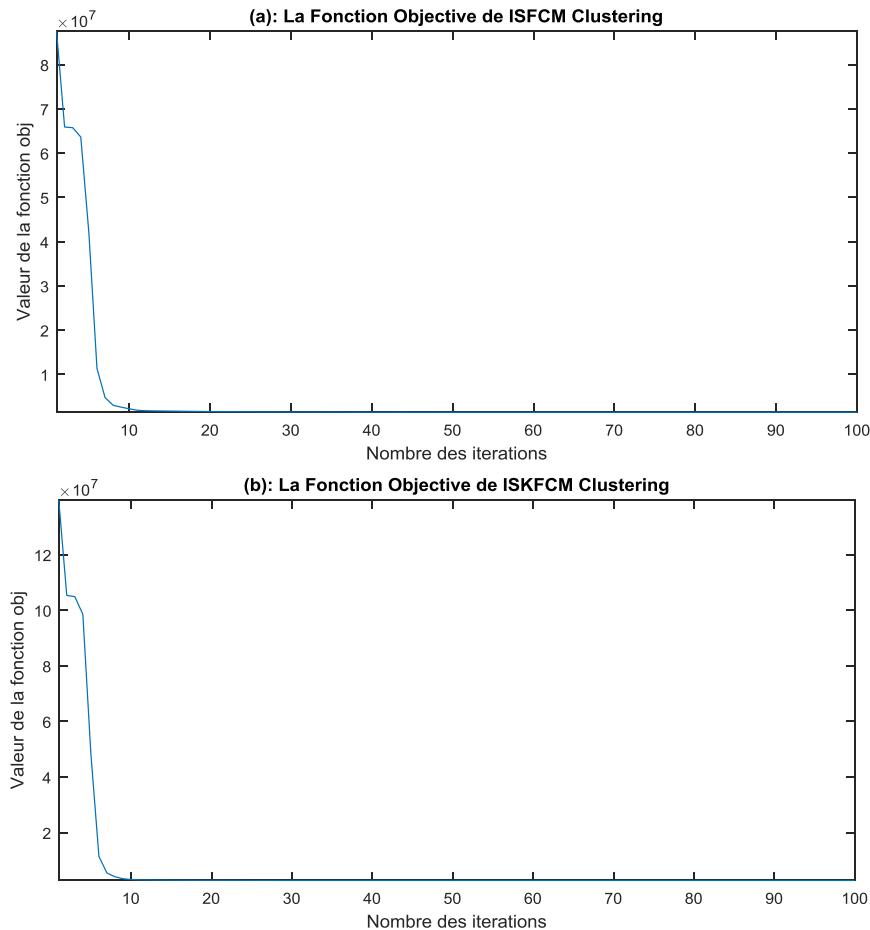


Figure IV.23 : Evolution de la fonction objective : (a) ISFCM, (b) ISKFCM

IV-5- Interprétation, Analyse des performances et discussions:

Les résultats présentés dans les figures IV.19 et IV.21 montrent que notre approche permet d'avoir une segmentation par classification rapide, efficace et plus nette, c'est-à-dire que l'on ne constate pas l'apparition des pixels dans la matière blanche, classifiés comme appartenant à la matière grise. Ceci est dû à l'utilisation de la coopération, qui incorpore l'espace des fonctions d'appartenance des voisins centrées sur un pixel dans le domaine spatial et aussi permet de prendre en compte les caractéristiques globales et locales de l'image. Bien que GKFCM et CsKFCM présentent des performances élevées, elles présentent aussi deux limitations majeures: l'existence d'une incohérence due aux valeurs d'appartenance initialisées de manière aléatoire des objets dans l'ensemble de données et l'incapacité à gérer les situations où le nombre de clusters n'est pas prédéterminé. À partir de cette étude expérimentale, il a été prouvé que nos méthodes proposées sont efficaces et de haute qualités.

De la figure IV.16 et ces résultats de comparaison en terme de segmentation, nous remarquons que les deux approches ISFCM et ISKFCM ont surpassé l'algorithme FCM standard et les méthodes de segmentation les plus récentes proposés dans cette thèse; où ils ont réussi dans une certaine mesure à gérer le bruit et à extraire les régions les plus homogènes, et leurs résultats sont très proches, ce qui est également confirmé par les résultats numériques illustrés dans le tableau IV.7. En fait, le taux de segmentation généré par le FCM standard est le plus faible, alors que la différence entre ceux générés par le ISFCM et est très grand, cette différence est due à l'initialisation aléatoire. De plus, d'après le tableau IV.8, il est remarquable que l'ISKFCM proposé fonctionne bien et robuste au bruit élevé.

L'interprétation visuelle, la comparaison et la précision des images segmentée illustré dans la figure IV.18 présente de meilleures performances, ISKFCM est efficace en termes de l'efficacité de la segmentation par rapport aux autres approches proposées. Cela a vérifié le fait que l'approche développée réussit à identifier simultanément les pixels des différentes régions. La raison la plus importante c'est que la procédure de sélection des valeurs optimales des paramètres initiaux tels que les valeurs d'appartenance et les centres de cluster joue un rôle majeur dans la détermination de la précision des approches.

À partir de l'analyse des graphes présenté dans les figures IV.15 et IV.17, on peut prédire que l'algorithme de clustering ISFCM et ISKFCM produisent des résultats de segmentation plus cohérents et plus fluides pour les images corrompu avec des niveaux de bruit élevés en raison de la présence d'informations spatiales. Cependant, dans les deux cas pour des niveaux de bruit gaussien et mixe (gaussien 0.04 et sel et poivre 0.04), l'effet de flou se produit aux bords de la région. Mais l'algorithme de clustering ISKFCM donne de bons résultats, malgré le fait que les images sont affectées par différents niveaux de bruit élevé. Cela est dû à l'incorporation du paramètre d'attraction de voisinage \bar{S}_j^* et \tilde{S}_j^* avec l'information spatiale et à l'optimisation de sa valeur pour refléter la corrélation des pixels de voisinage.

D'une façon générale cette étude présente une approche robuste et efficace pour la segmentation par classification des images médicales. Nous avons proposé deux nouvelles routines et extensions : ISFCM et ISKFCM. Ces techniques de segmentation basées sur FCM ont suivi deux critères. Tout d'abord, une nouvelle méthode d'initialisation des centres de cluster, permettant une convergence rapide de l'algorithme itératif, est présentée. Deuxièmement, nous généralisons l'algorithme de c-moyennes flou amélioré. Ainsi, nous gardons la capacité de l'algorithme à être calculé rapidement. De plus, l'utilisation du contexte spatial permet d'obtenir un clustering plus robuste. Selon une comparaison approfondie avec les méthodes de segmentation par classification les plus récentes, notre approche donne des résultats satisfaisants. L'utilisation des voisins pour améliorer le clustering avec l'algorithme

ISFCM ou ISKFCM corrige les images bruyantes sans affecter les bords. Donc on peut dire que l'effet des pixels voisins aux limites d'une région réelle étroite pourrait affecter la taille de la région après le clustering.

IV-6- Conclusion :

Dans ce chapitre, nous avons présenté des nouvelles techniques de segmentation d'images qui se concentrent sur les défis et problèmes posés par les images IRM cérébrales réelles normales et anormales. Deux approches modifiées ISFCM et ISKFCM sont proposées dans ce travail pour la délimitation et l'extraction des tumeurs cérébrales. Dans notre méthodologie, le décapage du crâne est utilisé pour éliminer les tissus non cérébraux et l'extraction des tissus cérébraux du cerveau humain. Le bruit et l'intensité d'inhomogénéité sont deux facteurs qui affectent la précision de la segmentation, l'algorithme de clustering ISKFCM incorpore des informations spatiales dans la mesure de similarité en intégrant un paramètre de configuration de voisinage pour améliorer les résultats de segmentation. Les performances sont testées avec plusieurs images synthétiques, simulées et réelles. Les algorithmes proposés ISFCM et ISKFCM sont plus productif car elles fournissent des résultats de segmentation supérieurs, ces dernières sont comparés à ceux d'autres modèles et les performances sont évaluées ce qui confirme la validité de nos approches.

Dans la suite nous présentons l'optimisation, l'évaluation et la mise en œuvre de notre système de segmentation dédié pour des applications en temps réel telles que l'analyse d'images cérébrales et ses résultats de haute qualité sont discutés.

Chapitre V :

*Application, Optimisation et évaluation du
système de segmentation sur
TMS320C6713DSP*

V-1-Introduction :

La mise en œuvre en temps réel des algorithmes de segmentation d'image dans des processeurs numériques de type DSP, est un domaine de recherche actif et très important dans diverses applications médicales pratiques, ce qui le rendent approprié par un accès plus rapide aux données, un transfert de données en temps réel, un calcul rapide, un contrôle d'exécution et la fidélité numérique. Dans ce chapitre, notre système de segmentation est implémenté à l'aide d'un DSP à virgule flottante TMS320C6713 de Texas Instruments en utilisant Matlab SimuLink et une version propriétaire du langage C évoluée avec le code composer studio pour la carte de développement C6713DSK. L'amélioration des performances est mesurée en incluant diverses techniques d'optimisation, et tous les résultats de profilage et de débogage sont affichés à l'aide de l'interface utilisateur graphique C6713. La section IV.5 illustre les résultats expérimentaux de l'algorithme proposé avec des évaluations qualitatives et quantitatives sur des données d'images cérébrales IRM simulées et réelles pour une segmentation améliorée. Enfin, une analyse comparative approfondie est effectuée pour mettre en évidence la technique optimale.

V-2- Outils de mise en œuvre matériel et logiciel :

Le traitement d'image en temps réel a fait des progrès considérables après le développement de processeurs spécialisés de type DSP. Le matériel DSP choisi doit être capable d'atteindre les meilleures performances avec une architecture prenant en charge un langage de haut niveau. Dans cette étude, des outils de mise en œuvre matériel et logiciel spécifiques sont nécessaires pour tester et intégrer notre algorithme de segmentation. Concernant l'implémenter : on a choisi le processeur TMS320C6713 DSP, Ce processeur est basé sur la technologie VLIW (Very Large Instruction Word) modifiée qui permet un calcul parallèle rapide et des outils logiciels associés tels que des compilateurs, des assembleurs, des simulateurs, des débogueurs, etc., sont fournis afin de faciliter la conception du système et le développement d'applications. Pour cela un kit de démarrage appropriés C6713DSK est disponible auprès de Spectrum Digital Incorporation qui comprend une carte et des outils logiciels. La carte doit être connectée à un PC standard fonctionnant sous son environnement de développement intégré : Code Composer Studio (CCS IDE). Ce dernier peut communiquer avec Matlab via MATLAB Link.

V-2-1- TMS320C6713 DSK:

Cette sous-section est divisée en trois (03) parties : Architecture du starter KIT TMS320C6713 DSK, architecture du processeur TMS320C6713 DSP et leurs avantages, où il sera discuté l'outil matériel et leur architecture avec une description détaillée des différents composants hardware montés sur le package TMS320C6713 DSK.

V-2-1-1- Architecture du starter KIT TMS320C6713:

Les kits de démarrage TMS320C67xx et y compris le périphérique TMS320C6713 composent la génération de DSP à virgule flottante dans la plate-forme DSP TMS320C6000. Le dispositif C6713 DSK est basé sur la haute performance et permet aux utilisateurs de développer et d'évaluer des applications. Le processeur TMS320C6713DSP est un processeur 32 bits à virgule flottante développé par Texas Instruments munie des synchrones :

- 8 Mbytes de mémoire DRAM volatile Flash.

- 512 Kbytes de mémoire non éléments suivants.
- Un convertisseur audio bidirectionnel de type « CODEC » AIC23 stéréo.
- Le TMS320C6713 DSP fonctionnant à 225 MHZ.
- Options de démarrage et un émulateur JTAG embarqué.
- Configuration de la carte logicielle via des registres implémentés dans CPLD.
- 4 LED et des switches DIP.
- Interface de mémoire externe 32 bits jusqu'à 512 Mo d'espace mémoire externe adressable.
- Ports standard pour cartes filles.
- Unité fonctionnelle 4xALU et 2x32 bits MAC.
- Une interface de type USB avec l'ordinateur hôte.
- L'alimentation est externe mais très simple (+5V).

L'outil de développement C6713 dispose d'un riche ensemble de périphériques qui comprend deux ports série audio multicanaux (McASP), deux ports série tamponnés multicanaux (McBSP), deux bus de circuits intégrés (I2C), un module d'entrée / sortie à usage général (GPIO) dédié, deux minuteries à usage général, une interface hôte-port (HPI) et une interface de mémoire externe sans colle (EMIF) capable de s'interfacer avec la SDRAM, la SBSRAM et les périphériques asynchrones. Les deux modules d'interface McASP prennent chacun en charge une zone d'horloge d'émission et une zone d'horloge de réception. Chacun des McASP dispose de huit broches de données série, qui peuvent être attribuées individuellement, à l'une des deux zones. Le port série prend en charge le multiplexage temporel sur chaque broche de 2 à 32 intervalles de temps. Le schéma du kit de démarrage décrivant la carte est illustré à la figure V.1




Figure V.1 : Le Kit de démarrage TMS320C6713 DSK [SHA 15].

Le C6713DSK a une bande passante suffisante pour prendre en charge les 16 broches de données série transmettant un signal stéréo de 192 kHz. Les données série dans chaque zone peuvent être transmises et reçues sur plusieurs broches de données série simultanément et formatées dans une multitude de variations du format Philips Inter-IC Sound (I2S). De plus, l'émetteur McASP peut être programmé pour produire simultanément plusieurs canaux de données codés S / PDIF, IEC60958, AES-3, CP-430, avec une seule RAM contenant la mise en œuvre complète des données utilisateur et des champs d'état de canal. Le McASP fournit également des fonctionnalités étendues de vérification d'erreur et de récupération, telles que le circuit de détection de mauvaise horloge pour chaque horloge maître haute fréquence, qui vérifie que l'horloge maître se trouve dans une plage de fréquences programmée. Les deux

ports I2C du TMS320C6713 permettent au DSP de contrôler facilement les périphériques et de communiquer avec un processeur hôte. De plus, le port série à mémoire tampon multicanal standard (McBSP) peut être utilisé pour communiquer avec des périphériques en mode interface périphérique série (SPI). Le périphérique TMS320C6713 a deux modes de démarrage: à partir de HPI ou à partir de ROM asynchrone externe. La génération TMS320C67x DSP est prise en charge par Texas Instruments eXpressDSP qui possède un ensemble d'outils de développement de référence de l'industrie, y compris un compilateur C / C ++ hautement optimisé, l'environnement de développement intégré (IDE) Code Composer Studio, l'émulation basée sur JTAG et le débogage en temps réel, et le noyau DSP / BIOS.




Figure V.2 : Schéma fonctionnel de la carte TMS320C6713 DSK[SHA 15].

IV-2-1-1-1- Le Codec AIC23:

Le C6713 DSK utilise un codec stéréo Texas Instruments de type AIC23 pour l'entrée et la sortie des signaux. Le codec échantillonne les signaux analogiques sur les entrées MIC IN ou LINE IN et ensuite les convertit en données numériques afin qu'elles puissent être traitées par le DSP. Lorsque le DSP a terminé avec les données qu'il utilise, le codec convertit les échantillons en signaux analogiques sur HP OUT ou LINE OUT émet les signaux afin que l'utilisateur puisse recevoir la sortie. Le codec communique en utilisant deux canaux série, un pour contrôler les registres de configuration internes et l'autre pour envoyer et recevoir des échantillons numériques. Le schéma du codec AIC23 est illustré dans la figure V.3.




Figure V.3 : Schéma global de l'AIC23 CODEC [SOL 13].

V-2-1-1-2- Cartographie de Mémoire:

La famille de DSP C67xx a un grand espace d'adressage adressable d'octets. Le code de programme et les données peuvent être placés n'importe où dans l'espace d'adressage unifié. Les adresses ont toujours une largeur de 32 bits [SOL 13]. La carte mémoire montre l'espace d'adressage d'un processeur 6713 générique sur la gauche avec des détails spécifiques sur la façon dont chaque région est utilisée sur la droite. Par défaut, la mémoire interne se situe au début de l'espace d'adressage. Des parties de la mémoire interne peuvent être reconfigurées dans le logiciel en tant que cache L2 plutôt que RAM fixe [HEE 14]. L'EMIF a 4 régions adressables distinctes appelées espaces d'activation de puce (CE0-CE3). La SDRAM occupe CE0 tandis que les partages Flash et CPLD CE1, CE2 et CE3 sont généralement réservés aux cartes filles. Le mappage de la mémoire est illustré à la figure V.4

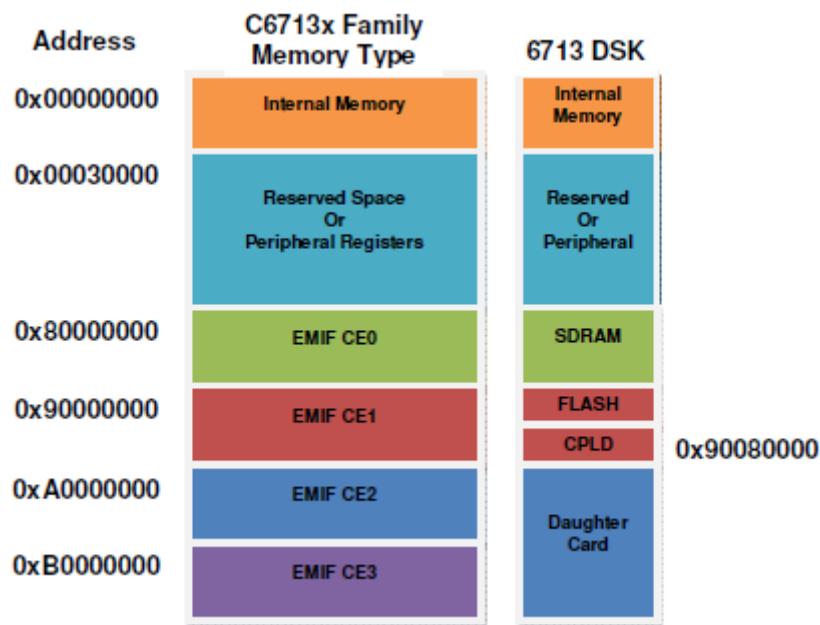


Figure V.4 : Schéma global de l'AIC23CODEC.

IV-2-1-2- Architecture du TMS320C6713 DSP:

Le TMS320C6713 DSP de la série TMS320C6000 est un DSP à virgule flottante qui possède une fréquence d'horloge initiale de 225 MHz. Le processeur C6713 peut exécuter des opérations en virgule flottante de 1,35 giga en une seconde (GFLOPS), c'est pourquoi le C6713 atteint un très haut niveau de parallélisme en envoyant et en exécutant plusieurs instructions en parallèle à des fréquences d'horloge élevées. Ce processeur a été introduit par TI et est basé sur l'architecture VelociTI. Le VelociTI est une architecture avancée utilisant des mots d'instructions très longs dans laquelle huit unités d'exécution permettent d'exécuter jusqu'à huit instructions par cycle. Ces instructions peuvent facilement utiliser les registres et les modes d'adressage et cela augmente l'efficacité des compilateurs C. L'architecture VelociTI supprime les inconvénients de l'architecture VLIW précédente en utilisant le conditionnement d'instructions, le branchement conditionnel et le branchement pré-extrait.

Le C6713 emploie une architecture cachette-basée à deux niveaux, et a un ensemble puissant de divers périphériques. La cachette de programme du niveau 1 (L1P) est une cachette avec une taille de 4K-Byte, et la cachette de données du niveau 1(L1D) est une cachette 4K-Byte placer-associative bidirectionnelle. La mémoire du niveau 2 ou la cachette (L2) se compose d'un espace mémoire 256K-Byte, partagé entre le programme et l'espace de

données. Les 64K bytes des 256K bytes dans la mémoire L2 peuvent être configurés en tant que mémoire, cachette, ou combinaison tracée des deux. Les bytes 192 K restants dans L2 servent de SRAM tracé. L'architecture du cœur C6713 DSP est représentée sur la figure V.5.

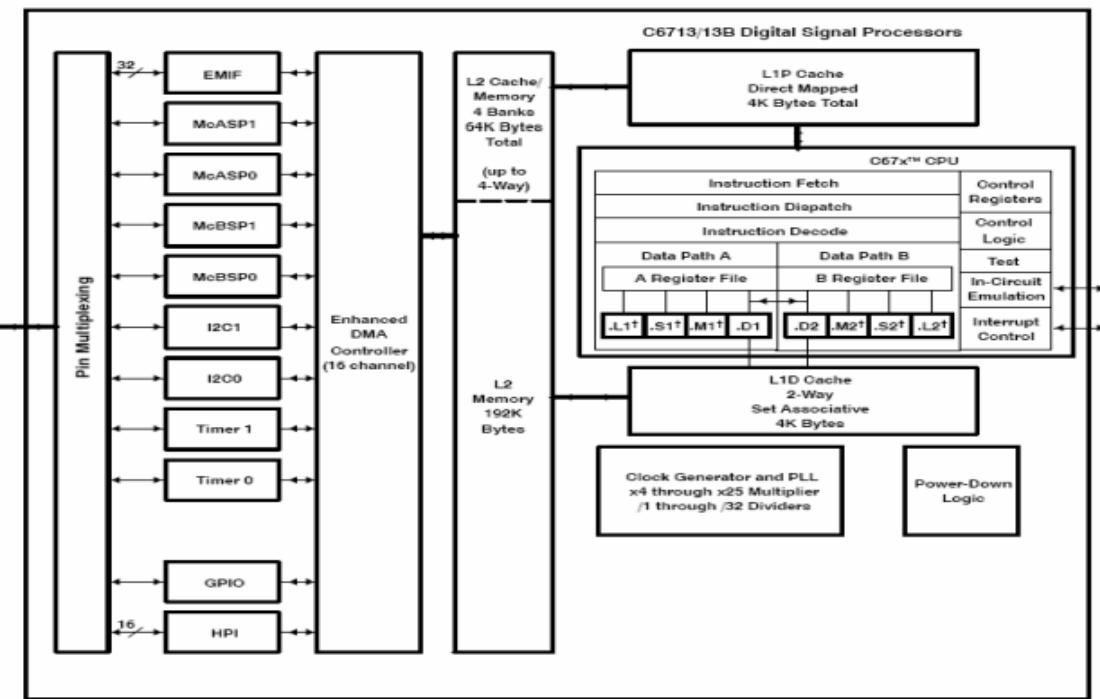


Figure V.5 : Architecture du processeur TMS320C6713 DSP [HEE 14].

V-2-1-3- Avantages et inconvénients du TMS320C6713 DSP:

Le coût du système numérique est inférieur à celui d'un système analogique en raison des progrès des technologies des semi-conducteurs (VLSI). Les algorithmes DSP peuvent être conçus et développés à l'aide de langages de haut niveau tels que C / C ++, Visual C et l'analyse et la simulation peuvent être effectuées sur le logiciel Matlab ou Labview. En utilisant des ordinateurs personnels, les performances des algorithmes peuvent être vérifiées. Par conséquent, un système numérique basé sur DSP est moins coûteux, facile à concevoir, simuler, développer, tester et entretenir [ING 11]

La fiabilité des systèmes numériques est très élevée car la mémoire et le matériel utilisés dans ces appareils restent inchangés pendant une longue durée. Dans toutes les conditions météorologiques intérieures ou extérieures, les performances des systèmes numériques restent les mêmes que celles des appareils analogiques.

L'implémentation du DSP est très flexible, on peut facilement changer les paramètres du système en faisant quelques changements dans le programme utilisé par le logiciel pour une application spécifique. Un système peut être conçu à l'aide d'un DSP qui peut effectuer de nombreuses opérations en utilisant simplement une variété de modules logiciels. Un appareil électronique peut être facilement mis à niveau pour ajouter plus de fonctionnalités en modifiant le programme dans la mémoire intégrée.

Les performances d'un système numérique restent les mêmes si le même système est fabriqué en grande quantité. La reproductibilité du système utilisant le DSP ne peut pas dégrader les performances de tous les systèmes similaires en raison de la nature numérique des signaux qui peuvent être restaurés et reproduits plusieurs fois par le système. Dans les appareils analogiques, les mêmes performances même de deux systèmes analogiques ne

peuvent pas être assurées en raison des composants analogiques utilisés qui présentent des caractéristiques différentes en raison de la tolérance de ces appareils.

Dans la conception d'un système utilisant DSP, certaines limitations sont rencontrées. En raison de la fréquence d'échantillonnage et de la largeur de bande différente des périphériques utilisés dans la conception d'un système numérique utilisant DSP, un problème de bande passante limitée se produit. Les systèmes numériques rencontrent l'erreur de quantification et les erreurs arithmétiques parce que les nombres fixes de bits sont utilisés dans les algorithmes DSP. En raison de la précision et de la plage dynamique limitée, les performances du système numérique peuvent être différentes de celles de l'analyse théorique.

V-2-2- Code Composer Studio:

La partie du software du kit TMS320C6713 DSK est le Code Composer Studio (CCS) qui fournit un environnement de développement intégré (IDE) avec un éditeur, débogueur, profileur, compilateur «C / C ++», optimiseur d'assemblage et éditeur de liens, simulateur, système d'exploitation en temps réel (DSP / BIOS), échange de données en temps réel (RTDX) entre l'hôte et la cible, analyse en temps réel et visualisation des données [HEE 14].

V-2-2-1- Description de la plate-forme d'expérimentation CCS:

La plate-forme utilisée pour la programmation et la communication avec le processeur C6713 est Code Composer Studio (CCS) via un émulateur JTAG intégré par une interface USB ou via un émulateur JTAG externe. Le CCS est utilisé pour générer des fichiers exécutables TMS320C6x; il est conçu exclusivement pour C6x et C5X. Trois outils, à savoir le compilateur C, l'assembleur et l'éditeur de liens, sont utilisés pour générer un programme exécutable à partir d'une source C / C ++ ou d'un assembleur. CCS fournit un outil software facile à utiliser pour créer et déboguer des programmes. Pour chaque application à exécuter sur le processeur C6713, il faut créer un «projet» dans Code Composer Studio, qui rassemble toutes les informations sur les fichiers source C requis, les fichiers d'en-tête et les bibliothèques C, y compris tous le compilateur et l'éditeur de liens et construire des options.

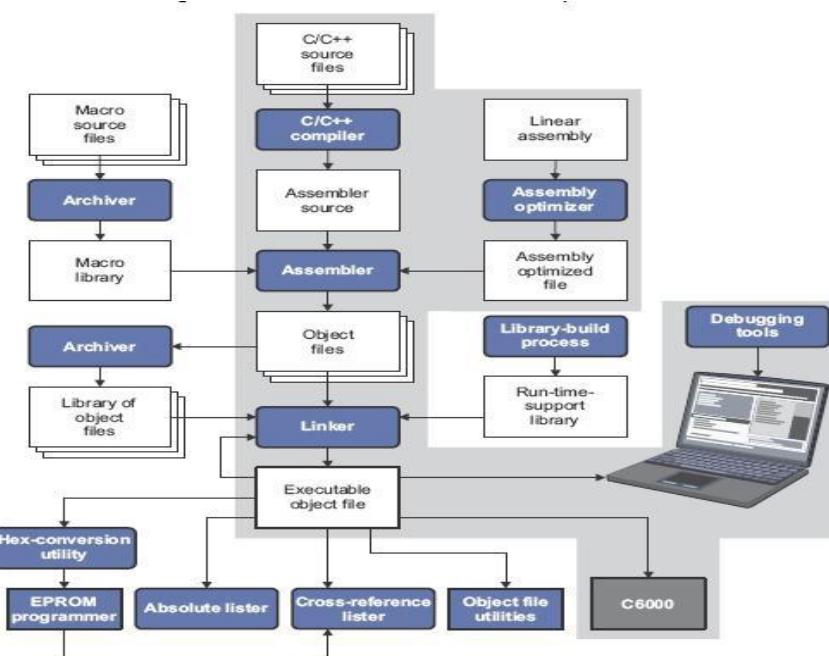


Figure V.6 : Modèle de travail du Code Composer Studio.

V-2-2-2- Interface et processus de programmation:

La TMS320C6713 DSP est prise en charge par l'ensemble d'outils de développement de référence TI eXpress DSP, y compris un compilateur C / C ++ hautement optimisé, l'environnement de développement intégré (IDE) Code Composer Studio, l'émulation basée sur JTAG et le débogage en temps réel, et le Noyau DSP / BIOS. Le gestionnaire de projet CCS organise les fichiers dans des dossiers pour les fichiers source; inclure des fichiers, des bibliothèques et des fichiers de configuration DSP / BIOS. Une fois les fichiers ajoutés au projet, toutes les modifications apportées à l'un des fichiers source seront automatiquement reflétées dans les fichiers du projet. Cela permet le développement de systèmes multiutilisateurs. CCS permet également de déboguer simultanément des conceptions mixtes multiprocesseurs. Il comprend également de nouvelles capacités d'émulation avec échange de données en temps réel (RTDX), ainsi que des capacités avancées de profilage de code DSP. Une fenêtre de surveillance améliorée surveille les valeurs des variables locales et globales et des expressions C / C ++ [ING 11]. Les utilisateurs peuvent rapidement visualiser et suivre les variables sur le matériel cible. Il a la capacité de partager des sources et des bibliothèques C et C ++ dans un projet multiutilisateur.




Figure V.7 : L'interface de programmation CCS [ING 11].

Le Code Composer Studio offre des fonctions de base robustes avec des outils de configuration et de visualisation graphique faciles à utiliser pour la conception et implémentation de systèmes. La programmation en C / C ++ pour l'application est respectée, liée et exécutée par le CCS. La figure IV.7 montre l'interface de programmation de CCS.

V-2-3- MATLAB Link pour Code Composer Studio:

MATLAB Link a été créée pour les outils de développement Code Composer Studio qui permet d'utiliser les fonctions MATLAB pour communiquer avec le Code Composer StudioTM et avec les informations stockées en mémoire et les registres sur une cible. Avec les liens, l'utilisateur peut transférer des informations vers et depuis Code Composer Studio et avec les objets intégrés, vous obtenez des informations sur les données et les fonctions stockées dans la mémoire et les registres de votre processeur de signal, ainsi que des

informations sur les fonctions de votre projet. Avec MATLAB Link pour Code Composer Studio, vous créez deux types d'objets: Liens qui connectent MATLAB à Code Composer Studio et les objets incorporés qui permettent d'accéder aux données et aux fonctions du projet dans Code Composer Studio et sur la cible.

La Cible intégrée pour Texas Instrument fournit une connexion entre Matlab et CCS ou il convertit le modèle Simulink en un projet CCS. Avec l'environnement de développement intégré (IDE), nous pouvons utiliser Matlab et Simulink pour analyser, façonnez et corriger le comportement du code en cours d'exécution, de cette façon l'IDE automatise le déploiement d'une application intégrée complète et facilite l'évaluation des différences possibles entre la simulation et l'exécution du code. Une autre utilisation possible de l'automatisation consiste à créer des scripts Matlab qui vérifient et examinent les algorithmes exécutés dans leur exécution finale. Le schéma illustré dans la figure V.8 suivante montre la relation entre MATLAB, CCS et le DSP de Texas Instruments.

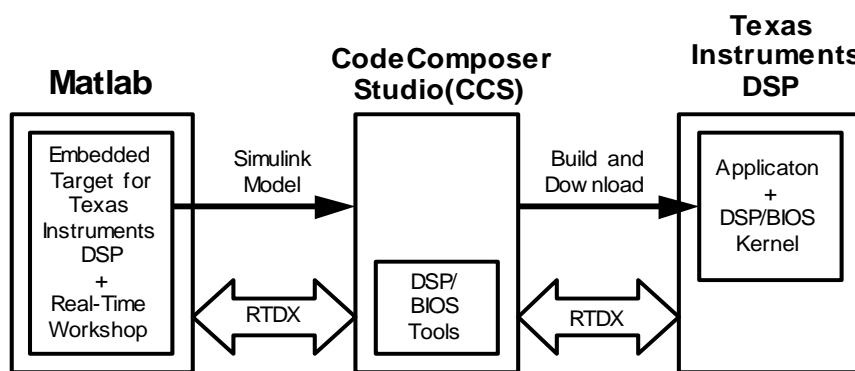


Figure V.8 : Cible intégrée pour C6713Texas Instrument.

V-3- Conception, configuration et implémentation sur C6713 DSK:

Le traitement d'image en temps réel a fait des progrès considérables après le développement des processeurs spécialisés de type DSP. Notre matériel DSP choisi doit être capable d'atteindre les meilleures performances avec une architecture prenant en charge un langage de haut niveau et un temps d'exécution plus élevé. Dans cette étude, des outils de mise en œuvre matériel et logiciel spécifiques sont nécessaires pour tester et intégrer notre algorithme de segmentation. Concernant l'implémenter : on a choisi le processeur TMS320C6713 DSP, Ce processeur est basé sur la technologie VLIW (Very Large Instruction Word) modifiée qui permet un calcul parallèle rapide et des outils logiciels associés tels que des compilateurs, des assembleurs, des simulateurs, des débogueurs, etc., sont fournis afin de faciliter la conception du système et le développement de l'application. Pour cela un kit de démarrage appropriés C6713DSK est disponible auprès de Spectrum Digital Incorporation qui comprend une carte et des différents outils logiciels. Cette carte doit être connectée à un PC standard fonctionnant sous son environnement de développement : Code Composer Studio et qui peut communiquer directement avec Matlab via l'option du MATLAB Link.

V-3-1- Modèle simulink complet du système de segmentation:

Une fois que l'algorithme proposé est développé, il a été complètement vérifié dans Matlab en utilisant plusieurs images d'entrée de type IRM. Ensuite, les fonctions intégrées de MATLAB ont été remplacées par des fonctions bien définies pour construire le model Simulink de notre systèmes de segmentation. On a utilisé un ensemble des Blocksets de la

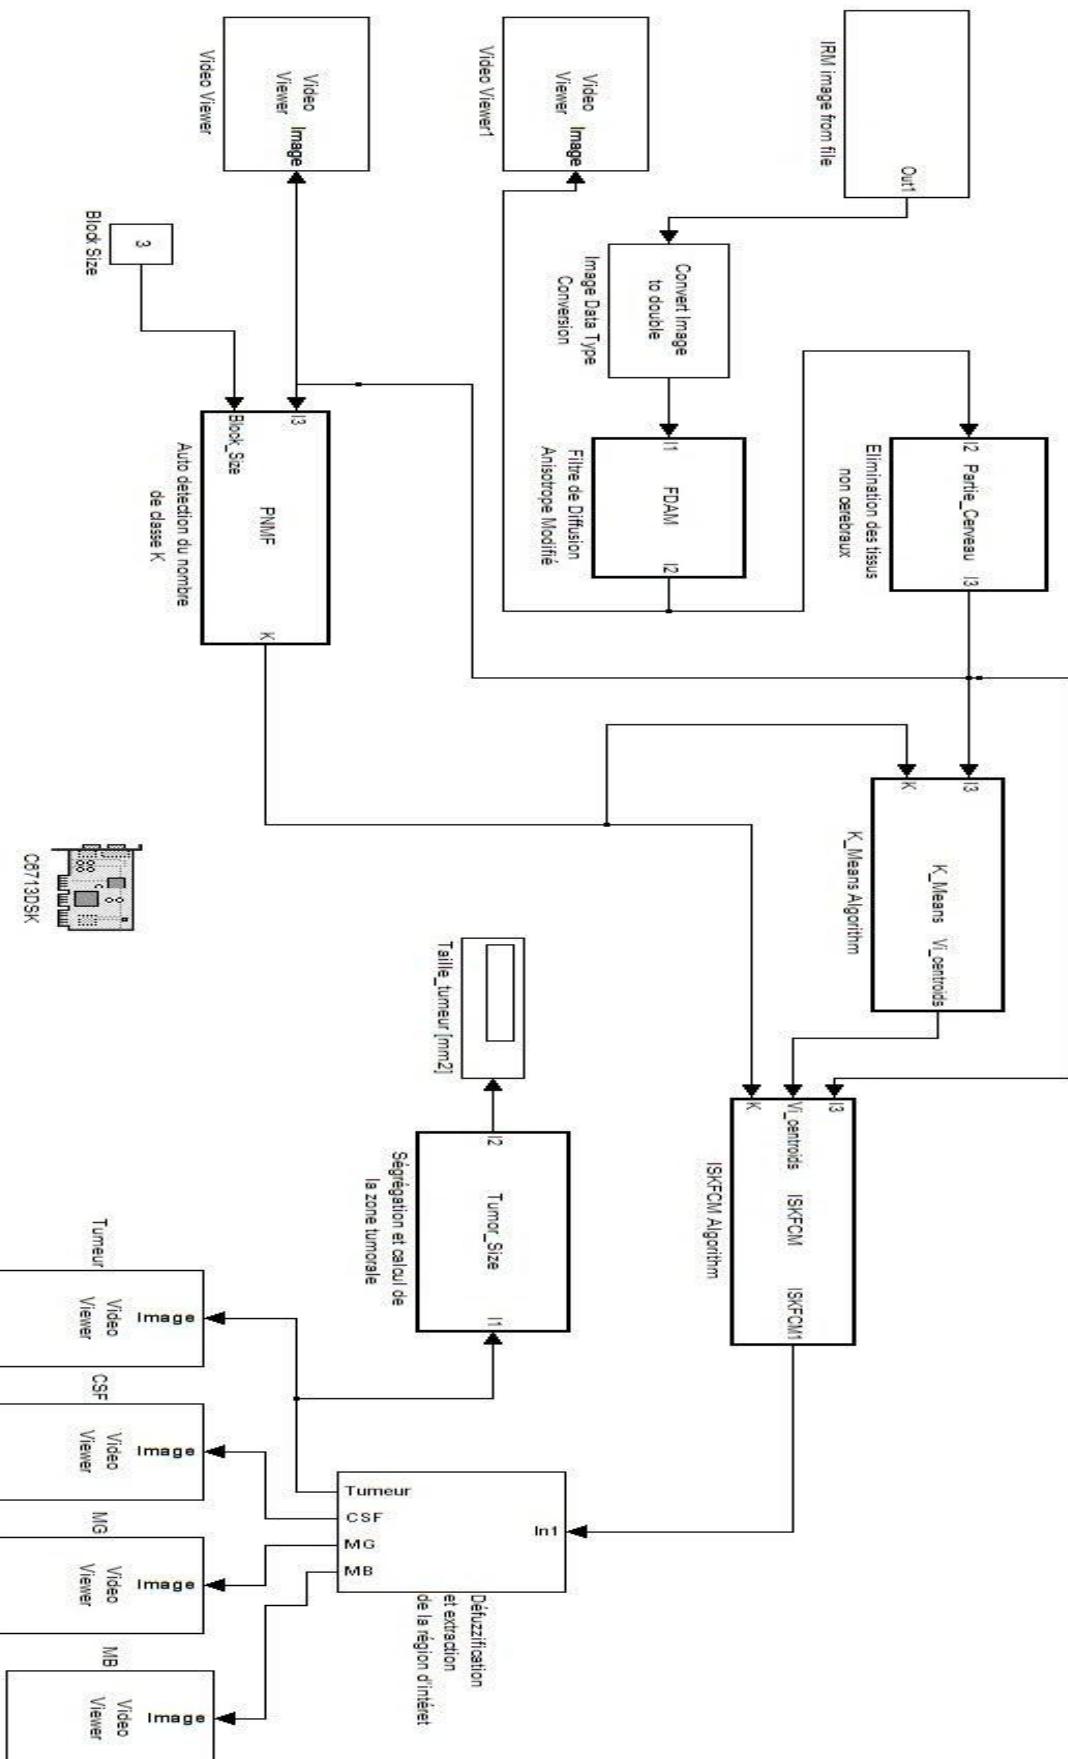


Figure V.9 : Modèle simulink complet du système de segmentation.

Pour la conception du modèle simulink, on a utilisé des différents Blocksets de la bibliothèque "Video and Image Processing Blockset". L'ensemble de ces blocksets sont présentés dans le tableau IV.1 suivant :

Tableau V.1 : Différents Blocksets de Matlab Simulink utilisés.

N°	Matlab Simulink Blocksets		
	Ensemble de blocs	Bibliothèque	Quantité
1	Image From File	Video and Image Processing Blockset> Sources	01
2	Display	Simulink> Sinks	01
3	Video Viewer	Video and Image Processing Blockset> Sinks	06
4	Embedded MATLAB Function	Simulink> User-Defined Functions	10
5	Constant	Simulink> Source	01
6	C6713DSK	Target for TI C6000> C6000 Target Preferences	01
7	Image data type conversion	Video and Image Processing Blockset> Conversions	05

Sur Matlab/Simulink, il existe une bibliothèque contenant un bloc spécifique pour chaque type de carte DSP, à partir de cette bibliothèque, nous ajoutons le bloc C6713 puis nous sélectionnons le type de processeur et également la valeur de la fréquence d'horloge. Concernant le passage du DSP Simulink Model au CCS, MATLAB a développé un outil "Matlab Link for code composer studio" qui lui a permis de communiquer avec le Code Composer Studio pour la compilation, le débogage en temps réel et le programme de liaison dans Integrated Development Environment (IDE). Le modèle simulink proposé de notre système de segmentation est illustré complètement dans la figure V.9 ci-dessus.

V-3-2- Étapes de mise en œuvre à l'aide du TMS320C6713 DSP:

Les différentes étapes de mise en œuvre à l'aide du processeur DSP concernent principalement le dépannage de DSK, la création d'un nouveau fichier de projet, les étapes de construction du code et enfin l'exécution du nouveau projet. Le modèle Simulink de notre système est aussi transformé en modèle implémenté sur DSP à l'aide de l'outil Real Time Workshop (RTW) et C6x ou les étapes suivantes sont exécutées l'un après l'autre:

Etape 1 : Conception et création du modèle Simulink. Premièrement, l'algorithme développé est implémenté sur l'environnement de développement MATLAB. La principale raison de cette sélection est la quantité importante des données disponibles et en raison de la popularité croissante de ce langage car il existe une grande quantité d'applications disponibles. L'algorithme ensuite doit être testé pour vérifier son bon fonctionnement en le simulant en utilisant des images de type IRM pour obtenir des résultats souhaités.

Etape 2 : Connexion du kit TMS320C6713 DSK et exécution le Diagnostics pour vérifier la configuration CCS et le bon fonctionnement de chaque unité, si les diagnostics de l'USB, émulation, le DSP, mémoire externe, flash, codec, LED et le commutateur DIP sont corrects, il indique l'état de diagnostic comme PASS, sinon il donne FAIL. La figure V.10 ci-dessous montre l'utilitaire de diagnostic et la connectivité C6713DSK.

Etape 3 : Démarrage du Code Composer Studio (CCS) en mode CPU pour connecter le starter kit C6713DSK via l'application CCS.

Etape 4 : La collaboration de MathWorks Corp et Texas Instruments Inc a réduit immensément la complexité de programmation de la carte. Maintenant, on peut lancer l'application MATLAB en étape principale puis le modèle Simulink pour définir les blocs

cibles en fonction de la configuration du kit DSP en utilisant les paramètres de configuration dans RTW, après cela en sélectionnant le fichier cible du système comme `ccslink_ert.tlc` qui génère automatiquement le code en langage C.




Figure V.10 : Le dépannage de la connectivité C6713 DSK.

Etape 5 : Accédez à l'option Link for CCS et définissez les paramètres suivants : Nom de la poignée: cc, Taille de la pile: 8192, Action de construction: construction.

Etape 6 : Enregistrer le modèle et configurer les options de compilation (voir la figure V.11) puis allez dans le RTW et cliquez sur générer le code. Ensuite le CCS génère un fichier de projet qui stocke les paramètres du projet et référence les différents fichiers utilisés. Le CCS crée automatiquement un sous-répertoire et y place le fichier projet. La première configuration de projet est définie comme active. Le nouveau projet hérite des options du compilateur et de l'éditeur de liens par défaut fournis pour les configurations de débogage.




Figure V.11 : Fenêtre de configuration des options de compilation.

Etape 7 : Après l'étape de configuration et une fois le projet est généré (voir la figure V.12), toutes les fichiers de prise en charge et les fichiers de bibliothèque doivent être joindre avant la phase d'exécution finale, ces types de fichier divise la mémoire de la carte en des sections. Les étapes de l'exécution du fichier de projet sont les suivants: Project-compile file, Project-Build, Project-Rebuild, File-Load program, Debug-Run.

Etape 8 : Après avoir exécuté le projet, le fichier de sortie est disponible dans c: \\\ cc studio-v31 \ my projects sous le nom et l'extension (exécutable.out).

(a)

(b)

```
### Loading TLC function libraries
.....
### Initial pass through model to cache user defined code
...
### Caching model source code
.....
### Writing header file Improved_Spatial_Fuzzy_C_Means_types.h
.
### Writing header file Improved_Spatial_Fuzzy_C_Means.h
### Writing header file Improved_Spatial_Fuzzy_C_Means_private.h
.

### Writing source file Improved_Spatial_Fuzzy_C_Means.c
### Writing source file Improved_Spatial_Fuzzy_C_Means_data.c
### Writing source file Improved_Spatial_Fuzzy_C_Means_main.c
.

### TLC code generation complete.
### Generating the DSP/BIOS configuration file ...
### Creating project in Code Composer Studio(tm)...
### Building Code Composer Studio(tm) project...
### Build complete
### Downloading COFF file
### Downloaded: Improved_Spatial_Fuzzy_C_Means.out
>>
```

Figure V.12 : (a) : Projet CCS et ses fichiers, (b) : Fenêtre de commande MATLAB, Génération du code TLC et téléchargement automatique du code C.

Concernant la mise en œuvre de notre système de segmentation en temps réel. L'algorithme a été implémenté avec succès sur le processeur C6713 DSP à l'aide du MATLAB Simulink, Code Composer Studio et Real Time Workshop (RTW). La figure V.13 montre un instantané de la configuration pour une mise en œuvre en temps réel, c'est-à-dire un ordinateur portable avec MATLAB Simulink, CCS et le kit matériel TMS320C6713 DSK.




Figure V.13 : Mise en place de l'implémentation en temps réel.

V-3-3- Emulation matérielle et échange de données en temps réel:

Le processeur TMS320C6713 DSP a une très bonne prise en charge de l'émulation qui permet au CCS de mieux surveiller et contrôler l'exécution du programme et les activités en temps réel. Le lien JTAG permet la communication avec le support d'émulation sur DSK. La liaison JTAG est un moyen de communication à faible intrusion avec d'autres systèmes DSP.

L'émulation permet le transfert de code et de données dans le DSP, générer des points d'arrêt de l'instruction matérielle, démarrer, arrêter et réinitialiser le processeur DSP. Examen du contenu des registres et de la mémoire du DSP. Le CCS fournit un support intégré pour effectuer diverses activités avec ces émulations. L'échange de données en temps réel et l'interface de programmation d'application DSP permettent l'échange de données bidirectionnel en temps réel entre l'hôte (PC) et le kit de démarrage DSK.

L'échange et le transfert de données en temps réel entre le PC et le DSK fonctionne en exécutant le RTDX sans arrêter leur application cible. La propriété RTDX offre également l'analyse et la visualisation des données en temps réel et continue tout au long du processus à l'aide de l'automatisation Object Linking and Embedding. Le programme d'application DSP appelle la bibliothèque API pour le transfert de données de l'hôte vers la cible. Le matériel d'émulation sur puce transfère les données vers ou depuis le PC hôte à l'aide de l'interface JTAG améliorée. La figure V.14 montre le transfert de données en temps réel pendant l'exécution de l'application DSP. La bibliothèque RTDX sur le PC hôte fonctionne en conjonction avec le Code Composer Studio. En utilisant l'API de communication et le RTDX, les données peuvent être affichées et analysées en temps réel.





Figure V.14 : L'outil JTAG et RTDX.

V-3-4- Résultats issus de l'implémentation et discussion:

Après que l'application MATLAB soit établi un lien avec le Code Composer Studio et en suite lance la compilation, le simulink s'interface avec CCS et génère automatiquement le code C/C++ du projet. La cible C6x prend alors automatiquement le code C/C++ généré et utilise les outils de Texas instrument CCS v3.1 pour compiler en un code machine et charger enfin ce code ciblé sur le processeur C6713DSP. Après le chargement et l'exécution du fichier exécutable sur le matériel DSK, la validation du système de segmentation est effectuée comme étape finale en utilisant les propriétés du Code Composer Studio.

Pour visualiser les résultats du système de segmentation proposé sous forme des images sur CCS, le tampon de sortie (output buffer) est mis à jour en permanence et au cours d'exécution. Le CCS est utilisé pour afficher les données de sortie actuellement stockées dans le tampon de sortie (out buffer). On doit sélectionner "View puis Graph puis image" et modifier la boîte de dialogue "Propriétés du graphe". L'adresse de départ du tampon de sortie est out_buffer de chaque fonction que l'on veut afficher. Les autres options peuvent être laissées par défaut. Puis appuyez sur OK et vérifiez que l'image de sortie est identique que

l'image d'entrée en premier stage. La capture instantanée de l'image d'entrée et ses images de sortie correspondantes sont illustrées dans la figure V.15 suivante.






Figure V.15 : Les résultats expérimentaux de ISKFCM et leur implémentation sur TMS320C6713 DSP: (a) image IRM original, (b) image résultante après pré-traitement, (c) Matière blanche MB, (d) Matière grise MG, (e) liquide céphalo-rachidien LCR.

De plus, les résultats présentés ci-dessous et la mise en œuvre sur le Starter Kit DSP TMS320C6713 ont clairement indiqué que l'algorithme ISKFCM donne des très bons résultats. Sur la base des tendances actuelles observées, il est essentiel de souligner que les résultats de l'implémentation vérifient que le comportement et les images de notre modèle implémenté sont précis et similaires aux résultats obtenus par simulation sur Matlab/Simulink. Les performances des algorithmes implémentés ISFCM et ISKFCM sont analysées en obtenant le nombre de cycles nécessaires pour exécuter leurs codes.

V-4- Codage et optimisation de l'algorithme ISFCM et ISKFCM sur CCS :

Pour créer une application efficace, il est nécessaire de se concentrer sur les performances, la puissance, la taille du code et le coût en fonction des objectifs. L'analyse du code d'application est le processus de collecte et d'interprétation des données sur les facteurs qui influencent l'efficacité d'une application. Le CCS fournit un outil de profil pour aider à analyser le code généré. Pour optimiser les performances, il est nécessaire de réduire les cycles de blocage et d'augmenter le taux de réussite de diverses mémoires cache. Cependant, cela nécessite un processus et des techniques spécifiques.

Le code C initial contenait un certain nombre de boucles conditionnelles non optimisées comme : for, if-else et ça consume beaucoup de temps. Les techniques d'optimisation du compilateur et de l'assembleur C ont également été optimisées pour des meilleures performances. La mémoire cache L2 a été activé et désactivé et élargie pour vérifier l'amélioration de performance. Après avoir appliqué diverses techniques d'optimisation, une réduction d'environ 12.6% de MIPS a été obtenue.

A l'aide de la fonction de mesure des performances de Code Composer Studio (profiling), on peut déterminer le temps d'exécution de l'algorithme ou l'exécution pas à pas du programme est nécessaire en utilisant les fonctions : breakpoints, l'activation de l'horloge DSP et RTDX qui permettent de contrôler finement l'exécution et de déterminer le temps de calcul (en nombre de cycles d'horloge). L'exécution pas à pas et la « Watch Window » combinés sont des outils puissants de débogage, car ils permettent de visualiser et modifier le contenu des variables à tout moment du déroulement d'un programme.

V-4-1- Profilage sans & avec optimisation du code C/C++:

Les codes C/C++ développés pour les deux algorithmes ISFCM et ISKFCM ont été optimisé pour une meilleure performance en utilisant diverses techniques ou le nombre d'instructions de branche générées par le code était ciblé. En combinant pour les boucles, qui effectuent des opérations sur le même ensemble de données, le nombre total de branches a été réduit. Des déclarations conditionnelles comme 'si' et d'autres ont été combinées d'une façon pour une meilleure performance. Tableau V.2 montre l'amélioration de performances obtenue.

Tableau V.2 : Mesure de performance sans&avec optimisation du code C.

N°	Profilage sans & avec optimisation du code C/C++		
	Fonctions	No. des Cycles CPU (Sans Optimisation)	No. des Cycles CPU (Avec Optimisation)
1	Image Conversion	395471	393225
2	Convert Image to double	350236	349957
3	Pré-traitement	9029522	8727113
4	K-means	9587775	9142286
5	PNMF	9931680	9210991
6	ISFCM	9519433	9301599
7	ISKFCM	9864251	9715739
8	Post-traitement	9448263	8945907
9	Convert Image to uint8	374526	369997
Total_ISFCM		48636906	46441075
Total_ISKFCM		48981724	46855215

V-4-2- Profilage sans & avec optimisation du compilateur C:

Le compilateur C6x offre une prise en charge du langage de haut niveau en transformant le code C en code source en langage assembleur plus efficace. Les outils du compilateur incluent un programme appelé shell (cl6x), qui est utilisé pour l'optimisation. Pour profiler le code C de l'algorithme ISFCM et ISKFCM proposés et aussi pour maximiser l'efficacité, il faut changer le compilateur par l'utilisation de l'option (-g -O3) et pour le linker, on ne change rien et garder l'option (-c -O) comme montre la figure V.16. L'option -O3 est le plus haut niveau d'optimisation. Les résultats d'optimisation sont illustrés dans le tableau V.3 :




Figure V.16 : L'outil de configuration du compilateur.

Tableau V.3 : Mesure de performance sans&avec optimisation du compilateur C.

N°	Profilage sans & avec optimisation du compilateur C		
	Fonctions	No. des Cycles CPU (Sans Optimisation)	No. des Cycles CPU (Avec Optimisation)
1	Image Conversion	393225	392899
2	Convert Image to double	349957	349957
3	Pré-traitement	8727113	8712816
4	K-means	9142286	9041049
5	PNMF	9210991	8807366
6	ISFCM	9301599	9258138
7	ISKFCM	9715739	9513815
8	Post-traitement	8945907	8344187
9	Convert Image to uint8	369997	369997
Total_ISFCM		46441075	45276409
Total_ISKFCM		46855215	45532086

V-4-3- Profilage sans & avec optimisation de la mémoire cache L2:

Dans notre travail, les besoins en mémoire proviennent du fait que les données doivent être initialement stockées et traités de manière appropriée. Le système DSP intégré à une ressource mémoire limitée, l'espace par défaut sélectionné par CCS ne répond pas aux exigences de stockage mémoire. La taille de la mémoire cache L2 a également été augmentée pour vérifier les performances améliorées. Le starter kit TMS320C6713 DSK offre une fonctionnalité permettant de modifier la taille du mémoire cache L2 de 0 Ko à 256 Ko. Cette modification peut être effectuée en modifiant le paramètre CACHE_L2CFG dans le fichier gel du projet CCS. L'effet de la modification de la taille du mémoire cache dépend grandement de la façon dont l'algorithme accède aux données. La performance avant et après l'ajustement de la mémoire cache L2 à 256 Ko est indiquée dans le tableau V.4 ci-dessous.

Tableau V.4 : Mesure de performance sans&avec optimisation de la mémoire cache L2.

N°	Profilage sans & avec optimisation de la mémoire cache L2		
	Fonctions	No. des Cycles CPU (Sans Optimisation)	No. des Cycles CPU (Avec Optimisation)
1	Image Conversion	392899	391225
2	Convert Image to double	349957	340196
3	Pré-traitement	8712816	8577113
4	K-means	9041049	8742286
5	PNMF	8807366	8510991
6	ISFCM	9258138	9201599
7	ISKFCM	9513815	9415739
8	Post-traitement	8344187	8045907
9	Convert Image to uint8	369997	369990
Total_ISFCM		45276409	44179307
Total_ISKFCM		45532086	44393447

V-4-4- Profilage sans & avec optimisation de l'assembleur:

Le Code Composer Studio offre des différents choix pour générer un code d'assembleur optimisé. Une façon d'optimiser le code assembléur linéaire consiste à réduire le nombre des cycles d'exécution dans une boucle. On peut le faire en réécrivant les instructions d'assembléur linéaires afin que les instructions d'assembléur finales s'exécutent en parallèle. Les résultats d'optimisation de l'assembléur sont illustrés dans le tableau V.5.

Tableau V.5 : Mesure de performance sans&avec optimisation de l'assembléur.

N°	Profilage sans & avec optimisation de l'assembléur		
	Fonctions	No. des Cycles CPU (Sans Optimisation)	No. des Cycles CPU (Avec Optimisation)
1	Image Conversion	391225	390899
2	Convert Image to double	340196	339957
3	Pré-traitement	8577113	8212816
4	K-means	8742286	8441049
5	PNMF	8510991	8107366
6	ISFCM	9201599	9018138
7	ISKFCM	9415739	9113815
8	Post-traitement	8045907	7644187
9	Convert Image to uint8	369990	369847
Total_ISFCM		44179307	42524259
Total_ISKFCM		44393447	42619936

V-5- Évaluation de performances et validation du système de segmentation

Cette section comprend une brève analyse des résultats des travaux expliqués dans le chapitre IV. Nous avons testé les performances de l'algorithme développées ISFCM et ISKFCM sur des images cérébrales IRM réelles et simulées en les segmentant principalement en des parties constituantes à savoir : (LCR) liquide céphalo-rachidien, (MG) matière grise et (MB) matière blanche et la partie tumorale. ISFCM et ISKFCM sont également comparée avec d'autres algorithmes de clustering concurrentes telles que : FCM, GFCM, RSCFCM, KGFCM, GKFCM, CsKFCM. Les résultats de chaque technique sont analysés individuellement en fonction des différents mesures de performance ou l'analyse qualitative est présentée suivie par l'analyse quantitative sur l'efficacité de la segmentation obtenue.

V-5-1- Outils de validation:

La validation de cluster fait partie intégrante de tout processus de clustering des images. Elle donne une idée de la qualité des termes des clusters, l'ensemble de données et du domaine du problème. Afin de valider le système de segmentation d'image médical, certaines des mesures de performance sont calculées et illustrées dans cette section. En ce qui concerne les performances et la précision de nos algorithmes de segmentation : ISFCM et ISKFCM sont évaluée à l'aide de diverses mesures de validation telles que : l'indice de similarité (ρ), le coefficient de partition Vpc et l'entropie de partition Vpe , la fonction de Fukuyama-Sugeno Vfs et la fonction de Xie-Beni Vxb . La précision de segmentation optimale (SA) et le taux de classification erronée (MCR) sont également utilisées pour évaluer les performances de segmentation en terme quantitative. Ces différentes mesures de validation sont définies en détail dans le chapitre I, la sous-section I-2-7.

V-5-2- Évaluation qualitative:

L'évaluation qualitative fournit des informations utiles sur l'application cible, le type et la qualité des images, les faiblesses de l'algorithme de segmentation et les résultats des différentes étapes d'une méthode. Parmi les expériences qu'on a faites, pour cette sous-section nous avons sélectionné une image IRM cérébrale réelle pondérée en T1 à partir de la base de données BRATS2019. Sur la figure V.12, les trois images en tranches sont extraites à partir des données de type IRM cérébrales 3D avec les plans : axial, sagittal et coronal, respectivement. L'algorithme ISKFCM a été testé sur différents volumes d'image sélectionnée avec un pré-traitement est appliqué. L'observation visuelle de ces résultats est clairement révélé la supériorité de l'approche proposée en termes d'efficacité de segmentation. En même temps, six algorithmes de segmentation d'image représentatifs ont été sélectionnés pour comparer avec l'algorithme ISKFCM. Les résultats expérimentaux de segmentation sont présentés sur la figure V.17.

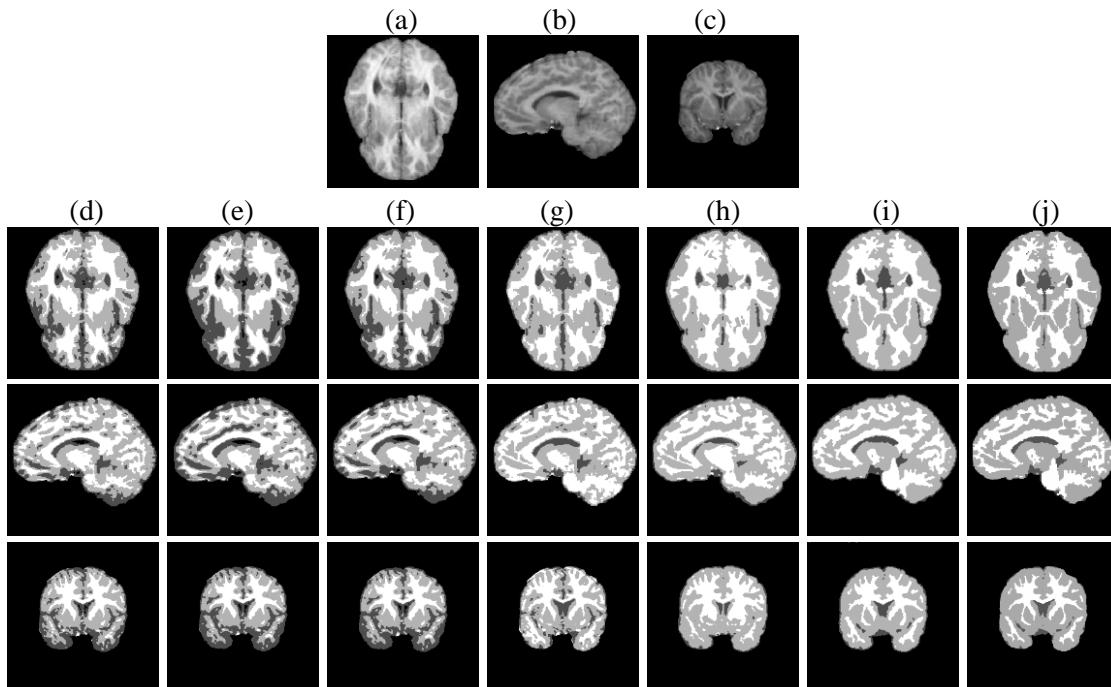


Figure V.17 : Comparaison des résultats de segmentation sur des images IRM réelles : (a) coupe axial, (b) coupe coronal, (c) coupe sagittale, (d) FCM, (e) GFCM, (f) KGFCM, (g) GKFCM (h) CsKFCM, (i) ISFCM, (j) ISKFCM.

On peut clairement voir et constater que les résultats de segmentation de l'ISFCM sont plus proches de l'ISKFCM, ce qui valide en outre l'efficacité de l'algorithme proposé sur des images IRM cérébrales réelles. L'effet de segmentation du CsKFCM et de KGFCM est relativement bon, mais ils ne sont pas idéaux pour le traitement de la structure de bord du tissu cérébral. En comparant avec l'approche ISKFCM, on remarque que cette dernière possède un meilleur degré de correspondance et des meilleurs résultats de segmentation.

V-5-2- Évaluation quantitative:

Afin de comparer plus clairement les performances des différents algorithmes de segmentation étudiés, l'évaluation quantitative est considérée ou les expériences sont également menées à l'aide des différents algorithmes de clustering. Dans cette sous-section, nous présentons plusieurs exemples avec des différents indices de validation. L'algorithme proposé est appliqué sur des images IRM cérébrales simulées et réelles acquises à partir d'un jeu de données BrainWeb et BRATS 2019 respectivement. Le même ensemble de données est utilisé pour évaluer les performances de segmentation sur différentes modalités(coupes en T1, T2 et PD).L'approche proposée est analysée en suite en termes d'efficacité de segmentation optimale (SA %), de l'indice de similarité (ρ), la fonction de Fukuyama-Sugeno Vfs, le coefficient de partition V_{pc} , la fonction de Xie-Beni V_{xb} , l'entropie de partition V_{pe} et le taux de classification erronée (MCR %).Le tableau V.6 suivant indique les résultats de segmentation en termes des indices de validité : ρ, V_{pc}, V_{pe} dans des différents niveaux de bruit gaussien et d'intensité d'inhomogénéité.

Tableau V.6 : Performances comparatives (ρ, V_{pc}, V_{pe}) des différents algorithmes de segmentation sur des images IRM cérébrales simulées avec différents IIH et niveaux de bruit.

T1-Image IRM	Indices de validité	Techniques de Segmentation							
		FCM	GFCM	GKFCM	KGFCM	RSCFCM	CsKFCM	ISFCM	ISKFCM
Bruit 5%, IIH 20%	ρ (%)	72.04	74.62	77.84	79.10	79.00	80.04	82.96	84.69
	V_{pc}	0.709	0.711	0.915	0.953	0.951	0.962	0.987	0.991
	V_{pe}	0.532	0.528	0.159	0.12	0.087	0.053	0.017	0.008
Bruit 5%, IIH 40%	ρ (%)	71.97	74.40	77.64	79.05	78.83	80.01	82.71	84.39
	V_{pc}	0.709	0.646	0.896	0.935	0.918	0.946	0.974	0.983
	V_{pe}	0.532	0.658	0.197	0.156	0.153	0.085	0.043	0.024
Bruit 7%, IIH 20%	ρ (%)	71.32	72.82	75.94	78.66	76.55	79.13	81.37	82.21
	V_{pc}	0.618	0.622	0.819	0.864	0.851	0.914	0.965	0.977
	V_{pe}	0.714	0.706	0.351	0.298	0.287	0.149	0.061	0.036
Bruit 7%, IIH 40%	ρ (%)	71.08	72.46	75.72	78.36	76.28	79.03	81.04	82.10
	V_{pc}	0.609	0.62	0.805	0.859	0.846	0.91	0.961	0.961
	V_{pe}	0.732	0.71	0.379	0.308	0.297	0.157	0.069	0.068
Bruit 9%, IIH 20%	ρ (%)	70.70	71.98	74.27	77.99	75.62	78.95	80.10	80.14
	V_{pc}	0.591	0.614	0.8	0.847	0.833	0.908	0.944	0.953
	V_{pe}	0.768	0.722	0.389	0.332	0.323	0.161	0.103	0.084
Bruit 9%, IIH 40%	ρ (%)	70.66	71.97	74.19	77.94	75.47	78.84	80.02	80.12
	V_{pc}	0.586	0.607	0.792	0.841	0.83	0.904	0.936	0.948
	V_{pe}	0.778	0.736	0.405	0.344	0.329	0.169	0.119	0.094

Pour des bonnes performances de clustering, la valeur de coefficient de partition V_{pc} doit être maximale et la valeur de l'entropie de partition V_{pe} doit être minimale.Les résultats obtenus montrent qu'en présence de bruit et l'intensité d'inhomogénéité sur des images IRM

cérébrales, la performance des algorithmes GFCM, GKFCM et KGFCM se dégradent également. L'algorithme RSCFCM et l'algorithme de clustering CsKFCM limitent leurs performances lorsque le niveau de variance du bruit augmente d'une façon progressive. Mais l'algorithme de clustering ISFCM produit des résultats supérieurs pour différents niveaux de bruit gaussien. Aussi l'algorithme de clustering ISKFCM fonctionne très bien et donne des bons résultats par rapport aux autres algorithmes proposés qui ne parviennent pas à supprimer l'effet du bruit ajouté et l'intensité d'inhomogénéité.

Une comparaison des mesures performances sélectionnés (V_{pc} , V_{pe} , ρ) pour les différents algorithmes est présentés sur les figures V.18, 19 et 20 respectivement.




Figure V.18 : Comparaison des performances en termes de coefficient de partition V_{pc} .

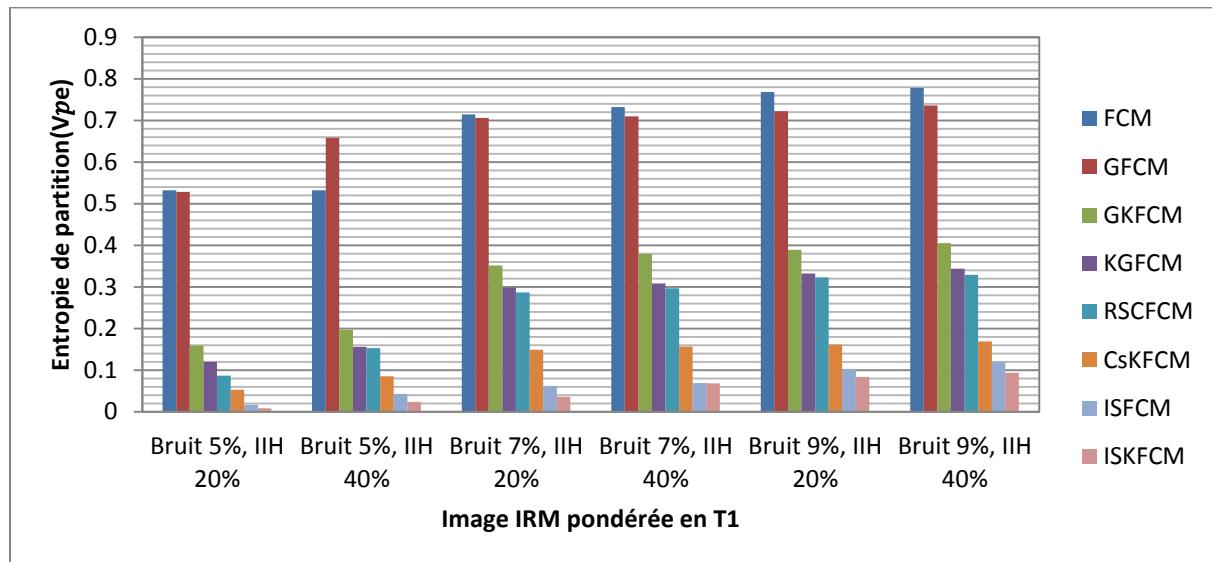


Figure V.19 : Comparaison des performances en termes d'entropie de partition V_{pe} .

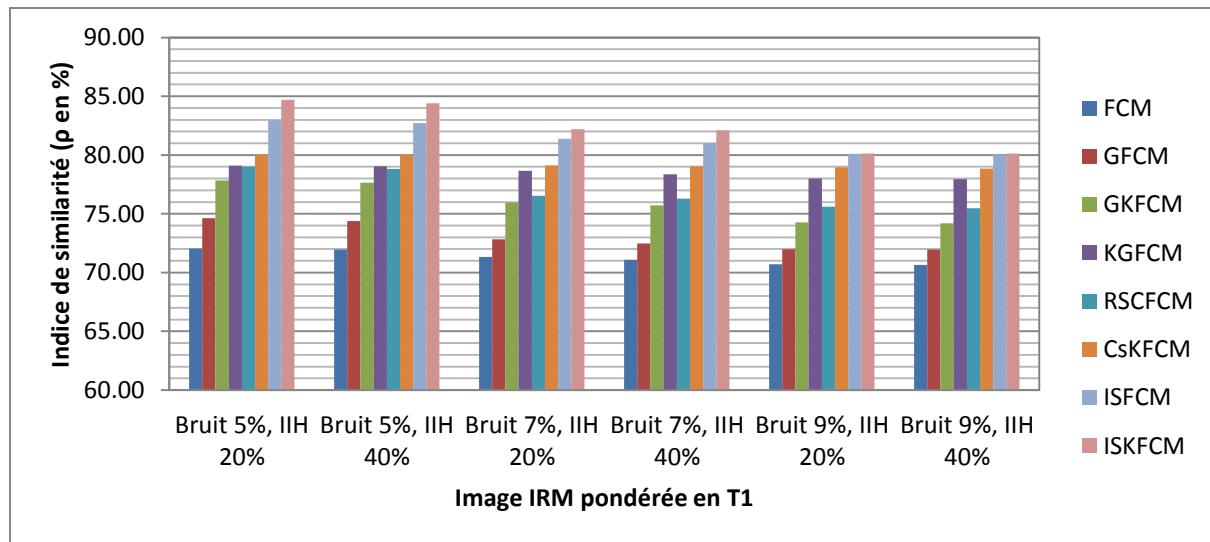


Figure V.20 : Comparaison des performances en termes de similarité (ρ).

Pour valider les performances de l'algorithme proposé en présence d'une distribution réelle du bruit gaussien et des différents niveaux d'intensité d'inhomogénéité (20-40%). Le tableau V.7 suivant montre les résultats d'évaluation en termes des deux fonctions : la fonction de Fukuyama-Sugeno V_{fs} et la fonction de Xie-Beni V_{xb} , ces résultats obtenus sont comparés en utilisant respectivement les algorithmes de clustering suivants : FCM, GFCM, GKFCM, KGFCM, RSCFCM, CsKFCM, ISFCM et ISKFCM.

Tableau V.7 : Performances comparatives (V_{xb} , V_{fs}) des différents algorithmes de segmentation sur des images IRM cérébrales simulées avec différents IIH et niveaux de bruit.

T1-Image IRM	Validité	Techniques de Segmentation							
		FCM	GFCM	GKFCM	KGFCM	RSCFCM	CsKFCM	ISFCM	ISKFCM
Bruit 5%, IIH 20%	V_{xb}	0.232	0.222	0.165	0.127	0.132	0.103	0.052	0.031
	V_{fs}	-100.180	-96.761	-106.055	-106.613	-111.112	-107.994	-134.642	-141.885
Bruit 5%, IIH 40%	V_{xb}	0.237	0.229	0.170	0.136	0.147	0.115	0.068	0.047
	V_{fs}	-94.112	-89.248	-101.253	-97.926	-96.485	-95.143	-118.339	-125.274
Bruit 7%, IIH 20%	V_{xb}	0.249	0.236	0.198	0.154	0.163	0.139	0.090	0.075
	V_{fs}	-72.364	-74.379	-76.476	-79.712	-80.364	-71.677	-96.174	-97.115
Bruit 7%, IIH 40%	V_{xb}	0.254	0.238	0.201	0.165	0.179	0.142	0.107	0.081
	V_{fs}	-63.615	-62.667	-70.224	-68.344	-64.231	-68.368	-79.217	-91.396
Bruit 9%, IIH 20%	V_{xb}	0.261	0.242	0.212	0.180	0.188	0.150	0.122	0.103
	V_{fs}	-51.954	-53.145	-59.391	-53.453	-55.450	-60.147	-64.552	-69.881
Bruit 9%, IIH 40%	V_{xb}	0.265	0.248	0.217	0.184	0.191	0.153	0.139	0.116
	V_{fs}	-50.687	-52.881	-54.125	-49.913	-52.274	-56.339	-47.964	-57.483

Comme nous observons à partir du tableau V.7 que pour la fonction de Xie-Beni (V_{xb}), les algorithmes KGFCM et CsKFCM produisent des résultats raisonnables, mais pour la FCM, GFCM et GKFCM une erreur de classification est bien remarquée en raison d'une mauvaise classification des pixels et même pour les valeurs de la fonction de Fukuyama-Sugeno V_{fs} qui sont plus faible par rapport aux autres algorithmes. L'une des raisons le plus important est l'intégration des informations spatiales ou les deux algorithmes ISFCM et ISKFCM produisent des meilleures résultats et conduit à une analyse efficace ou la valeur

optimisée du paramètre de voisinage reflète la corrélation entre les pixels voisins qui aident à améliorer les performances de la segmentation. L'analyse comparative et l'observation visuelle de ces résultats a clairement révélé la supériorité de l'approche proposée en termes d'efficacité de segmentation. Les résultats quantitatifs des deux fonctions Xie-Beni Vxb et Fukuyama-Sugeno Vfs, sont présentés graphiquement sur les deux figures V.21 et V.22.

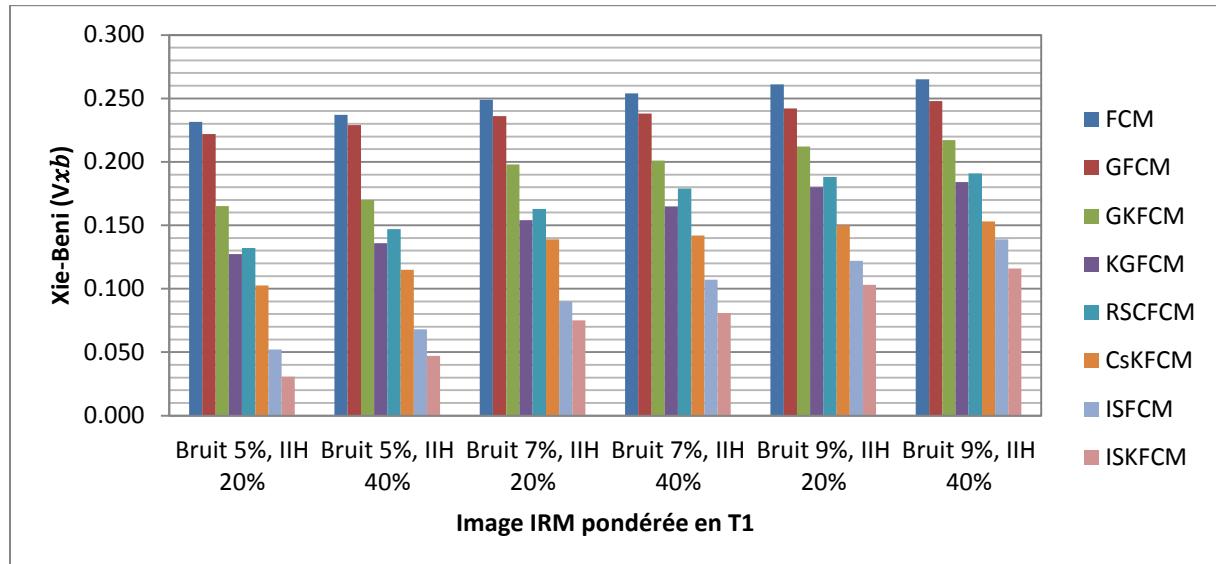


Figure V.21 : Comparaison des performances en termes de la fonction de Xie-Beni Vxb.

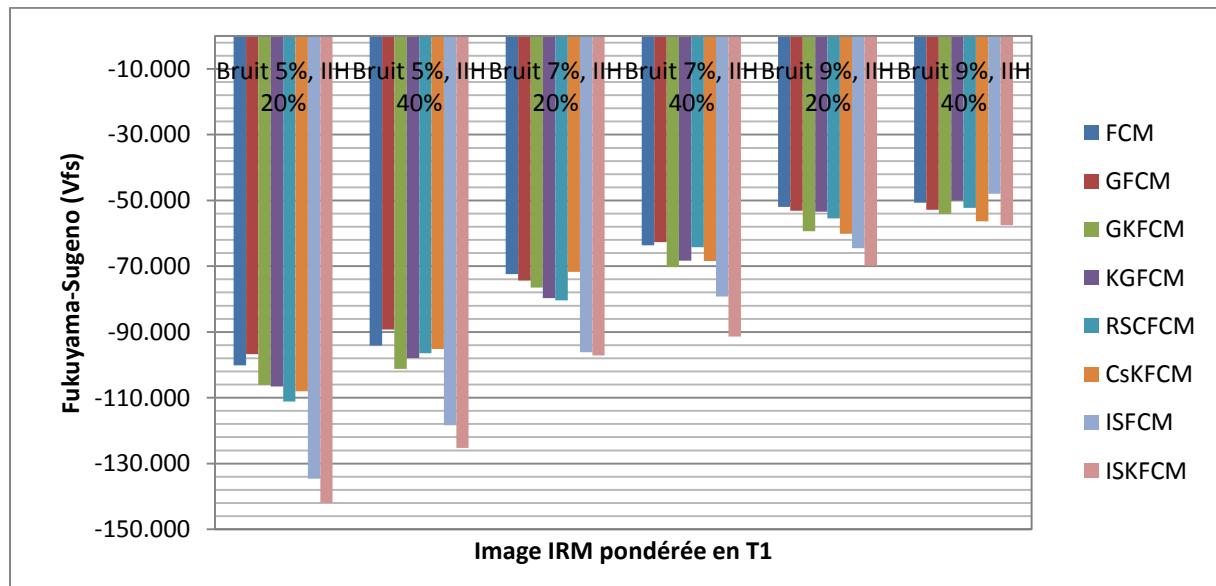


Figure V.22 : Comparaison des performances en termes de Fukuyama-Sugeno Vfs.

L'étape suivante aborde brièvement les performances de l'algorithme ISKFCM. Pour bien évaluer et comparés ses performances pour les diverses approches, nous utilisons deux rapports de validation : la classification erronée (MCR) et la précession de la qualité de segmentation (SA) dans nos expériences. La valeur de MCR se situe dans une plage de [0% – 100%], où les valeurs inférieures indiquent des meilleures performances de segmentation et l'inverse est vrai pour le rapport SA%. Les résultats de segmentation des différents algorithmes sur des images IRM cérébrales simulées avec différents IIH et niveaux de bruit sont présentés sur le tableau V.8.

Tableau V.8 : Performances comparatives (SA%, MCR%) des différents algorithmes de segmentation sur des images IRM cérébrales simulées avec différents IIH et niveaux de bruit.

T1-Image IRM	Indices de validité	Techniques de Segmentation							
		FCM	GFCM	GKFCM	KGFCM	RSCFCM	CsKFCM	ISFCM	ISKFCM
Bruit 5%, IIH 20%	SA	77.56	83.39	97.46	97.88	97.65	97.92	98.83	98.91
	MCR	22.44	16.61	2.54	2.12	2.35	2.08	1.17	1.09
Bruit 5%, IIH 40%	SA	76.95	83.01	94.98	96.79	95.82	97.11	97.52	98.06
	MCR	23.05	16.99	5.02	3.21	4.18	2.89	2.48	1.94
Bruit 7%, IIH 20%	SA	74.17	81.74	91.61	95.34	94.16	95.23	96.71	97.85
	MCR	25.83	18.26	8.39	4.66	5.84	4.77	3.29	2.15
Bruit 7%, IIH 40%	SA	73.82	81.19	89.95	94.15	93.08	94.85	95.96	97.22
	MCR	26.18	18.81	10.05	5.85	6.92	5.15	4.04	2.78
Bruit 9%, IIH 20%	SA	69.19	80.36	86.82	93.83	91.66	94.07	95.74	96.49
	MCR	30.81	19.64	13.18	6.17	8.34	5.93	4.26	3.51
Bruit 9%, IIH 40%	SA	69.03	79.97	86.49	92.74	90.55	93.69	95.92	96.77
	MCR	30.97	20.03	13.51	7.26	9.45	6.31	4.08	3.23

Selon les résultats présentés dans le tableau V.8, on remarque que les algorithmes FCM, GFCM et GKFCM ne segmentent pas bien les images bruitées. Bien que KGFCM, RSCFCM et CsKFCM puissent réduire l'effet du bruit dans une certaine mesure, ils sont toujours sensibles au bruit intense et classent mal certaines parties de pixels. Cependant, nous observons que le ISFCM et ISKFCM proposés donnent des résultats de segmentation exceptionnels par rapport aux performances médiocres de leurs concurrents algorithmes. La comparaison montre que l'algorithme ISKFCM a un taux d'erreurs de classification inférieur pour les images d'IRM cérébrales et donc on peut conclure que l'algorithme ISKFCM proposés dans cette recherche obtienne des meilleurs résultats et en particulier pour la segmentation d'images fortement bruyantes.

Les résultats obtenus en différentes densités de bruit et d'intensité d'inhomogénéité sont donnés sous forme d'histogramme et présentés sur les figures V.23 et V.24 suivantes.




Figure V.23 : Mesures quantitatives pour la précision de segmentation (SA%).

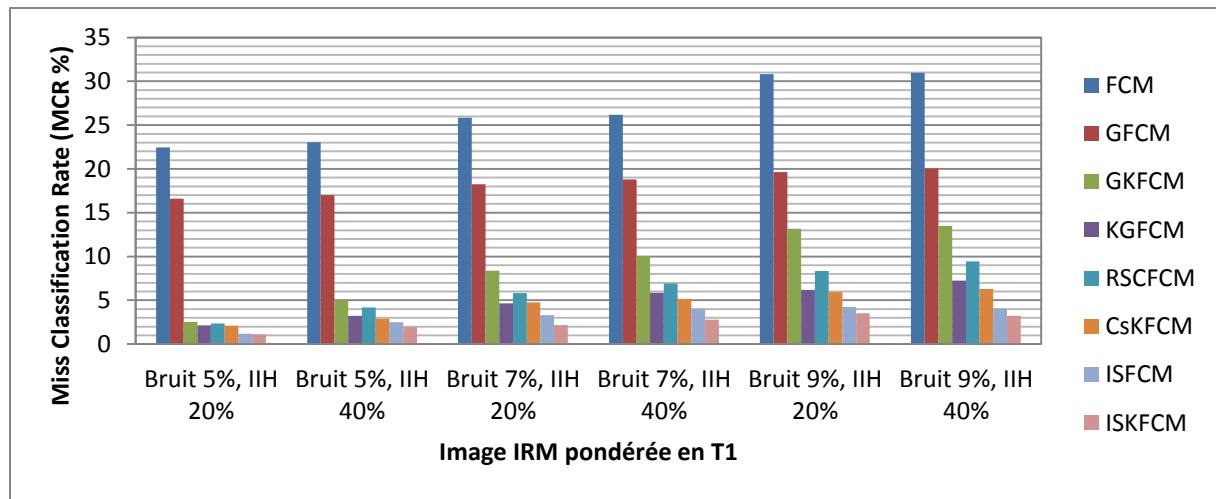


Figure V.24 : Mesures quantitatives pour les taux de classification erronés (MCR%).

Dans cette étude, une expérimentation approfondie est effectuée pour évaluer les performances. Ces expériences connexes ont été menées sur des images IRM cérébrales réelles pondérée en T1, T2 et PD. Les 36 ensembles de données réels ont été considérés pour chaque pondération d'image IRM. Ces ensembles de données sont obtenues de la base de données BRATS2018 et BRAST2019 pour tester et analyser les performances des algorithmes ISKFCM et ISFCM. Afin de valider la précision de notre modèle de segmentation et évaluer quantitativement les effets de segmentation des divers algorithmes, nous avons calculé le taux de performances des critères : ρ , V_{pc} , V_{pe} , V_{xb} , V_{fs} , SA , MCR , dont les résultats des valeurs moyennes sont présentés dans le tableau V.9 suivant.

Tableau V.9 : Les valeurs moyennes des Mesures de performances (ρ , V_{pc} , V_{pe} , V_{xb} , V_{fs} , SA , MCR) sur 36 images cérébrales réelles.

Image IRM	Mesures de performance	Techniques de Segmentation							
		FCM	GFCM	GKFCM	KGFCM	RSCFCM	CsKFCM	ISFCM	ISKFCM
Images IRM cérébrales pondérée en T1	ρ (%)	70.92	72.32	75.03	78.24	75.97	78.99	80.63	81.14
	V_{pc}	0.601	0.614	0.804	0.853	0.84	0.909	0.952	0.959
	V_{pe}	0.748	0.7185	0.381	0.3205	0.309	0.159	0.088	0.071
	V_{xb}	0.257	0.241	0.207	0.171	0.180	0.146	0.115	0.094
	V_{fs}	-59.655	-60.768	-65.054	-62.855	-63.080	-64.133	-71.977	-78.969
	SA(%)	71.55	80.81	88.72	94.01	92.36	94.46	96.08	97.10
	MCR (%)	28.44	19.20	11.28	5.98	7.63	5.54	3.92	2.95
Images IRM cérébrales pondérée en T2	ρ (%)	71.35	72.75	75.46	78.67	76.73	79.75	81.39	81.9
	V_{pc}	0.613	0.626	0.816	0.872	0.859	0.928	0.971	0.978
	V_{pe}	0.598	0.5685	0.231	0.1705	0.298	0.148	0.077	0.06
	V_{xb}	0.235	0.219	0.185	0.149	0.154	0.12	0.089	0.068
	V_{fs}	-58.214	-59.327	-63.613	-61.414	-64.651	-65.704	-73.548	-80.54
	SA(%)	72.87	82.06	90.04	95.33	93.75	95.7	97.47	98.49
	MCR (%)	27.13	17.94	9.96	4.67	6.25	4.33	2.53	1.51
Images IRM cérébrales pondérée en PD	ρ (%)	70.59	71.99	74.7	77.91	75.55	78.57	80.21	80.72
	V_{pc}	0.58	0.593	0.783	0.832	0.823	0.892	0.935	0.942
	V_{pe}	0.707	0.6775	0.34	0.2795	0.239	0.089	0.018	0.013
	V_{xb}	0.282	0.266	0.232	0.196	0.208	0.174	0.143	0.122
	V_{fs}	-57.922	-59.035	-63.321	-61.122	-65.075	-66.128	-73.972	-80.964
	SA(%)	69.98	79.24	87.15	92.44	91.17	93.27	94.89	95.91
	MCR (%)	31.3	22.06	14.14	8.84	9.91	7.82	6.2	5.23

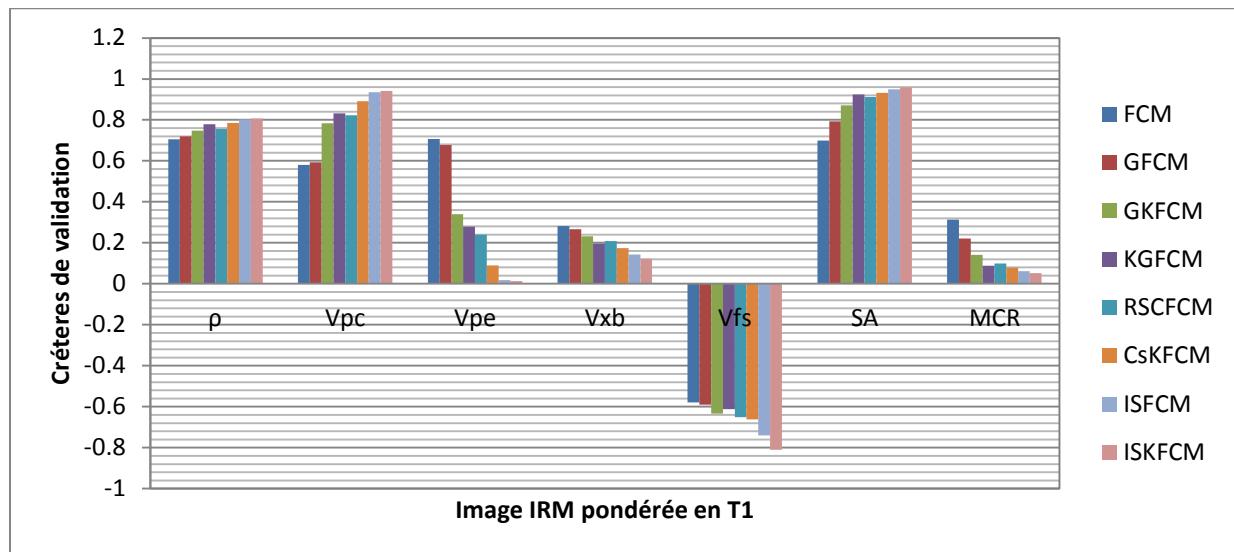


Figure V.25 : Comparaison des critères de validation pour des images IRM pondérées en T1.

Le tableau V.9 et la figure V.25 comparent les performances de divers algorithmes de FCM spatiale et ses variantes. Il est important de souligner que l'ISKFCM était supérieur à la méthode ISFCM pour la plupart des ensembles de données réels en raison de l'impact des informations spatiales sur le voisinage et de l'optimisation du paramètre de distance du voisinage. Tous les résultats rapportés dans ce tableau confirment bien que les méthodes proposées sont les meilleures options en termes de qualité de clustering mesurée par la moyenne de l'indice SA%. En outre, les performances de l'algorithme ISKFCM en termes de ρ , V_{pc} , V_{pe} sont nettement meilleures et la plus élevée parmi les indices de validité considérés.

V-6- Comparaison des résultats de segmentation en termes de convergence

Pour déterminer le comportement de convergence des deux fonctions d'objectif de ISFCM et ISKFCM, un ensemble des expériences sont effectuées sur des images IRM réelles pondérées en T1, T2 et PD et comparer avec les autres méthodes de clustering sélectionnées en termes de convergence. Si l'approche de segmentation est très efficace, elle ne devrait nécessiter que moins d'itérations pour sa convergence. Le comportement de convergence et les valeurs moyennes de nombre d'itérations obtenu pour les différentes approches sur trois ensembles de données sont présentés dans le tableau V.10 suivant.

Tableau V.10 : Comparaison des comportements de convergence.

Approches de segmentation	Comportement de convergence (Nbre des itérations)		
	Images IRM cérébrales pondérée en T1	Images IRM cérébrales pondérée en T2	Images IRM cérébrales pondérée en PD
FCM	103	98	100
GFCM	99	101	96
GKFCM	92	95	97
KGFCM	87	89	91
RSCFCM	75	79	77
CsKFCM	86	83	88
ISFCM	64	69	73
ISKFCM	70	78	75

A partir du tableau V.10, la représentation graphique des résultats de convergence est illustrée dans la figure V.5ou nous avons présenté une comparaison du nombre d'itérations des différents algorithmes améliore considérablement les performances du clustering.

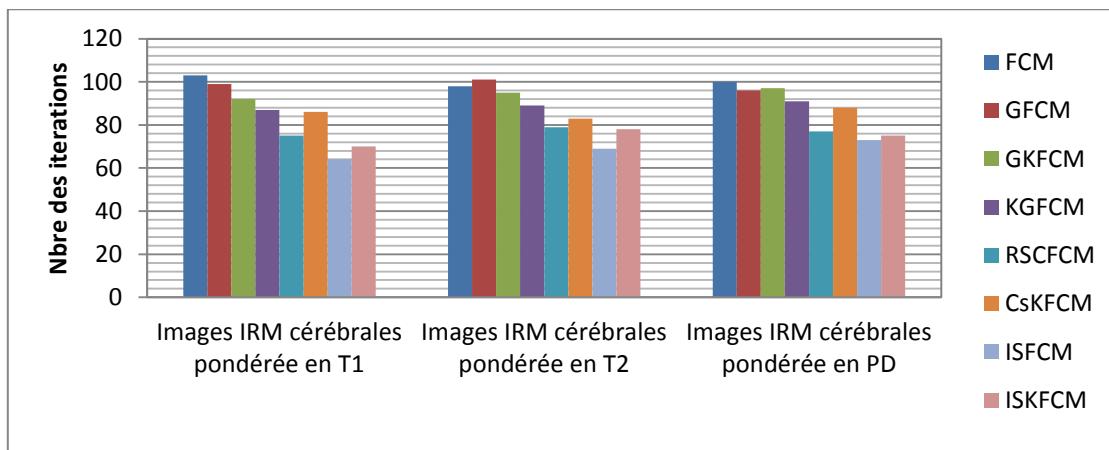


Figure V.26 : Nombre d'itérations effectuées par ISKFCM et d'autres méthodes de clustering.

La figure V.26 ci-dessus révèle que l'algorithme proposé réalise de manière appropriée la segmentation d'images cérébrales IRM réelles. En plus de ces résultats représentés sous forme graphiques, il est révélé ainsi que l'approche ISFCM nécessite moins d'itérations pour sa convergence dans les trois ensembles de données considérés, tandis que les autres approches nécessitent approximativement plus d'itérations pour converger. Cette performance cohérente de l'algorithme ISFCM et ISKFCM n'est devenue possible qu'en raison de l'absence de caractère aléatoire lors de la recherche des centres de cluster initiaux. Par ailleurs, on voit les autres algorithmes sélectionnés ont besoin d'un nombre différent d'itérations pour atteindre les centres de clusters finaux. On peut également remarquer le comportement de convergence de système proposé et démontre sa supériorité sur ses homologues.

V-7- Conclusion :

Ce chapitre a décrit la mise en œuvre de l'algorithme ISFCM et ISKFCM sur PC ainsi que sur C6713DSK via SIMULINK, Real Time Workshop et DSP Target Support. Après l'implémentation embarquée de l'algorithme sur DSK, les résultats du profilage sont obtenus et améliorés en termes de temps d'exécution. Des techniques d'optimisation de méthodes proposées sont effectuées grâce au processus de CCS. Cependant, ce travail a été concentré sur la conception d'un système basé sur le clustering pour l'amélioration de la qualité de la segmentation des images médicales. La méthode proposée a été testée et comparée à sept approches concurrentes basées sur la FCM spatiale de la littérature. Trois pondérations d'images (T1, T2 et PD) ont été utilisées pour l'évaluation des performances en termes de mesures : ρ , V_{pc} , V_{pe} , V_{xb} , V_{fs} , SA, MCR. Par une analyse qualitative et quantitative, les résultats expérimentaux montrent que la méthode proposée ISKFCM donne des meilleurs résultats de segmentation souhaitée et elle est plus robuste sur toutes les images médicales testées.

Conclusion générale

Conclusion générale

Ce travail de recherche est orienté sur une étude comparative des nouvelles méthodes de segmentation d'image qui ont fait l'objet de nombreux travaux de recherche dans ce domaine.

Le but fondamental de cette étude est de proposer des nouvelles méthodes robustes de type C-Moyennes floue pour segmenter les images IRM cérébrales et mettre en valeur l'efficacité de ces méthodes proposées. Ces dernières ont largement atteint les objectifs des travaux de recherche. L'imagerie médicale a révolutionné les procédures de diagnostic modernes ou l'Imagerie par résonance magnétique (IRM) a gagné en particulier une importance dans le diagnostic des images cérébrales.

Mais le problème avec le processus d'acquisition des données et des phénomènes naturels interférents dégrade la qualité de ces images par des distorsions telles que l'inhomogénéité d'intensité, le bruit, l'effet de volume partiel et d'autres artefacts d'imagerie. Ces imperfections peuvent conduire à de fausses décisions par le médecin dans certains cas les plus graves. Le système de segmentation développé fournit des informations détaillées et significatives sur les différents tissus cérébraux et la tumeur cérébrale humaine en fonction des caractéristiques extraites. En outre, ce système aide les chirurgiens en localisant exactement la tumeur dans le cerveau, afin d'effectuer des interventions chirurgicales.

La contribution de cette thèse est de fournir un algorithme amélioré de segmentation d'image utilisant le principe de l'approche C-moyennes floue améliorée pour faire progresser les performances avec une application à l'analyse de données médicales. Pour atteindre cet objectif, une étude exhaustive a été menée pour étudier les diverses techniques de segmentation existantes. L'analyse comparative de l'algorithme C-moyennes floue améliorée basées sur Kernel avec contraintes spatiales ISKFCM et l'algorithme C-moyennes floue améliorée basées sur contraintes spatiales ISFCM sont appliquée sur des divers ensembles de données médicales à savoir, BRATS2018, BRATS2019 et BrainWeb. Les méthodes proposées peuvent également être appliquées à des images IRM de différentes modalités (T1, T2 et PD) car elles ne dépendent d'aucun protocole d'imagerie et de modèles de formation. Notre contribution peut se résumer comme suit:

- De manière méthodologique, nous avons tout d'abord étudié et présenté un panorama des nouvelles méthodes de segmentation pour segmenter les images médicales de type IRM. A savoir les méthodes : CsFCM [ADH 15], CsKFCM [GHA 18], GKFCM [REH 16], KGFCM [ZHA 13], GKWFLICM [MEM 18], RSCFCM [Ji 14]. Ainsi que les principes de base de l'anatomie cérébrale et la technique d'imagerie par résonance magnétique.
- Avant d'entamer le processus de segmentation, nous avons développé une méthode de correction d'intensité pour minimiser l'impact des inhomogénéités d'intensité dans les images IRM. Toutes les images d'entrée subissent une étape

de pré-traitement en utilisant un Filtre de Diffusion Anisotrope modifié (FDAM). Ensuite, l'ablation du crâne (partie non cerveau) est réalisée en appliquant la méthode de croissance de region.

- Pour déterminer les centroïdes initiaux de l'algorithme ISFCM et ISKFCM, on a exécuté l'algorithme k-means modifié (k-means#) en terme d'optimisation, ainsi que le nombre optimal de clusters est prédéterminé d'une manière semi-automatique en utilisant l'algorithme PNMF.
- Nous avons présenté des algorithmes de clustering spatial robustes : ISFCM et ISKFCM pour aborder les problèmes des images de résonance magnétique cérébrales. Les concepts de noyau normé (la distance de kernel), terme d'information spatiale et l'utilisation de la distance Euclidienne ont été utilisés pour développer les deux méthodes proposées dans cette thèse. Les résultats expérimentaux démontrent la robustesse et l'efficacité d'amélioration.
- L'exploration de la post-segmentation a été effectuée par la défuzzification et l'extraction de la région d'intérêt, ensuite le calcul de la zone tumorale et l'extraction de leurs caractéristiques.
- Le processeur de signal numérique TMS320C6713 DSP, Code Composer Studio et l'ensemble des blocs Matlab/Simulink sont utilisés pour mettre en œuvre le système de segmentation proposé. Les performances sont mesurées en incluant diverses techniques d'optimisation et tous les résultats sont affichés à l'aide de l'interface utilisateur graphique C67613.
- Les performances des algorithmes ISFCM et ISKFCM ont été comparées aux algorithmes existants par une évaluation qualitative et quantitative. La métrique d'évaluation objective utilisée pour la segmentation basée sur le clustering est l'indice de similarité (ρ), le coefficient de partition (V_{pc}) et l'entropie de partition (V_{pe}), la fonction de Fukuyama-Sugeno (V_{fs}) et la fonction de Xie-Beni (V_{xb}), la précision de segmentation optimale (SA) et le taux de classification erronée (MCR).
- En comparant les résultats des méthodes proposées avec les méthodes existantes, il a été prouvé que nos méthodes proposées sont très prometteuses.

Les méthodes présentées dans cette thèse sont destinées uniquement à la 2D. Pour étudier le tissu du cerveau, pour estimer le volume du cerveau, pour effectuer des opérations chirurgicales, un neurologue a besoin d'une vue 3D du cerveau. Il existe de nombreuses méthodes d'extraction de volumes cérébraux, qui traitent des coordonnées 3D. Toutes les méthodes de traitement 3D sont complexes et prennent plus de temps pour extraire le volume du cerveau. On peut étendre le présent travail en ajoutant un autre module qui peut convertir les résultats 2D en un volume cérébral 3D. Ce travail est en cours.

Les algorithmes ISFCM et ISKFCM proposés dans cette recherche seront utiles pour obtenir des performances cohérentes et améliorées. On espère également que ce travail motivera et aidera les futurs chercheurs qui s'intéressent aux domaines du clustering flou à trouver des algorithmes de clustering plus robustes avec des performances améliorées ainsi que la capacité de surmonter les limites de certains algorithmes de clustering flou populaires.

Bibliographie

Bibliographie

- [ADH 12] S.K. Adhikari, J.K. Sing, D.K. Basu, M. Nasipuri, P.K. Saha, «*Segmentation of MRI brain images by incorporating intensity inhomogeneity and spatial information using probabilistic fuzzy C-means clustering algorithm*». International Conference on Communications, Devices and Intelligent Systems, pp. 133–136, 2012.
- [ADH 15] S. K. Adhikaria, J. K. Singb, D. K. Basub, M. Nasipuriba, «*Conditional spatial fuzzy C-means clustering algorithm for segmentation of MRI images*». Applied Soft Computing, vol. 34, pp. 758–769, 2015.
- [AIN 19] M. T. Aina Qistina, I. Haidi, «Reduction of Salt-and-Pepper Noise from Digital Grayscale Image by Using Recursive Switching Adaptive Median Filter», Symposium on Intelligent Manufacturing and Mechatronics, Singapore, pp. 32–47, 2019.
- [ALE 06] A. Alessio, P. Kinahan et T. Lewellen, «*Modeling and incorporation of system response functions in 3-d whole body PET*». IEEE Transaction on Medical Imaging, vol. 25, pp. 828–837, 2006.
- [ARA 13] S. Arastehfar, A. Pouyan et A. Jalalian, «*An enhanced median filter for removing noise from MR images*», Journal of AI and Data Mining, vol. 1, No. 1, pp. 13-17, 2013.
- [BAL 10] M. A. Balafar, A. R. Ramlı, M. I. Sarıpan et S. Mashohor, «*Review of brain MRI image segmentation methods*». Artificial Intelligence Review, vol. 33, pp. 261-274, 2010.
- [BAY 14] B. Bayar, N. Bouaynaya, and R. Shterenberg, «*Probabilistic non-negative matrix factorization: Theory and application to microarray data analysis*». Journal of Bioinformatics and Computational Biology, pp. 12–25, 2014.
- [BAY 14] B. Bayar, N. Bouaynaya, et R. Shterenberg, «*Probabilistic non-negative matrix factorization: Theory and application to microarray data analysis*». Journal of Bioinformatics and Computational Biology, pages 12–25, 2014.
- [BEH 06] Y. Behzadi et al, «*Caffeine reduces the initial dip in the visual bold réponse at 3 t*». Neuroimage, No. 32, pp. 9-15, 2006.
- [BHA 94] B. BHANU et S. LEE, «*Genetic Learning for Adaptive Image Segmentation*». Springer, 1994.
- [BHA 94] L. Chaabane, «*Genetic Learning for Adaptive Image Segmentation*». Springer, 94.
- [BHA 99] S.M. BHANDARKAR et H. ZHANG, «*Image segmentation using evolutionary computation*». IEEE Transactions on Evolutionary Computation, vol 3, pages 1–21, 1999.
- [BIT 13] A. BITAM, «*Analyse et segmentation d'image multispectrales : Application aux images MSG*». Thèse de doctorat, Université de Tizi-Ouzou Mouloud Mammeri, 2013.
- [CAI 07] W. Cai, S.Chen, D. Zhang, «*Fast and robust fuzzy C-means clustering algorithms incorporating local information for image segmentation*». Pattern Recognition, vol. 40, no. 3, pp. 825-838, 2007.

- [CER 13] C. Ceritoglu, Tang, M. Chow, et. al., «*Computational analysis of LDDMM for brain mapping*». *Frontiers in Neuroscience*, vol.7, pp. 1-8, 2013.
- [CHE 05] B. Chen, P.C. Tai, R. Harrison, P. Yi, «*Novel hybrid hierarchical-Kmeans clustering method (H-K-means) for microarray analysis*», *IEEE Computational Systems Bioinformatics Conference*, pp. 105–108, 2005.
- [CHU 06] K.S. Chuang, H.L. Tzeng, S. Chen, J. Wu, T.J. Chen, «*Fuzzy C-means clustering with spatial information for image segmentation*». *Comput. Med. Imaging*, pp. 9–15, 2006.
- [CLA 95] L. P. Clarke, R. P. Velthuizen, M. A. Camacho, J. J. Heine, M. Vaidyanathan, L. O. Hall, R. W. Thatcher et M. L. Silbiger, «*MRI segmentation: methods and applications*». *Magnetic Resonance Imaging*, vol. 11, pp. 343-368, 1995.
- [COC 95] J.P. COCQUEREZ, «*Analyse d'images : filtrage et segmentation*». Masson, 1995.
- [COH 91] L. COHEN, «*On active contour models and balloons*». *Computer Vision, Graphics and Image Processing*, vol 53, pages 211–218, 1991.
- [DAB 07] K. Dabov, A. Foi, V. Katkovnik et K. Egiazarian, «*Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering*». *IEEE Trans. On Image Processing*, Vol. 16, No. 8, pp. 2080-2008, 2007.
- [DES 13] I. Despotovic, E. Vansteenkiste, W. Philips, «*Spatially Coherent Fuzzy Clustering for Accurate and Noise-Robust Image Segmentation*». *IEEE Signal Process. Lett*, vol. 20, pp. 295–298, 2013.
- [DUB 16] Y. K. Dubey, M. M. Mushrif, K. Mitra, «*Segmentation of brain mr images using rough set based intuitionistic fuzzy clustering*». *Biocybernetics and Biomedical Engineering*, vol. 36, no.2, pp. 413–426, 2016.
- [EKA 17] D. O. D. Ekashanti, A. A.M. Faudzi, T. L. Mengko, K. Suzumori, «*Recursive Gauss-Seidel median filter for CT lung image denoising*». *Eighth International Conference on Graphic and Image Processing*, 2017.
- [ELA 15] A. Elazab, C. Wang, F. Jia, J. Wu, G. Li, Q. Hu, «*Segmentation of Brain Tissues from Magnetic Resonance Images Using Adaptively Regularized Kernel-Based Fuzzy C-Means Clustering*». *Comput. Math. Methods Med.* Vol. 2015, 2015.
- [GER 99] L. Germond, «*Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale*». Thèse de doctorat, Université Joseph FOURIER Grenoble 1, 1999.
- [GHA 18] B. Gharnali, S. Alipour, «*MRI Image Segmentation Using Conditional Spatial FCM Based on Kernel-Induced Distance Measure*». *Engineering, Technology & Applied Science Research*, vol. 8, no. 3, pp. 2985-2990, 2018.
- [GON 01] R. C. Gonzalez, R. E. Woods, «*Digital Image Processing*». Prentice Hall, New York, 2001.
- [GON 13] M. Gong et al., «*Fuzzy C-Means Clustering With Local Information and Kernel Metric for Image Segmentation*». *IEEE Transactions on Image Processing*, vol. 22, No. 2, pp. 573–584, 2013.

- [GON 13] M. Gong, Y. Liang, S. Shi, J. Ma, «*Fuzzy c-means clustering with local information and kernel metric for image segmentation*». IEEE Trans. Image Process, vol. 22, no. 2, pp. 573-584, 2013.
- [GUO 16] F. Guo, X. Wang, J. Shen, «*Adaptive fuzzy c-means algorithm based on local noise detecting for image segmentation*». IET Image Process, vol. 10, no. 4, pp. 272-279, 2016.
- [HAR 98] K. Haris, S N. Efstratiadis, N. Maglaveras, A. K. Katsaggelos, «*Hybrid image segmentation using watersheds and fast region merging*». IEEE Transactions on Image Processing, vol. 7, no. 12, pp. 1684-1699, 1998.
- [HAU 11] D. Y. Haung, T. W. Lin, W. C. Hu, «*Automatic Multilevel Threshold Based on Two Stage Otsu's Method With Cluster Determination With Valley Estimation*». Inter. Journal of Innovative Computing, Information and Control, vol. 7, no. 10, pp. 5631-5644, 2011.
- [HEE 14] R. K. Heena, «*Implementation of Image Registration for Satellite Images using Mutual Information and Particle Swarm Optimization Techniques*». International Journal of Computer Applications, vol. 97, pp. 07-14, 2014.
- [ING 11] P.V. Ingole, A. K. Sapkal, G.G. Sarate, S. R. Hirekhan, «*Implementation of Signal Generator (DSP) Using TMS 320 C 6713 DSK*». International Journal of Computer Science Engineering and Technology, vol. 11, pp. 95-98, 2011.
- [JI 14] Z. Ji et al., «*Robust spatially constrained fuzzy c-means algorithm for brain MR image segmentation*». Pattern Recognition, vol. 47, No. 7, pp. 2454-2466, 2014.
- [JI 14] Z. Ji, J. Liu, G. Cao, Q. Sun, Q. Chen, «*Robust Spatially Constrained Fuzzy C Means Algorithm for Brain MR Image Segmentation*». Pattern Recognition, vol. 47, pp. 2454-2466, 2014.
- [JOH 96] B. Johnston, M. Atkins, B. Mickiewicz et M. Anderson, «*Segmentation of multiple sclerosis lesions in intensity corrected multispectral MRI*». IEEE Transaction on Medical Imaging, vol. 15, no. 2, pp. 154–169, 1996.
- [KAL 07] K. Kalinova, «*Imaging (Ultrasonography, Computed Tomography) of patients with hydatid Liver Disease*». Journal of Veterinary Medicine, Vol.10, No.1, pp. 45 – 51, 2007.
- [KAM 16] S. Kamarujjaman, S. Chakraborty, M. Maitra, «*An unsupervised modified spatial fuzzy C-mean method for segmentation of brain MR image*». Intl. Conference on Advances in Computing, Communications and Informatics, India, pp. 125-131, 2016.
- [KAN 10] S.R. Kannan, S. Ramathilagam, A. Sathya, R. Pandiyarajan, «*Effective fuzzy c-means based kernel function in segmenting medical images*», Comput. Biol. Med, vol. 40, pp. 572–579, 2010.
- [KAN 15] M. Kang et J. M Kim, «*Fuzzy C-means clustering with spatially weighted information for medical image segmentation*». IEEE Symposium on Computational Intelligence for Multimedia, Signal and Vision Processing, 2015.
- [KOW 12] M. K. Kowar, S. Yadav, «*Brain Tumour Detection and Segmentation Using Histogram Thresholding*». International Journal of Engineering and Advanced Technology, vol. 1, no. 4, 2012.
- [KRI 10] S. Krinidis, V. Chatzis, «*A robust fuzzy local information C-means clustering algorithm*». IEEE Trans. Image Process, vol. 19, pp. 1328–1337, 2010.

[KWA 99] R K-S Kwan, A C Evans, G B Pike. «*MRI simulation-based evaluation of image-processing and classification methods*». IEEE Transactions on Medical Imaging, vol. 18, no. 11, pp.1085–1097, 1999.

[LAG 10] H. LAGUEL, «*Déploiement sur une plateforme de visualisation, d'un algorithme coopératif pour la segmentation d'images IRM basé sur les systèmes multi-agents*». Thèse de doctorat, Université des Sciences et de la Technologie Houari Boumediene, 2010.

[LAM 13] C. LAMICHE, «*Fusion Et Fouille De Données Guidées Par Les Connaissances : Application A L'analyse D'image*». Thèse de doctorat, Université Mohamed Khider de Biskra, 2013.

[LAN 06] A. Langville, C. D. Meyer, R. Albright, J. Cox, D. Duling, «*Algorithms, initializations and convergence for the nonnegative matrix factorization*». NCSU Technical Report Math, pp. 1–18, 2006.

[LAN 06] A. Langville, C. D. Meyer, R. Albright, J. Cox, et D. Duling, «*Algorithms, initializations and convergence for the nonnegative matrix factorization*». NCSU Technical Report Math 81706, pages 1–18, 2006.

[LE 11] T. Le and K. Gardiner, «*A validation method for fuzzy clustering of gene expression data*». Intl' Conf. on Bioinformatics and Computational, Las Vegas, Vol. 1, pp. 23-29, 2011.

[LE 12] T. Le, T. Altman, K. Gardiner, «*A Probability Based Defuzzification Method for Fuzzy Cluster Partition*». Intl Conf. on Artificial Intelligence, Vol. 2, pp. 1038-1043, 2012.

[LEE 99] D. D. Lee et H. S. Seung, «*Learning the parts of objects by non-negative matrix factorization*». Nature, 401:788–793, 1999.

[LEE 99] D. D. Lee, H. S. Seung, «*Learning the parts of objects by non-negative matrix factorization*». Nature, vol. 401, pp.788–793, 1999.

[LI 12] S. Li et X. Kang, «*Image Enhancement Using Improved Mean Filter at Low and High Noise Density*», IEEE Transactions on Consumer Electronics, vol. 58, No. 2, pp. 626-632, 2012.

[LI 14] Li, C. Gore, J. Davatzikos, C., «*Multiplicative intrinsic component optimization (MICO) for MRI bias field estimation and tissue segmentation*». Magn. Reson. Imaging, Vol 32, pp. 913–923, 2014.

[LIU 12] H.Q. Liu, F. Zhao, L. Jiao, «*Fuzzy spectral clustering with robust spatial information for image segmentation*», Appl. Soft Comput, vol. 12, no. 11, pp. 3636–3647, 2012.

[MAD 05] A. Madabhushi et J. K. Udupa, «*Interplay between intensity standardization and inhomogeneity correction in MR image processing*». IEEE Transactions on Medical Imaging, vol. 24, pp. 561-576, 2005.

[MAD 15] S. Madhukumar, N. Santhiyakumari, «*Evaluation of k-Means and fuzzy C-means segmentation on MR images of brain*». Egyptian Society of Radiology and Nuclear Medicine, vol. 46, no. 2, pp. 475-479, 2015.

[MAN 14] Wang, Manyu et al., «*A new image denoising method based on Gaussian filter*». International Conference on Information Science, Electronics and Electrical Engineering, pp. 163-167, 2014.

- [MAR 12] E. N. Marieb, K. Hoehn, «*Human Anatomy and Physiology*». 9th edition, Pearson publishers, 2012.
- [MEL 12] M. MELIANI, «*Segmentation d'Image par Coopération Régions-Contours*». Thèse de magister, Ecole nationale Supérieure en Informatique, Oued-Smar Alger, 2012.
- [MEM 18] K. H. Memona, D. Lee, «*Generalised kernel weighted fuzzy C-means clustering algorithm with local information*». *Fuzzy Sets and Systems*, vol. 340, pp. 91-108, 2018.
- [MER 12] N. MERZOUGUI, «*Un algorithme évolutionnaire pour la segmentation d'images basé sur le diagramme de Voronoï*», mémoire de magister, université kasdi merbah Ouargla, 2012.
- [MUH 16] S. Muhammad, H. Ayyaz, A. J. Muhammad, T. S. Choi, «*Fuzzy-based hybrid filter for Rician noise removal*». *Signal, Image and Video Processing*, vol.10, no.2, pp. 215-224, 2016.
- [OSH 04] S. Osher, M. Burger, D. Goldfarb, J. Xu et W. Yin, «*Using geometry and iterated refinement for inverse problems (1): Total variation based image restoration*». CAM-Report, UCLA, pp. 4–13, 2004.
- [PAL 95] N. R. Pal et J. C. Bezdek, «*On Cluster Validity for the Fuzzy C-Means Model*». *IEEE Trans. Fuzzy Syst*, vol. 3, no. 3, pp. 370-379, 1995.
- [RED 98] W. Reddinger, CT image quality; OutSource, Inc., 1998. [Online] available of URL: <http://www.e-radiography.net/mrict/CT_IQ.pdf>, [May 21, 2020].
- [REH 16] K. Rehna, T. Ciza, M. Abdul Rahiman, «*Gaussian Kernel Based Fuzzy C-Means Clustering Algorithm for Image Segmentation*». *Computer Science &Information Technology*, vol. 6, pp. 47–56, 2016.
- [RIT 13] P. Ritu, S. Singh. «*Review on Machine Learning Techniques for Automatic Segmentation of Liver Images*». *International Journal of Advanced Research in Computer Science and Software Engineering*, vol. 3, no. 4, 2013.
- [ROS 08] J.L. ROSE, «*Croissance de région variationnelle et contraintes géométriques tridimensionnelles pour la segmentation d'image*». Thèse de doctorat, Institut National des Sciences Appliquées de Lyon, 2008.
- [ROS 11] R. Rosniza, J. Nursuriati, M. Rozi, «*Skull Stripping Magnetic Resonance Images Brain Images: Region Growing versus Mathematical Morphology*». *Inter Journal of Computer Information Systems and Industrial Management Applications*, Vol 3, pp. 150–158, 2011.
- [SAL 12] B. SALAH EDDINE, «*Reconnaissance d'objets dans une image application au tri/contrôle de qualité*». Mémoire de Magister, Université de Batna Hadj Lakhdar, 2012.
- [SAR 08] M. Sarifuddin, R. Missaoui, M. Paindavoire, «*An enhanced detector of blurred and noisy edges*», *Signal Processing for Image Enhancement and Multimedia processing. Multimedia systems and applications*. Vol. 31, pp. 127-140, 2008.
- [SCH 12] A. Schenk. «*Liver Segmentation and its Application to Hepatic Interventions*». Thèse de doctorat, Université de Bremen, 2012.
- [SEB 07] I. Sebari, D-C. He, «*Les approches de segmentation d'image par coopération régions-contours*», *Revue Télédétection*, vol. 7, n° 1-2-3-4, pp 499-506, 2007.

- [SHA 04] A. Sharf, M. Alexa, et D. Cohen-Or, «*Context-based surface completion*». SIGGRAPH Conference, pp. 878–887, 2004.
- [SHA 15] B. Sharmila, N. Karalan and D. Nedumaran, «*Image Processing on DSP Environment Using OpenCV*». International Journals of Advanced Research in Computer Science and Software Engineering, vol. 5, pp. 489-493, 2015.
- [SLE 98] J. Sled, A. Zijdenbos et A. Evans, «*A nonparametric method for automatic correction of intensity non uniformity in MRI data*». IEEE Transaction on Medical Imaging, vol. 17, no. 1, pp. 87–97, 1998.
- [SOL 13] R. Solanki, R. Kumar, T. Raikwar, «*The Automatic License Plate Recognition*». International journal of engineering research and applications, vol. 3, pp. 304-310, 2013.
- [SON 19] J. Song, Z. Zhang, «*A Modified Robust FCM Model with Spatial Constraints for Brain MR Image Segmentation*». Information, vol. 10, no. 2, 2019.
- [TEH 17] A. TEHAM, «*Conception d'une approche Bio-inspirée pour le traitement des données optiques*». Thèse de doctorat, Université d'Oran USTO, 2017.
- [VAN 02] J.F. Vansteenkiste, «*Imaging in lung cancer: positron emission tomography scan*». European Respiratory Journal, vol. 19, no. 35, 2002.
- [VEL 10] Velmurugan, T. Santhanam, «*Computational complexity between k-means and k-means clustering algorithms for normal and uniform distributions of data points*», Journal of Computer Science, vol.6, pp. 363-368, 2010.
- [VER 16] H.Verma, R. Agrawal, A. Sharan, «*An improved intuitionistic fuzzy cmeans clustering algorithm incorporating local information for brain image segmentation*». Applied Soft Computing, vol. 46, no. 9, pp. 543–557, 2016.
- [VOV 07] U. Vovk, F. Pernus et B. Likar, «*A review of methods for correction of intensity inhomogeneity in MRI*». IEEE Transactions on Medical Imaging, vol. 26, pp. 405-421, 2007.
- [WAN 13] Z. Wang, Q. Song, YC. Soh, K. Sim, «*An adaptive spatial information theoretic fuzzy clustering algorithm for image segmentation*». Comput. Vision Image Understanding, vol. 117, pp.1412–1420, 2013.
- [WAR 06] Simon K.Warfield, Kelly H.Zouet William M.Wells, «*Validation of image segmentation by estimating rater bias and variance*». Springer, Berlin- Heidelberg, 2006.
- [WEM 04] M. N. Wemick, J. N. Aarsvold, «*Emission Tomography: The Fundamentals of PET and SPECT*». Academic Press, 2004.
- [WES 11] P. Wesseling, J. M. Kros, J. W. Jeuken, «*The pathological diagnosis of diffuse gliomas: towards a smart synthesis of microscopic and molecular information in a multidisciplinary context*». Diagnostic Histopathology, Vol. 17, No. 11, pp. 486-494, 2011.
- [XIA 10] K. Xiao, S. H. Hock, A. Bargiela, «*Automatic Brain MRI Segmentation Scheme Based on Feature Weighting Factors Selection on Fuzzy C-Means Clustering Algorithms with Gaussian Smoothing*». International Journal of Computer Intelligence in Bioinformatics and Systems Biology, vol. 1, no. 3, 2010.
- [XIN 16] F. Xing, Y. Xie, L. Yang, «*Automatic Learning-Based Framework for Robust Nucleus Segmentation*». IEEE Trans. on Medical Imaging, vol. 35, no. 2, pp. 550-566, 2016.

- [YAN 09] Y. Yan. «*A Postprocessing Method for Scatter Compensation in Single Photon Emission Computed Tomography*». Thèse de doctorat. Université de l'États-Unis , 2009.
- [ZEN 12] Z. Zeng, J. Wang, T. Shepherd et R. Zwigelaar, «Region-based active surface modelling and alpha matting for unsupervised tumour segmentation in PET». IEEE International Conference on Image Processing, pp. 1997–2000, 2012.
- [ZHA 06] Y. J. Zhang, «An Overview of Image and Video Segmentation in the Last 40 Years». Advances in Image and Video Segmentation, pp. 1-16, 2006.
- [ZHA 13] F. Zhao, L. Jiao, H. Liu, «*Kernel generalized fuzzy c-means clustering with spatial information for image segmentation*». Digital Signal Processing, vol. 23, pp. 184–199, 2013.
- .

Annexes

Annexe A :

A-1- Défauts des images IRM:

Les trois paramètres entrent en jeu dans la formation d'une image : la densité protonique p , le temps de relaxation spin-réseau T1 et le temps de relaxation spin-spin T2. Mais d'autres facteurs que l'on ne maîtrise pas toujours affectent la qualité des images et provoquent des artefacts, compliquant la segmentation des tissus cérébraux ou la reconnaissance de structures cérébrales. La qualité des images de RMN est évidemment un point clé dans la segmentation des tissus cérébraux. Tout autant que le rapport signal sur bruit, le rapport contraste sur bruit est un critère de qualité de l'image [LAG 10].

- Les facteurs liés au mouvement : Tout mouvement de protons lors de la formation de l'image possède des conséquences sur la qualité de l'image acquise. Il est provoqué par les mouvements de l'organe étudié : respiration régulière, déglutitions et mouvements volontaires du patient durant l'acquisition. La durée de l'acquisition est donc un paramètre important quant à la qualité de l'image. Ce mouvement plus ou moins rapide qui va perturber les moments magnétiques longitudinaux et transversaux des régions analysées et donc modifier des signaux de résonance magnétique.

-Le déplacement chimique : Dans les milieux biologiques, les électrons ne sont pas libres mais liés à une molécule. Dans ces conditions, le champ magnétique effectif qui agit sur un proton n'est pas véritablement celui escompté car il est modifié par son environnement chimique. Il en résulte une modification de la fréquence de résonance des protons, ou déplacement chimique.

-Le champ statique : En principe, on considère que le champ statique est homogène. En pratique, il ne l'est pas tout à fait. On parle alors de l'hétérogénéité du champ qui modifie localement la fréquence de résonance des protons. De plus, les variations locales de susceptibilité magnétique vont provoquer des distorsions du champ magnétique.

-Le recouvrement de spectre : Il y a recouvrement de spectre lorsque le champ d'exploration (FOV) est plus petit que l'échantillon étudié. Ce phénomène se traduit par une superposition d'informations situées en dehors du champ d'exploration sur l'image.

A-2- Bases d'un scanner IRM:

Le 80% de notre corps humain est composé d'atomes d'hydrogène. L'atome d'hydrogène a un noyau positif fort comprenant une particule de proton. Ce proton a sa propre vitesse de rotation, sa direction de rotation et son axe de rotation. L'alignement parallèle des noyaux d'hydrogène est établi par un aimant supraconducteur refroidi à l'hélium liquide. Les noyaux d'hydrogène, dans cet état, sont soumis à un rayonnement radiofréquence qui perturbe l'alignement analogue des noyaux d'hydrogène. Lorsque les noyaux absorbent une certaine quantité de signal radiofréquence, ils passent d'un état de niveau d'énergie inférieur à un état de niveau d'énergie supérieur. Dès que le rayonnement radiofréquence est arrêté, les noyaux reviennent à leur position d'origine avec une certaine émission d'énergie relative. Cette énergie émise est produite à la suite du déplacement des noyaux de l'état d'énergie excité à l'état fondamental, qui est enregistré et traité ultérieurement en utilisant un processeur de signal. Cette procédure donne une image spatiale de la structure interne du corps humain.

La même procédure est utilisée à plusieurs reprises pour obtenir des images cérébrales 3D (MR). Dans un scanner IRM, des transformées de Fourier bidimensionnelles sont effectuées sur les structures d'image obtenues. Une configuration simple d'un système de balayage (IRM) est illustrée à la figure A.1 suivante.




Figure A.1 : Les bases d'un scanner IRM

A-3- Effets du bruit et de la non-uniformité des pixels dans IRM:

Presque toutes les techniques d'acquisition d'images en imagerie médicale sont sensibles au bruit. L'influence non prédictive du caractère aléatoire des valeurs de pixels générées par les capteurs et les circuits de l'IRM est appelée bruit.

La source principale de bruit qui se produit dans l'image IRM est due à l'émission des fréquences radio qui sont générées en raison du mouvement thermique. Ce type de bruit dégrade le signal entrant des disparités de magnétisation diagonales du spin volontairement excité qui se produit sur le plan de coupe choisi. Une base importante d'un bruit aléatoire dans l'imagerie IRM est le bruit thermique qui établit une source aléatoire statistiquement autonome entrant dans les données IRM par rapport au temps. Le bruit thermique est caractérisé comme un champ aléatoire gaussien avec une moyenne nulle et une variance constante et peut être visualisé en blanc. Généralement pour la reconstruction IRM, en raison d'erreurs de phase, l'amplitude du signal IRM est utilisée pour l'évaluation visuelle et d'autres tâches qui peuvent être effectuées par le traitement d'image.

Le bruit structuré est un autre bruit qui dégrade la qualité de l'image RM. Habituellement, ce type de bruit se produit en raison des physionomies du système IRM et des pulsations physiques de la machine respective. La source du bruit caractérise ce type de bruit. L'une des principales origines du bruit est due à la zone électromagnétique ambiante sélectionnée par les capteurs radiofréquences qui acquièrent le signal MR. Une autre source de bruit se produit en raison du corps humain qui a été capturé.

Annexe B :

Variantes de factorisation matricielle non négative (NMF)

B-1-La norme standard NMF :

La factorisation matricielle non négative (NMF) est une approche de décomposition matricielle qui décompose une matrice non négative en deux matrices non négatives de bas rang. Elle a été introduite comme méthode de réduction de dimensionnalité pour l'analyse de modèle [LEE 99]. Lorsqu'un ensemble d'observations est donné dans une matrice avec des éléments non négatifs, NMF cherche à trouver une approximation de rang inférieur de la matrice de données, où les facteurs qui donnent l'approximation de rang inférieur sont également non négatifs. La contrainte de non-négativité est requise dans certaines applications afin d'obtenir des résultats et des interprétations physiquement significatifs. Les données étaient représentées par une matrice d'expression V de taille N*M, dont les lignes contiennent les niveaux d'expression de N gènes dans M échantillons. Le NMF réduit la dimensionnalité des données en un petit nombre (k < N), définis comme des combinaisons linéaires positives des N gènes.

Mathématiquement, cela correspond à la factorisation de la matrice V en deux matrices à entrées positives, $V=WH$, le problème est formulé comme suit: Etant donné une matrice non négative : $V \in R^{n \times m}$, NMF fournit deux matrices non négative $W \in R^{n \times k}$ et $H \in R^{k \times m}$ telles que $V=WH$. Les facteurs optimaux minimisent l'erreur quadratique et ils sont les solutions au problème d'optimisation suivant :

$$\text{Min } f(W,H) = \|V - WH\|_F^2 \text{ tel que } W,H \geq 0 \quad (\text{B.1})$$

Où $\|\cdot\|_F$ désigne la norme de Frobenius et f est la fonction de distance euclidienne au carré entre V et WH . Observez que la fonction de coût f est convexe par rapport à l'une des variables W ou H , mais pas les deux. La minimisation alternée d'un tel coût conduit à l'algorithme des moindres carrés alternatifs [LAN 06] qui peut être décrit comme suit:

- a. Initialisez W au hasard ou en utilisant n'importe quelle connaissance a priori.
- b. Estimez H comme $H = (W^T W)^- W^T V$ avec W fixé.
- c. Réglez tous les éléments négatifs de H sur zéro ou sur une petite valeur positive.
- d. Estimez W comme $W = V H^T (H H^T)^-$ avec H fixé.
- e. Réglez tous les éléments négatifs de W sur zéro ou sur une petite valeur positive.

Dans cet algorithme, A^- désigne l'inverse de MoorePenrose de A . cette algorithme a été largement utilisé. Cependant, il n'est pas garanti de converger vers un minimum global ni même vers un point stationnaire. De plus, elle n'est souvent pas suffisamment précise, et elle peut être lente lorsque les matrices de facteurs sont mal conditionnées ou lorsque les colonnes de ces matrices sont colinéaires. De plus, la complexité de l'algorithme peut être élevée pour des problèmes à grande échelle car il implique l'inversion d'une grande matrice [BAY 14].

Une règle de mise à jour multiplicative est proposée, dont il a été prouvé qu'elle converge vers un point stationnaire, et ne souffre pas des inconvénients. L'algorithme de règle de mise à jour multiplicative est montré dans l'Eq. (B.2) comme cas particulier d'une classe de règles de mise à jour, qui convergent vers un point stationnaire du problème NMF.

$$\begin{cases} H_{ij} \leftarrow H_{ij} \frac{(W^T V)_{ij}}{(W^T W H)_{ij}} \\ W_{ij} \leftarrow W_{ij} \frac{(V H^T)_{ij}}{(W H H^T)_{ij}} \end{cases} \quad (B.2)$$

L'itération de ces règles de mise à jour converge vers un maximum local de la fonction objectif:

$$F = \sum_{i=1}^n \sum_{j=1}^m [V_{ij} \log(WH)_{ij} - (WH)_{ij}] \quad (B.3)$$

Les règles de mise à jour préservent la non-négativité de W et H et contraint également les colonnes de W à additionner à l'unité. Cette contrainte de somme est une manière commode d'éliminer la dégénérescence associée à l'invariance de WH sous la transformation $W \rightarrow WS, H \rightarrow S^{-1}H$, où S est une matrice diagonale.

B-2- Variantes probabilistes de NMF:

On suppose que les données représentées par la matrice non négative V, sont corrompues par un bruit gaussien blanc additif, et suivent la distribution conditionnelle suivante:

$$p(V|W, H, \sigma^2) = \prod_{i=1}^N \prod_{j=1}^M N(V_{ij} | u_i^T h_j, \sigma^2) \quad (B.4)$$

Où $N(\cdot | \mu, \sigma^2)$ est la fonction de densité de probabilité de la distribution gaussienne avec moyenne μ et écart-type σ . Les u_i et h_j désignent respectivement la ième ligne de la matrice W et la j ième colonne de la matrice H. Les a priori gaussiens moyens zéro sont avec des écarts types W et H, respectivement, imposés à u_i et h_j pour contrôler les paramètres du modèle. W et H sont estimés à l'aide du critère MAP en minimisant la fonction suivante:

$$f(W, H) = \|V - WH\|_F^2 + \alpha \|W\|_F^2 + \beta \|H\|_F^2 \text{ tel que } W, H \geq 0 \quad (B.5)$$

Où les paramètres α et β dépendent de σ , σ_W et σ_H . Il a été montré que les règles de mise à jour pour le problème d'optimisation dans (B.5) sont données par :

$$\begin{cases} H_{ij} \leftarrow H_{ij} \frac{(W^T V)_{ij}}{(W^T W H + \beta H)_{ij}} \\ W_{ij} \leftarrow W_{ij} \frac{(V H^T)_{ij}}{(W H H^T + \alpha W)_{ij}} \end{cases} \quad (B.6)$$

Observez que, puisque la matrice de données V est non négative, les règles de mise à jour de (B.6) conduisent à des facteurs non négatifs W et H tant que les valeurs initiales de l'algorithme sont choisies non négatives.

B-3- NMF clairsemé:

On La rareté est un principe de régularisation populaire dans la modélisation statistique, et a été utilisé pour réduire la non-unicité des solutions et également pour améliorer l'interopérabilité des résultats NMF. Le NMF clairsemé impose une parcimonie à la matrice factorielle H en contrignant la norme 11 de ses colonnes et impose une norme unitaire sur les colonnes de W pour assurer l'unicité:

$$\text{Min } f(W, H) = \|V - WH\|_F^2 + \lambda \sum_{i=1}^n \|h_i\|_1 \text{ tel que } W, H \geq 0 \quad (B.7)$$

Annexe C :

C-1- L'espace mémoire du C6713:

L'espace mémoire du C6713 est adressable par octet. La mémoire interne est organisée en deux espaces distincts : un pour le programme et l'autre pour les données, avec deux ports internes de 32 bits pour accéder à la mémoire interne.

Tableau C.1 : Organisation de la mémoire du C6713

Memory Block Description	Block Size (Bytes)	Hex Address Range
Internal RAM (L2)	192K	0000 0000–0002 FFFF
Internal RAM/cache	64K	0003 0000–0003 FFFF
Reserved	24M–256K	0004 0000–017F FFFF
External memory interface (EMIF) registers	256K	0180 0000–0183 FFFF
L2 registers	128K	0184 0000–0185 FFFF
Reserved	128K	0186 0000–0187 FFFF
HPI registers	256K	0188 0000–018B FFFF
McBSP 0 registers	256K	0190 0000–0193 FFFF
McBSP 1 registers	256K	0194 0000–0197 FFFF
Timer 0 registers	256K	0198 0000–019B FFFF
Timer 1 registers	512	019C 0000–019C 01FF
Interrupt selector registers	4	019C 0200–019C 0203
Device configuration registers	256K–516	091C 0204–019F FFFF
Reserved	256K	01A0 0000–01A3 FFFF
EDMA RAM and EDMA registers	768K	01A4 0000–01AF FFFF
Reserved	16K	01B0 0000–01B0 3FFF
GPIO registers	240K	01B0 4000–01B3 FFFF
Reserved	16K	01B4 0000–01B4 3FFF
I2C0 registers	16K	01B4 4000–01B4 7FFF
I2C1 registers	16K	01B4 8000–01B4 BFFF
Reserved	16K	01B4 C000–01B4 FFFF
McASP0 registers	16K	01B5 0000–01B5 3FFF
McASP1 registers	160K	01B5 4000–01B7 BFFF
Reserved	8K	01B7 C000–01B7 DFFF
PLL registers	264K	01B7 E000–01BB FFFF
Reserved	256K	01BC 0000–01BF FFFF
Emulation registers	4M	01C0 0000–01FF FFFF
Reserved	52	0200 0000–0200 0033
QDMA registers	16M–52	0200 0034–02FF FFFF
Reserved	720M	0300 0000–2FFF FFFF
Reserved	64M	3000 0000–33FF FFFF
McBSP0 data port	64M	3400 0000–37FF FFFF
McBSP1 data port	64M	3800 0000–3BFF FFFF
Reserved	1M	3C00 0000–3C0F FFFF
McASP0 data port	1M	3C10 0000–3C1F FFFF
McASP1 data port	62M	3C20 0000–7FFF FFFF
Reserved 1G +	256M	8000 0000–8FFF FFFF
EMIF CE0*	256M	9000 0000–9FFF FFFF
EMIF CE1*	256M	A000 0000–AFFF FFFF
EMIF CE2*	256M	B000 0000–BFFF FFFF
EMIF CE3*	1G	C000 0000–FFFF FFFF

Annexe D :

Liste des publications

D-1- CONFERENCES (National & International):

Boucif BEDDAD, Kaddour HACHEMI, « *Brain Tumor Detection by using a Modified FCM and Level Set Algorithms* ». 4th International Conference on Control Engineering & Information Technology, Tunisia, pp. 163-167, 2016.

Boucif BEDDAD, Kaddour HACHEMI, « *Hardware Implementation of Real-Time Image Segmentation Algorithms using TMS320C6713 DSP and VM3224K2 Daughter Kit* ». 4th International Conference on Automation, Control Engineering & Computer Science, Morocco, pp. 163-167, 2017.

Boucif BEDDAD, Kaddour HACHEMI, « *Efficient Implementation of An Improved Median Filter on TMS320C6416 Digital Signal Processor* ». The Third International Conference on Electrical Sciences and Technologies in Maghreb, Algeria, pp. 163-167, 2018.

Boucif BEDDAD, Kaddour HACHEMI, Jack-Gerard POSTAIRE, František JABLONCIK, Oussama MESSAI, « *An Improvement of Spatial Fuzzy C-means Clustering Method for Noisy Medical Image Segmentation* ». Sixth International Conference on Image and Signal Processing and their Applications, Algeria, pp. 163-167, 2019.

Frantisek JABLONCIK, Libor HARGAS, Dusan KONIAR, Jaroslav BULAVA, Boucif BEDDAD, « *Ciliated epithelium segmentation using texture features classification* ». 13th International Conference ELEKTRO 2020, Italy, pp. 1-5, 2020.

Boucif BEDDAD, Kaddour HACHEMI, Jack-Gerard POSTAIRE, « *Fast and efficient Preprocessing Algorithm for Removing Highly Impulsive Noise in Digital Images* ». First National Conference on Artificial Intelligence and Information Technologies CNIATI'20, Algeria, pp. 1-5, 2021.

D-2- JOURNALS (International):

Boucif BEDDAD, Kaddour HACHEMI, Sundarapandian VAIDYANATHAN, « *Design and Implementation of a New Cooperative Approach to Brain Tumor Identification from MRI Images* ». International Journal of Computer Applications in Technology, vol. 1, no. 3, 2019.

Résumé :

L'approche traditionnelle C-moyennes floues (FCM) fait partie des méthodes les plus courantes et les plus utilisées pour la segmentation d'image non supervisée. La technique FCM n'utilise pas pleinement les informations spatiales pour résoudre le problème de la sensibilité au bruit et de l'inhomogénéité d'intensité qui affectent considérablement les performances de segmentation d'image médicale. Sur la base des différents défis rencontrés, la recherche actuelle vise l'étude comparative des nouvelles méthodes de segmentation d'image à savoir SFCM, CsFCM, CsKFCM, GKFCM, RSCFCM, KGFCM, GKWFLICM. Afin de minimiser la fonction objective de C-moyennes floues, le concept de noyau normé (kernel) et le terme d'information spatiale du voisinage de chaque pixel sont incorporé pour développer deux nouvelles techniques basée sur le processus de clustering. La première concerne la C-moyennes floues spatiale améliorées basé sur la distance euclidienne nommé ISFCM, la deuxième est C-moyennes floues spatiale améliorées basé sur la distance du noyau normé (kernel) nommé ISKFCM. Les deux algorithmes proposés sont appliqués à la fois sur des images synthétisées artificielles, des images simulées générées par BrainWeb et des images cérébrales IRM réelle pondérées en T1, T2 et PD.

Les ISFCM et ISKFCM ont été implémentés pratiquement en temps réel à l'aide d'un DSP à virgule flottante de type TMS320C6713DSP de Texas Instruments. L'amélioration des performances est mesurée en incluant diverses techniques d'optimisation et tous les résultats de profilage et de débogage sont affichés à l'aide de l'interface utilisateur graphique C6713. Les résultats expérimentaux de segmentation démontrent que les algorithmes présentés sont plus robustes au bruit et l'inhomogénéité d'intensité, aussi les performances ont été validées après une évaluation quantitative et qualitative à l'aide de diverses mesures telles que : l'indice de similarité (ρ), le coefficient de partition (Vpc) et l'entropie de partition (Vpe), la fonction de Fukuyama-Sugeno (Vfs) et la fonction de Xie-Beni (Vxb), la précision de segmentation optimale (SA) et le taux de classification erronée (MCR).

Mots clefs : Image par Résonance Magnétique, TMS320C6713DSP, Information spatiale et clustering, Techniques de segmentation SFCM, CsFCM, CsKFCM, GKFCM, ISFCM, ISKFCM, RSCFCM, KGFCM, GKWFLICM,

الملخص :

تعتبر تقنية Fuzzy C-Means من بين الطرق الأكثر شيوعاً والأكثر استخداماً لتجزئة الصور الغير خاضعة للرقابة. غالباً تقنية FCM لا تستخدم المعلومات المكانية بشكل كامل لحل مشكلة حساسية الضوضاء وعدم تجانس الكثافة التي تؤثر بشكل كبير على أداء تجزئة الصور الطبية. بناءً على التحديات المختلفة التي تمت مواجهتها ، يهدف البحث الحالي إلى دراسة مقارنة للطرق الجديدة لتجزئة الصورة ذكر من بينها: SFCM و CsFCM و CsKFCM و GKFCM و RSCFCM و GKWFLICM و KGFCM. لخفض قيمة الدالة الموضوعية لتقنية Fuzzy C-Means ، تم دمج مفهوم المسافة المستحدثة من (kernel) و خاصية المعلومات المكانية لجوار كل بکسل pixel لتطوير تقنيتين جديدتين على أساس عملية التجميع Clustering. تتعلق الأولى بـ تقنية Fuzzy C-Means المكانية المحسنة القائمة على المسافة الإلقيدية المسماة ISFCM ، والثانية هي Fuzzy C-Means المكانية المحسنة القائمة على مسافة النواة الطبيعية kernel المسماة ISKFCM. تم تطبيق الخوارزميتين المقترنتين على كل من الصور المركبة الاصطناعية ، والصور المحاكاة التي تم إنشاؤها بواسطة BrainWeb وصور الدماغ الحقيقية الملتقطة بالرنين المغناطيسي على شكل T1 و T2 و PD.

تم تنفيذ خوارزميات التجزئة ISFCM و ISKFCM في الوقت الحقيقي باستخدام خاصية معالج الإشارة الرقمية DSP من نوع TMS320C6713DSP المصطنع من طرف شركة Texas Instruments. أيضاً تم قياس الأداء المحسن من خلال تضمين تقنيات التحسين المختلفة وتم عرض جميع نتائج التمييز وتصحيح الأخطاء باستخدام واجهة المستخدم الرسومية C6713. أظهرت النتائج التجريبية للتجزئة أن الخوارزميات المقدمة تعتبر أكثر قوة في مواجهة حساسية الضوضاء وعدم تجانس شدة الكثافة ، بينما تم التتحقق من صحة الأداء بعد التقييم الكمي والنوعي باستخدام مقاييس مختلفة مثل: مؤشر التشابه (ρ) ، معامل التقسيم Vpc والإنتروبيا التقسيمية Vpe ، دالة Fukuyama-Sugeno Vfs و دالة Xie-Beni Vxb ، دقة التجزئة المثلثي (SA) . ومعدل سوء التصنيف (MCR) .

الكلمات مفتاحية : صورة بالرنين المغناطيسي ، معالج Clustering ، التجميع ، المعلومات المكانية ، تقنيات التجزئة SFCM و CsFCM و CsKFCM و ISKFCM و GKFCM و RSCFCM و GKWFLICM و .

